一种利用振动信号进行故障检测的基于卷积的方法集成

XianYeow Lee*、Aman Kumar*、Lasitha Vidyaratne*、Aniruddha Rajendra Rao*、
Ahmed Farahat、Chetan Gupta 工业人工智能实验室，日立美国有限公司，研发部门

2023年5月10日

{xian.lee, aman.ku mar, lasitha.vidyaratne, aniruddha.rao, ahmed.farahat, chetan.gupta}@hal.hitachi.com

arXiv:2305.05532v1 [eess.SP] 5 May 2023

关键词：时间序列，分类，卷积，集成，振动数据。

摘要

本文聚焦于解决一项故障检测问题：使用从试验台上的行星齿轮箱采集的振动信号多变量时间序列。针对多变量时间序列分类，已有多种传统机器学习和深度学习方法，包括基于距离、面向函数型数据、由特征驱动以及基于卷积核的方法。近期研究表明，采用 ROCKET 等基于卷积核的方法，以及结合残差网络和全卷积网络的一维卷积神经网络，在多变量时间序列数据分类方面表现稳健。我们提出了一种由三种基于卷积核的方法组成的集成，并通过优于其他方法、达到超过 98.8% 的准确率，展示了其在这一故障检测问题上的有效性。

1 引言

预测与健康管理（PHM）旨在预测设备可能发生的故障或健康状态退化，并管理为缓解此类状况所需采取的措施。预测与健康管理涉及解决多项任务，例如故障检测与隔离、故障预测以及剩余使用寿命估计（RUL） [30, 17]。预测与健康管理是一个至关重要的领域，在多个行业中具有广泛的应用。为实现预测与健康管理，研究人员提出了多种方法，这些方法可分为基于模型的方法和数据驱动方法。前者利用基于物理的模型来表征设备的退化过程，而后者则利用系统测量的历史数据来学习退化模式。数据驱动方法的典型示例包括传统机器学习方法，以及近年来兴起的深度学习模型。

本文重点研究如何利用作为 ICPHM 2023数据挑战赛 [13]一部分、通过试验台采集的行星齿轮箱振动数据来解决故障检测问题。振动数据由沿 x, y, z 方向测得的加速度计测量值所构成的多变量时间序列数据组成，因此该问题可以表述为一个多变量时间序列分类问题。在过去几年中，研究人员提出了多种多变量时间序列分类方法，并由此涌现出许多先进技术。这些方法包括传统的基于机器学习的方法，例如基于距离的方法和特征驱动方法，以及通过数据学习特征的深度学习方法。基于距离的方法涉及动态时间规整技术 [23, 28, 22]，其本质上是在时间轴上执行拉伸和压缩操作，以计算时间序列之间的最优对齐。特征驱动方法采用人工设计的特征提取方案，从时间序列数据中计算出一组规模较小的静态特征。随后，这些特征可用于传统分类方法。标准特征提取方法的范围涵盖基于简单汇总统计量的方法 [6, 14, 10], 、基于函数型数据分析的技术 [25, 24, 18], ，以及基于小波和形状片段的技术 [7, 26, 20, 4, 33]。在这些技术中，近年来开发的方法，例如基于变换的集成层次投票集体（HIVE-COTE） [4] 和随机卷积核变换（ROCKET） [11] ，已在各种多变量时间序列分类应用中展现出良好的应用前景。与这些传统方法相比，基于深度学习的方法能够直接从时间序列数据中学习分类任务。循环神经网络 [27]及其变体，例如长短期记忆网络（LSTM） [16], 和门控循环单元（GRU） [9] ，专门用于通过时间递归机制处理时间序列。

时间序列数据的卷积核是以滑动窗口方式应用于输入数据的滤波器。这些滤波器通常是由固定大小的数值数组组成的小型数组，与对应的输入值逐元素相乘，然后求和以生成单个输出值。卷积运算可用于提取

*表示贡献相同。

时间序列数据中的不同类型特征 [11], , 例如局部模式、趋势和周期性。根据所需特征的类型，可以使用不同类型的卷积核。ROCKET 及其变体 [12, 29] 的成功在很大程度上归功于利用卷积核提取特征。近期研究提出，采用具有一维卷积核的卷积神经网络处理时间序列数据，这主要得益于卷积神经网络架构所具有的显著计算效率优势。其中，一维残差网络（ResNet）架构和一维全卷积网络（FCN）架构在多变量时间序列数据分类 [32]任务中表现出了稳健的性能。

在进行初步数据分析后，我们确定了几种先进技术，并将其应用于最初发布的模型开发数据集。随后，我们确定了表现最好的三个模型，这些模型都具有使用卷积核这一共同特点，并开发了一种集成技术来结合这三个模型的结果。

2 数据描述

本节概述了本研究中用于生成所研究数据集的试验台配置。该试验台由驱动电机、两级行星齿轮箱、两级平行轴齿轮箱和磁力制动器组成。数据主要针对行星齿轮箱。电机由交流电驱动，并通过速度传感器控制试验台的转速，范围为 0 至 6000 转/分钟（rpm）。磁力制动器向平行轴齿轮箱的输出轴施加扭矩。在实际应用中，由于承受较大的交变应力和冲击，行星齿轮箱第二级的太阳轮轮齿容易发生损坏，从而产生四种常见的太阳轮故障：表面磨损、崩齿、裂纹和缺齿。振动信号通过美国国家仪器公司的便携式数据采集系统采集，安装在行星齿轮箱第二级上的加速度传感器由 PCB Piezotronics 公司制造。振动信号是在两种不同的运行工况下采集的：一种为电机转速 1500 转/分钟、负载 10 Nm；另一种为电机转速 2700转/分钟、负载 25 Nm。在本文中，我们将这两个数据集分别称为运行工况 1500 转/分钟和运行工况 2700转/分钟。每个振动信号均沿 x, y 和 z 方向记录，持续五分钟，采样频率为 10 kHz。随后，使用窗口大小为 200 个数据点的方法，将振动信号划分为较小的片段。

本次挑战提供的数据集包含 50000 个振动信号、对应的真实标签以及两种不同的运行工况。信号包括正常状态（类别 0）和四种不同的故障状态（裂纹 - 类别 1、表面磨损 - 类别 2、崩齿 - 类别 3、缺齿 - 类别 4）。数据中每个类别均有 10000 个样本。给定的数据不存在缺失值，且类别分布均衡。

3 探索性数据分析

在本节中，我们将进行简单的探索性数据分析，并简要讨论由此引出的下一节建模方法选择。正如第 2 节所述，本研究所用数据的各类别样本数相同，且采集频率一致，因此无需考虑类别不平衡或分布不平衡等因素。在图 1 和图 4 中，我们分别绘制了运行工况为 1500 转/分钟和 2700转/分钟时各通道数据的均值、方差和极差。根据图中结果，我们观察到，在这两种运行工况下，各通道的均值和方差总体上保持恒定，未呈现明显趋势，说明时间序列数据是平稳的。此外，我们还可以观察到，在这两种运行工况下，z-通道采集的数据极差最大，其次是 y-通道的数据，最后是 x-通道的数据，不过它们总体上仍处于相同数量级。

接下来，我们绘制各类别数据的均值，并在图 2 和图 5 中将其可视化。在两种运行工况下，我们可以观察到，各类别在每个通道中的振动均值高度重叠。最后，图 3 和图 6 分别展示了 1500 转/分钟和 2700转/分钟运行工况下数据的方差。有趣的是，在 1500 转/分钟的运行工况下，我们可以观察到，各缺陷类别的振动大多呈现出不同的方差大小。例如，在图 3 中，我们可以清楚地看到，通道 x 中与类别 0 相关的振动方差最大，其次依次为类别 1、3、4 和 2。对于在 2700转/分钟运行工况下从其他通道采集的振动数据，可以得到不同的观察结果。如图 6 所示，各类别的方差明显区分开来，但排列顺序有所不同。尽管如此，由于均值高度重叠，我们得出结论：对数据的原始特征使用简单的线性分类器，或 k 近邻算法等朴素的基于距离的算法，都无法获得具有竞争力的分类性能。因此，在下一节中，我们将探讨利用自动特征提取或特征学习来提升性能的方法。

4 建模

本节讨论几种已知的、据报道在时间序列分类方面达到最先进性能的方法，具体包括一维和二维基于卷积的方法、基于长短期记忆网络的方法，以及自动化

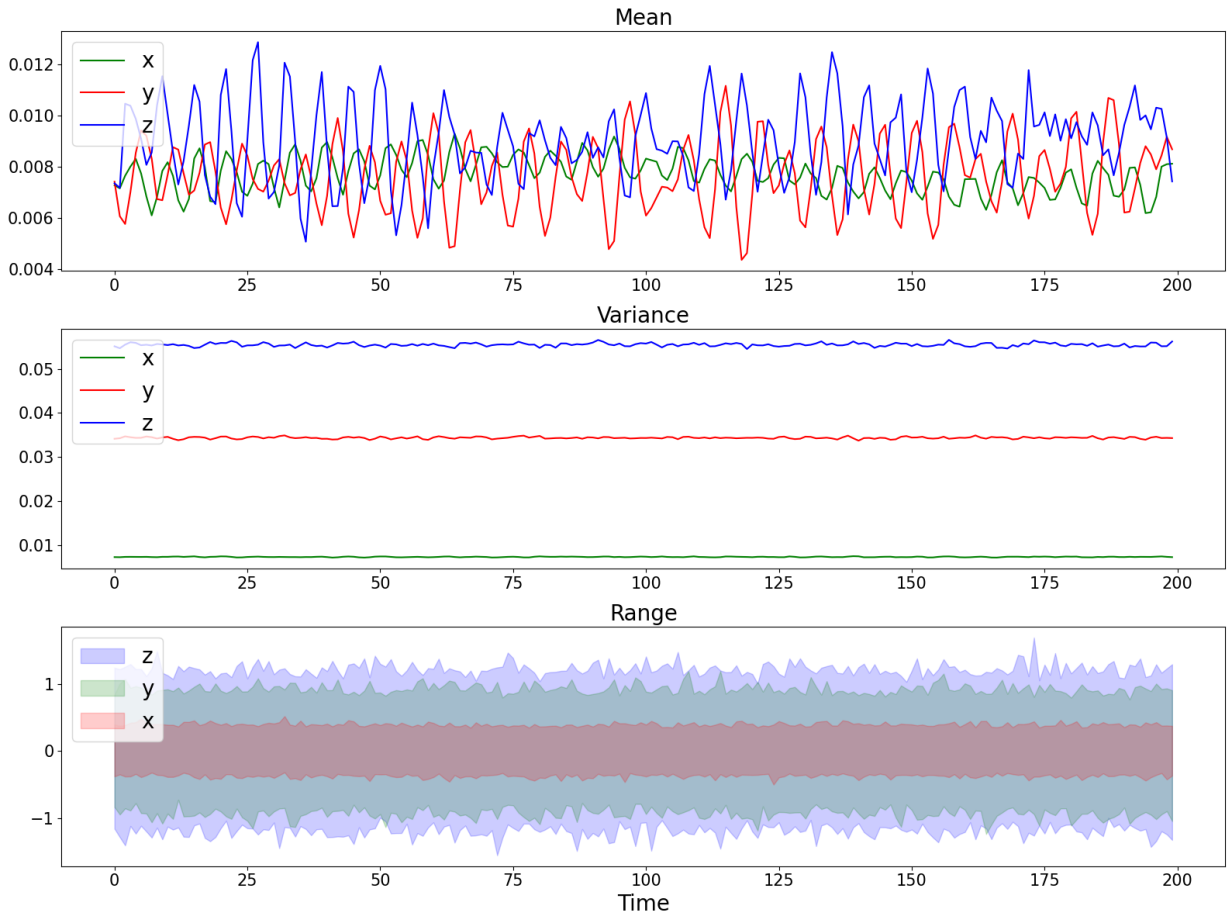


图 1：运行工况 1500 转/分钟下振动数据的均值、方差和范围。

特征提取结合传统机器学习分类器，例如随机森林、逻辑回归和K近邻，以及将上述一种或多种方法结合起来的混合方法。请注意，上述大多数方法都可以直接接收原始时间序列数据作为输入，无需对数据进行预处理以供模型使用，二维卷积方法除外。为了对时间序列数据进行预处理以用于二维卷积，我们对时间序列执行短时傅里叶变换，得到包含频率和时间信息的频谱图。随后，我们将频谱图作为图像输入二维卷积神经网络模型。此外，我们还尝试了简单的数据增强技术，例如向时间序列数据添加有界噪声，以增加训练数据点的数量。然而，对于这个振动数据集，我们发现训练数据量已经足够大，使用数据增强并未在准确率方面带来任何额外提升。

总体而言，我们发现，尽管大多数方法的分类性能普遍较好，交叉验证准确率均高于 90%，但有三种特定方法始终优于其他方法。下面我们将详细讨论这三种方法。

4.1 多尺度1D残差网络

该模型架构基于 CSI-Net [31] 的一个简化变体。该变体是作为轻量级版本开发的，用于时间序列分类。该方法的核心思想是，使用不同尺寸的一维卷积核从时间序列数据中沿时间轴提取多尺度特征，再将这些多尺度特征结合起来进行分类。

具体而言，该模型架构由一个初始共享卷积块组成，该卷积块由一维卷积、批归一化和最大池化层构成。随后，三个并行的特征提取器对该卷积块的输出进行处理。这些特征提取器各包含三个一维卷积、批归一化和 ReLU激活函数模块，并在最后一个模块之后采用残差连接和平均池化，生成一个 256 维特征向量。这些特征提取器之间唯一的区别在于一维卷积层采用了不同的卷积核尺寸，分别为 3、5 和 7。随后，将提取的特征拼接起来，形成一个 768 维特征向量，再经全连接层和 Softmax层处理以完成分类。

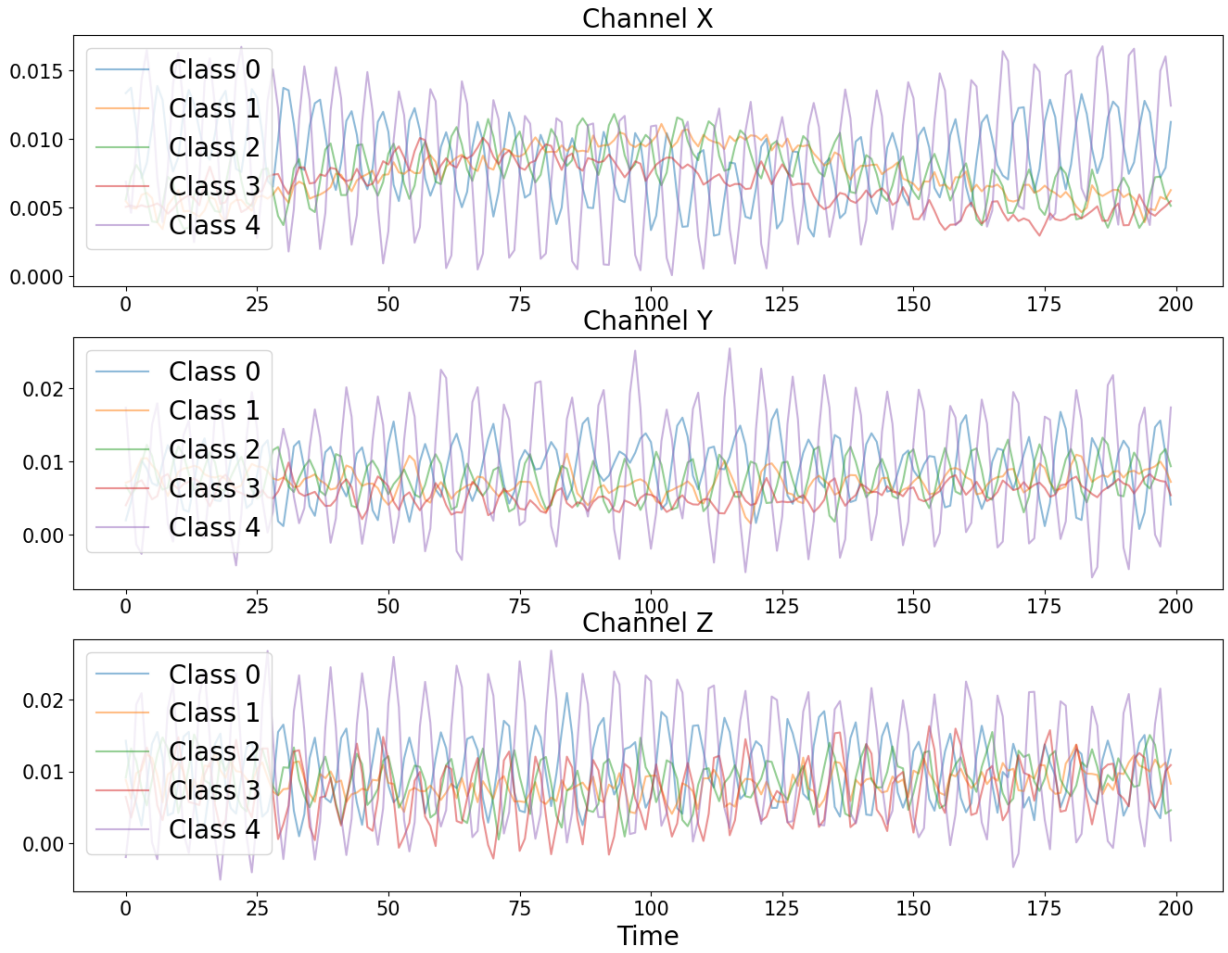


图 2：各类别的　　运行工况为 1500 转/分钟时振动数据各通道的均值　　.

为提高该实现的泛化能力，我们还在标准交叉熵损失函数中加入了三元组边界损失 [5, 8]，并在训练过程中使用学习率调度器来降低学习率。通过实验我们发现，这两项改动提高了该方法整体的验证准确率和测试准确率。

为训练该模型，我们使用线性插值将三个通道中的振动数据从 200 个点上采样至 512 个点，以匹配模型的输入维度。此外，我们还使用了 Adam 优化器，初始学习率为 0.001，并采用学习率调度器，在验证准确率趋于平稳时将学习率降低至原来的 0.1 倍。我们训练模型 100 轮，并保存验证准确率最高的模型。更多细节请参阅基于 [3] 的实现。

4.2 LSTM-FCN

长短期记忆网络是一类传统的神经网络，凭借门控函数解决梯度消失问题的能力，已被证明优于循环神经网络 [16]。LSTM 维护一个记忆向量和一个隐藏向量，用于控制每个时间步的输出和状态更新，并能够学习序列中的时间依赖关系 [15]。

对于时间序列多分类问题，采用时间卷积或一维卷积已被证明是一种有效的学习模型 [32]。全卷积网络由时间卷积和全局平均池化组成，分别用于分类前的特征提取和参数缩减 [19]。

我们采用了一种由全卷积块（见于卷积神经网络架构）构成的架构，并加入了一个长短期记忆网络块和丢弃层。全卷积块包含三个堆叠的时间卷积块（一维卷积），其滤波器尺寸分别为 128、256 和 128；每个卷积块都配有批归一化和 ReLU激活函数。最后一个卷积块之后是全局平均池化。

与此同时，时间序列输入被发送至维度重排层，该层通过将任意单变量时间序列转换为具有单个时间步的多变量时间序列来变换输入，然后将其传递至LSTM块和一个Dropout层。该输出与此前获得的全局平均池化层的输出一起，

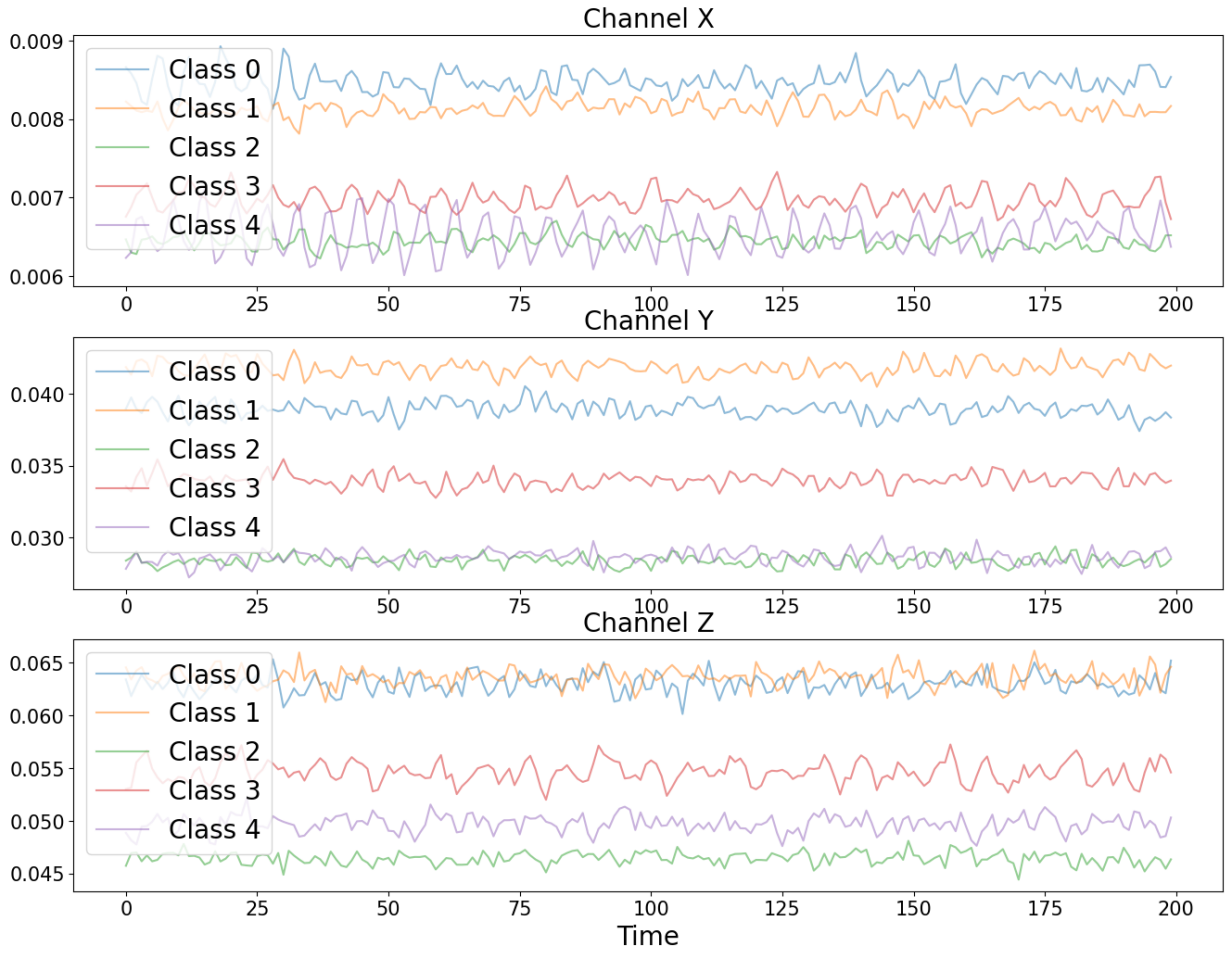


图 3：特定类别的 v　　1500 转/分钟运行工况下振动数据各通道的方差值。

进行拼接后通过 Softmax层，以完成最终分类。分类所使用的损失函数是负对数似然或交叉熵损失。

与前文讨论的多尺度 ResNet 类似，我们使用了 Adam 优化器和学习率调度器，并对模型进行了 100 训练轮次。我们发现，学习率调度器有助于稳定训练并提升整体泛化能力，尤其是在使用 1500 转/分钟运行工况数据进行训练时效果显著，因为我们观察到该数据存在较大的方差。LSTM-FCN 的实现基于 [1]。

4.3 ROCKET

ROCKET（随机卷积核变换） [11]是一种用于时间序列分类的快速有效方法。其原理是对时间序列数据应用随机卷积滤波器，然后将得到的特征输入线性分类器。这种方法基于这样的洞见：结合适当的特征工程，线性模型对于高维数据可以非常有效。

Rocket 中使用的随机卷积滤波器本质上是将时间序列数据投影到一小组固定随机向量上所得到的随机投影。随后，使用最大池化操作处理生成的特征，该操作用于识别每个特征图中的最大值，并将这些最大值拼接成一个特征向量。

事实证明，Rocket 的性能可与最先进的时间序列分类方法相媲美，同时速度显著更快、可扩展性更强。此外，它实现简单、易于解读，因为可以将生成的特征可视化并加以分析，从而深入了解时间序列数据的特性。

MiniRocket 是 Rocket 的一个配置版本 [11] ，具有近乎确定性的特点，在保持准确率相当的同时，在较大的数据集上速度快 75 倍。MiniRocket [12] 是一种快速且准确的时间序列分类特征提取技术。事实证明，在多个基准时间序列数据集上，MiniRocket 的表现优于最先进的方法，同时也比傅里叶变换和小波等传统特征提取技术快得多。此外，MiniRocket 易于并行化，也能够扩展至大型数据集。

与 ROCKET 相比，MiniRocket 使用一组固定的卷积核，超参数更少。这减少了核选项的数量，并在保持准确率的同时最大限度地提高计算效率。不同于

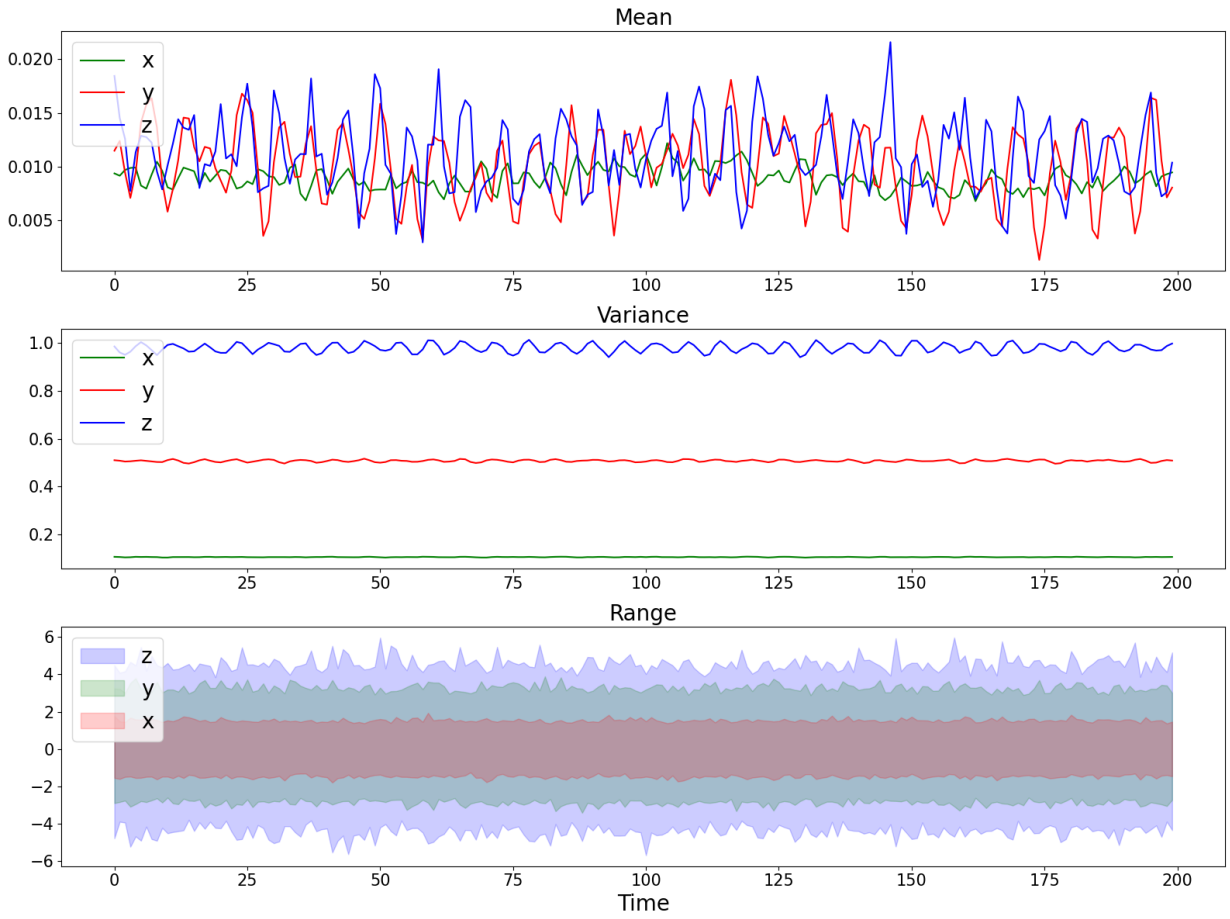


图 4：运行工况为 2700转/分钟时振动数据的均值、方差和范围。

ROCKET、MiniRocket 仅使用长度为 9 的卷积核，并将权重值限制为 -1 或 2，采用一组规模较小且固定的 84 个卷积核，这些卷积核几乎完全具有确定性。MiniRocket 还将每个卷积核的最大膨胀率数量限制为 32，以保持计算效率。MiniRocket 唯一的随机组成部分是偏置值，该值是从一个随机训练样本的卷积输出分位数中抽取的。

我们使用 sktime [21] 上提供的模块实现 MiniRocket [2] 。它用于生成约 10000 个特征，然后我们使用岭分类器进行多分类。

方法	折 1	折叠 2	折叠 3	第 4 折	第 5 折	平均准确率	平均训练时间（秒）
多尺度一维残差网络	98.50	98.56	98.59	98.44	98.51	98.520 ± 0.058	799
LSTM-FCN	98.03	97.24	97.05	96.36	97.74	97.284 ± 0.579	524
MiniRocket	97.95	97.54	97.61	97.89	97.48	97.694 ± 0.212	542
集成（平均）	98.97	98.78	98.84	98.74	98.99	**98.864 ± 0.112**	-
集成（最大值）	98.88	98.72	98.88	98.73	99.05	98.852 ± 0.135	-

表1：运行工况为 1500 转/分钟时的五折交叉验证结果。总体准确率最佳的方法以粗体突出显示。

4.4 集成

集成方法通常用于提高分类结果。两种常见方法是取平均概率值或最大概率值进行分类。通过结合多个模型的输出，我们可以利用每个模型所学习到的不同方面。在本例中，我们使用三个不同的模型，并希望通过集成利用它们各自的独特优势。最终，这种方法可以提高准确率，并提供更加稳健的预测。

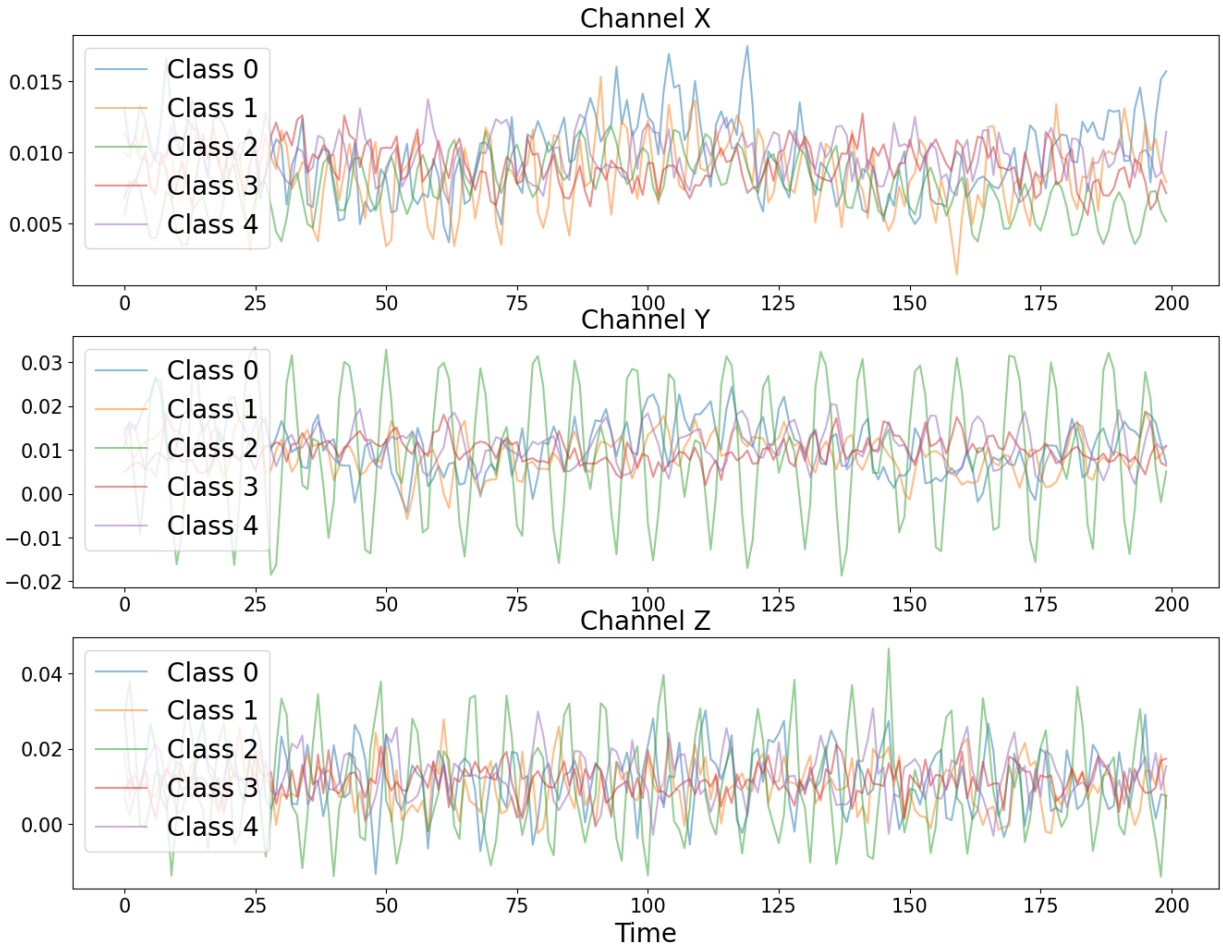


图5：类别特异性　　运行工况为 2700转/分钟时振动数据各通道的 fic 均值　　.

方法	第 1 折	第 2 折	第 3 折	第 4 折	第 5 折	平均准确率	平均训练时间（秒）
多尺度一维 ResNet	98.39	98.41	98.44	98.43	98.39	98.412 ± 0.023	796
LSTM-FCN	99.05	98.88	98.80	98.82	98.94	98.890 ± 0.090	522
MiniRocket	97.31	97.59	97.52	97.50	97.55	97.494 ± 0.108	559
集成（平均）	99.01	98.86	98.84	98.74	98.99	**98.968 ± 0.064**	-
集成（最大值）	98.91	98.86	98.95	99.02	99.01	98.950 ± 0.067	-

表2：运行工况为2700转/分钟时的五折交叉验证结果。总体准确率最高的方法以粗体突出显示。

我们的整体方法总结于图7中。我们将来自全部三个通道的振动数据输入上述三个独立模型，并相应地执行所需的预处理和模型训练。我们不使用单个模型的输出进行分类，而是获取每个模型的预测类别概率，并将它们结合起来进行最终分类：要么直接取最大类别概率，要么对类别概率求平均后取最大平均概率。

5 结果

5.1 准确率比较

我们在振动数据上进行了五折交叉验证实验，以评估各个单独方法和我们提出的集成方法的性能。对于每一折，我们报告了各方法的准确率，以及总体平均准确率和标准差。为了将数据划分为各折，我们按 70/10/20 的比例进行划分，

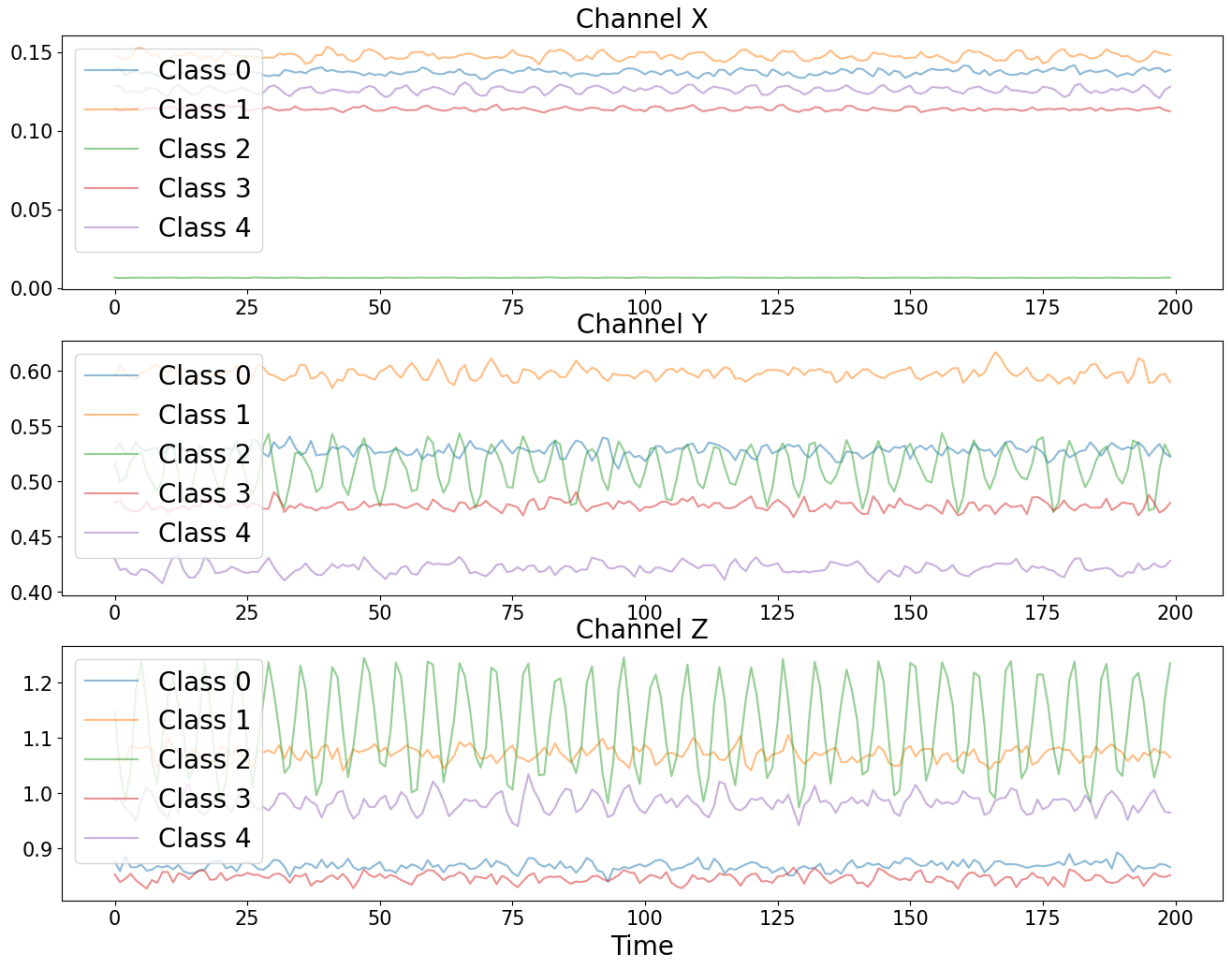


图 6：特定类别的 v　　运行工况为 2700转/分钟时振动数据各通道的方差值。

分别对应训练数据、验证数据和测试数据。

在表1中，我们列出了运行工况为1500 转/分钟的数据实验测试得分。比较各单独方法（多尺度一维 ResNet、LSTM-FCN 和 MiniRocket）后，我们发现，多尺度一维 ResNet 的平均表现最佳，且在五个随机折中的标准差最低，其次是 MiniRocket 和 LSTM-FCN。尽管 LSTM-FCN 和 MiniRocket 的表现略低于多尺度一维 ResNet，但当我们对这三种方法进行集成时，仍然观察到了性能提升。通过平均操作和最大值操作进行集成后，总体准确率分别达到98.86和98.85。同样，表2展示了运行工况为2700转/分钟的数据实验测试得分。比较该数据集上的各单独方法后，我们发现，LSTM-FCN 在五个随机折中的平均表现最佳，其次是多尺度一维 ResNet 和 MiniRocket，而在所有方法中，多尺度一维 ResNet 的标准差表现最佳。对这些方法进行集成也取得了类似的性能提升，采用平均操作和最大值操作进行集成后的总体准确率分别达到98.96和98.95。我们还使用另一个采用不同随机种子划分的独立五折数据集，重复了表1和表2中的实验，并观察到了相似的结果，即五种方法的排序基本一致。基于这些结果，我们得出结论：在该数据集的背景下，通过取平均值对这三种方法进行集成，可以在准确率方面取得最佳性能。

5.2 训练时间比较

我们还想指出，根据表1和表2的最后一列，与 LSTM-FCN 和 MiniRocket 相比，多尺度一维 ResNet 的训练时间约长 300 秒。需要注意的是，集成方法没有记录时间，因为计算平均概率或最大概率所需的时间可以忽略不计；而使用集成模型的代价仅仅是三个独立模型训练时间的总和。在我们的实验中，两种基于深度学习的方法——多尺度一维 ResNet 和 LSTM-FCN——均在一台配备六核英特尔中央处理器和 12 GB 显存 NVIDIA TITAN Xp 图形处理器的工作站上运行。相比之下，MiniRocket 实验是在八核 M2 中央处理器上进行的，因为它无法从图形处理器加速中获益。因此，从终端用户的角度来看，

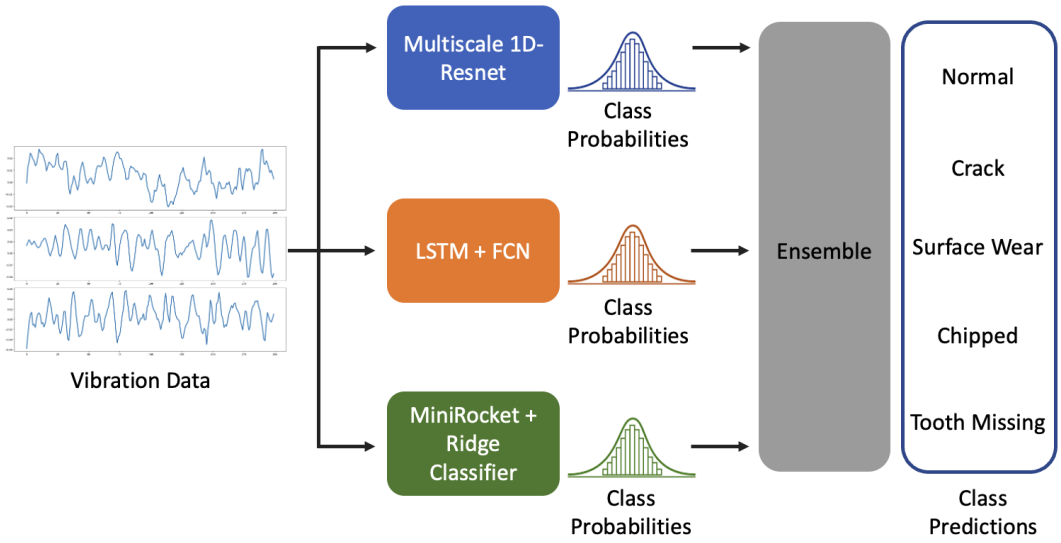


图7：我们方法的概览：通过集成策略，将两种深度学习方法与一种自动特征提取方法及岭分类器相结合，最终完成缺陷分类。

如果准确率非常重要且拥有充足的计算资源，那么采用集成方法便能获得较高的准确率。另一方面，如果计算资源受限，使用 MiniRocket 也能取得具有竞争力的分类性能。

5.3 补充分析与讨论

本节通过五折交叉验证的混淆矩阵（横轴显示真实标签，纵轴显示预测结果），进一步分析并比较集成策略的性能。从图8可以看出，在1500 转/分钟的运行工况下，我们的集成方法几乎能完美地将崩角类别（类别3）分类，因为没有其他类别被预测为崩角；而裂纹类别（类别1）似乎是最难分类的类别。有趣的是，在2700转/分钟的运行工况下，我们的集成方法几乎能完美地识别表面磨损类别（类别2），因为没有其他类别被预测为表面磨损；对于其他类别，该方法的表现也相近，如图9所示。未来可以利用这些发现，设计更好的损失函数或数据增强策略，以提高该方法的准确率。

6 结论

总之，我们提出的基于振动信号进行故障检测的方法取得了良好的效果。我们采用了三种不同的模型，即多尺度一维 ResNet、LSTM-FCN 和 MiniRocket，并且每种模型单独使用时都表现出色。然而，采用取平均概率最大值的集成（平均）方法，进一步提高了准确率。值得注意的是，每种模型都有其自身的优势。它们以不同的方式使用卷积核，从时间序列数据中提取信息，而集成方法使我们能够充分利用每种模型所学习到的不同特征。在未来的工作中，我们计划向集成模型中添加更多模型，针对训练数据不易获取的应用场景引入少样本学习技术，探索函数式方法，并进一步利用领域知识来提高我们方法的准确率。另一项研究方向是优化此类模型并降低其计算复杂度，使其能够轻松部署在边缘设备上。这通常是设备预测与健康管理应用中的一项重要要求。

参考文献

[1] Lstm-fcn-pytorch. https://github.com/roytalman/LSTM-FCN-Pytorch. 访问日期：2023年3月29日。[2] Minirocket. https://github.com/angus924/minirocket. 访问日期：2023年3月29日。[3] Multi-scale-1d-resnet. https://github.com/geekfeiw/Multi-Scale-1D-ResNet. 访问日期：2023年3月29日。

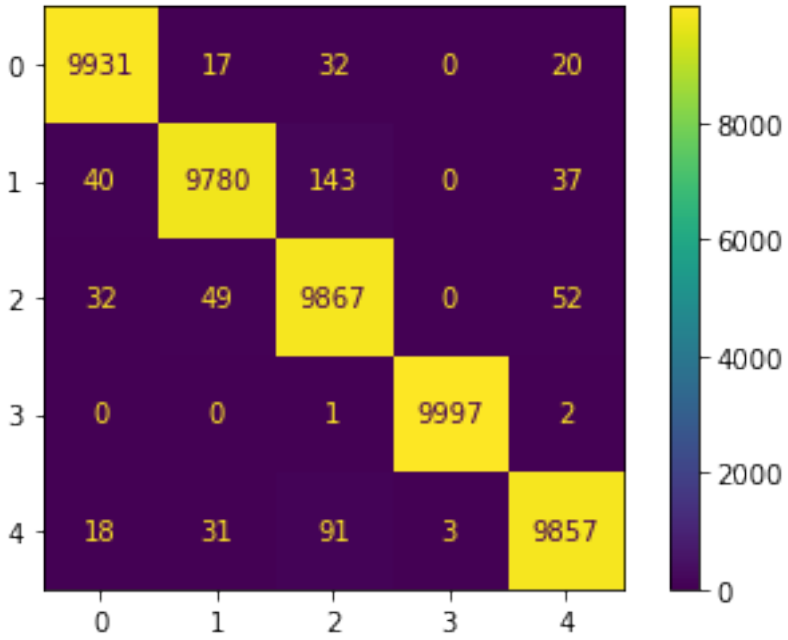


图 8：集成（平均）方法在运行工况 1500 转/分钟下的混淆矩阵

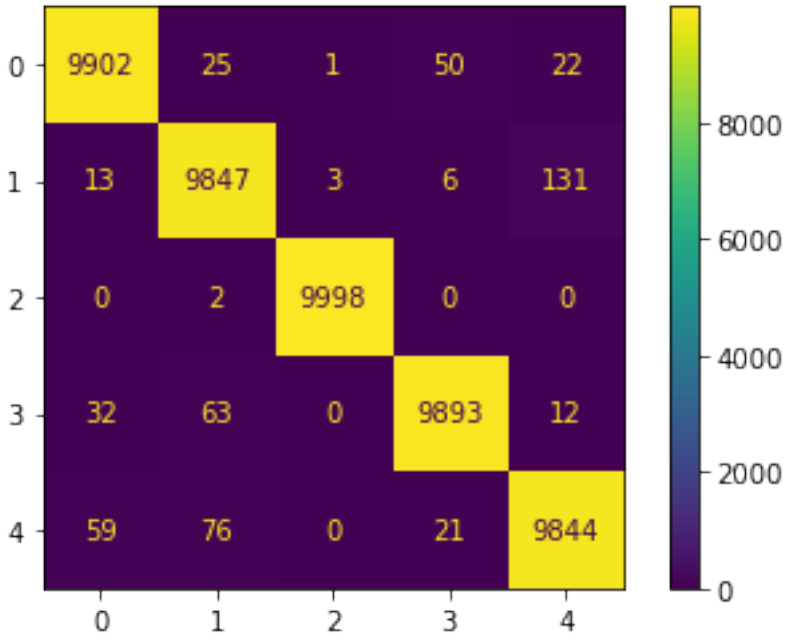


图 9　　：集成（平均）方法在运行工况 2700转/分钟下的混淆矩阵

[4] Anthony Bagnall、Michael Flynn、James Large、Jason Lines 和 Matthew Middlehurst。关于基于变换的集成层次投票集体 1.0 版（HIVE-COTE v1. 0）的使用与性能。在 *Advanced Analytics and Learning on Temporal Data: 5th ECML PKDD Workshop, AALTD 2020, Ghent,Belgium September 18 2020 Revised Selected Papers 6* 3 18 2020 ,,, 中，第 – 页。施普林格，。

[5] Vassileios Balntas、Edgar Riba、Daniel Ponsa 和 Krystian Mikolajczyk。利用三元组和浅层卷积神经网络学习局部特征描述符。载于 *Bmvc*，第 1 卷，第 3 页，2016 年。[6] Mar´ılia Barandas、Duarte Folgado、Let´ícia Fernandes、Sara Santos、Mariana Abreu、Patr´ícia Bota、Hui Liu、Tanja Schultz 和 Hugo Gamboa。TSFEL：时间序列特征提取库。 *SoftwareX*，11:100456，2020 年。[7] Pimwadee Chaovalit、Aryya Gangopadhyay、George Karabatis 和 Zhiyuan Chen。基于离散小波变换的时间序列分析与挖掘。 *ACM Computing Surveys (CSUR)*，43(2):1–37，2011 年。

[8] Gal Chechik、Varun Sharma、Uri Shalit 和 Samy Bengio。通过排序进行图像相似性的大规模在线学习。 *Journal of Machine Learning Research*，11(3)，2010。[9] Kyunghyun Cho、Bart Van Merri¨enboer、Caglar Gulcehre、Dzmitry Bahdanau、Fethi Bougares、Holger Schwenk 和 Yoshua Bengio。使用 RNN 编码器-解码器学习用于统计机器翻译的短语表示。 *arXiv preprint arXiv:1406.1078*，2014。[10] Maximilian Christ、Nils Braun、Julius Neuffer 和 Andreas W Kempa-Liehr。基于可扩展假设检验的时间序列特征提取（tsfresh——一个 Python 包）。 *Neurocomputing*，307:72–77，2018。[11] Angus Dempster、Fran˛cois Petitjean 和 Geoffrey I Webb。Rocket：使用随机卷积核实现极快且准确的时间序列分类。 *Data Mining and Knowledge Discovery*，34(5):1454–1495，2020。[12] Angus Dempster、Daniel F. Schmidt 和 Geoffrey I. Webb。MiniRocket。载于 *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining* 2021 。

ACM，8 月。[13] N. Enshaei、H. Chen、F. Naderkhani、J. Lin、S. Shahsafi、S. Giliyana、M. Mirzaei、S. Li、C. Hansen 和 J. Rupe。适用于系统健康监测机器学习的 ICPHM'

23 *IEEE* 基准 *Conference on Prognostics and Health Management (ICPHM) 2023.* 2023 振动数据集。载于 , , 。[14] Ben D Fulcher。基于特征的时间序列分析。 *arXiv preprint arXiv:1709.08055*，2017。[15] Alex Graves 和 Alex Graves。 *Supervised sequence labelling*。施普林格，2012。[16] Sepp Hochreiter 和 J¨ urgen Schmidhuber。长短期记忆。 *Neural computation*，9(8):1735–1780，1997。[17] Yang Hu、Xuewen Miao、Yong Si、Ershun Pan 和 Enrico Zio。预测与健康管理：从设计、开发和决策角度进行的综述。 *Reliability Engineering & System Safety* 217 108063, , : 。 2022 [18] Piotr Kokoszka 和 Matthew Reimherr。 *Introduction to Functional Data Analysis*。2017 年 9 月。[19] Min Lin、Qiang Chen 和 Shuicheng Yan。网络中的网络。 *arXiv preprint arXiv:1312.4400*，2013。[20] Jason Lines、Luke M Davis、Jon Hills 和 Anthony Bagnall。用于时间序列分类的形状片段变换。载于 *Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining*，第 289–297 页，2012。[21] Markus L¨oning、Franz Kir´aly、Tony Bagnall、Matthew Middlehurst、Sajaysurya Ganesh、George Oastler、Jason Lines、Martin Walter、ViktorKaz、Lukasz Mentel、chrisholder、Leonidas Tsaprounis、RNKuhns、Mirae Parker、Taiwo Owoseni、Patrick Rockenschaub、danbartl、jesellier、eenticott shell、Ciaran Gilbert、Guzal Bulatova、Lovkush、Patrick Sch¨afer、Stanislav Khrapov、Katie Buchhorn、Kejsi Take、Shivansh Subramanian、Svea Marie Meyer、AidenRushbrooke 和 Beth rice。sktime/sktime：v0.13.4，2022 年 9 月。[22] Jiangyuan Mei、Meizhu Liu、Yuan-Fang Wang 和 Huijun Gao。为多变量时间序列分类学习基于马氏距离的动态时间规整度量。 *IEEE transactions on Cybernetics*，46(6):1363–1374，2015。[23] Meinard M¨uller。动态时间规整。 *Information retrieval for music and motion*，第 69–84 页，2007。[24] Aniruddha Rajendra Rao 和 Matthew Reimherr。使用神经网络进行非线性函数建模。 *Journal of Computational and Graphical Statistics* 0 0 1 10, 2023 ，( ): – 。[25] Aniruddha Rajendra Rao 、 Haiyan Wang 和 Chetan Gupta。用于时间序列双向降维的函数方法。载于 *2022 IEEE International Conference on Big Data (Big Data)* 1099 1106, ，第 2022 – 页。[26] Manel Rhif 、 Ali Ben Abbes 、 Imed Riadh Farah 、 Beatriz Mart´ınez 和 Yanfang Sang。小波变换在非平稳时间序列分析中的应用：综述。 *Applied Sciences*，9(7):1345，2019。[27] Mike Schuster 和 Kuldip K Paliwal。双向循环神经网络。 *IEEE transactions on Signal Processing* 45 11 2673 2681, 1997 ，( ): – 。[28] Mohammad Shokoohi-Yekta 、 Bing Hu 、 Hongxia Jin 、 Jun Wang 和 Eamonn Keogh。将 DTW 推广到多维情形需要采用自适应方法。 *Data mining and knowledge discovery*，31:1–31，2017。[29] Chang Wei Tan、Angus Dempster、C. Bergmeir 和 Geoffrey I. Webb。MultiRocket：用于时间序列分类中卷积输出的有效汇总统计量。 *ArXiv*，abs/2102.00457，2021。[30] Kwok-Leung Tsui、Nan Chen、Qiang Zhou、Yizhen Hai 和 Wenbin Wang。预测与健康管理：数据驱动方法综述。 *Mathematical Problems in Engineering*，2015:1–17，2015 年 5 月。[31] Fei Wang、Jinsong Han、Shiyuan Zhang、Xu He 和 Dong Huang。CSI-Net：统一的身体表征与动作识别。 *arXiv preprint arXiv:1810.03064*，2018。[32] Zhiguang Wang、Weizhong Yan 和 Tim Oates。使用深度神经网络从头开始进行时间序列分类：一个强大的基线。载于 *2017 International joint conference on neural networks (IJCNN)*，第 1578–1585 页。IEEE，2017。[33] Lexiang Ye 和 Eamonn Keogh。时间序列形状片段：一种支持准确、可解释且快速分类的新技术。 *Data mining and knowledge discovery*，22:149–182，2011。