基于哈密顿神经网络的机器故障分类 ks

JeremyShen[1], JawadChowdhury[2],Sourav Banerjee[3] 和 Gabriel Terejanu[2l]美国密歇根州安娜堡，密歇根大学电气与计算机工程系[2]美国北卡罗来纳州夏洛特，北卡罗来纳大学夏洛特分校计算机科学系[3]美国南卡罗来纳州哥伦比亚，南卡罗来纳大学机械工程系 *jmshen@umich.edu, mchowdh5@uncc.edu, banerjes@cec.sc.edu, gabriel.terejanu@uncc.edu*

关键词: 物理信息神经网络、监督学习、能量守恒、动力系统

摘要: 本文提出一种新方法，通过传感器测量数据估算总能量特征，据此对旋转机械的故障进行分类。总体目标是超越黑箱模型，并纳入支配机械系统行为的其他物理约束。利用观测数据训练哈密顿神经网络，以描述系统在正常及各种异常工况下的守恒能量。估算得到的总能量函数以哈密顿神经网络权重的形式表示，可作为新的特征向量，借助现成的分类模型区分不同故障。实验使用 MaFaulDa 数据库进行，结果显示，该模型在二分类（正常与异常）中的曲线下面积（AUC）达到 0.78，在多分类问题（正常及 5 种不同异常工况）中的曲线下面积达到 0.84，表现出良好的前景。

arXiv:2301.02243v1 [cs.LG] 4 Jan 2023

1 引言

确保部件可靠性的一种经济有效的方法，是在当前基于计划的维护方法中加入确定性的部件健康状态和使用数据，以指导选择性维护和针对性维护活动。安全关键型应用和生产应用需要状态监测与故障诊断系统，以防范意外故障。早期故障检测可减少非计划故障，进而降低生命周期成本，并提高战备状态和任务保障能力。各种机械设备和制造工具，如数控机床、重型设备、飞机、直升机、航天器、汽车发动机及其他机器，都会产生振动。分析这些振动数据是设备或结构发生故障前检测其劣化的关键。机器故障通常会通过模态参数的变化，在其内部特征中留下关键迹象。例如，故障可能改变系统的固有频率，产生独特的阻尼特性，导致刚度退化，产生声学频率等。系统中的缺陷和故障还可能使能量从机械能转换为电能或电磁能的形式发生变化，从而留下独特的特征。振动信号的统计特征在时域、频域和时频域中各有不同优势，可用于检测故障模式，相关研究已十分深入 [Nayana 和 Geethanjali，2017，Van 等，2020，Li 等，2016]。研究人员提出了多种方法，通过时域和频域分析从这些振动信号中提取特征 [Lei 等，2008], 傅里叶变换和小波变换 [Li 等， 2013],以及流形学习 [Jiang 等， 2009]。研究还表明，整合并混合使用特征提取算法能够产生协同效应，兼具各自优势并弥补不足 [Usamentiaga 等，2013，Rizzo 和 di Scalea， 2006]。该领域的大多数研究都基于振动传感器采集的数据 [Yen 和 Lin，2000，Seshadrinath 等，2014，Bellini 等， 2008], ；这类传感器成本低，且便于非侵入式部署。然而，它们会产生海量数据。由于这类数据集规模庞大，要找出上述独特特征及其各自的旁轴贡献极具挑战性。因此，近年来，人们部署了多种由特征提取驱动的机器学习算法来应对这一挑战 [Amin 等，2015，Wei 等，2019，Caggiano 等，2019，Yin 等， 2019]。

构建和部署机器学习模型以支持决策的一项挑战，是实现足够的泛化能力，使模型能够在数据分布的一部分上学习，并在另一部分上进行预测

。在物理系统的数据上进行学习时，这一挑战会更加突出，因为神经网络（NN）等机器学习模型只能近似捕捉其底层物理定律。近期，物理信息神经网络（PINN）领域涌现出一些新方法 [Karniadakis 等人， 2021] 用于训练 NN，使其不仅拟合观测数据，还遵循底层物理规律。本研究利用哈密顿神经网络（HNN） [Greydanus 等人，2019] 从噪声数据中学习能量守恒动力系统的哈密顿方程。

哈密顿神经网络用于表征旋转机械的总能量，旋转机械广泛应用于动力涡轮机、直升机和数控机床等领域。在参考文献 [Ribeiro 等人， 2017], 作者提出了一种基于相似度的模型，用于计算信号与一组表征目标运行工况的原型信号之间的相似度分数。这些相似度分数特征与时域和频域特征结合起来，使用现成的分类模型（如随机森林）对系统行为进行分类。

本研究的主要贡献在于，在生成判别性特征时有意识地考虑旋转机械的底层物理规律。具体而言，在哈密顿神经网络的开发和训练过程中，将能量守恒作为归纳偏置。尽管这些机械系统本质上具有耗散性，我们假设在短时间内，由于电动机输入能量，系统能量保持守恒。我们的方法所提取的特征表现为哈密顿神经网络的权重，这些权重表征系统的总能量。换言之，我们尝试依据能量函数识别运行工况。与以往方法相同，这些物理信息特征随后用于训练现成的分类器（如逻辑回归和随机森林），以预测机械系统的状态。实验基于里约热内卢联邦大学的机械故障数据库（MaFaulDa）[1] 开展。所提出的系统在二分类（正常与异常）任务中取得了颇有前景的曲线下面积（AUC）0.78，在多分类问题（正常及 5 种不同的异常工况）中则达到 0.84。

本文结构如下：第 2 节介绍哈密顿神经网络和MaFaulDa数据集的背景。第 3 节介绍我们提出的方法，该方法用于提取物理信息特征，以对运行工况进行分类。第 4 节展示实证评估结果，第 5 节总结我们的研究发现。

[1] http://www02.smt.ufrj.br/~offshore/mfs/page_01.html

2 背景

2.1 哈密顿神经网络

运动的哈密顿方程（式 1）以正则坐标、位置$\mathbf{q}$和动量$\mathbf{p}$以及系统的哈密顿量$\mathcal{H}$来描述机械系统。

$$\frac{d\mathbf{q}}{dt} = \frac{\partial \mathcal{H}}{\partial \mathbf{p}}, \quad \frac{d\mathbf{p}}{dt} = -\frac{\partial \mathcal{H}}{\partial \mathbf{q}} \tag{1}$$

哈密顿神经网络采用的方法，并非使用神经网络直接学习哈密顿向量场 $\left(\frac{\partial \mathcal{H}}{\partial \mathbf{p}}, -\frac{\partial \mathcal{H}}{\partial \mathbf{q}}\right)$，而是将哈密顿量本身表示为神经网络形式的参数化函数进行学习 [Greydanus 等人， 2019]。这种区别使模型能够学习真正感兴趣的量，并且还可以通过自动微分计算其对正则坐标的导数，轻松获得向量场。给定训练数据后，通过最小化以下损失函数（式 2）来学习哈密顿神经网络的参数。

$$\mathcal{L} = \left\| \frac{\partial \mathcal{H}}{\partial \mathbf{p}} - \frac{d\mathbf{q}}{dt} \right\|_2 + \left\| \frac{\partial \mathcal{H}}{\partial \mathbf{q}} + \frac{d\mathbf{p}}{dt} \right\|_2 \tag{2}$$

2.2 机械故障数据库（MaFaulDa）

为了开发和测试基于哈密顿量的特征提取方法，并对存在损坏/缺陷的不同运行状态进行分类，需要一套全面的机器故障和振动数据。机械故障数据库（MaFaulDa）包含一套来自 SpectraQuest Alignment-Balance-Vibration System 的全面振动数据，其中涵盖多种故障类型，见图 1。该设备由两个支撑轴承、一个转子和一台电动机构成。轴承上装有加速度计，用于测量各轴承径向、轴向和切向上的振动。此外，数据库还包含转速计（用于测量系统旋转频率）和麦克风（用于采集系统运行期间的声音）所记录的数据。该数据库包含 10 种不同的运行状态和总计 1951 组振动数据：(1) 正常运行，(2) 转子不平衡，(3) 下悬臂轴承故障：外滚道，(4) 下悬臂轴承故障：滚动体

，(5) 下悬臂轴承故障：内滚道，(6) 悬臂轴承故障：外滚道，(7) 悬臂轴承故障：滚动体，(8) 悬臂轴承故障：内滚道，(9) 水平轴错位，(10) 垂直轴错位。

正常运行。系统在无故障的正常工况下运行，共采集了 49 组数据；每组数据的转速固定，范围为 737 rpm 至 3686 rpm，步长约为 60 rpm。

转子不平衡。为模拟不同程度的不平衡运行，将不同载荷（6、10、15、20、25、30、35）g 安装在转子上。该数据库共包含 333 种不同的不平衡运行场景，涵盖载荷与旋转频率的不同组合。

轴承故障。滚动轴承是机器中最复杂的部件之一，也是最容易发生故障的部件。将三个缺陷轴承分别安装在各个轴承位置上，每个轴承均带有一种不同的缺陷（外滚道、滚动体和内滚道）。此外，还将三种质量（6、10、20）g 加装到转子上，以在不同旋转频率下形成转子不平衡与轴承故障的组合。悬垂端轴承故障场景共 558 种，悬臂端轴承故障场景共 513 种。

水平轴错位。通过将电机轴水平移动（0.5、1.0、1.5、2.0）mm，引入水平轴错位故障。该数据库共包含 197 种不同场景，涵盖水平轴错位与旋转频率的各种组合。

垂直轴错位。通过将电机轴垂直移动（0.51、0.63、1.27、1.4、1.78、1.9）mm，引入垂直轴错位故障。该数据库共包含 301 种不同场景，涵盖垂直轴错位与旋转频率的各种组合。

3 方法

所提出的旋转机械运行状态识别方法，是利用哈密顿神经网络从振动数据中学习系统的总能量，并将哈密顿量的参数用作判别特征。其基本思路是，不同故障下的总能量特征各不相同。我们的主要假设是，由于电动机注入能量，系统的能量在短时间内守恒，因此可以使用哈密顿神经网络 [Greydanus 等人， 2019]。整体模型架构如图 2 所示。

第一步是使用仅在正常工况数据上训练的自编码器，从原始振动数据中构建一组广义坐标。随后，使用编码器神经网络，将任意运行工况下采集的 8 个振动测量值转换为低维表示（本例中为二维）。这种构建任意坐标的方法已在最初的哈密顿神经网络论文中提出 [Greydanus 等人， 2019]。

使用新开发的坐标后，第二步是在 5 秒内以 50 kHz 采样率生成的每组数据序列上训练一个哈密顿神经网络。哈密顿量$\mathcal{H}_\theta$ 的参数 θ 充分表征了运行状态的能量函数，并可用于训练分类器。

哈密顿量的参数化具有高维特性（在我们的案例中有 41,200 个权重），因为它取决于哈密顿神经网络中所选的层数和每层隐藏神经元的数量。因此，我们选择在最后的建模步骤中训练随机森林分类器之前，使用主成分分析（PCA）降低其维度。

4 数值结果

我们将所提出的故障分类系统应用于 MaFaulDa数据集，并按 70 : 30 的比例划分训练数据和测试数据。鉴于采集的数据存在不平衡，即正常运行电机的数据集有 49 个，而所有故障运行电机的数据集共有 1800+ 个，我们采用合成少数类过采样技术（SMOTE） [Chawla等人， 2002] 来生成少数类的合成数据点。我们使用 PyCaret[2] 框架开发分类器并对哈密顿神经网络特征进行预处理。

本文考虑两种不同的任务。第一种是二分类，即使用随机森林区分正常工况与异常状态；第二种是多分类问题，即使用逻辑回归区分表 1 中列出的类别，其中类别 0 为正常工况。

图 3 和图 4 分别给出了两项任务的受试者工作特征（ROC）曲线。在测试数据上计算的宏平均曲线下面积，二分类为 0.78，多分类问题为 0.84；相应的 F1分数分别为 0.96 和 0.51，这表明哈密顿神经网络中的物理信息特征能够

[2]https://pycaret.org

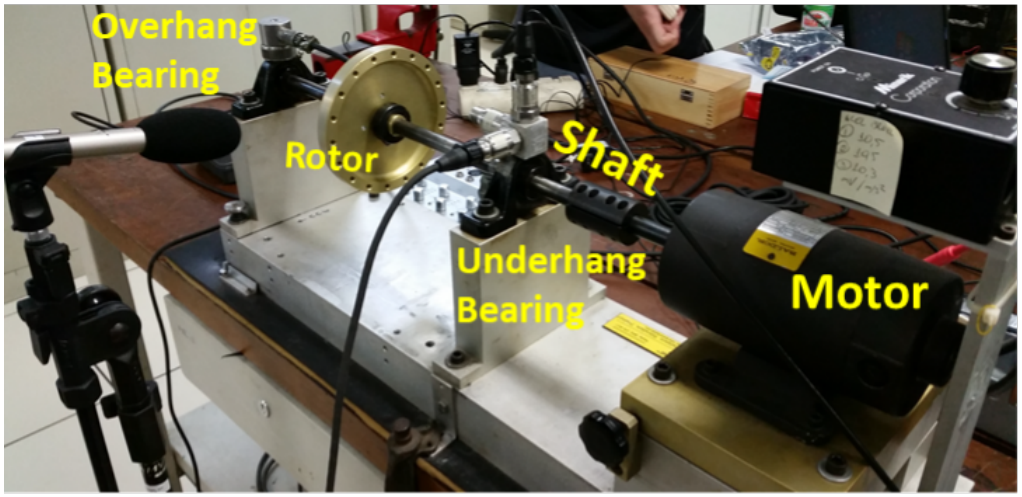


图 1：SpectraQuest系统：对中-平衡-振动

表 1：成对分类——测试集结果

类别	正常 vs X	AUC	F1分数
1	水平不对中	0.59	0.80
2	不平衡	0.92	0.95
3	悬臂	0.85	0.85
4	下悬臂	0.80	0.88
5	垂直不对中。	0.91	0.92

捕捉系统的状态。由于各类别中的样本分布偏斜，这些分类问题存在不平衡，因此我们选择不报告准确率，而此前的研究曾报告过准确率 [Ribeiro 等，2017，Marins 等人， 2018]。不过，我们注意到，参考文献 [Ribeiro 等人， 2017] 在一次 10 折交叉验证中报告的 F1分数为 0.99，高于我们二分类任务的 0.96；而我们的多分类 F1分数较低，是因为对轴承故障类别进行了合并。

表 1 展示了各个独特故障运行工况与正常工况之间两两分类的曲线下面积。图 6 展示了 10 种不同运行工况（1 种正常工况和 9 种故障工况）的相空间。有趣的是，在所有两两比较中，模型发现正常工况与水平不对中工况之间的区分颇具挑战性，我们计划在未来的研究中进一步探讨这一点。我们确实预期，引入的故障会导致各种工况的相图发生细微变化，见图 6。然而，从定性角度来看，我们发现悬臂/滚珠故障的相图与其他工况显著不同，这表明悬臂的子类，即滚珠故障、保持架故障和外滚道故障，应各自作为独立类别处理。

讨论旋转频率对哈密顿量的影响。图 5 展示了不同速度下正常运行电机的哈密顿量。有趣的是，尽管并未对此进行约束，哈密顿向量场的整体结构在不同速度下基本保持不变，而哈密顿量的大小则如预期般随速度升高而增大。由此可见，在此情形下，向量场取决于运行工况，而其大小取决于运行速度。

关于耗散系统中的哈密顿神经网络的讨论。哈密顿神经网络能够学习多个系统的总能量 [Greydanus 等人， 2019], 包括理想的弹簧-质量系统。尽管哈密顿神经网络旨在守恒能量，但探究它从耗散系统中学到了什么也很有意思。我们认为，这种方法的适用范围更广，即使这一假设不成立时也同样适用。

我们使用弹簧-质量-阻尼器系统研究了哈密顿神经网络在耗散系统中的行为。该系统是非保守系统，哈密顿神经网络所构建的哈密顿量并非弹簧-质量-阻尼器系统的传统物理解；其守恒量不是总能量，广义坐标也不是经典力学所定义的位置和动量。尽管如此，对轨迹进行定性分析后可以发现，哈密顿神经网络针对阻尼比的每个取值都会生成独特的解，见图 7。虽然我们无法运用传统物理学来理解哈密顿神经网络在弹簧-质量-阻尼器系统上的结果，但显然，这些结果可用于区分不同的系统。

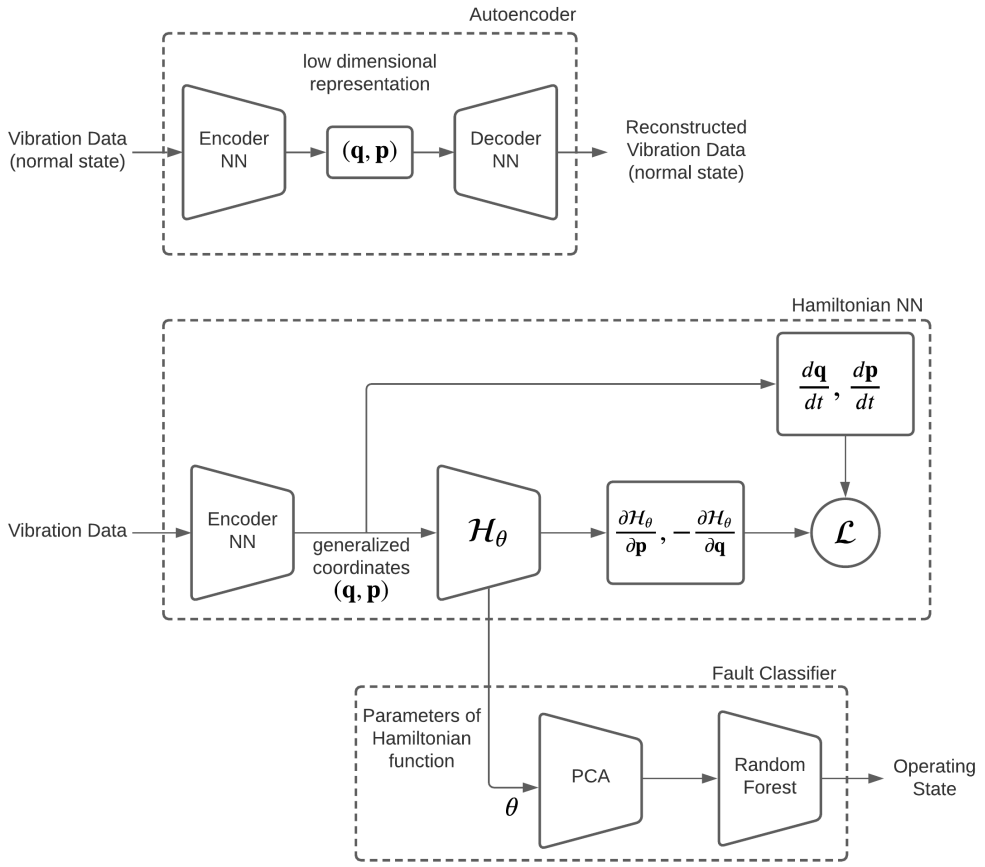


图 2：所提出的故障分类模型

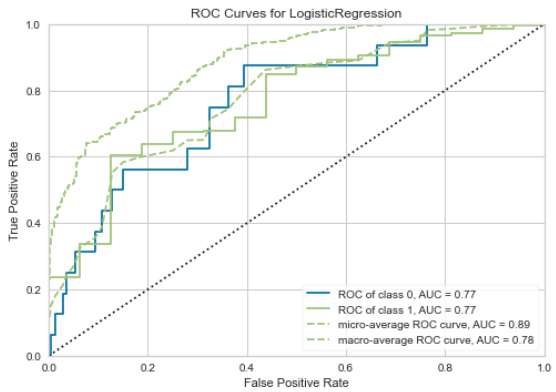


图 3：测试集上的结果——二分类

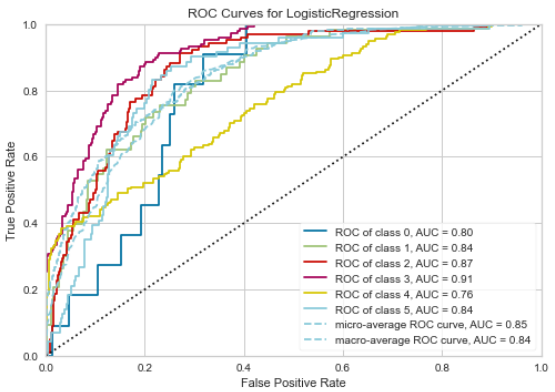


图 4：测试集上的结果——多分类问题

5 结论

本文提出了一种新型预测模型，用于区分旋转机械的正常与异常运行工况。该模型基于利用哈密顿 tonian 神经网络。实验数据得出的性能指标表明，所提出的物理信息特征是机器故障分类的理想候选方案。

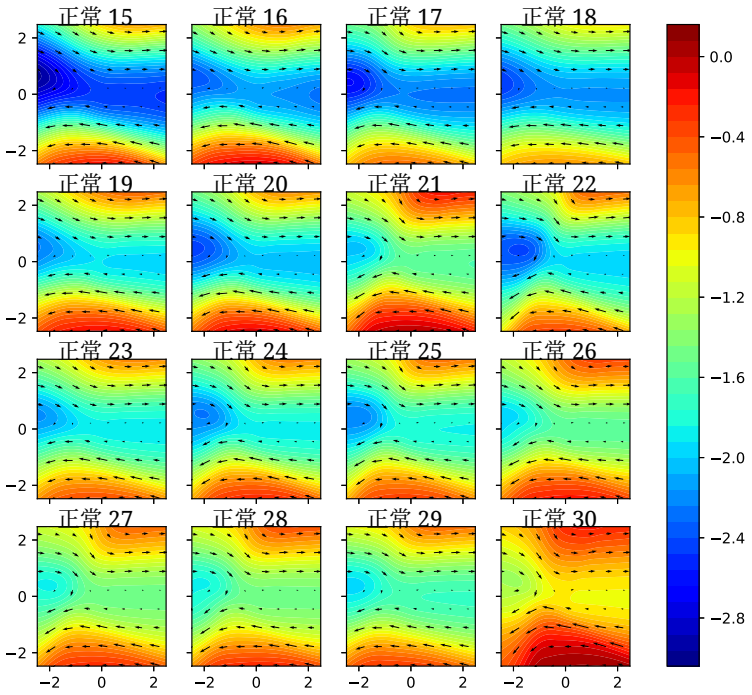


图 5：旋转频率对哈密顿量的影响

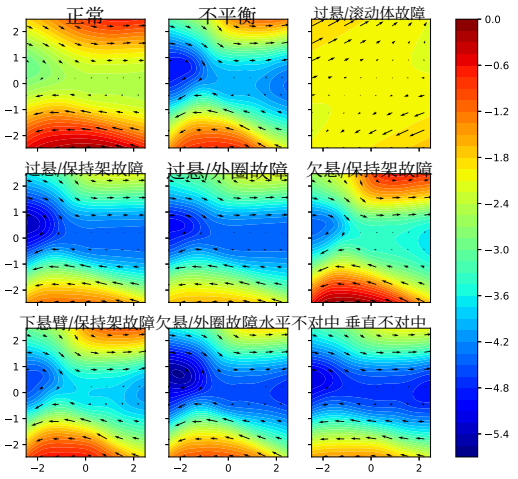


图6：各种运行工况下的相图

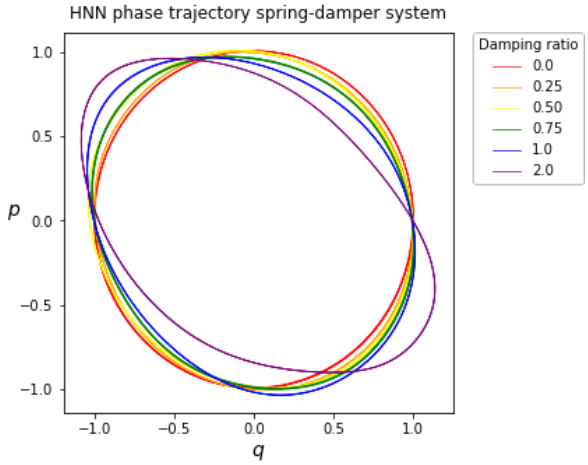


图7：哈密顿神经网络在可变阻尼比下的结果

致谢

本研究由美国国家食品与农业研究所通过资助编号 2017- 67017-26167 以及美国陆军研究办公室通过资助编号 W911NF-22-1-0035 提供资助。本文所载的观点和结论作者的观点，不应被解释为代表美国陆军研究办公室、美国国家食品与农业研究所或美国政府的官方政策，无论这些政策是明示还是暗示。尽管本文包含任何版权声明，美国政府仍有权为政府用途复制并分发转载件。

参考文献

Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., and Chooi, W.-T. (2015). 使用小波变换和机器学习技术对脑电信号进行特征提取与分类。《澳大拉西亚医学物理与工程科学》, 38(1):139–149. Bellini, A., Immovilli, F., Rubini, R., and Tassoni, C. (2008). 通过振动信号或电流信号诊断感应电机轴承故障：批判性比较。载于*2008*年*IEEE*工业应用学会年会, pages 1–8. Caggiano, A., Zhang, J., Alfieri, V., Caiazzo, F., Gao, R., and Teti, R. (2019). 基于机器学习的图像处理在增材制造在线缺陷识别中的应用。《*CIRP*年鉴》, 68(1):451–454. Chawla, N. V., Bowyer, K. W., Hall, L. O., and Kegelmeyer, W. P. (2002). SMOTE：合成少数类过采样技术。《人工智能研究杂志》, 16:321–357. Greydanus, S. J., Dzumba, M., and Yosinski, J. (2019). 哈密顿神经网络。载于第*33*届神经信息处理系统会议（*NeurIPS*），加拿大温哥华。Jiang, Q., Jia, M., Hu, J., and Xu, F. (2009). 使用监督流形学习进行机械故障诊断。《机械系统与信号处理》, 23(7):2301–2311. Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S., and Yang, L. (2021). 物理信息机器学习。《自然综述：物理》, 3(6):422–440. Lei, Y., He, Z., and Zi, Y. (2008). 旋转机械智能故障诊断的新方法。《专家系统与应用》, 35(4):1593–1600. Li, C., S˜A¡nchez, R.-V., Zurita, G., Cerrada, M., and Cabrera, D. (2016). 利用振动测量和深度统计特征学习对旋转机械进行故障诊断。《传感器》, 16(6). Li, P., Kong, F., He, Q., and Liu, Y. (2013). 利用小波分析进行旋转机械故障诊断的多尺度斜率特征提取。《测量》, 46(1):497–505. Marins, M. A., Ribeiro, F. M., Netto, S. L., and da Silva, E. A. (2018). 改进的基于相似度的建模，用于旋转机械故障分类。《富兰克林研究所学报》, 355(4):1913–1930. 机器学习在信号分析与处理中的最新进展特刊。Nayana, B. R. and Geethanjali, P. (2017). 统计时域特征在根据振动信号识别轴承故障方面的有效性分析。《*IEEE*传感器杂志》, 17(17):5618–5625. Ribeiro, F., Marins, M., Netto, S., and da Silva, E. (2017). 基于相似度模型的旋转机械故障诊断。载于*XXXV Simp´*巴西电信与信号处理研讨会˜，*S*˜巴西圣佩德罗。

Rizzo, P. 和 di Scalea, F. L. (2006). 利用导波超声从股线中提取特征以检测缺陷。结构健康监测，5(3):297–308. Seshadrinath, J., Singh, B., 和 Panigrahi, B. K. (2014). 利用复小波研究变频驱动器中的多重故障诊断所涉及的振动特征。*IEEE*电力电子汇刊，29(2):936–945. Usamentiaga, R., Venegas, P., Guerediaga, J., Vega, L., 和 L´opez, I. (2013). 利用主动热成像提取并分析特征，以自动表征汽车碳纤维复合材料中的冲击损伤。《*NDT & E International*》，54:123–132. Van, B., Van Hoa, N., Nguyen, H., 和 Jang, Y. M. (2020). 利用振动信号提取机器故障检测中的统计特征。载于国际信息与通信技术融合会议（*ICTC*），第666–669页。Wei, J., Chu, X., Sun, X.-Y., Xu, K., Deng, H.-X., Chen, J., Wei, Z., 和 Lei, M. (2019). 材料科学中的机器学习。*InfoMat*，1(3):338–358. Yen, G. 和 Lin, K.-C. (2000). 用于振动监测的小波包特征提取。*IEEE*工业电子汇刊，47(3):650–667. Yin, L., Ye, B., Zhang, Z., Tao, Y., Xu, H., Salas Avila, J. R., 和 Yin, W. (2019). 一种基于机器学习的涡流检测缺陷检测新特征提取方法。《*NDT & E International*》，107:102108.