

最大化互信息约束的 R-NLN 高频工件图像分类模型

许知建, 欧阳, 李毅, 李柏林, 熊鹰
(西南交通大学 机械工程学院, 四川 成都 610031)

摘要: 高频元件精密加工工件需要定制, 难以获取足量的图像样本以训练传统的 CNN 模型来完成自动化分类。提出基于元学习训练策略的关联非局部网络高频工件分类模型。在经典 CNN 模型的基础上引入 NLN 模块, 通过关联样本的全局和局部特征提取自适应的任务特征; 通过最大化互信息约束优化模型, 提高模型的鲁棒性。实验结果表明: 与多种主流的小样本分类模型相比, 所提模型对 miniImageNet 和高频工件数据集分类的准确率有显著提高。

关键词: 高频工件; 元学习; 非局部网络; 互信息约束; 图像分类

中图分类号: TP391.41 文献标志码: A 文章编号: 1671-5276(2023)06-0089-05

R-NLN High-frequency Components Image Classification Model with Maximum Mutual Information Constraints

XU Zhijian, OU Yang, LI Yi, LI Bailin, XIONG Ying

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: High-frequency precise machining components need to be customized, which leads to the difficulty in obtaining enough image samples to train traditional CNN models for the realization of automatic classification. This paper proposes a related non-local network high-frequency components classification model based on a meta-learning training strategy. A NLN module is introduced based on the classical CNN model to extract adaptive task features by correlating global and local features of samples. The model is optimized by maximizing mutual information constraints to improve the robustness of the model. The experimental results show that the proposed model significantly improves the classification accuracy on miniImageNet and high-frequency precise components datasets compared with various mainstream few-shot learning classification models.

Keywords: high-frequency component; meta-learning; non-local network; mutual information constraints; image classification

0 引言

现代工业生产中, 通常采用基于零件的表面图像进行零件分类^[1]。在卷积神经网络(convolutional neural network, CNN)^[2]提出之前, 常用人工设计的图像特征, 如尺度不变特征变换 SIFT^[3]、方向梯度直方图 HOG^[4]、模板匹配^[5]等完成零件的分类。但人为定义的特征, 对于不同种类零件的泛化性较差。近年来, 随着数据量的爆炸式增加和计算机硬件性能的飞速发展, 基于 CNN 的深度学习模型在图像分类领域取得了重要的地位。但当样本数量较少时, CNN 无法将训练集的数据合理泛化到测试集。基于此, 研究者提出了小样本学习(few-shot learning, FSL)^[6]。而高频元件精密加工工件(简称为高频工件)因其需定制而产量极低, 是该问题下典型的工程应用对象。

为使小样本模型能够有效提取图像特征, VILALTA 等^[7]提出了基于元学习的模型, 在识别新类之前, 只训练模型提取特征的能力, 这类模型被称为特征提取器。为使模型在提取特征后具有分析特征的能力, 研究者提出了基于度量的分类算法^[8], 在特征提取器之后设置一个度量

器(measurer), 在统一的特征空间中比较支持集(support set)样本特征和查询集(query set)样本特征之间的距离, 最后输出类别概率分布以完成分类。

文献[9]的实验结果表明, 对于自然图像的分类, 传统小样本模型分类效果次于传统 CNN 模型。2018 年, WANG 等^[10]提出了非局部网络(non-local network, NLN), 通过非局部操作提取图像的全局特征, 该网络被广泛应用于小样本目标识别和分类领域。YUE 等^[11]将 NLN 应用于细粒度目标识别和视频分类, 取得了良好的效果。LIU 等^[12]提出使用 NLN 进行图像恢复, 将 NLN 嵌入到循环神经网络(recurrent neural network, RNN), 在训练集更小的情况下取得了较好的性能。黄立勤等^[13]提出一种 NLN 模块结合非局部卷积神经网络和图卷积网络, 应用于肺动静脉的自动分离。然而, NLN 只完成了由全局到局部的全局提取部分, 并且高频工件图像还存在类间差异小、全局噪声大的特点, 所以要求模型不仅可以提取任务特征, 还具备较好的鲁棒性。

因此, 本文提出一种基于最大化互信息(mutual information, MI)约束的关联非局部网络(related non-local network, R-NLN)高频工件分类模型。R-NLN 将查询(支

基金项目: 四川省重大科技专项(18ZDZX0140)

第一作者简介: 许知建(1995—), 男, 四川南充人, 硕士研究生, 研究方向为机器视觉、深度学习, xuzhijian_ben@foxmail.com。

持)样本的全局特征和局部特征(local feature),通过 NLN 进行交叉关联以获得适应于查询任务的任务特征;又通过在损失函数中加入互信息熵正则项,最大化约束任务特征和局部特征之间的互信息。本文的主要贡献有:

1)提出了一种基于关联特征的 R-NLN 特征提取器,完成对工件表面图像自适应任务特征的提取;

2)提出了一种将最大化互信息作为约束条件的损失函数,提高了模型的鲁棒性。

1 模型结构和相关理论

1.1 R-NLN 总体结构

R-NLN 是元学习训练策略下基于度量的一种网络模型,主干结构由特征提取器 ξ 和度量器 Ω 组成,特征提取器 ξ 由基础特征提取器 ξ_1 和任务特征提取器 ξ_2 组成,如图 1 所示。 ξ_1 是 CNN 的一组卷积核 $K_1 = \{a_i | a \in \mathbf{R}^{n \times n \times c}, i > 0\}$ 提取基类的特征,再通过叠加非线性激活层

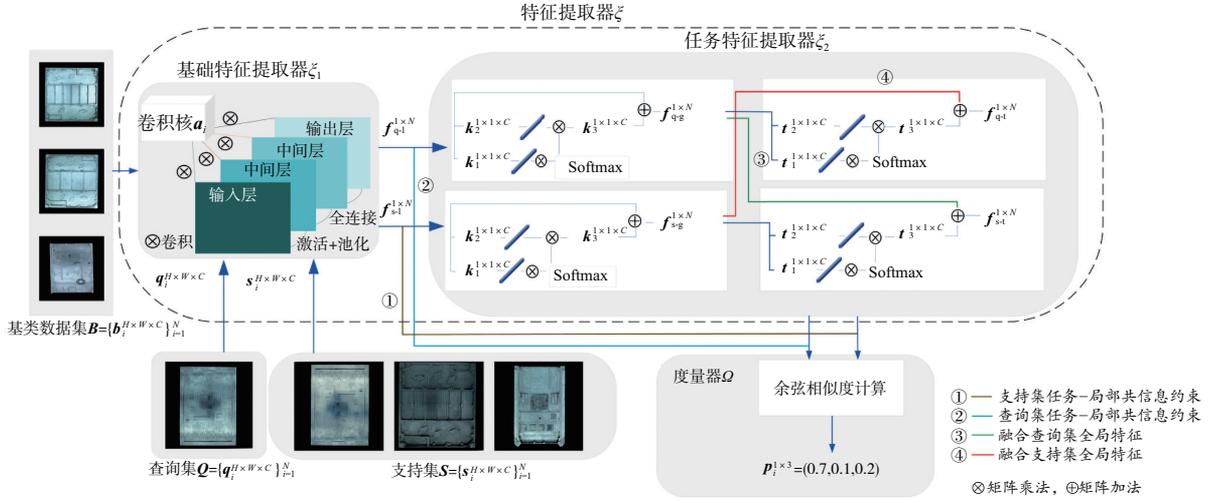


图 1 R-NLN 总体结构

1.2 基于 NLN 的任务特征提取器 ξ_2

ξ_2 采用了 NLN 作为模型的嵌入单元来提取图像的任务特征。传统卷积核普遍选用 3×3 或 5×5 的规格,通过遍历样本上的所有区域以提取该区域的特征。这类卷积核可有效降低样本的维度,减少模型权重的参数规模,从而保证训练的可行性。但是由于自身只能提取局部区域的特征,忽略了远距离像素点之间的关系,所以难以提取全局特征,因此把这样的网络称为局部网络。

与局部网络相反,非局部网络的特点是不受卷积核规格的限制,采用了非局部单元(non-local block)扩大特征参考的区域。非局部单元的特征提取如下式所示:

$$y_i = \frac{1}{\Theta(\mathbf{x})} \sum_j f(\mathbf{x}_i, \mathbf{x}_j) g(\mathbf{x}_j) + \mathbf{x}_i \quad (1)$$

式中:向量 \mathbf{x} 是指输入的图像特征; i 和 j 分别是特征上的 i 位置和 j 位置; y_i 是在 i 位置上的全局特征值; \mathbf{x}_i 是在 i 位置的原始特征值; \mathbf{x}_j 是在 j 位置的原始特征值; $f(\mathbf{x}_i, \mathbf{x}_j)$ 是计算图像上 i 位置和 j 位置的关联度的线性函数; $g(\mathbf{x}_j)$ 是将 j 位置的原始特征值线性映射为全局特征值的函数;

(activation layer)、池化层(pooling layer)提取样本局部特征 $f_i^{1 \times N}$,并对损失函数进行梯度下降完成对 K_1 权重的训练。 ξ_1 以查询集 $Q = \{q_i^{H \times W \times C}\}_{i=1}^N$,支持集 $S = \{s_i^{H \times W \times C}\}_{i=1}^N$ 为输入,通过 ξ_1 输出样本对应的查询和支持样本局部特征向量 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 。 ξ_2 是由两级 NLN 组成,第一级以向量 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 为输入,通过一组非局部卷积核 $K_2 = \{k_i | k \in \mathbf{R}^{1 \times 1 \times c}, i = 1, 2, 3\}$ 遍历输入向量以提取查询样本和支持样本的全局特征向量 $f_{q-g}^{1 \times N}$ 和 $f_{s-g}^{1 \times N}$ 。第二级 NLN 通过非局部卷积核 $K_3 = \{t_i | t \in \mathbf{R}^{1 \times 1 \times c}, i = 1, 2, 3\}$ 将 $f_{q-g}^{1 \times N}$ 和 $f_{s-g}^{1 \times N}$ 进行交叉融合,最后输出任务特征向量 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 。

度量器 Ω 采用余弦相似度对比函数,遍历所有的支持样本,通过 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 的余弦向量夹角进行相似度计算。训练过程中,度量器将对基于 $f_{q-1}^{1 \times N}$ 与 $f_{s-1}^{1 \times N}$ 以及 $f_{s-1}^{1 \times N}$ 与 $f_{q-1}^{1 \times N}$ 之间的互信息约束的损失函数进行梯度下降,以更新 ξ_2 中 K_2 和 K_3 的权重,最后针对每个查询样本 $q_i^{H \times W \times C}$ 输出预测概率向量 $p_i^{1 \times N}$ 。

$\Theta(\mathbf{x})$ 作为归一化函数将输入映射到统一的特征空间。

总的来说,非局部单元以特征向量 \mathbf{x} 为输入,通过提取图像上每个位置与任一固定位置原始特征值关联程度的加权和,来提取全局特征向量 $f_g^{1 \times N}$ 。

在任务特征提取器 ξ_2 中,使用了两组非局部单元来提取任务特征。第一组非局部单元是全局特征提取单元,如图 2 所示。在使用模型实现运算的过程中,图中的 $k_1^{1 \times 1 \times c}$ 和 $k_2^{1 \times 1 \times c}$ 通过卷积操作计算了局部特征所有位置之间的相关性, $k_3^{1 \times 1 \times c}$ 完成了所有位置的特征值映射。该组非局部单元并行使用了基础特征提取器 ξ_1 的输出 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$,同时从查询样本和支持样本的局部特征中提取全局特征 $f_{q-g}^{1 \times N}$ 和 $f_{s-g}^{1 \times N}$ 。第二组非局部单元是任务特征提取单元,也是完成特征“关联”的关键单元。查询集和支持集的任务特征 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 定义分别如下:

$$f_{s-1}^i = \frac{1}{\Theta(\mathbf{x})} \sum_j f(f_{s-g}^i, f_{s-g}^j) g(f_{s-g}^j) + f_{q-1}^i \quad (2)$$

$$f_{q-1}^i = \frac{1}{\Theta(\mathbf{x})} \sum_j f(f_{q-g}^i, f_{q-g}^j) g(f_{q-g}^j) + f_{s-1}^i \quad (3)$$

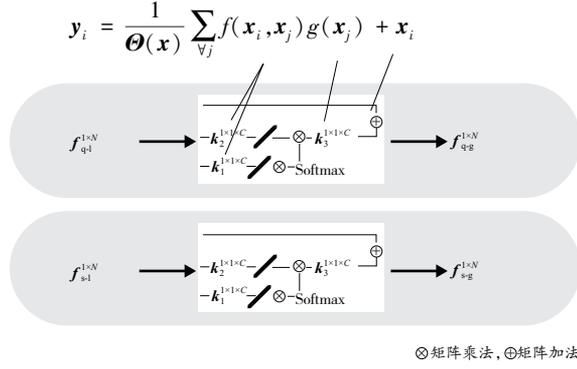


图2 全局特征提取单元

由式(2)和式(3)可得,非局部单元是基于局部特征和全局特征的加权和来提取任务特征。其中 $f_{q-1}^{1 \times N}$ 是基于 $f_{s-1}^{1 \times N}$ 和 $f_{q-g}^{1 \times N}$ 的加权和来提取,而 $f_{s-1}^{1 \times N}$ 则对称地基于 $f_{q-1}^{1 \times N}$ 和 $f_{s-g}^{1 \times N}$ 的加权和来提取。如图3所示,在使用任务特征提取单元实现特征提取的过程中,图中的 $t_1^{1 \times 1 \times C}$ 和 $t_2^{1 \times 1 \times C}$ 通过卷积操作计算了全局特征所有位置之间的相关性, $t_3^{1 \times 1 \times C}$ 完成了所有位置的特征值线性映射。这种交叉式的关联通过将全局特征和局部特征融合得到任务特征。

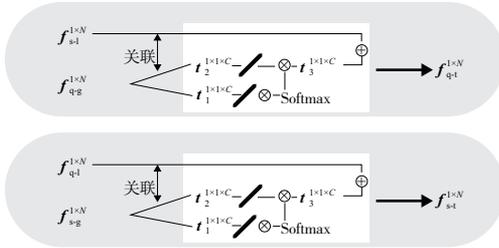


图3 任务特征提取单元

1.3 基于余弦相似度的度量器 Ω

特征之间的相似度通常使用特征向量之间的相对度量距离来表示。R-NLN 通过将 $f_{q-1}^{1 \times N}$ 和 $f_{s-1}^{1 \times N}$ 进行余弦相似度计算以输出类别的分布概率。对于两个 n 维向量 \mathbf{A} 和 \mathbf{B} , 它们之间的相似度定义为

$$s(\mathbf{A}, \mathbf{B}) = \cos\alpha = \frac{\langle \mathbf{A}, \mathbf{B} \rangle}{\|\mathbf{A}\|_{l_2} \|\mathbf{B}\|_{l_2}} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (4)$$

式中: s 是相似度函数 similarity; i 代表向量的第 i 维。

对于图像特征,余弦相似度对于特征向量之间的度量更倾向于相对距离而非绝对距离,这有利于消除由于各种测量因素而造成的绝对误差。任务特征之间的距离 \hat{y} 定义如下:

$$\hat{y}_{i,j} = d(f_{q-1}^i, f_{s-1}^j) = 1 - \frac{\langle f_{q-1}^i, f_{s-1}^j \rangle}{\|f_{q-1}^i\|_{l_2} \|f_{s-1}^j\|_{l_2}} \quad (5)$$

式中 i 和 j 分别表示第 i 和第 j 个样本; d 为余弦距离函数。

对于第 i 个查询样本的 f_{q-1}^i ,将其与所有的支持样本

$f_{s-1}^{j=0,1,\dots,n}$ 进行度量,最后基于多分类问题常用的 Softmax 函数,按式(6)输出查询样本 i 的分类概率分布:

$$p_i^{1 \times j} = 1 - \text{Softmax}(\hat{y}_{i,j}) = 1 - \frac{e^{\hat{y}_{i,j}}}{\sum_{j=1}^n e^{\hat{y}_{i,j}}} \quad (6)$$

1.4 基于最大化互信息约束的损失函数

在 ξ_2 提取任务特征的过程中,会受到遍布于高频工件表面的全局噪声干扰,又由于样本数量稀少,模型在训练后期极有可能对噪声信号产生过拟合。但是 ξ_1 提取的局部特征都是低维度特征,受到干扰的幅度较小,所以考虑在损失函数中利用局部特征抗干扰性较好的特点构建相关正则项,以约束模型在训练时参考局部特征和任务特征之间的互信息,从而预防模型对噪声产生过拟合,提高R-NLN模型的鲁棒性。本文采用交叉熵损失函数:

$$l_{c-e} = -[y \log(\hat{y}) + (1-y) \log(1-\hat{y})] \quad (7)$$

式中: \hat{y} 代表样本标签类别的预测概率; y 代表该样本的真实标签。

基于信息熵理论,互信息被定义为:对于两个随机变量 X 和 Y ,如果其联合分布为 $p(x,y)$,边缘分布为 $p(x)$ 和 $p(y)$,则 X 和 Y 的互信息分布 $I(X;Y)$ 为

$$I(X;Y) = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log \frac{p(x,y)}{p(x)p(y)} \quad (8)$$

在R-NLN中,需要最大化局部特征向量 f_i 和任务特征向量 f_i 的互信息,由于信息熵是对一个随机变量不确定性的度量,所以使用信息熵来度量互信息的大小。对于一个离散型的随机变量 $X \sim p(x)$,信息熵被定义为

$$H(X) = - \sum_{x \in X} p(x) \log p(x) = E \left[\log \frac{1}{p(X)} \right] \quad (9)$$

上式表明信息熵是随机变量 X 的函数 $\log(1/p(X))$ 的期望。熵的值越大,表示该随机变量的离散程度越大。本文使用互信息熵的大小来描述局部特征和任务特征之间的互有信息量,当局部特征和任务特征之间的重合度较大时,互信息熵 L_{MI} 越小,反之亦然。结合式(8)和式(9),提出互信息熵正则项 l_{MI} :

$$l_{MI} = H(I(f_i;f_i)) = -E \left(\log \frac{s(f_i, f_i)}{\sum_{j \in [1,n]} s(f_i, f_j)} \right) \quad (10)$$

最后基于交叉熵损失函数和互信息正则项,提出最大化互信息约束的损失函数 L_{oss} :

$$L_{oss} = \frac{1}{N} \sum_i (l_{c-e} + \lambda l_{MI}) \quad (11)$$

式中: λ 是用于平衡交叉熵和互信息熵正则项的超参数; N 是查询集样本的数量。

通过梯度反向传播更新特征提取器 ξ_2 中卷积核组 $\mathbf{K}_2 = \{k_i | k_i \in \mathbf{R}^{1 \times 1 \times C}, i=1,2,3\}$ 的权重 \mathbf{W} :

$$\frac{\partial L_{oss}}{\partial \mathbf{W}} = \nabla l_{c-e} + \lambda \nabla l_{MI} \quad (12)$$

$$\mathbf{W} = \mathbf{W} - \eta (\nabla l_{c-e} + \lambda \nabla l_{MI}) \quad (13)$$

式中 η 是控制每一次反向传播中的梯度下降速度的超参数,即学习率。

在交叉熵损失函数中,加入了基于互信息熵的正则化

项后,参数的权重变化将会受到互信息的约束,避免了训练过程中受到干扰信号的影响而导致的过拟合,进而提高了 R-NLN 模型的鲁棒性。

2 实验

2.1 数据集和实验环境

采用 miniImageNet 数据集和高频元件精密加工工件数据集(简称为高频工件数据集)进行实验。其中,miniImageNet 数据集包含 100 类的自然图像,每类包含 600 张彩色图像,共有 60 000 张图像样本。高频工件数据集是科技专项下制作的数据集,包括 50 类小样本工件图像,每类包含 15 张彩色图像,共有 750 张原始图像样本,部分样本如图 4 所示。

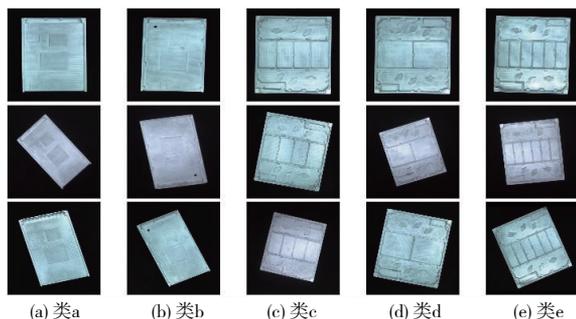


图 4 部分高频工件数据集实例

由于高频工件的样本较小,所以对该数据集采用了随机水平/垂直翻转将数据集扩大 2 倍。采用 16 : 4 : 5 的比例设置验证集、训练集、测试集。表 1 展示了数据集的基本情况。

表 1 数据集基本情况

基本参数	miniImageNet	高频工件数据集
类数量	100	50
类样本数量	600	15
训练集类数量	64	32
验证集类数量	16	8
测试集类数量	20	10
样本规格	84×84×3	224×224×3
样本总数(数据增强前)	60 000	750
样本总数(数据增强后)	60 000	2 250

实验软件采用 PyTorch 深度学习框架,硬件采用 Intel © CoreTM I5-9400F CPU@2.90Ghz、NVIDIA Geforce GTX 1080 GPU、32G 运行内存的工作站。训练和测试阶段都基于小样本学习下的标准方法 N -way K -shot 进行,所有实验均采用 Adam 优化算法加速模型的训练速率,超参数 λ 和 η 初始值分别设置为 0.1 和 0.01。

2.2 分类性能实验

高频工件在表面纹理、特征形状以及颜色上都未表现出较大差异,属于语义差别较小的图像。而自然图像在上

述方面的差异较大。为探究 R-NLN 的性能是否依赖于类间的语义性差别大小,选取自然图像数据集和高频工件图像数据集作对照实验。

对于自然图像分类,使用小样本领域的经典数据集 miniImageNet 进行分类测试。在训练过程中,从 38 400 个训练集样本里随机抽取 1 000 个任务样本,每个任务即为 1 个 mini-batch,并且每 10 个任务作为 Epoch,所以一共有 100 个 Epoch,即训练次数为 100 次。

对于高频工件图像分类,使用高频工件数据集进行分类测试。在训练过程中,从 1 440 个训练集样本里随机抽取 1 000 个任务样本,每个任务即为 1 个 mini-batch。为了完成对照实验,所以选取每 10 个任务作为 1 个 Epoch,即训练次数同样为 100 次。

过程中采取跨任务机制训练 R-NLN 模型,在每个 5-way 1-shot(或 5-way 5-shot)任务中,除了每个类的 1(或 5)张图像外,还会从每个类别中随机抽取 4 张图像作为查询集。即对于一个 5-way 1-shot(或 5-way 5-shot)任务,每一个训练集中会有 5(或 25)张支持集图像和 25 张查询集图像。

采用小样本领域的 3 类主流算法进行对比实验,包括:基于迁移学习的方法 SSMN^[14]和 PPA^[15];基于元学习的方法 MN^[16]、PN^[17]、RN^[18]、MAML^[19]和 AAN^[20];基于图卷积网络的方法 TPN^[21]和 GCN^[22]。采用平均分类准确率 mAp 来评价各种算法的性能。在测试过程中,从测试数据集中随机抽取 1 000 个任务样本,以重复 10 次的 Top-1 的平均分类准确率作为最终的评价指标。在训练中为了优化梯度下降过程,每训练 1 个 Epoch 则使学习率减小 1/2。由于采用了端到端的训练形式,所以过程中也无需微调超参数。实验结果如表 2 所示。

表 2 分类性能实验结果 单位:%

模型	类型	miniImageNet (自然图像)		特种机 加工工件图像	
		1-shot	5-shot	1-shot	5-shot
SSMN	局部特征+迁移学习	58.32	71.23	48.44	70.22
PPA	共享参数+迁移学习	59.60	73.74	49.23	72.31
MAML	优化模型+元学习	43.09	60.63	42.11	58.22
AAN	优化模型+元学习	54.89	62.37	52.67	61.26
GCN	图卷积+元学习	53.03	64.78	51.23	63.27
TPN	图卷积+元学习	54.47	67.05	52.12	65.50
MN	度量+元学习	44.38	57.58	43.12	56.42
PN	度量+元学习	44.43	66.04	42.18	64.79
RN	度量+元学习	50.13	64.33	49.22	63.12
R-NLN(本文)	度量+元学习	61.89	74.51	53.87	74.09

从表 2 中可以看出,以 5-way 5-shot 为参考,在自然图像 miniImageNet 分类中,R-NLN 的 mAp 比迁移学习算法高 2.0%,比图卷积算法高 8.6%,比其他元学习方法高 11.8%。在高频工件图像分类中,R-NLN 的 mAp 比迁移学习算法高 2.8%,比图卷积算法高 9.7%,比其他元学习方法高 12.6%。

因此可知,由于任务特征的提取和互信息约束的共同作用,提高了模型对于自然图像中关键特征的学习能力,在不依赖于类间语义距离的情况下对于复杂语义图像的理解有比较显著的提升。在高频工件图像中,R-NLN 在 mAp 上不仅比同类的元学习算法高 6.1%,而且比图卷积算法高 9.6%,比迁移学习算法高 5.0%。这是因为在损失函数上采用了互信息约束,对样本表面噪声的抗干扰能力做了特定优化,所以模型的鲁棒性有一定的提升。

2.3 消融实验

R-NLN 主要通过两点来提高小样本高频工件的分类准确率:1)提取基于 NLN 的全局特征和局部特征的自适应任务特征;2)通过损失函数的互信息约束减少模型对于元件表面噪声的拟合。为了能够分析任务特征提取和互信息约束对于各自模型的提升,使用控制变量法对模型进行了消融实验,分别验证了以上两点的有效性。

实验以 5-way 1-shot(5-shot)为基准,采用 16:4:5 的比例设置验证集、训练集、测试集。在训练过程中,从 1 440 个训练集样本里随机抽取 1 000 个任务样本,每个任务即为 1 个 mini-batch,选取每 10 个任务作为 1 个 Epoch,即训练次数为 100 次。使用 RN 和 PN 作为对照组,进行了 4 组实验:①只提取任务特征;②只进行互信息约束;③不提取任务特征+不进行互信息约束;④同时进行任务特征提取和互信息约束。实验结果如表 3 所示。

表 3 在高频工件数据集上的消融实验结果 单位:%

消融模型	1-shot	5-shot
RN(对照组)	49.22	63.12
PN(对照组)	42.18	64.79
①只提取任务特征	48.16	70.29
②只进行互信息约束	41.23	60.77
③不提取任务特征+不进行互信息约束	41.09	60.24
④提取任务特征+互信息约束	53.91	74.52

从表 3 的实验结果可以看出:以 5-shot 的数据为基准,通过比较对照组 PN、RN 及 ①和 ③,可知 R-NLN 中的任务特征提取模块提高了 10.1% 的准确率。因为任务特征的本质是基于全局特征和局部特征的关联度而提取的细粒度特征,它对于查询样本具有更好的适应性,在小样本条件下由于支持样本数量少,模型需要尽可能地理解样本,而提取任务特征在这样的情况下能显著提高模型的性能。

通过比较对照组 PN、RN 及 ②和 ③,可知,互信息约束在没有进行任务特征提取的条件下,无法显著提高模型的性能。因为互信息约束本身是通过对于局部特征和任务特征的互信息来消除模型对于噪声的拟合,如果不进行任务特征的提取,那么实际上任务特征就退化为全局特征,相当于约束了全局和局部特征之间的互信息,失去了任务特征对于不同任务之间噪声的适应性,所以并不能显著降低模型对于噪声的拟合。

通过对比 ①和 ④可知,互信息约束在提取任务特征的

前提下提高了 4.3% 的准确率。原因是最大化互信息约束有效提高了模型的鲁棒性,弥补了全局特征容易拟合噪声的短板。

综上所述,本文提出的“任务特征提取”和“互信息约束”各司其职,一方面提高了模型对于任务特征的提取能力,另一方面通过最大化互信息约束充分利用了局部特征中的优点,提高了模型的鲁棒性,所以 R-NLN 模型可以获得更高的分类精度。

3 结语

本文针对高频元件精密加工工件样本稀缺难以训练传统 CNN 模型的问题,提出了一种最大化互信息约束的 R-NLN 高频工件图像分类模型。R-NLN 将查询(支持)样本的全局特征和局部特征通过 NLN 进行交叉关联以获得适应于查询任务的任务特征,从而提高了模型对支持样本和查询样本之间重点关联部分的提取能力。此外,针对高频工件图像上全局噪声信号较为明显的特点,通过在损失函数中添加互信息熵正则项,以实现在训练过程中最大化任务特征和局部特征之间互信息的约束,完成模型的鲁棒性优化。对 miniImageNet 和 高频工件数据集的实验结果表明,该模型的性能显著高于其他主流的小样本分类模型。

参考文献:

- [1] 匡逊君,赵文倩,李明富. 基于图像不变矩和 SVM 的机械零件分类识别[J]. 制造业自动化,2012,34(15):65-68,72.
- [2] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [3] LOWE D G. Object recognition from local scale-invariant features[C]// Proceedings of the Seventh IEEE International Conference on Computer Vision. Kerkyra, Greece: IEEE, 2002: 1150-1157.
- [4] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05). San Diego, CA, USA: IEEE, 2005:886-893.
- [5] SCHWEITZER H, BELL J W, WU F. Very fast template matching[M]// Computer Vision — ECCV 2002. Berlin, Heidelberg: Springer Berlin Heidelberg, 2002:358-372.
- [6] 赵凯琳,靳小龙,王元卓. 小样本学习研究综述[J]. 软件学报,2021,32(2):349-369.
- [7] VILALTA R, DRISSI Y. A perspective view and survey of meta-learning[J]. Artificial Intelligence Review, 2002, 18(2):77-95.
- [8] 刘冰,李瑞麟,封举富. 深度度量学习综述[J]. 智能系统学报,2019,14(6):1064-1072.
- [9] 刘颖,雷研博,范九伦,等. 基于小样本学习的图像分类技术综述[J]. 自动化学报,2021,47(2):297-315.
- [10] WANG X L, GIRSHICK R, GUPTA A, et al. Non-local neural networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018:7794-7803.

(下转第 101 页)

3 结语

本文基于阻尼非线性模态理论,综合采用多谐波平衡法、雅克比矩阵快速计算方法等先进数值仿真技术,建立了干摩擦耗散特性结构的非线性模态高效仿真分析方法,为扩展到实际工程结构奠定基础,具有很好的应用价值。主要结论如下:

1) 实现了含干摩擦梁结构的非线性模态分析,揭示其非线性模态频率与非线性模态阻尼比随振幅增长的变化规律,并将非线性模态与强迫振动响应联系,验证了系统在共振区域的响应可以通过非线性模态近似,避免了强迫振动响应的计算;

2) 提出了通过模态应变能法对非线性模态阻尼比计算结果进行验证的技术途径,进而验证了本文建立的非线性模态数值仿真计算方法可以有效评估系统的阻尼能力,为后期干摩擦装置的设计和优化提供指导。

参考文献:

- [1] 郭鑫星,周瑾,曹晓彦,等. 叶片式阻尼器的参数辨识研究[J]. 机械制造与自动化,2021,50(6):37-40,55.
[2] ROSENBERG R M. The normal modes of nonlinear n-degree-

of-freedom systems [J]. Journal of Applied Mechanics, 1962, 29(1):7-14.

- [3] SLATER J C. A numerical method for determining nonlinear normal modes[J]. Nonlinear Dynamics, 1996, 10(1):19-30.
[4] LEE Y S, KERSCHEN G, VAKAKIS A F, et al. Complicated dynamics of a linear oscillator with a light, essentially nonlinear attachment [J]. Physica D: Nonlinear Phenomena, 2005, 204(1/2):41-69.
[5] KRACK M. Nonlinear modal analysis of nonconservative systems: extension of the periodic motion concept [J]. Computers & Structures, 2015, 154:59-71.
[6] 康佳豪,徐超,李东武,等. 基于谐波平衡-时频转换法的摩擦振子稳态响应分析[J]. 振动与冲击, 2020, 39(12):170-176,205.
[7] 阳刚,周标,臧朝平. 含接触界面的叶盘结构强迫振动响应快速预测方法[J]. 航空动力学报, 2019, 34(9):1953-1961.
[8] CHEN J J, ZANG C P, ZHOU B, et al. High-fidelity calculation of modal damping caused by friction at blade roots for single blades and tuned bladed disc assemblies [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2021, 235(15):2810-2831.

收稿日期:2022-05-17

(上接第93页)

- [11] YUE K Y, SUN M, YUAN Y C, et al. Compact generalized non-local network [C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York: ACM, 2018:6511-6520.
[12] LIU D, WEN B H, FAN Y C, et al. Non-local recurrent network for image restoration [C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, Canada. New York: ACM, 2018:1680-1689.
[13] 黄立勤,陈柳清,潘林,等. 结合血管拓扑和 Non-local CNN-GCN 的肺动静脉分离方法[J]. 福州大学学报(自然科学版), 2022, 50(1):24-30.
[14] CHOI J, KRISHNAMURTHY J, KEMBHAVI A, et al. Structured set matching networks for one-shot part labeling [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018:3627-3636.
[15] QIAO S Y, LIU C X, SHEN W, et al. Few-shot image recognition by predicting parameters from activations [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018:7229-7238.
[16] VINALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning [C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM, 2016:3637-3645.
[17] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for

few-shot learning [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017:4080-4090.

- [18] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018:1199-1208.
[19] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]//Proceedings of the 34th International Conference on Machine Learning - Volume 70. Sydney, NSW, Australia. New York: ACM, 2017:1126-1135.
[20] REN M Y, LIAO R J, FETAYA E, et al. Incremental few-shot learning with attention attractor networks [EB/OL]. (2018-5-25) [2022-4-26] 2018; arXiv: 1810.07218. <https://arxiv.org/abs/1810.07218>.
[21] LIU Y B, LEE J, PARK M, et al. Learning to propagate labels: Transductive propagation network for few-shot learning [EB/OL]. 2018; arXiv:1805.10002. <https://arxiv.org/abs/1805.10002>.
[22] GARCIA V, BRUNA J. Few-shot learning with graph neural networks [EB/OL]. (2017-11-10) [2022-4-26] 2017; arXiv:1711.04043. <https://arxiv.org/abs/1711.04043>.

收稿日期:2022-05-26