DOI: 10.3901/JME.2019.07.073

基于次优网络深度学习的 3D 打印机故障诊断*

李 川^{1,2,3} 张绍辉² José Valente de Oliveira³

(1. 重庆工商大学国家智能制造服务国际科技合作基地 重庆 400067;

2. 华南理工大学机械与汽车工程学院 广州 510641;

3. 葡萄牙阿尔加维大学 CEOT 中心 法鲁 8005-139 葡萄牙)

摘要: 为实现精度可靠且成本节约的 3D 打印机故障诊断, 采用消费级姿态传感器采集打印机的健康状态数据, 并提出次优网络深度学习以弥补低成本硬件精度的不足。次优网络深度学习在由预训练和精细调节组成的传统深度学习基础上, 一方面提出预分类方法自适应确定次优的网络结构参数, 另一方面采用精细分类方法进一步提高故障诊断分类的精度。试验中, 将姿态传感器安装于并联臂 3D 打印传动链的末端即打印头上。传感器全部通道的运动信号作为输入信息, 采用深度玻尔兹曼机构构建了次优网络故障诊断算法进行大数据驱动故障诊断。将所提出的次优网络深度学习故障诊断方法与其他方法相比较, 其结果表明, 所提出方法可以有效诊断 3D 打印机的传动故障。

关键词: 3D 打印; 故障诊断; 深度学习; 次优网络; 大数据

中图分类号: TH17

Fault Diagnosis for 3D Printers Using Suboptimal Networked Deep Learning

LI Chuan^{1,2,3} ZHANG Shaohui² José Valente de Oliveira³

(1. National Research Base of Intelligent Manufacturing Service,

Chongqing Technology and Business University, Chongqing 400067;

2. School of Mechanical & Automobile Engineering, South China University of Technology, Guangzhou 510641;

3. CEOT, Universidade do Algarve, Faro 8005-139, Portugal)

Abstract: For reliable and cost-saving diagnosis of 3D printer faults, a customer-goods level attitude sensor is employed to collect healthy condition data of the printer. To make up for the inferior precision of the low-cost hardware, a suboptimal networked deep learning (SNDL) method is developed. In addition to conventional deep learning architecture composed of pre-training and fine-tuning, there are two new merits for SNDL. A pre-classifying strategy is first proposed to adaptively determine the suboptimal network structure. A fine-classifying approach is on the other hand adopted for further improving fault classification performance. In the experiments, the attitude sensor is installed on the end of the transmission chain (i.e., the printing head of the delta 3D printer). Motion signals collected from all channels of the sensor are used as the input vector of the suboptimal networks, which are developed by deep Boltzmann machines for the big data-driven fault diagnosis. The addressed SNDL method is compared with peer methods. The results show that the present SNDL is capable of effectively diagnosing transmission faults for the 3D printer.

Key words: 3D printing; fault diagnosis; deep learning; suboptimal network; big data

0 前言

3D 打印是一种具有广阔应用前景的快速成型增材制造技术, 它以数字模型文件为基础, 通过逐层打印的方式制造物体或产品^[1]。常见的 3D 打印机

按照传动结构可以分为并联 3D 打印机和串联 3D 打印机两种, 串联机构可以为 3D 打印机提供较大的运动空间, 而并联机构 3D 打印机具有结构紧凑、重量轻、刚度好和传动精度高等优点^[2]。

无论采用何种传动机构的 3D 打印机, 在使用一段时间后, 其传动精度都可能会退化。以并联臂 3D 打印机为例, 其传动链上的万向球轴承、同步传动带等都可能因为磨损或老化产生传动间隙, 从而影响最终打印的产品质量。虽然影响 3D 打印产品

* 国家自然科学基金(51775112, 51605406)、国家重点研发计划(2016YFE0132200)和重庆高校优秀成果转化(KJZH17123)资助项目。
20180624 收到初稿, 20181106 收到修改稿

质量的因素比较多,但机械传动精度是最重要的因素之一^[3]。因此,面向3D打印的故障诊断是保障打印质量和精度的重要措施。

机械故障诊断的实施过程至少包括两个方面。第一方面是选择有效的运行参数。已有的研究表明,机械系统运行过程的振动、温度、声音、电流、润滑油磨粒参数等都可用于反映机械系统的健康或故障状态^[4-5]。为了有效获取机械状态参数,人们常常在系统的合适位置安装各种不同的传感器以采集对故障敏感的过程信号。除了采集有效的传感器信号,另一方面的重要因素是故障诊断算法。虽然对故障敏感的传感器可以监测到更微弱的故障,但合适的故障诊断算法可以在一定程度上提升传感器对故障的诊断能力。为了处理大量传感器产生的监测大数据,研究人员利用传感器信号在时域、频域、时频域或其他非线性域的不同形式^[6-7],采用回归、分类、聚类等不同手段开展了故障诊断^[8-9]。

已有故障诊断方法在典型机械系统(如齿轮、轴承等旋转机械)中得到了成功的应用^[10]。与这些常见的机械系统相比,3D打印机结构紧凑、运动复杂,而且市场商用3D打印机对成本比较敏感,高灵敏度的故障诊断传感器价格较高,市场推广较难,这都给有市场实用价值的3D打印机故障诊断带来挑战。为了有效监测故障,前期提出在3D打印机传动链的末端(即打印头)安装一个姿态传感器,通过对打印头姿态的监测来诊断3D打印状态^[11]。虽然采用工业级的姿态传感器可以有效识别打印故障,但其硬件成本仍然较高。为了使3D打印机故障诊断更加具有商业实用价值,本研究提出采用消费级的姿态传感器来采集3D打印的状态信号。消费级姿态传感器已经在手机等消费电子产品中得到广泛应用,其成本完全在商用3D打印机可接受的范围内。但是,低成本传感器的不足之处就是其故障诊断灵敏度较低。为了弥补消费级姿态传感器的不足,研究进一步提出采用更好的故障诊断算法提升硬件系统的综合表现。

深度学习是一种基于大数据的故障诊断方法,其有效性已经得到故障诊断领域众多大数据研究人员的验证^[12]。深度学习的核心是由两阶段学习构成的,即无监督训练(Pre-training)和有监督学习(Fine-tuning)相结合。这种两阶段的学习方式有效提升了对大数据的深度学习性能。在基于深度学习的故障诊断方法中,合适的深度网络结构和合适的分类器一直都是研究的重点^[13]。有鉴于此,我们受到包括Pre-training和Fine-tuning的两阶段深度学习方法的启发,提出一种次优深度学习网络,进一步采

用两阶段分类(Pre-classifying和Fine-classifying),一方面自适应地确定一种具有较好性能的次优网络结构,另一方面进一步提升深度学习网络的设备状态分类性能。通过次优网络深度学习弥补消费级姿态传感器的硬件不足,以并联臂3D打印机为例试验测试,为提高3D打印故障诊断的商业实用性奠定基础。

1 并联臂3D打印姿态监测

如图1所示并联臂3D打印机的传动示意图,在打印机外框架范围内,3个驱动电动机以三角形的结构分别独立带动3条同步带运行。每条同步带上安装有1个滑块,每个滑块上有2根连杆与之相联。3个电动机通过3根同步带、3个滑块分别带动6根连杆的一端运行。6根连杆的另一端分别与打印头呈三角形相连接,其连接由每根连杆两端安装的万向球轴承来实现。这样,通过3个电动机的运动可以合成打印头在外框架分为的三维空间内运动。通过在运动过程中喷射打印材料,可以在工件台上打印出三维实体的工件产品。

图1 并联臂3D打印传动示意图

图1所示的并联臂3D打印传动机构属于一种典型的3-P[2-SS]机构,其自由度计算如下

$$A = 6 \times (k - m - 1) + \sum_{i=1}^m n_i \quad (1)$$

式中, A 为自由度数, k 是包括外框架在内的构件数, m 是运动副的数目, n_i 表示第 i 个运动副的自由度数。由图1可知, $k=11$ (1个外框架、3个滑块、6个连杆、1个打印头)、 $m=15$ (3个移动副和12个球面副)、移动副自由度为1、球面副自由度为3。此外,连杆自由度属于局部自由度,而局部自由度对打印头的最终输出运动并没有影响。因此,将以上参数代入式(1)并减去6根连杆的局部自由度,可以

计算得并联臂 3D 打印机的自由度 $A=3$ 。

即使对于完全精确设计和制造的 3D 打印机，经过一段时间后也会产生传动性能退化。通过简单的机理分析可知，如果构件本身没有破坏，那么机械传动性能退化主要来自于同步带的松弛、万向球轴承的磨损等，其结果将会在传动链的末端即打印头上得到反映。因此，通过监测打印头的运动状态，可以间接反映整条传动链的故障诊断。为此，研究采用姿态传感器来监测打印头的运动姿态。

姿态传感器是一种三维运动姿态测量系统，可广泛嵌入到手机、航模无人机、机器人、机械云台、车辆船舶、地面及水下设备等设备，以测量三维姿态与方位^[14]。姿态传感器一般基于 MEMS 技术制造，其输出包含 3 轴陀螺仪、3 轴加速度计、3 轴电子罗盘等运动传感器。理论上，可以采用 3 轴陀螺仪信号生成姿态角，其计算如下

$$\phi_i = (\omega_i - \omega_b)dt + \phi_{i-1} \quad (2)$$

式中， ϕ_i 表示在时间 $t=i$ 时刻测得的姿态角，其在 x 、 y 、 z 三轴的分量分别为 α 、 β 、 γ ； ω_i 是陀螺仪输出的角速度， ω_b 是角速度偏差。但是，式(2)的计算存在累积误差，所以进一步利用 3 轴加速度计和 3 轴电子罗盘计算并校正式(2)得到的结果。利用 3 轴加速度计和 3 轴电子罗盘计算的 3 轴姿态角如下

$$\alpha = \arctan\left(\frac{a_x}{\sqrt{a_y^2 + a_z^2}}\right) \quad (3)$$

$$\beta = \arctan\left(\frac{a_y}{\sqrt{a_x^2 + a_z^2}}\right) \quad (4)$$

$$\gamma = \arctan\left(\frac{m_y \cos \beta + m_x \sin \beta \sin \alpha - m_z \sin \beta \cos \alpha}{m_x \cos \alpha + m_z \sin \alpha}\right) \quad (5)$$

式中， a_x 、 a_y 、 a_z 分别是 x 、 y 、 z 这 3 轴的加速度； m_x 、 m_y 、 m_z 分别是 3 轴的电子罗盘输出。

采用以上监测原理，姿态传感器共可以监测 3D 打印传动链末端的 12 种运动信号。其中，3 轴姿态角的数据是计算得到的二手数据，所以研究中只选择其余 9 个通道的原始信号 $S(t)=\{s_1(t), s_2(t), \dots, s_9(t)\}$ 。与军品级或工业级姿态传感器相比，消费级姿态传感器价格低廉，具有大规模商业应用的低成本优势，但其缺点是监测精度较低。因此本研究提出一种次优网络深度学习的方法，通过更好的故障诊断算法来弥补监测传感器硬件精度的不足。

2 次优网络深度学习的方法

2.1 深度玻尔兹曼机的预训练与精细调节

深度学习网络一般采用逐层无监督的预训练(Pre-training)与全网络有监督的精细调节(Fine-tuning)相结合的学习策略。采用这种学习策略，数据中的各种特征都可以在更高层次的网络中得到有效表示。当应用到设备状态分类时，可以在网络最高层的分类器中得到更好的结果。

深度玻尔兹曼机是一种典型的深度学习网络，研究中采用深度玻尔兹曼机为例来构建网络结构。标准的深度玻尔兹曼机是由一系列随机二值神经元通过对称耦合连接而成的，其网络结构包括 1 个可见层 v 和 L 个隐层 $h^{(1)}, \dots, h^{(l)}, \dots, h^{(L)}$ 。在网络 $\{v, h^{(1)}, \dots, h^{(L)}\}$ 中传递的能量 E 定义为^[15]

$$E(v, h^{(1)}, \dots, h^{(L)} | \theta) = -\sum_{i=1}^{N_v} \sum_{j=1}^{N_l} W_{ij} v_i h_j^{(1)} - \sum_{i=1}^{N_v} b_i v_i - \sum_{i=1}^{N_v} \sum_{j=1}^{N_l} b_j^{(l)} h_j^{(l)} - \sum_{i=1}^{L-1} \sum_{j=1}^{N_l} \sum_{k=1}^{N_{l+1}} w_{jk}^{(l)} h_j^{(l)} h_k^{(l+1)} \quad (6)$$

式中， $\theta=\{W, b\}$ 为网络参数， W_{ij} 表示第 i 个可见神经元与第 j 个隐含神经元之间的连接权值， b_i 表示第 i 个偏差项， N_v 表示可见层神经元数， N_l 表示第 l 个隐层的神经元数。

由于标准的深度玻尔兹曼机只能处理二值(0 或者 1)神经元，当将其应用到故障诊断时，需要进行适当修改以能够处理实数值信号。为此，在可见层引入标准差 σ ，式(6)可改写为^[16]

$$E(v, h^{(1)}, \dots, h^{(L)} | \theta) = -\sum_{i=1}^{N_v} \sum_{j=1}^{N_l} W_{ij} v_i h_j^{(1)} / \sigma_i^2 + \sum_{i=1}^{N_v} 2(v_i - b_i)^2 / \sigma_i^2 - \sum_{i=1}^{N_v} \sum_{j=1}^{N_l} b_j^{(l)} h_j^{(l)} - \sum_{i=1}^{L-1} \sum_{j=1}^{N_l} \sum_{k=1}^{N_{l+1}} w_{jk}^{(l)} h_j^{(l)} h_k^{(l+1)} \quad (7)$$

可见层与隐层之间的联合分布可以计算如下

$$p(v, \{h^{(l)}\} | \theta) = \frac{1}{Z(\theta)} \exp(-E(v, \{h^{(l)}\} | \theta)) \quad (8)$$

式中， $Z(\theta)$ 表示与网络参数 θ 有关的正则化常数。应用上式表示的玻尔兹曼机能量函数，对第 i 个可见层神经元，其条件概率分布计算可得

$$p(v_i | h^{(1)}, \theta) = \mathcal{N}\left(v_i \mid \sum_{j=1}^{N_l} h_j^{(1)} W_{ij} + b_i, \sigma_i^2\right) \quad (9)$$

式中， $\mathcal{N}(\mu, \sigma^2)$ 表示正态分布的概率密度，其均值为

μ , 标准差为 σ 。采用同样方法, 可以推导不同隐层神经元的条件概率分布为

$$p(h_j^{(l)} | \mathbf{h}^{(l-1)}, \mathbf{h}^{(l+1)}, \theta) = s \left(\sum_{i=1}^{N_{l-1}} h_i^{(l-1)} W_{ij}^{(l-1)} + \sum_{k=1}^{N_{l+1}} h_k^{(l+1)} W_{jk}^{(l)} + b_j^{(l)} \right) \quad (10)$$

式中, $s(\cdot)$ 为 Sigmoid 函数。上式存在两个特例: 对最后一个隐层(即 $l=L$), $N_{L+1}=0$; 对第一个隐层(即 $l=1$), 上式中的参数设置为

$$\mathbf{h}^{(l-1)} = \mathbf{v} \quad \sum_{i=1}^{N_{l-1}} h_i^{(l-1)} W_{ij}^{(l-1)} = \sum_{i=1}^{N_l} v_i W_{ij} / \sigma_i^2 \quad (11)$$

以上公式描述的玻尔兹曼机网络并不自动具备分类功能。当将其应用于设备状态分类问题时, 一般在其顶层增加 Softmax 分类器, 此时玻尔兹曼机网络的顶层就是 Softmax 分类器的输入 $\mathbf{a}$, 其第 i 个元素可表示为

$$a_i = \sum_{j=1}^{N_{L-1}} h_j^{(L-1)} W_{ij}^{(L-1)} \quad (12)$$

对于给定的 N_L 个神经元, 分类器将其分配到 c 类, 其结果归属于第 i 类的概率记为

$$p_i = \frac{\exp(a_i)}{\sum_{i=1}^{N_L} \exp(a_i)} \quad \sum_{i=1}^{N_L} p_i = 1 \quad (13)$$

采用此方法, 一个输入信号可以被归类到具有最大概率的类别 $\hat{i}$, 用公式表示如下

$$\hat{i} = \arg \max_i p_i = \arg \max_i a_i \quad (14)$$

在深度玻尔兹曼机中, 其学习过程分为预训练和精细调节两个阶段。第一个阶段为预训练阶段, 采用逐层无监督学习方式对网络参数进行初步学习。第二个阶段采用自顶向下的有监督学习方法, 称为精细调节过程。在这个阶段, 网络的输出层被一个用 Sigmoid 函数连接的多层感知机所代替, 然后采用反向传播算法精细修正网络参数。在预训练阶段, 采用无监督学习且只需要考虑当前层的参数; 而在精细调节阶段, 采用有监督学习且全面考虑了整个网络结构的参数优化问题。但是, 当深度玻尔兹曼机应用于 3D 打印故障诊断时, 仍然存在两个问题: 一是如何确定更好的网络结构, 包括网络层的数量、每层的神经元数量等; 二是如何进一步提升分类器的性能。为此, 下面提出一种基于预分类和精细分类策略的次优网络结构。

2.2 基于预分类和精细分类的次优网络结构

次优网络深度学习的理念受到集成参数自适应调整及隐含层降噪的深层 RBM 算法所启发^[17], 本

研究将其中的参数自适应调整理念用于预分类和精细分类相结合的次优玻尔兹曼机网络。令深度玻尔兹曼机的学习样本 $\mathbf{X}$ 包括两部分, 即

$$\mathbf{X} |_{\mathbf{C}} = \{\mathbf{X}_1 |_{\mathbf{C}_1}, \mathbf{X}_2 |_{\mathbf{C}_2}\} \quad (14)$$

式中, $\mathbf{C}$ 为样本所对应的分类标签, $\mathbf{X}_1$ 和 $\mathbf{X}_2$ 分别为训练集样本中的数据集合 1(用于训练模型)和数据集合 2(用于测试模型), 其对应的分类标签为 $\mathbf{C}_1$ 和 $\mathbf{C}_2$ 。

对于第 l 个隐层 $\mathbf{h}^{(l)}$, 假设存在映射矩阵 $\mathbf{A} \in \mathbf{R}^{L \times c}$, 使得该隐层状态与训练集标签信息 $\mathbf{C}_1$ 相对应, 即

$$\mathbf{h}^{(l)} \mathbf{A} = \mathbf{C}_1 \quad (15)$$

在上式两边同时乘以 $\mathbf{h}^{(l)}$ 的转置矩阵 $\mathbf{h}^{(l)T}$, 整理得

$$\mathbf{A} = (\mathbf{h}^{(l)T} \mathbf{h}^{(l)})^{-1} \mathbf{h}^{(l)T} \mathbf{C}_1 \quad (16)$$

对于测试样本 $\mathbf{X}_2$, 根据网络参数 $\theta = \{\mathbf{W}, \mathbf{b}\}$, 可以获得该隐含层的输出 $\mathbf{P}$ 。结合上式表述的隐含层与标签信息之间的映射矩阵, 可得到测试样本的理论标签为

$$\hat{\mathbf{C}}_2 = \mathbf{P} |_{\mathbf{X}_2} \mathbf{A} \quad (17)$$

对于测试样本, 其理论标签与实际标签之间的错误率 η 可计算如下

$$\eta = \frac{\sum_{i=1}^N \hat{\mathbf{C}}_2 \neq \mathbf{C}_2}{N} \quad (18)$$

式中, N 为测试样本的总数。通过控制错误率 η 的大小, 可以修正隐层的神经元数量, 从而获得更优的神经元数。理论上, 只有当 $\eta=0$ 时, 隐层可以达到最优的结构。但这在实际上是不现实的, 因为最优网络对应的深度学习计算资源消耗太多。因此, 通过适当控制错误率 η (本研究中设置为 0.1, 是同时考虑计算效率和识别正确率的经验参数), 可以获得次优结构的深度学习网络参数。

需要说明的是, 次优网络结构的自适应调节过程, 其实质上是一个预分类(Pre-classifying)过程。在这一过程中, 通过分类标签的有监督学习, 分别逐层优化玻尔兹曼机网络的结构。因此, 调节次优网络结构的预分类过程, 与深度学习的预训练(Pre-training)过程在理念上具有相似之处, 两者都是逐层优化, 可以节约计算资源。但在实现手段上, 两者又有所不同, 预训练采用无监督学习, 而预分类采用有监督学习。

预分类过程可以在一定程度上优化网络结构, 通过控制错误率 η 的大小获得次优网络结构。但是, 设备状态分类的效果还取决于分类器的性能。在常

见的深度学习过程中, 精细调节和最终分类过程的多层感知机使用的都是 Softmax 分类器, 原因是该分类器的反向误差传递过程中, 其分类结果的绝对值大小表征属于该类别的概率, 这在理论上属于一种近似线性化的分类表达。

支持向量机(SVM)采用非线性的误差损失函数, 已有研究人员用支持向量机代替多层感知机以提高分类精度^[18]。研究中, 除了在深度学习的精细调节过程中使用 Softmax 的误差损失函数外, 采用多类支持向量机作为精细分类器。当采用支持向量机精细分类时, 令式(12)为其输入 $\mathbf{X}_n$, 式(13)为其输出 $\mathbf{Y}_n$, 设类别 y_n 为二值数类, 则支持向量机分类由如下优化问题描述^[8]

$$\begin{aligned} \min_{\mathbf{w}, \xi_n} & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{n=1}^N \xi_n \\ \text{s.t.} & \mathbf{w}^T \mathbf{x}_n \tau_n \geq 1 - \xi_n \\ & \xi_n \geq 0 \quad n = 1, 2, \dots, N \end{aligned} \quad (19)$$

式中, $\tau_n \in \{-1, 1\}$, ξ_n 为第 n 个松弛变量, C 为罚函数。上式可以表述为如下无约束 L2 范数形式

$$\min_{\mathbf{w}} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{n=1}^N \max(1 - \mathbf{w}^T \mathbf{x}_n \tau_n, 0)^2 \quad (20)$$

通过求解以上公式, 支持向量机计算得到对应的类别为

$$\hat{i} = \arg \max_{\tau} (\mathbf{w}^T \mathbf{x}) \tau \quad (21)$$

基于以上方法, 可以利用支持向量机构造标准的二值分类器。但在应用到故障诊断时, 由于 3D 打印机的故障位置不同, 可能会产生不同的故障类别。为解决这一问题, 一般采用一对多(OAA)策略来应对 I 个故障模式。为此, 通过独立训练 I 个支持向量机, 得到第 i 个支持向量机的输出为

$$a_i(\mathbf{x}) = \mathbf{w}^T \mathbf{x} \quad (22)$$

相应地, 对于多分类问题, 式(21)可以修改为

$$\hat{i} = \arg \max_i a_i(\mathbf{x}) \quad (23)$$

需要说明的是, 次优网络深度学习的精细分类过程和精细调节过程采用了两个不同的分类方法。在精细调节过程中, 为了有效利用线性化概率的损失函数, 采用了多层感知机来确定次优网络的连接权值等参数。在精细分类过程中, 为了提高设备状态分类的非线性能力, 采用了一对多支持向量机进行精细分类。

2.3 在 3D 打印故障诊断中的应用

图 2 示出了基于次优网络深度学习的 3D 打印机故障诊断流程, 具体步骤描述如下。

图 2 3D 打印机故障诊断流程示意图

(1) 采集安装在打印机传动链末端即打印头上的姿态传感器的信号 $\mathbf{S}(t)$ 。

(2) 将不同健康状态下的数据集随机分为训练样本 $\mathbf{S}_1(t)$ 和测试样本 $\mathbf{S}_2(t)$ 。

(3) 将训练样本及其对应的状态标签用于训练次优网络深度玻尔兹曼机, 具体如下。

① 将训练样本 $\mathbf{S}_1(t)$ 分为学习样本中的训练集 $\mathbf{X}_1$ 和测试集 $\mathbf{X}_2$, 利用预分类(Pre-classifying)确定次优网络的错误率 η 参数: 可见层神经元数 N_v 与一个样本的长度相同, 而基于式(14)~(18)可自适应地逐层确定各隐层的神经元数量 N_l 。

② 采用训练样本 $\mathbf{S}_1(t)$ (不需使用其样本标签), 基于无监督学习预训练(Pre-training)各层之间网络参数和权值。

③ 采用训练样本 $\mathbf{S}_1(t)$ 及其标签, 采用误差反传的有监督学习, 精细调节(Fine-tuning)次优网络的网络参数和权值。

④ 将深度玻尔兹曼机最顶层作为式(19)~(23)定义的支持向量机输入, 进行精细分类(Fine-classifying)以训练支持向量机分类器。

(4) 将训练好的次优网络深度玻尔兹曼机用于 3D 打印机故障诊断。对于输入的任意一组姿态传感器信号, 输出其健康或故障状态。结束。

3 故障诊断试验测试

为了测试所提出的次优网络深度学习方法, 研究中搭建了 3D 打印机故障诊断试验平台。如图 3 所示, 该 3D 打印机由实验室自行装配 (SLD-BL600-6), 在打印机传动链的末端即打印头上安装有一个消费级姿态传感器(BWT901, 维特), 传感器信号输出到计算机(Precision 5520, Dell)建立大数据集进行故障诊断分析试验。

图3 3D打印机故障诊断试验平台

令6根连杆的两端连接的万向球轴承编号分别为 $A \sim L$, 3根同步带的编号分别为 M 、 N 、 O , 试验中分别预设了 $A \sim O$ 之一故障的15种故障状态, 加上全部正常的状态, 共计16种模式。万向球轴承的故障一般是磨损引起的间隙, 为了模拟这种磨损间隙故障, 试验中将固定螺丝松动0.25圈以产生间隙, 如图4a所示。同步带的故障一般是由于老化松弛产生的自由长度延长, 试验中将同步带放松1个齿(1.5 mm)的距离以模拟其故障, 如图4b所示。

在试验中准备3D打印机的运行程序, 分别设置20个 $R=105\text{ mm}$ 的圆, 使3D打印机的打印头按照预设的路径进行运动。传感器的数据采集程序安

图4 试验中的故障位置

装于计算机中, 在每一种状态模式下, 采用100 Hz的采样频率采集数据。试验中共采集了24 000组数据, 每组数据时间长度为1 s, 总体数据量较大。由于姿态传感器的原始输出有9个通道, 因此, 每一个数据样本的长度为900。试验中将24 000组数据打乱后, 随机分为两组, 其中70%(即16 800组数据)用于次优网络深度学习建模, 剩下的30%(即7 200组数据)用于故障诊断性能测试。

4 结果与讨论

4.1 次优网络深度学习诊断结果

图5示出了姿态传感器采集的一个数据样本中的9个通道的信号。为了利用这些姿态传感器的运动信号诊断3D打印机的故障, 试验中采用所提出的次优网络深度学习方法对数据进行分析。

图5 姿态传感器采集的一段信号

由于深度玻尔兹曼机可见层的神经元数量与一个样本的长度相等, 因此试验中可以首先确定 $N_1=900$ 。然后基于式(14)~(18)自适应地逐层确定各隐层的神经元数量 N_i , 设置循环次数为50, 自适应地得到 $N_2=327$ 、 $N_3=41$ 。分类器的种类为16, 因此, 网络的输出为16。这样, 采用预分类的方法自适应地确定了次优的网络结构。接下来对次优结构的深

度玻尔兹曼机网络进行预训练和精细调整, 并采用支持向量机进行精细分类器的学习, 从而完成次优网络训练。

将剩下的7 200组数据在应用深度玻尔兹曼机进行测试, 试验共重复5次, 故障诊断的正确率平均为97.84%, 结果表明所提出的方法可以有效诊断3D打印机的故障。

4.2 与其他同类方法的比较

为了凸显所提出方法的有效性,研究首先比较了姿态传感器中各通道信号的性能。分别采用 3 轴陀螺仪、3 轴加速度计或者 3 轴电子罗盘信号作为输入,采用相同的次优网络深度学习进行测试,试验共重复 5 次,其结果如表 1 所示。

表 1 采用姿态传感器不同通道进行故障诊断结果

输入信号	每次诊断正确率(%)					均值 (%)	方差
	1	2	3	4	5		
全部通道	97.94	97.86	97.92	97.94	97.54	97.84	0.0292
3 轴陀螺仪	32.90	32.77	31.98	32.76	32.22	32.53	0.1615
3 轴加速度	41.74	40.97	41.46	42.32	41.56	41.61	0.2389
3 轴电子罗盘	94.93	93.88	94.41	93.76	94.96	94.39	0.3185

从表 1 可知,采用姿态传感器的全部 9 个通道信号具有最优的故障诊断效果(诊断正确率的均值为 97.84%),次之是 3 轴电子罗盘信号的故障诊断效果,再次之是 3 轴加速度信号的诊断效果,而 3 轴陀螺仪信号的诊断效果在所有类别中最差。结果表明,消费级姿态传感器的每一类运动信号都可以在一定程度上用于 3D 打印机故障诊断,但全面利用姿态传感器的各通道运动信号,对 3D 打印机的故障诊断效果更佳。

在采用姿态传感器的全部 9 个通道的信号进行故障诊断的前提下,接下来比较不同诊断算法的性能。仍然采用预分类确定的次优网络,采用多层感知机结合 Softmax 分类器用于同样的故障诊断,试验重复 5 次,其结果如图 6 所示,诊断正确率的均值为 96.76%。为了进一步比较,采用优化的支持向量机对相同的数据进行 3D 打印机故障诊断,试验也重复 5 次,其结果也示于图 6,其诊断正确率的均值为 93.96%。结合表 1 和图 6 可见,采用次优网络结构的方法得到的识别正确率在 96%以上,而采用单独优化支持向量机的方法得到的识别正确率在 94%以下。而且本文方法(深度玻尔兹曼机结合优化支持向量机)得到的识别正确率为 97.84%,而深度

图 6 不同算法的故障诊断效果的盒形图对比

玻尔兹曼机结合 Softmax 分类器得到的识别正确率明显小于本文方法。需要说明的是,由于本文提出的方法和深度玻尔兹曼机都采用了次优网络结构,因此差别在 Softmax 与支持向量机两者的分类能力上。在总体上,采用支持向量机作为精细分类器可以进一步提高 3D 打印机故障诊断的效果。

5 结论

(1) 提出采用姿态传感器诊断 3D 打印机的机械传动故障,将低成本的消费品级姿态传感器安装于并联臂 3D 打印机的传动链末端,以降低故障诊断的硬件成本和提升其实用性。

(2) 为了弥补消费品级姿态传感器硬件精度的不足,提出一种面向故障诊断的次优网络深度学习的方法,在传统深度学习的预训练(Pre-training)和精细调节(Fine-tuning)的基础上,增加预分类(Pre-classifying)自适应确定深度玻尔兹曼机网络的结构,采用精细分类(Fine-classifying)进一步提升基于大数据的设备状态分类效果。

(3) 试验结果表明,次优网络深度学习与低成本姿态传感器相结合,可以有效诊断 3D 打印机的故障状态。与其他方法相比较,利用姿态传感器的全部通道信号比单独使用部分通道信号诊断效果更好,次优网络深度学习比传统的玻尔兹曼机和支持向量机等方法可以达到更高的诊断精度。

参 考 文 献

- [1] MOHAMMED M I, GIBSON I. Design of three-dimensional, triply periodic unit cell scaffold structures for additive manufacturing[J]. Journal of Mechanical Design, 2018, 140(7): 071701.
- [2] 常定勇, 方跃法, 叶伟. 双输出 3D 打印解耦并联机器人的设计与分析[J]. 机械工程学报, 2017, 53(7): 39-46. CHANG Dingyong, FANG Yuefa, YE Wei. Design and analysis of a double output 3D printing decoupling parallel manipulator[J]. Journal of Mechanical Engineering, 2017, 53(7): 39-46.
- [3] MILLER D B, GLISSON W B, YAMPOLSKIY M, et al. Identifying 3D printer residual data via open-source documentation[J]. Computers & Security, 2018, 75: 10-23.
- [4] JIA F, LEI Y G, LIN J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical Systems and Signal Processing, 2016, 72-73: 303-315.

- [5] 李川, 朱荣荣, 杨帅. 基于多指标模糊融合的滚动轴承诊断的最优频带解调方法[J]. 机械工程学报, 2015, 51(7): 107-114.
- LI Chuan, ZHU Rongrong, YANG Shuai. Optimal frequency band demodulation for fault diagnosis of rolling element bearings based on fuzzy fusion of multiple criteria[J]. Journal of Mechanical Engineering, 2015, 51(7): 107-114.
- [6] SHAO H, JIANG H, ZHAO H, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis[J]. Mechanical Systems and Signal Processing, 2017, 95: 187-204.
- [7] MAO Yongfang, QIN Shuren, QIN Yi. Demodulation based on harmonic wavelet and its application into rotary machinery fault diagnosis[J]. Chinese Journal of Mechanical Engineering, 2009, 23(3): 419-425.
- [8] DING X, HE Q. Energy-fluctuated multiscale feature learning with deep ConvNet for intelligent spindle bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(8): 1926-1935.
- [9] JING Yabing, LIU Changwen, BI Fengrong, et al. Diesel engine valve clearance fault diagnosis based on features extraction techniques and FastICA-SVM[J]. Chinese Journal of Mechanical Engineering, 2017, 30(4): 991-1007.
- [10] SHEN C Q, WANG D, KONG F R, et al. Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier[J]. Measurement, 2013, 46: 1551-1564.
- [11] HE K, YANG Z, BAI Y, et al. Intelligent fault diagnosis of delta 3D printers using attitude sensors based on support vector machines[J]. Sensors, 2018, 18: 1298.
- [12] ZHAO R, YAN R, CHEN Z, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [13] HINTON G E, SALAKHUDINOV R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504-507.
- [14] AHMED H, TAHIR M. Accurate attitude estimation of a moving land vehicle using low-cost MEMS IMU sensors[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18, 1723-1739.
- [15] SALAKHUTDINOV R, HINTON G. An efficient learning procedure for deep Boltzmann machines[J]. Neural Computation, 2012, 24(8): 1967-2006.
- [16] LI C, SANCHEZ R V, ZURITA G, et al. Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis[J]. Neurocomputing, 2015, 168: 119-127.
- [17] 张绍辉. 集成参数自适应调整及隐含层降噪的深层 RBM 算法[J]. 自动化学报, 2017, 43(5): 855-865.
- ZHANG Shaohui. Deep RBM algorithm with adaptive adjustment parameters and de-noising in hidden layer[J]. Acta Automatica Sinica, 2017, 43(5): 855-865.
- [18] TANG Y. Deep learning using linear support vector machines, in: Workshop on representational learning[C]// The 30th International Conference on Machine Learning, Atlanta, USA, June 16-21, 2013: 1-6.
-
- 作者简介: 李川(通信作者), 男, 1975 年出生, 博士, 教授。主要研究方向为机械故障诊断和智能计算。
E-mail: chuanli@21cn.com
- 张绍辉, 男, 1985 年出生, 博士后。主要研究方向为机械故障诊断和智能计算。
E-mail: 350699269@qq.com
- José Valente de Oliveira, 男, 1965 年出生, 博士, 教授。主要研究方向为智能计算和故障诊断。
E-mail: jvo@ualg.pt