

基于 VMD-DSSC 的轴承故障诊断

胡永涛^{1,2}, 董明如^{2,3}, 李 婕^{1,2}, 李进军^{1,2}

(1. 河南工学院 电气工程与自动化学院, 河南 新乡 453003; 2. 新乡市旋转机械运行状态智能监测工程技术研究中心, 河南 新乡 453003; 3. 河南工学院 电子信息工程学院, 河南 新乡 453003)

摘要: 针对大数据背景下轴承故障诊断中有标签样本少的问题, 设计了深度半监督小样本分类器并用于轴承故障诊断。首先, 采用受限玻尔兹曼机构建深度学习分类器, 利用无标签样本完成参数预训练, 结合有标签样本调优参数, 获得准确的分类模型。然后, 改进激活函数, 解决梯度消失问题, 提高收敛速度, 增强分类性能。最后, 利用变分模态分解将信号分解为一系列本征模态函数, 并提取样本熵作为故障特征输入至分类器实现故障模式识别。轴承故障诊断实验及风电机组高速轴承故障诊断结果表明, 深度半监督小样本分类器能够充分利用无标签样本及有标签样本实现轴承故障模式识别, 并具有故障诊断准确率高、稳定性好、耗时少、实时性好等优点, 为轴承故障诊断提供了一种新方法, 亦可用于数据清洗, 为智能故障诊断提供有效样本。

关键词: 轴承故障诊断; 大数据; 深度学习; 小样本分类; 激活函数

中图分类号: TH165+.3

文献标志码: A

文章编号: 2096-7772-(2024)03-0006-07

0 引言

旋转机械广泛应用于冶金、电力、采矿、交通等领域, 轴承作为旋转机械的关键组成部件, 受冲击、变载等影响, 极易损坏, 如果不能得到及时修复, 将导致更大的故障^[1]。准确快速的轴承故障诊断是保证设备安全稳定运行的有效途径, 受到了工程及学术界的高度重视。轴承故障诊断一般包括数据采集、特征提取、故障模式识别等步骤, 是多方法融合的模式识别过程。其中, 特征提取是机械故障诊断的关键, 根据故障特征进行故障模式识别和智能决策是故障诊断的最终目标^[2-3]。大数据、人工智能、状态监测等技术的发展及广泛应用为故障诊断提供了海量数据支持, 同时也为故障诊断带来了新的挑战, 如何充分有效利用状态监测大数据实现故障诊断成为当前故障诊断领域亟待解决的问题。

2006 年 Hinton 等人基于人工神经网络提出了深度学习的概念^[4], 并在图像处理、语音识别、自然语言处理等领域得到广泛应用^[5-7]。近几年, 深度学习在故障诊断领域得到广泛研究, 并取得一定成果。基

于深度学习的智能故障诊断成为当前故障诊断的研究热点。深度学习智能故障诊断模型的训练需要大量有标签样本, 虽然状态监测系统的广泛应用为其提供了大数据基础, 然而这些数据大多是无标签样本, 仅有少量有标签样本, 如轴承从正常运行到故障停机, 会经历正常状态、微弱故障、严重故障等至少三种状态的变化, 通常可以根据时间确定前期少量样本为正常状态, 中期少量样本为微弱故障, 后期少量样本为严重故障。其中, 微弱故障何时出现, 何时转换为严重故障, 成为故障诊断的难点。因此, 如何充分利用大量无标签样本及少量有标签样本实现样本分类成为深度学习实现智能故障诊断的瓶颈。

上述问题的本质是小样本分类问题, 传统的小样本分类器有人工神经网络^[8]、支持向量机^[9]、极限学习机^[10]等, 以上分类器均为浅层学习模型, 存在收敛速度慢、易陷入局部最优、分类性能受参数影响较大、学习能力弱等问题。深度学习具有极强的模式识别能力, 在故障模式识别中取得广泛应用。文献[11]采用总体经验模态分解提取故障特征, 堆叠稀疏自编码器构建深度学习故障诊断模型用于旋转机械故障

收稿日期: 2023-11-09

基金项目: 国家自然科学基金面上项目(62273299); 河南省科技攻关计划项目(222102210087, 242102320248, 242102240040)

第一作者简介: 胡永涛(1987—), 男, 河北邯郸人, 副教授, 博士, 主要从事机械故障诊断研究。

诊断。文献 [12] 提取机械振动信号的时域、频域和时频域统计特征作为故障特征, 构建深度学习分类器, 较好地实现了齿轮和轴承的故障诊断。文献 [13] 采用变分模态分解和奇异值分解提取故障特征, 结合卷积神经网络实现了齿轮箱故障诊断。上述研究构建了深度学习分类器, 虽然采用无监督的预训练和有监督的微调两种方式训练分类模型实现了故障诊断, 但是其预训练及微调均需大量有标签样本, 无法体现深度神经网络半监督学习的优势。

针对上述问题, 本文利用多层受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM) 构建深度半监督小样本分类器 (Deep Semi-supervised Small-sample Classifier, DSSC), 采用预训练和微调的方式训练分类模型。预训练采用无标签样本逐层对特征进行编码, 初步确定网络参数。微调利用有标签样本通过反向传播算法调优网络参数, 获得准确的分类模型。为了提高收敛速度, 解决微调反向传播时由于少量有标签样本差异较大导致梯度消失的问题, 提出了改进的激活函数。与现有深度学习分类器相比, DSSC 最大优势是可以充分利用大量无标签样本和少量有标签样本训练模型, 具有网络结构简单、训练耗时少、准确率高优点, 结合常规特征提取方法即可实现故障诊断, 亦可用于深度学习智能故障诊断的数据清洗, 为其提供大量有效样本。

1 深度半监督小样本分类器

1.1 分类器建模

为了充分利用大量无标签样本及少量有标签样本实现故障模式识别, 基于 RBM 设计了深度半监督小样本分类器。RBM 是一种基于统计力学的随机神经网络^[14], 由可见层 v 和隐含层 h 组成, 可见层和隐含层是全连接的, 可见层和隐含层内各神经元无连接。DSSC 结构如图 1 所示, 由 1 个输入层、3 个隐含层、1 个输出层及 1 个标签层构成, 其中输入层及隐含层构成 3 层 RBM。




图 1 DSSC 结构

输入层接收大量样本的特征, 并对特征进行首次编码, 其神经元个数与输入特征维数相同。隐含层 1 接收输入层的输出, 对其进行再次表编码后逐层传输至后续隐含层。隐含层神经元个数对分类性能影响较小, 可根据经验选取。输出层为 Softmax 分类器, 根据隐含层 3 的输出对输入样本进行分类, 其神经元个数与样本类别数相同。上述过程为无监督学习, 其分类性能较差。为了提高分类性能, 设置了标签层, 标签层利用少量有标签样本进行有监督学习, 以进一步优化分类模型。标签层神经元个数与输出层相同。DSSC 的训练过程包括预训练和微调两个步骤。预训练采用无监督学习方式, 由下向上对大量样本进行逐层训练, 再重新编码输入特征, 以初步确定各层 RBM 参数及样本标签, 如图 1 中虚箭头所示。

对于给定的可见层和隐含层神经元, 其能量函数可表示为:

$$E(v, h) = -\sum_{i=1}^n \sum_{j=1}^m w_{ij} v_i h_j - \sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j \quad (1)$$

式中: v_i 和 h_i 分别为可见层第 i 个神经元和隐含层第 j 个神经元的二值状态, 其联合分布可表示为:

$$P(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (2)$$

式中: $Z = \sum e^{-E(v, h)}$ 为归一化常数, 给定 v , 则隐含层第 j 个神经元激活的概率为:

$$P(h_j | v) = \delta(b_j + \sum_{i=1}^n w_{ij} v_i) \quad (3)$$

同理, 对于给定的 h , 可见层第 i 个神经元激活的概率为:

$$P(v_i | h) = \delta(b_i + \sum_{j=1}^m w_{ij} h_j) \quad (4)$$

式中: $\delta(\cdot)$ 为激活函数, 式 (3) 和式 (4) 分别描述了输入信号特征表示及重构过程, 可采用对比散度 (Contrastive Divergence, CD) 算法^[15], 通过最小化损失函数, 更新训练参数 w 、 a 和 b , 通常采用均方误差表示损失函数:

$$J_{MSE} = \frac{1}{M} \sum_{i=1}^M (\|x^m - z^m\|^2) \quad (5)$$

式中: x^m 为一个样本输入, M 为输入样本数, z^m 为重构样本。

参数更新完毕后, 隐含层 3 的输出被输入 Softmax 分类器, 进行样本分类。

由于预训练为无监督学习, 经预训练得到的网络参数不是最优参数, 分类误差较大。为了提高模型分类准确率, 需利用有标签样本对参数进行微调。微调为有监督学习, 利用少量有标签样本, 计算输出误差,

采用反向传播 (Back Propagation, BP) 和梯度下降算法调优模型参数, 提高分类准确率, 获得最优分类模型, 如图 1 中虚线所示。经预训练和微调后所得模型即可对测试样本进行分类。

1.2 改进激活函数

根据 DSSC 训练方式可知, 激活函数是模型训练的关键, 直接影响训练速度及分类性能。深度学习中常用的激活函数为 sigmoid、tanh 和 relu 三种^[16], 其表达式分别如下:

$$y_{\text{sigmoid}} = \frac{1}{1 + e^{-x}} \quad (6)$$

$$y_{\text{tanh}} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

$$y_{\text{relu}} = \max(0, x) \quad (8)$$

sigmoid 函数是最早应用的 S 型非线性激活函数, 能够把输入压缩至 0—1 之间, 对中间区域的信号增益较大, 对两侧区域信号增益较小。在反向传播过程中, 当输入处于两侧区域 (输入过大或过小) 时, 其导数趋于 0, 导致梯度消失, 训练无法继续进行。此外, sigmoid 函数收敛速度较慢。tanh 函数是 sigmoid 函数改进的激活函数, 能够把输入压缩至 -1—1 之间, 相对于 sigmoid 函数具有更快的收敛速度, 但没有解决输入过大或过小导致的梯度消失问题。relu 函数是一种分段线性的激活函数, 当输入小于等于 0 时, 输出为 0, 神经元不被激活, 具有极强的稀疏性; 当输入大于零时, 输出等于输入, 梯度保持不变, 缓解了梯度消失问题。relu 函数运算简单、收敛速度快, 是目前深度学习中应用最为广泛的激活函数。虽然 relu 函数解决了梯度消失和收敛速度问题, 但将小于等于 0 的输入强制置零会导致 RBM 大量神经元激活概率为 0, 无法有效学习特征。对于大于 0 的输入, 由于输出保持不变, 如果输入过大, 将导致梯度爆炸, 同样无法顺利进行训练。因此, relu 不能直接作为 RBM 的激活函数。

本文所设计的 DSSC 最大优势是可以充分利用少量有标签样本实现分类。由于有标签样本特征之间存在较大差异, 且数量较少, 采用现有激活函数极易导致梯度消失或梯度爆炸, 无法顺利地实现微调并获得良好的分类模型。为了解决激活函数收敛速度慢、梯度消失及梯度爆炸问题, 本文结合三种激活函数的优点, 利用 sigmoid 函数、tanh 函数的指数运算因子, 对 relu 函数进行改进, 改进后的激活函数 e-relu 表达式如下:

$$y_{\text{e-relu}} = \begin{cases} \ln(1 + e^x) - \ln 2, & x \leq 0 \\ \ln \sqrt{x+1}, & x > 0 \end{cases} \quad (9)$$

当输入小于等于 0 时, 采用平滑的指数对数函数, 修正 relu 函数强制置零的缺陷, 以提升特征学习能力; 当输入大于 0 时, 采用对数函数, 以减缓上升趋势, 避免梯度爆炸。四种激活函数曲线如图 2 所示。由图 2 可知, e-relu 函数没有刻意屏蔽有效信号, 而是有选择地激活负值, 具有一定的稀疏能力, 且收敛速度较快, 能够同时缓解梯度消失和梯度爆炸问题, 可保证模型的正常训练。




图 2 四种激活函数曲线

2 基于 VMD-DSSC 的故障诊断方法

DSSC 是一种快速的小样本分类器, 不具备直接处理原始振动信号的能力, 将其用于故障诊断需借助一定的特征提取方法。变分模态分解 (Variational Mode Decomposition, VMD) 是一种新的信号自适应分解方法^[17], 能够把信号分解为一系列本征模态函数, 相比小波分解、经验模态分解、局部均值分解等方法, 具有较好的抑制模态混叠的能力。样本熵是一种信号复杂度度量方法^[18], 是近似熵的改进方法, 具有较好的一致性、不依赖样本长度等优点。当轴承发生故障时, 其振动信号的成分及复杂度发生变化, 可通过 VMD 将信号分解为不同频率成分的子信号, 并提取各子信号的样本熵作为故障特征, 再利用 DSSC 实现轴承故障诊断。基于上述分析, 提出了基于 VMD-DSSC 的轴承故障诊断模型, 如图 3 所示。诊断具体步骤如下:

步骤 1: 获取轴承振动信号, 包括大量无标签样本及少量有标签样本。

步骤 2: 利用 VMD 将信号分解为不同成分子信号, 计算各子信号的样本熵作为故障特征。

步骤 3: 将大量无标签样本的故障特征输入 DSSC 模型进行预训练, 初步确定网络参数。

步骤 4: 利用少量有标签样本对 DSSC 模型进行微调, 确定最优参数, 获得分类模型。

步骤 5: 利用上述模型对测试集进行测试, 确定所有样本类别, 实现故障诊断。




图 3 VMD-DSSC 故障诊断模型

3 实验分析

通过轴承故障诊断实验验证本文模型的有效性。轴承故障振动数据来源于凯斯西储大学轴承故障模拟试验台^[19], 电机转速 1750 rpm, 负荷 1.47 kW, 测试轴承为 SKF6205 深沟球滚动轴承。轴承滚动体、内圈和外圈分别加工有 0.007 英寸、0.014 英寸、0.021 英寸三个等级的单点损伤, 加上正常轴承, 共计 10 种状态。每种状态分别取 100 个样本, 共 1000 个样本进行实验, 每个样本数据长度为 2048 点。采用 VMD 对所有样本进行分解, 根据样本频谱确定分解层次为 6, 每个样本被分解为 6 个频率成分的子信号。计算所有子信号的样本熵作为故障特征, 得到的特征矩阵。为了验证模型的性能, 分别研究有标签样本和激活函数对故障诊断性能的影响。根据输入特征及样本类别, 设置 DSSC 结构为, 训练迭代次数为 200, 动量参数为 0.8, 学习率为 0.001。

3.1 有标签样本对故障诊断性能的影响

采用大量有标签样本进行微调能够很好地提高分

类器性能, 但实际应用中往往仅能获取少量有标签样本和大量无标签样本。因此, 结合 DSSC 训练方式, 采用大量无标签样本进行预训练, 利用不同数量的有标签样本进行微调, 验证有标签样本对故障诊断性能的影响, 确定 DSSC 实现准确分类所需最少有标签样本数。

每类状态取所有样本用于预训练, 分别采用 5、10、15、20、25、30、35、40、45 和 50 个有标签样本用于微调, 其余样本用于测试, 共计 10 种实验, 每种实验重复 20 次; 采用分类准确率的均值、标准差及训练耗时评价分类性能。不同有标签样本分类准确率均值及标准差如图 4 所示。由图 4 可以看出, 平均分类准确率随有标签样本的增多而增大, 标准差随有标签样本个数的增多而减小。有标签样本过少时, 分类准确率较低, 标准差较大, 如每类有标签样本 10 个时, 平均分类准确率为 90.4%, 标准差为 7.78%, 训练耗时 7.88 s, 分类性能较差。当每类有标签样本 30 个时, 平均分类准确率达到 99.35%, 标准差为 1.676%, 训练耗时 11.71 s, 分类性能得到极大改善; 当每类有 50 个样本时, 分类准确率达到 99.95%, 标准差为 0.082%, 训练耗时 18.63 s, 分类性能得到进一步改善。




图 4 不同有标签样本时分类准确率均值及标准差

综上所述, DSSC 能够很好地利用无标签样本进行预训练, 当微调所用有标签样本数为预训练样本数的 30% 时, 即可实现准确可靠的分类。但随着有标签样本的增加, 训练耗时也随之增加, 因此, 实际应用中考虑实时故障诊断的要求, 应合理设置有标签样本的数量。

3.2 激活函数对故障诊断性能的影响

为了验证激活函数对分类性能的影响, 对 sigmoid、tanh、relu 和 e-relu 四种激活函数进行对

比研究。每类有标签样本为 30 个, 其余样本用于测试。四种激活函数训练准确率曲线如图 5 所示, 由图可以看出, 采用 e-relu 作为激活函数时, 训练准确率在第 55 次迭代达到稳定的 100%; 采用 tanh 作为激活函数时, 训练准确率在第 164 次迭代时达到稳定的 100%; 采用 sigmoid 作为激活函数时, 训练准确率在第 184 次迭代时达到 100%; 而采用 relu 作为激活函数时, 训练准确率则稳定在 10%。四种激活函数故障诊断性能如表 1 所示。采用 relu 作为激活函数时, 准确率为 10%, 标准差为 0%, 无法实现故障诊断。采用 tanh 和 sigmoid 函数作为激活函数时, 准确率分别为 94.06% 和 94.88%, 稳定在 95% 以下, 虽然 tanh 耗时少于 sigmoid, 但其准确率略低于 sigmoid; 采用 e-relu 作为激活函数时准确率最高, 为 99.35%, 标准差为 1.676%, 高于 sigmoid, 低于 tanh, 耗时为 11.71s, 高于 relu, 但低于 sigmoid 和 tanh。因此, 采用 e-relu 作为激活函数时故障诊断性能最好。




图 5 不同激活函数训练准确率曲线

表 1 不同激活函数故障诊断性能

激活函数	准确率	标准差	耗时
e-relu	99.35%	1.676%	11.71s
relu	10.00%	0.00%	4.92s
tanh	94.06%	1.843%	13.49s
sigmoid	94.88%	1.152%	15.89s

综上分析, 虽然 relu 函数有强大的稀疏能力, 其训练速度也最快, 但同时也导致特征无法得到有效学习, 故不能用作 RBM 的激活函数。tanh 函数和 sigmoid 函数性质基本相同, 易产生梯度消失, 采用它们作为激活函数时, 无法获得最佳分类性能。e-relu 综合了三种激活函数的优点, 具有缓解梯度消失的能力及收敛速度快的优点, 适合作为本文模型激活函数。

4 工程应用

为了验证本文模型在实际工程应用中的有效性, 对风电机组高速轴承进行故障诊断。数据来源于某风力发电厂 2MW 风电机组的状态监测系统, 采用加速度传感器采集高速轴承振动数据, 每小时采集一次数据, 采样频率 97.656KHz, 采样时间 6s, 数据长度 585936 点, 幅值单位为 G。停机检查发现高速轴承内圈有裂纹, 传感器安装位置及故障轴承如图 6 所示, 经计算内圈故障频率为 283.2Hz。停机前 1200 小时内高速轴承的幅值均方根曲线如图 7 所示。图 7 展示了高速轴承的故障恶化趋势, 前 500 小时均方根值小于 2, 为正运行状态; 501—800 小时均方根值介于 2—2.5 之间, 表明轴承发生了微弱故障; 在微弱故障情况下继续运行 400 小时后均方根值大于 2.5, 表明轴承发生了严重故障。高速轴承在 1200 小时内经历了正常、微弱故障和严重故障三种状态, 分别标记为 1、2 和 3。



(a) 传感器安装位置 (b) 故障轴承

图 6 传感器安装位置及故障轴承




图 7 1200 小时内幅值均方根曲线

通过均方根阈值仅能够判断故障发生的大致时间。为了确定微弱故障及严重故障发生的具体时间, 及时提出预防和维护警告, 采用本文模型对高速轴承 1200 小时内的状态进行故障诊断。1200 小时内共有 1200 个样本, 全部用于预训练。由于微调需选取有标

签样本,根据实际运行情况,确定第1—200小时为正常运行,第651—750小时为微弱故障,第1001—1200小时为严重故障,因此微调时3种状态有标签样本数分别为200、100和200。预训练集、微调集及测试集样本如表2所示。

表2 训练集及测试集样本

样本 / 类别	预训练集	微调集	测试集
1—500/1	1—500	1—200	1—500
501—800/2	501—800	651—750	501—800
801—1200/3	801—1200	1001—1200	801—1200

采用预训练集和微调集训练故障诊断模型,然后,将测试集输入训练好的模型,预测所有样本类别。所有样本预测类别如图8所示。由图8可以看出,在300—500小时内,有14个样本被判定为微弱故障,但大部分样本被判定为正常,即从第300小时起,轴承可能发生了轻微故障,但不能根据该结果判定此时已经发生故障。




图8 所有样本预测类别

为了判断此时是否已经发生故障并确定故障类型,对第300小时的样本进行包络分析,结果如图9所示。由图9可以看到,280.1 Hz的频率成分及其2倍频与内圈故障频率非常接近,可以判定此时内圈已经发生故障。综上分析,轴承故障的产生是一个连续的由弱到强的过程,在故障早期,由于特别微弱,不能通过均方根阈值判断,而本文模型能够在大量信号中获取故障信号,为后期分析提供有效样本,结合包络分析能够及时判定早期的微弱故障,相比均方根阈值判断提前了200小时。




图9 第300小时样本的包络分析

5 结束语

本文设计了深度半监督小样本分类器,其可以充分利用大量无标签样本和少量有标签样本进行模型训练,有标签样本达到训练样本的30%即可实现快速、准确、稳定的模式识别。此外,提出的改进的激活函数,缓解了梯度消失问题,且具有较快的收敛速度。在此基础上提出的基于VMD-DSSC的轴承故障诊断方法,具有故障诊断准确率高、实时性好的优点。所提方法能够有效实现轴承故障诊断,为大数据下的机械故障诊断提供了一种新方法,也可用于数据清洗,为智能故障诊断提供有效样本。

参考文献:

- [1] 汪祖民,张志豪,秦静,等.基于卷积神经网络的机械故障诊断技术综述[J].计算机应用,2022,42(4):1036-1043.
- [2] 杨滨,和丹,祝丽莉,等.基于DIA的最优尺度形态滤波器及其在轴承故障诊断中应用[J].噪声与振动控制,2023,43(5):181-187.
- [3] 刘俊峰,俞翔,万海波.基于改进傅里叶模态分解和频带熵的滚动轴承故障诊断方法[J].中国舰船研究,2022,17(2):190-197.
- [4] HINTO G E, SALAKHUTDIONV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [5] 洪彝,钱旭升,申明磊,等.基于深度学习的CT-MR图像联合配准分割方法[J].Computer Engineering, 2023, 49(9):234-245.
- [6] 马猷纲,杨乘.基于深度学习的反语音欺骗模型[J].信息与电脑,2023,35(4):55-58.
- [7] ALDUNATE A, MALDONADO S, VAIRETTI C, et al. Understanding customer satisfaction via deep learning and natural language processing[J]. Expert System with Application, 2022, 209:118309.
- [8] 温嘉斌,赵红阳,刘子宁.基于神经网络的无刷直流电机传

- 感器故障检测及容错系统[J]. 电子测量与仪器学报, 2018, 32(10):39–46.
- [9] 刘松松, 张辉, 毛征, 等. 基于 HRM 特征提取和 SVM 的目标检测方法[J]. 国外电子测量技术, 2014, 33(10):38–41.
- [10] XU J W, ZHANG Y X, YIN Z. Early bearing fault diagnosis based on improved SFLA and ELM network[J]. Transactions of the Canadian Society for Mechanical Engineering, 2018, 42(2):187–193.
- [11] XIE Y, ZHANG T. Fault diagnosis for rotating machinery based on convolutional neural network and empirical mode decomposition[J]. Shock and Vibration, 2017, 19(8):1–12.
- [12] LI C, SÁNCHEZ R, ZURITA G, et al. Fault diagnosis for rotating machinery using vibration measurement deep statistical feature learning[J]. Sensors, 2016, 16(6):895–913.
- [13] LIU C, CHENG G, CAO X H, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. Sensors, 2018, 18(5):1523.
- [14] DONOHO D L. Compressed sensing[J]. IEEE Transactions on Information Theory, 2006, 52(4):1289–1306.
- [15] SHERI A M, RAFIQUE A, PEDRYCZ W, et al. Contrastive divergence for memristor-based restricted Boltzmann machine[J]. Engineering Applications of Artificial Intelligence, 2015, 37:336–342.
- [16] SOUZA P V D C, TORRES L C B, GUIMARAES A J, et al. Data density-based clustering for regularized fuzzy neural networks based on nullneurons and robust activation function[J]. Soft Computing, 2019, 23(2):12475–12489.
- [17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3):531–544.
- [18] RICHMAN J S, LAKE D E, MOORMAN J R. Sample entropy[J]. Methods in Enzymology, 2004, 384(2):172–184.
- [19] Bearing Data Center. Seeded fault test data [EB/OL]. (2020–02–21) [2023–10–10]. <https://engineering.case.edu/bearingdatacenter>.

Bearing Fault Diagnosis Based on VMD–DSSC

HU Yongtao^{1,2}, DONG Mingru^{2,3}, LI Jie^{1,2}, LI Jinjun^{1,2}

(1. School of Electrical Engineering and Automation, Henan Institute of Technology, Xinxiang 453003, China; 2. Xinxiang Engineering Research Center for Intelligent Condition Monitoring of Machinery, Xinxiang 453003, China; 3. School of Electronic Information Engineering, Henan Institute of Technology, Xinxiang 453003, China)

Abstract: In response to the problem of limited labeled samples in bearing fault diagnosis under the background of big data, a deep semi-supervised small sample classifier (DSSC) was designed and used for bearing fault diagnosis. Firstly, a deep learning classifier is constructed using a constrained Boltzmann mechanism, parameter pre-training is completed using unlabeled samples, and parameter tuning is combined with labeled samples to obtain an accurate classification model. Then, the activation function is improved to solve the gradient vanishing problem, improve convergence speed, and enhance classification performance. Finally, the signal was decomposed into a serial of intrinsic mode functions by variational mode decomposition, and sample entropies were calculated as the features, which were input to the classifier to recognize the fault types. The results of bearing fault diagnosis experiment and high-speed bearing fault diagnosis of wind turbines show that DSSC can fully utilize unlabeled and labeled samples to achieve bearing fault pattern recognition, and has advantages such as high fault diagnosis accuracy, good stability, less time consumption, and good real-time performance. It provides a new method for bearing fault diagnosis and can also be used for data cleaning, providing effective samples for intelligent fault diagnosis.

Key words: bearing fault diagnosis; big data; deep learning; small-sample classification; activation function

(责任编辑 王 磊)