

DOI: 10.19650/j.cnki.cjsi.J2513806

面向小样本纹理分类的多模态证据融合框架*

熊鹏文^{1,2,3}, 胡慕烨^{1,2,3}, 黄雨轩^{1,2,3}, 曾成^{1,2,3}, 叶艳辉^{1,2,3}

(1. 南昌大学先进制造学院 南昌 330031; 2. 智能机器人江西省重点实验室 南昌 330031;
3. 南昌大学机器人研究所 南昌 330031)

摘要:传统多模态融合方法假设各模态数据在不同样本上的质量分布均匀,未能充分考虑模态间信息可靠性的动态变化。这种静态融合策略在数据质量异质性较强的情境下,难以对低质量模态进行适应性调控,从而导致信息融合过程受噪声干扰或模态缺失等因素的影响较大,无法充分发挥融合优势。当样本数量较少时,上述问题进一步削弱了分类器的鲁棒性。为增强模型在小样本纹理分类任务上的可靠性和适应性,提出一种面向小样本纹理分类的多模态证据融合框架(SMEF-TC)。在主观逻辑框架下,采用狄利克雷分布统一刻画类别概率与预测不确定性,使模型在推理阶段无需额外的不确定性量化步骤,有效避免了传统贝叶斯推断所依赖的高成本计算。在考虑各个模态不确定性的基础上,通过证据理论进行融合,使模型能够自适应地调整不同模态在决策中的贡献,避免冗余信息的干扰。相比传统方法,SMEF-TC在多模态融合过程中不仅考虑了各模态的信息证据,还考虑了预测不确定性,这种策略让模型在噪声环境、部分模态缺失或数据质量不均衡的情况下,仍能维持较高的识别精度。实验结果表明,所提出的 SMEF-TC 框架在公开的纹理数据集 LMT-108 和 LMT-184 上分别取得 96.53% 和 94.70% 的准确率,该方法在面向小样本纹理辨识任务时,相比现有方法更为精准和稳健。

关键词: 多模态融合; 纹理分类; 证据理论; 不确定性

中图分类号: TH7 TP391 **文献标识码:** A **国家标准学科分类代码:** 520.60

Small-sample multi-modal evidence fusion framework for texture classification

Xiong Pengwen^{1,2,3}, Hu Muye^{1,2,3}, Huang Yuxuan^{1,2,3}, Zeng Cheng^{1,2,3}, Ye Yanhui^{1,2,3}

(1. School of Advanced Manufacturing, Nanchang University, Nanchang 330031, China; 2. Jiangxi Key Laboratory of Intelligent Robot, Nanchang 330031, China; 3. Robotics Research Institute, Nanchang University, Nanchang 330031, China)

Abstract: Conventional multi-modal fusion approaches assume that quality is uniformly distributed across samples, overlooking dynamic inter-modal reliability. Such static strategies struggle to down-weight low-quality modalities when data heterogeneity is high, rendering the fused representation susceptible to noise, missing modalities, and other degradations, thereby diminishing fusion benefits. Under small-sample conditions, these limitations further erode classifier robustness. To enhance reliability and adaptability in small-sample texture recognition, we propose the small-sample multi-modal evidence fusion framework for texture classification (SMEF-TC). Built on subjective logic, SMEF-TC leverages a Dirichlet distribution to jointly model class probabilities and epistemic uncertainty, thereby eliminating extra uncertainty-quantification during inference and the high computational overhead of traditional Bayesian methods. Incorporating modality-specific uncertainties, evidence theory fuses multi-modal information, enabling the model to adaptively recalibrate each modality's contribution and effectively suppress redundant or noisy cues. By simultaneously accounting for information evidence and predictive uncertainty, SMEF-TC retains high recognition accuracy under conditions of noise, modality absence, and imbalanced quality. Experiments on the public LMT-108 and LMT-184 texture datasets yield accuracies of 96.53% and 94.70%, respectively, confirming that SMEF-TC offers superior precision and robustness for small-sample texture classification compared with existing techniques.

Keywords: multimodal fusion; texture classification; Dempster-Shafer evidence theory; uncertainty

收稿日期: 2025-03-06 Received Date: 2025-03-06

* 基金项目: 国家自然科学基金(62373181, 62163024)、江西省“双千计划”(jxsq2023201097)、江西省杰出青年基金(20232ACB212002)、江西省重点研发计划青年科学家(S20252488)、国家重点研发计划“智能机器人”专项(2023YFB4704903)项目资助

0 引言

纹理反映物体的材质、形态及表面状态等重要信息,是人类了解和认知物体重要的特征之一^[1-2]。通过对纹理进行提取和分析,纹理分类已经在物体识别、人脸识别、图像和视频检索、遥感/医学图像分析^[3-4]等计算机视觉和模式识别领域得到广泛的应用^[5-6]。随着现代机器人逐渐走向更加复杂和多变的环境,如何让机器人精准感知和理解周围世界,成为其高效完成任务的关键。纹理识别为机器人提供了与物体交互的宝贵信息,机器人可以通过掌握周围环境中物体表面材料的属性来调整控制策略,以更智能的方式执行抓取、组装、监测等任务。因此,研究健壮的材质表面纹理的分类与识别方法对于机器人的设计具有重要意义^[7]。

传统的单模态纹理分类大多是基于图像识别法^[8],使用灰度共生矩阵(gray-level co-occurrence matrix, GLCM)、局部二值模式(local binary pattern, LBP)等技术^[9],通过从图像中提取纹理特征并进行分类。然而,只考虑单一模态数据往往无法应对复杂环境中的多变因素。例如,低光照、遮挡、噪声等问题常导致纹理特征无法被准确提取,影响识别精度。特别地,在小样本纹理分类任务中,单一模态表征在判别能力与鲁棒性方面的固有局限常导致模型难以充分挖掘有限训练数据中的有效特征。多模态信息的引入有效缓解了这一问题。不同模态在感知机制与特征分布上的互补^[10],使模型能够在更丰富的特征空间中进行推理,从而显著提升分类准确率与泛化性能^[11]。因此,在小样本受限的场景下,多模态特征的协同融合成为提升纹理识别性能的关键策略。

近年来,多模态融合技术得到了广泛关注和快速发展,在各种领域的应用中取得了巨大的成功^[12-14],司坤宇等^[15]提出的基于混合差分卷积和高效视觉 Transformer 网络的三模态融合方法,通过差分卷积增强特征提取,利用视觉 Transformer 加强图像全局信息的捕捉。沈瑜等^[16]提出的基于局部与全局信息协同的双分支多模态医学图像融合方法,结合了多尺度卷积和多维注意力机制,提升了图像中局部细节与全局结构的融合精度。任楚岚等^[17]提出的基于自适应融合技术的多模态实体对齐模型,利用多模态变分自编码器补全模态缺失数据,采用动态模态融合方法有效整合模态信息。但是,这些现有的融合策略大多假设每个模态数据的质量对于所有样本基本稳定,为每个模态的特征分配或学习一个权重^[18],在处理模态信息不均衡时适应性不足,未能进一步最大化互补信息^[19]、有效避免冗余信息干扰,进而无法充分发挥融合的优势^[20],特别是在样本数量受限的场景下,这种局限性会急剧影响模型性能。

为了提高纹理识别和分类的稳定性和可靠性,不仅要知道分类结果,还要知道结果的可信度,这就需要对预测的不确定性建模。Lakshminarayanan 等^[21]提出了一种简单且可扩展的预测不确定性估计方法(deep ensemble, DE),利用深度集成技术增强了深度神经网络在预测时的不确定性估计能力,但此方法需要同时训练多个模型,这会显著增加计算开销,不利于在大规模任务中应用。Soleimany 等^[22]提出了证据深度学习方法(evidential deep learning, EDL),采用证据分布来量化模型的预测不确定性,在一定程度上避免了传统贝叶斯方法所需的高计算成本,但它需要在推理阶段进行额外的计算来量化不确定性,这导致了实时应用的困难,并且在涉及多源数据的任务中,该方法难以提供准确、全面的不确定性评估。

针对上述问题,提出一种面向小样本纹理分类的多模态证据融合框架(small-sample multi-modal evidence fusion framework for texture classification, SMEF-TC),主要工作包括:首先,在主观逻辑架构下,采用狄利克雷分布对类别概率分布以及预测不确定度进行建模;其次,提出了一种简单高效的证据融合规则,在考虑各个模态证据不确定度的基础上,引导多个模态的证据深层次交叉融合,动态评估每个模态的证据可信度,精确控制模态间的贡献,避免冗余信息的干扰;最后,基于 LMT-108 和 LMT-184 纹理数据集进行纹理识别实验,将提出的 SMEF-TC 与 DE^[21]、EDL^[22]、基于传统神经网络的分类方法弹性角度边际损失(elastic angular margin loss, EAML)^[23]、基于深度激活图随机化编码的纹理识别方法(random encoding of aggregated deep activation maps for texture recognition, RADAM)^[24]和基于顺序无关与随机化编码的视觉 Transformer 纹理识别方法(vits with orderless and randomized token encodings for texture recognition, VORTEX)^[25]等先进方法比较,实验结果验证了面向小样本纹理分类任务时,该模型有效性和鲁棒性。

1 面向小样本纹理分类的多模态证据融合框架

为基于不同模态的不确定性进行可靠的多模态融合,需要模型能够准确表征各单一模态的不确定性。在使用 Softmax 层的传统分类器中,Softmax 函数输出的最大值对应的类别作为模型预测结果。据研究表明^[26-27],即使 Softmax 函数输出的最大值对应的类别不是真实标签,即预测错误,模型也会给予该预测结果较高的置信度。为获得可靠的单模态不确定性,引入狄利克雷分布(Dirichlet distributions, DIR)以生成更具表达力的预测分布。然而,狄利克雷分布在多模态场景下的融合过程缺乏解析形式的封闭解,直接对各模态的分布进行联合建

模在理论与实现上均面临挑战。为了灵活地利用多种模态的狄利克雷分布的不确定性,引入主观逻辑(subjective logic, SL)来预测不同模态的不确定性^[28]。

1.1 SMEF-TC 方法

SMEF-TC 整体框架如图1所示。可概括为异质特征抽取、层次化证据生成、主观概率刻画、不确定性驱动的证据耦合4阶段。系统首先对来自多源传感渠道的原始观测进行模态解耦,分别交由互不共享参数的特征提取器以端到端方式编码,获得维度齐整但表征语义异构的高层特征表示。将这些模态特征送入层次化证据投影头(hierarchical evidence projection head, HEP-Head),提取对应的证据向量。接着,狄利克雷主观概率映射器(Dirichlet-

based subjective probability mapper, DSP-Mapper)将每个模态的证据向量映射为狄利克雷分布的浓度参数,并在主观逻辑框架下计算得到每个模态的概率权重分配集。该概率权重集包含各类别的置信度以及整体不确定度,反映模型对该模态预测结果的信任程度和未知程度。最后通过面向不确定性的多模态证据融合模块(uncertainty-aware multi-modal evidence fusion module, UMEF-Module)将所有模态的概率权重分配集进行深层次交叉融合,输出最终的联合概率权重分配集。融合后的联合概率权重分配集综合了全部模态的信息,为最终的分类决策提供依据,并体现了模型对各类别预测的整体置信度和不确定性,实现对异构感知信息的自适应可靠融合。




图1 SMEF-TC 整体框架
Fig. 1 Overall framework of SMEF-TC

HEP-Head 的内部结构如图2所示。两层全连接层(full connection, FC)、一层全局平均池化层(global average pooling, GAP)用于对各模态提取的高维特征进行进一步变换和全局信息汇聚。随后通过主成分分析(principal component analysis, PCA)特征降维,并采用ReLU激活函数将输出限定为非负值,生成每个模态的证据向量。




图2 层次化证据投影头
Fig. 2 Hierarchical evidence projection head

1.2 不确定性建模

传统神经网络的输出可以看成单纯形上的一个点,而狄利克雷分布表征了单纯形上每个点的概率^[29]。然而,经典深度神经网络分类器通常在最后一层使用Softmax层,这可能赋予错误的预测结果较高的置信度,

易导致模型在处理复杂任务时不稳定。引入总体不确定性可解决这个问题,在主观逻辑框架下,采用狄利克雷分布对输出结果的二阶概率和总体不确定性进行建模,更精确地评估分类的不确定性,从而有效避免传统方法中在分类错误时产生的高置信度偏差。

现有的基于不确定性的算法通常需要额外的计算来量化不确定性^[30],而 SMEF-TC 允许模型在单一推理过程中同时估计类别概率与不确定性,保持高精度预测的基础上,显著提升了计算效率。在多分类问题的情境下,主观逻辑提供了一种机制,将狄利克雷分布的参数与相应的预测置信度及不确定度进行联系。在这种框架下,每一类别被赋予一个对应的置信度值,用于反映给定类别分辨结果的确定性。同时,整个分类问题的总体不确定度也被量化,表示在面对所有可能输出时,分类器的整体不确定性。所有类别的置信度值以及整个问题的总体不确定度均为非负实数,且其总和始终=1,确保了这些量在数学上具有规范性。

对于 K 分类问题,类别置信度与分类不确定度关系满足式(1),即:

$$u^m + \sum_{k=1}^K b_k^m = 1 \quad (1)$$

其中, b_k^m 为基于模态 m 预测的第 k 类置信度, u^m 为在该分类问题中对于模态 m 的不确定度。

证据 e_k^m 是从输入数据中提取的量度, 为第 m 个模态类别 k 的分类决策提供支持。对给定狄利克雷分布 $Dir(\mathbf{p}^m, \boldsymbol{\alpha}^m)$, 采用主观逻辑框架将证据和狄利克雷分布的浓度参数相耦合。它不仅仅是对输入信息的单一反映, 还在数学上通过影响每个类别的先验分布, 进而影响整个分类模型的推理过程。在动态更新过程中, 证据随着数据的变化而变化, 为模型提供了灵活的推断机制。

将证据 e_k^m 与狄利克雷分布浓度参数 α_k^m 关联, 如式 (2) 所示。

$$e_k^m = \alpha_k^m - 1 \quad (2)$$

置信度 b_k^m 与不确定度 u^m 的值由式 (3) 确定, 即:

$$\begin{cases} b_k^m = \frac{e_k^m}{S^m} = \frac{\alpha_k^m - 1}{S^m} \\ u^m = \frac{K}{S^m} \\ S^m = \sum_{k=1}^K (e_k^m + 1) = \sum_{k=1}^K \alpha_k^m \end{cases} \quad (3)$$

其中, S^m 为狄利克雷强度。

由式 (3) 可知, 在不确定性建模机制下, 第 k 类所获得的证据量与其分配的置信度之间直接正相关。当某一类别获取的证据量增多时, 该类别的置信度亦随之增高, 表明在该类别正确分类的概率上升, 反之, 当该类别所获得的证据减少时, 对应的置信度下降, 反映出对该类别预测正确的信心减弱。置信度的分配不仅是对已有信息的定量评估, 更是一种在不确定条件下的主观意见表达。因此, 该方案对置信度的赋值可被视为一种高度依赖于证据提供和信息融合的主观推断, 反映不同类别在识别问题中的相对可靠性。基于这种主观推断, 对于类别概率 $\hat{p}^m$, 相应的狄利克雷分布均值为: $\hat{p}_k^m = \alpha_k^m / S^m$ 。

1.3 面向不确定性的多模态证据融合规则

证据理论 (dempster-shafer evidence theory, DSET) 允许将来自不同模态的证据 (置信度和不确定度) 进行融合, 从而形成一个综合证据^[31]。然而, 在多分类任务下, 传统的证据融合方法常涉及对多个证据源的复杂集成与加权操作, 这需要在多维空间内进行高阶运算, 从而导致计算量随类别数目的增加而急剧增长。在模态数目较多或大规模数据集的情境下, 无法充分发挥不同模态的优势^[32], 这将显著影响系统的实时性和可扩展性, 限制实际应用中的普适性。因此, 如何在保持融合精度的同时降低计算开销, 在多分类问题中至关重要。为缓解这一问题, 提出一种约简的、面向不确定性的多模态证据融合规则 (uncertainty-aware multi-modal evidence fusion rule, UMEF-Rule)。

对于使用 N 个模态信息的 K 分类任务, 需要融合 N 个独立的概率权重分配集。

第 m 个模态的概率权重分配集如式 (4) 所示。

$$\mathbf{M}^m = \{ \{ b_k^m \}_{k=1}^K, u^m \} \quad (4)$$

多模态融合之后, 得到联合概率权重分配集如式 (5) 所示。

$$\mathbf{M} = \{ \{ b_k \}_{k=1}^K, u \} \quad (5)$$

为方便分析, 先考虑使用两个模态信息的分类情况。证据融合规则如图 3 所示。

	b_1^2	b_2^2	b_3^2	$\cdots$	b_K^2	u^2
b_1^1	$b_1^1 b_1^2$					$b_1^1 u^2$
b_2^1		$b_2^1 b_2^2$				$b_2^1 u^2$
b_3^1			$b_3^1 b_3^2$			$b_3^1 u^2$
$\vdots$				$\ddots$		$\vdots$
b_K^1					$b_K^1 b_K^2$	$b_K^1 u^2$
u^1	$b_1^2 u^1$	$b_2^2 u^1$	$b_3^2 u^1$	$\cdots$	$b_K^2 u^1$	$u^1 u^2$

图3 面向不确定性的多模态证据融合规则

Fig. 3 Uncertainty-aware multi-modal evidence fusion rule

此时, 联合概率权重分配集 $\mathbf{M}$ 由概率权重分配集 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 融合得到。证据融合规则如式 (6) 所示。

$$\mathbf{M} = \mathbf{M}^1 \oplus \mathbf{M}^2 \quad (6)$$

具体运算规则如式 (7) 所示。

$$\begin{cases} b_k = \frac{1}{1-C} (b_k^1 b_k^2 + b_k^1 u^2 + b_k^2 u^1) \\ u = \frac{1}{1-C} u^1 u^2 \end{cases} \quad (7)$$

其中, C 为 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 相互冲突的部分 (图 3 中空白部分), 表达式如式 (8) 所示。

$$C = \sum_{i \neq j} b_i^1 b_j^2 \quad (8)$$

如图 3 所示, 联合概率权重分配集 $\mathbf{M}$ 中的联合置信度 $\{b_k\}_{k=1}^K$ 和总体不确定度 u 对应图中深色部分。在二模态分类任务中, 面向不确定性的多模态证据融合规则的特点为:

1) 当 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 的置信度都较低时, $\mathbf{M}$ 一定是低置信度。这表明, 当模态信息的支持不足或者证据弱化时, 整个分类决策系统的可靠性也会随之下降;

2) 当 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 置信度都较高时, $\mathbf{M}$ 一定是高置信度。这表明当各个模态均提供强力支持时, 不同模态的信息在决策中相互促进, 系统能够有效利用来自两个模态的互补信息, 提升对目标类别的判断精度;

3) 当 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 其中一个置信度较高时,最终分类由置信度高的模态决定。在信息不对称的情况下,系统倾向于依赖更为可信的证据来源做出最终决策;

4) 当 $\mathbf{M}^1$ 和 $\mathbf{M}^2$ 冲突时, $\mathbf{M}$ 置信度降低。在此情况下,两个模态的证据相互对立,导致最终决策的不确定性增加,这强调了模态间协调一致性的重要性。

将上述证据融合规则推广到 N 模态 K 分类,融合规则如式 (9) 所示。

$$\mathbf{M} = \mathbf{M}^1 \oplus \mathbf{M}^2 \oplus \cdots \oplus \mathbf{M}^N \quad (9)$$

根据式 (3),对应的多模态联合证据和狄利克雷分布浓度参数如式 (10) 所示。

$$\begin{cases} S = \frac{K}{u} \\ e_k = b_k S \\ \alpha_k = e_k + 1 \end{cases} \quad (10)$$

据上述证据融合规则,可得估计的多模态联合证据 $\mathbf{e} = \{e_k\}_{k=1}^K$ 和联合狄利克雷分布参数 $\mathbf{a} = \{\alpha_k\}_{k=1}^K$,从而得到每个类别最终的置信度和预测不确定性。

特别地,三模态分类任务融合规则如式 (11) 所示。

$$\mathbf{M} = \mathbf{M}^1 \oplus \mathbf{M}^2 \oplus \mathbf{M}^3 \quad (11)$$

为进一步减少计算复杂度,简化三模态分类具体融合公式,如式 (12) 所示。

$$\begin{cases} b_k = \frac{1}{1-C} (b_k^1 b_k^2 b_k^3 + b_k^1 b_k^2 u^3 + b_k^1 b_k^3 u^2 + b_k^2 b_k^3 u^1 + b_k^1 u^2 u^3 + b_k^2 u^1 u^3 + b_k^3 u^1 u^2) \\ u = \frac{1}{1-C} u^1 u^2 u^3 \end{cases} \quad (12)$$

其中, $C = \sum_{o \neq p \neq q} b_o^1 b_p^2 b_q^3$ 。

1.4 SMEF-TC 损失函数

传统神经网络常采用交叉熵 (cross-entropy, CE) 作为分类损失,用于衡量模型预测的概率分布与真实标签分布之间的差异,表达式如式 (13) 所示。

$$L_{CE} = - \sum_{j=1}^K y_{ij} \log p_{ij} \quad (13)$$

其中, p_{ij} 是系统基于第 i 个样本对第 j 类给出的预测概率。对于 SMEF-TC,根据从证据网络中获得的第 i 个样本的证据,可得到狄利克雷分布的浓度参数 $\mathbf{a}_i$,并形成意见 $Dir(\mathbf{p}_i | \mathbf{a}_i)$, $\mathbf{p}_i$ 是单纯形上的类别概率。

基于狄利克雷分布对概率和不确定性的建模,模型损失函数如式 (14) 所示。

$$L_{ACE}(\mathbf{a}_i) = \int \left(- \sum_{j=1}^K y_{ij} \log p_{ij} \right) \frac{1}{B(\mathbf{a}_i)} \prod_{j=1}^K p_{ij}^{\alpha_{ij}-1} d\mathbf{p}_i = \sum_{j=1}^K y_{ij} (\psi(S_i) - \psi(\alpha_{ij})) \quad (14)$$

其中, $B(\mathbf{a}_i)$ 是狄拉克雷分布的归一化常数, $\psi(x)$ 为 Digamma 函数 (Gamma 函数的导数)。

式 (14) 是交叉熵在由 $\mathbf{a}_i$ 确定的单纯形上的积分。该损失函数设计的证据增强机制通过优化过程不断提升网络对正确类别的信心,最终使正确类别的置信度最大化。然而,尽管该方法能够确保正确标签的证据占主导地位,但并未有效地抑制错误标签产生的证据。

为将错误标签的证据约束到趋近于 0,减少错误分类的干扰,引入库尔贝克-莱布勒散度 (Kullback-Leibler divergence, KL divergence) 如式 (15) 所示。

$$\begin{cases} D_{KL}[Dir(\mathbf{p}_i | \tilde{\mathbf{a}}_i) || Dir(\mathbf{p}_i | \mathbf{I})] = \\ \log \left(\frac{\Gamma(\sum_{k=1}^K \tilde{\alpha}_{ik})}{\Gamma(K) \prod_{k=1}^K \tilde{\alpha}_{ik}} \right) + \sum_{k=1}^K (\tilde{\alpha}_{ik} - 1) \times \\ \left[\psi(\tilde{\alpha}_{ik}) - \psi\left(\sum_{j=1}^K \tilde{\alpha}_{ik}\right) \right] \\ \tilde{\mathbf{a}}_i = \mathbf{y}_i + (\mathbf{I} - \mathbf{y}_i) \cdot \mathbf{a}_i \end{cases} \quad (15)$$

其中, $\tilde{\mathbf{a}}_i$ 是狄利克雷分布的调整参数,避免将真实标签的证据惩罚为 0。

对于每个样本 i 的狄利克雷分布浓度参数 $\mathbf{a}_i$,该样本损失如式 (16) 所示。

$$L(\mathbf{a}_i) = L_{ACE}(\mathbf{a}_i) + \lambda D_{KL}[Dir(\mathbf{p}_i | \tilde{\mathbf{a}}_i) || Dir(\mathbf{p}_i | \mathbf{I})] \quad (16)$$

其中, λ 为平衡因子 ($\lambda > 0$),用于调节损失函数中项的权重。

如果 λ 过大,在网络训练过程中 KL 散度会过度主导优化过程,从而导致对参数空间的探索受限,无法充分挖掘潜在的解空间。此时,网络可能倾向于输出一种近乎均匀的概率分布,缺乏足够的区分能力。因此,在实验阶段,需逐步增加 λ 的值,引导网络在训练过程中从初期宽泛分布逐渐过渡到更精确可靠的类别预测。

为了确保所有模态在多模态证据融合框架下能够同步生成合理且一致的预测意见,采用多任务学习策略,在保证模态间协调性的同时,还能够强化每个模态在自身任务上的学习能力。在式 (16) 的基础上,综合考虑各个模态在融合之前的预测,得到的总损失函数如式 (17) 所示。

$$L_0 = \sum_{i=1}^K (L(\mathbf{a}_i) + \sum_{m=1}^M L(\mathbf{a}_i^m)) \quad (17)$$

2 实验设置

采用公开的纹理数据集 LMT-108 和 LMT-184 作为实验基准,将提出的 SMEF-TC 方法和现有的基于不确定理论的分类方法:深度集合 (DE)^[21]、证据深度学习 (EDL)^[22]、基于传统神经网络的分类方法弹性角度边际

损失(EAML)^[23]以及两种最新的面向小样本纹理识别的特征聚合方法:基于深度激活图随机化编码的纹理识别方法(RADAM)^[24]、基于顺序无关与随机化编码的视觉Transformer纹理识别方法(VORTEX)^[25]进行对比。

LMT-108数据集涵盖了108种不同类别的表面纹理,每种纹理均提供10个独立样本。针对该数据集,采用每类随机选取2个样本作为训练集,其余8个样本作为测试集的划分策略,即将20%的样本用于训练,80%的样本用于测试。对于LMT-184数据集,该数据集包含184种不同类别的表面纹理,每种纹理对应5个独立样本。划分策略同样遵循每类随机选择1个样本作为训练集,其余4个样本作为测试集的原则,实现20%样本用于训练,80%样本用于测试的分配比例。训练:测试=2:8的划分方式在模拟小样本条件下的纹理识别场景的同时,确保了各类别在训练与测试阶段均有代表性样本覆盖。

对于LMT-108数据集中加速度模态的处理,仅选取加速度信号的Z轴分量作为特征提取与分类的依据。尽管原始数据在滑动(Movement)与轻拍(Tapping)两个尺度下均同步采集了X、Y、Z这3轴的加速度信息,但考虑到Z轴方向通常更直接地反映触觉探测器垂向接触过程中的纹理响应特性,且在相关工作中已验证其对纹理识别具有更高的判别性,因此本方法优先保留Z轴信号以减少冗余,提升特征表示的针对性与有效性。

特别地,为适配RADAM与VORTEX模型对三通道彩色图像输入格式的要求,并确保各方法间的公平对比,在处理LMT-108与LMT-184数据集的加速度模态与声音模态时,依然采用梅尔频率倒谱系数方法(mel-frequency cepstral coefficients, MFCC)作为统一的特征提取器,得到特征矩阵。在不改变原始特征信息量的前提下,对该矩阵进行归一化处理,并通过固定映射方式生成伪彩色图像,仅调整输入数据的表达形式以适配模型输入要求,而不引入额外信息或失真。以LMT-184数据集为例,经过处理的伪彩色特征表示如图4所示。

以基于LMT-184纹理数据集的实验为例,SMEF-TC实验流程如图5所示。实验模型采用随机梯度下降(SGD)优化器进行训练,初始学习率设置为0.001,动量设置为0.9,权重衰减系数设置为0.0005,所有实验均在Python3.7平台上进行。具体实验步骤为:1)从每个样本中提取图像模态3种尺度信息、声音模态2种尺度信息和加速度模态2种尺度信息的高层特征。图像模态的特征提取器采用ResNet-50骨干网络,声音和加速度模态的特征提取器采用MFCC;2)将所有特征分别输入层次化证据投影头,生成各个模态的证据向量;3)通过狄利克雷主观概率映射器,将证据映射为概率权重分配集;4)分别对各模态中由不同尺度信息得到的概率权重分配集进行模

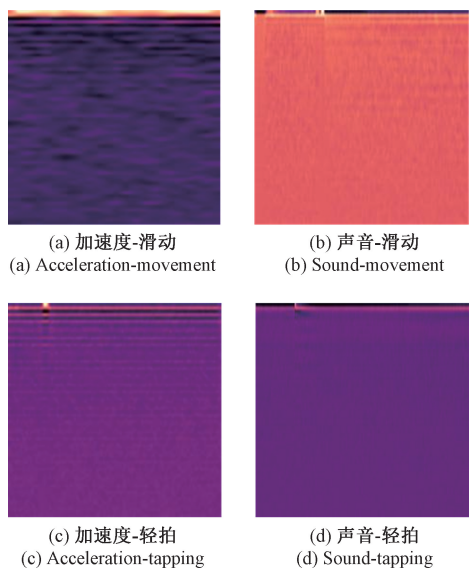


图4 伪彩色特征表示

Fig. 4 Pseudo-colored representation

态内部多尺度融合,获取每种模态的概率权重分配集;5)将3种模态各自的概率权重集进行模态间证据交叉融合,得到联合概率权重分配集;6)计算多模态证据融合损失函数值;7)反向传播优化模型参数。

3 实验结果分析

拼接和加权平均融合是常用的多模态特征融合方法^[33]。由于现有的基于不确定理论的分类方法和面向小样本场景的纹理识别方法都只使用单模态数据,为方便比较,选择拼接作为特征融合的手段来进行多模态纹理分类。

3.1 总体实验结果

1) 准确度分析

由表1的对比实验结果可知,小样本识别场景下,SMEF-TC在LMT-108和LMT-184上的细粒度分类取得最高准确率,分别为96.53%和94.70%,分别较次优方法EAML和VORTEX提升0.85%和0.66%,这表明多模态特征协同增强机制的有效性,SMEF-TC在类别数量显著扩增时仍能保持领先优势。除RADAM外,其余方法在LMT-184上的准确率均有所下降,这反映了随着纹理类别及其内部变异性增加,判别难度在显著加大。然而,SMEF-TC的跌幅(-1.83个百分点)仍要小于传统基于不确定度理论的分类方法DE(-2.15个百分点)和EDL(-1.53个百分点),显示出更强的数据分布适应性。RADAM小幅提升0.74%,原因可能是其统计聚合策略在大规模类别下的稳定性优势。




图 5 实验流程
Fig. 5 Experiment flowchart

表 1 细粒度分类实验结果

Table 1 Experimental results of fine-grained classification

数据集	方法	准确率/%
LMT-108	DE	94.68
	EDL	94.33
	EAML	95.72
	RADAM	93.26
	VORTEX	94.81
	SMEF-TC	96.53
LMT-184	DE	92.53
	EDL	92.80
	EAML	93.89
	RADAM	93.95
	VORTEX	94.08
	SMEF-TC	94.70

2) 计算效率分析

实验总训练迭代次数设定为 20 个 Epoch,对于 LMT-108 和 LMT-184 数据集,改进前后的证据融合规则均都在第 10 个 Epoch 左右达到收敛。

根据图 6 所示结果,改进后的证据融合规则有效降低了时间复杂度。在 LMT-108 数据集上,改进之后每个 Epoch 的计算时间减少了 2.58%,而在 LMT-184 数据集上,改进后每个 Epoch 的计算时间减少了 4.17%。这一计算效率的提升来源于对多模态证据融合机制的优化。与 LMT-108 实验相比,在 LMT-184 实验中,图像模态内部信息尺度更多,进行证据融合所需要的计算资源需求更大,因此在该数据集上对计算复杂度的优化效果更为显著。

3) 鲁棒性分析

为进一步验证 SMEF-TC 方法的有效性和鲁棒性,在 LMT-108 数据集上进行抗噪实验。随机抽取 1/2 样本中




图 6 计算效率分析

Fig. 6 Computational efficiency analysis

的任一模态数据,并引入不同标准差的高斯噪声,人为增加信息的不确定性。图 7 的实验结果表明,随着噪声标准差的增加,数据的不确定性增强,所有方法的分类准确率均有所下降。然而,得益于面向不确定性的多模态证据融合规则,在噪声环境中,SMEF-TC 的性能下降幅度最小,展现出了较强的鲁棒性。受噪声影响最大的是基于传统神经网络的分类方法 EAML。不加噪声时,其分类准确率仍仅次于 SMEF-TC,但在较大标准差的噪声环境下,该方法受到严重干扰,性能大幅下降,在大多数情况下准确率最低。这表明传统神经网络方法在面对信息不确定性的增加时,决策边界较为不稳定,适应性差。




图 7 不同标准差的识别准确率

Fig. 7 Recognition accuracy with different standard deviations

值得注意的是,在本次抗噪实验中可观测到一种非线性的性能衰减-回弹-饱和轨迹。随着噪声标准差 σ 逐步增大,所有模型在早期区间准确率曲线单调递减,此阶段噪声方差破坏了图像模态的空间域的纹理细节,还淹没了加速度与声音模态梅尔频率倒谱系数(MFCC)中微弱但判别性较强的时频纹理,模型决策边界被系统性扰偏,性能迅速下滑。当 σ 继续增大、跨越临界域后,曲线出现轻微回弹,最终趋于稳定。分析后发现原因可能是:(1)MFCC 表征在谱域存在显著的能量密度脊线与谐波走向,属于宏观、低频的结构化先验。当噪声强度足够高时,随机噪声在空间上近似各向同性且能量分散,系统对这类“白化”干扰具备天然低通效应,自动抑制高频噪

声分量;(2)深层网络在大噪声极限下,倾向于依赖更稳定的跨模态协同证据,这促使判别策略从细粒度局部差异转向粗粒度统计趋势,出现性能回弹。最终,各模型准确率在高 σ 区间收敛到一个平台值,反映了网络对随机扰动的抗噪饱和能力及 MFCC 表征内在的结构鲁棒性。

3.2 基于 LMT-108 的 SMEF-TC 分类实验

LMT-108 数据集的泛分类混淆矩阵如图 8 所示。在 LMT-108 上,如果不要求精确到小类,SMEF-TC 的识别准确率接近 100%。




图 8 LMT-108 泛分类混淆矩阵

Fig. 8 LMT-108 coarse-grained confusion matrix

对于同一大类中的不同小类,识别准确率如表 2 所示。木材识别准确率最高,为 100%。其次是纤维,为 98.33%,120 个测试样本中只有 2 个错误分类。识别效果最差的石材类别,也有 91.67% 的分类准确率,整体上展现了该方法良好的分类性能。

表 2 LMT-108 识别准确率		
Table 2 LMT-108 recognition accuracy		
材料	类别数	准确率/%
G1:网状物 (Meshes)	13	96.15
G2:石材 (Stones)	9	91.67
G3:空白光滑表面 (Blank Glossy Surfaces)	9	95.83
G4:木材 (Wood Types)	13	100.00
G5:橡胶 (Rubbers)	5	97.50
G6:纤维 (Fibers)	15	98.33
G7:泡沫 (Foams)	12	97.92
G8:箔纸 (Foils and Papers)	15	95.00
G9:纺织品与布料 (Textiles and Fabrics)	17	95.59

为验证多模态证据融合的优越性,分别单独对 3 个模态进行分类评估,实验结果如表 3 所示。只使用单一

模态的其中一种信息(即未经过模态内多尺度融合阶段)进行分类时,SMEF-TC在多数情况下的性能较差,识别准确率降低,这主要源于输入信息的片面性。在基于不确定性理论的证据融合规则下,该方法在前期融合阶段有效整合模态内多尺度信息,显著提升了单模态的分类能力。SMEF-TC方法在关注不同模态信息联合特征

表达的同时,动态衡量各模态的不确定性。这一机制使得模型在高噪声或部分模态信息缺失的情况下,能够自适应调整决策信賴度,并在最终决策阶段将这些不确定性信息进一步融合,在分类过程中实现精细化的主动修正,避免模态信息的局限性给最终分类结果带来不稳定影响。

表3 LMT-108 单模态与多模态混合融合性能
Table 3 LMT-108 performance of single-modal and multi-modal hybrid fusion

模态尺度	图像		声音				加速度			全部模态/%
	I^{Flash}	$I^{NotFlash}$	I	s^{Move}	s^{Tap}	s	a^{Move}	a^{Tap}	a	
大类	0.79	0.75	0.88	0.82	0.63	0.91	0.85	0.64	0.93	99.65
小类	0.75	0.73	0.85	0.78	0.59	0.86	0.81	0.65	0.87	96.53

3.3 基于 LMT-184 的 SMEF-TC 分类实验

LMT-184 泛分类混淆矩阵如图 9 所示。对于多数大类,SMEF-TC 识别准确率同样接近 100%,表明该方法在较粗粒度分类任务上具有高度稳定的分类能力。




图 10 LMT-184 各类别数占比
Fig. 10 Proportion of each category in LMT-184

表 4 LMT-184 识别准确率
Table 4 LMT-184 recognition accuracy

材料	类别数	准确率/%
C1:木材 (Wood)	88	94.89
C2:可生物降解类 (Biodegradable Types)	24	95.83
C3:聚合物 (Polymers)	18	97.22
C4:陶瓷 (Ceramics)	4	87.50
C5:玻璃 (Glasses)	4	93.75
C6:石材 (Stones)	28	95.54
C7:金属 (Metals)	12	97.92
C8:复合材料 (Composites)	6	75.00




图 9 LMT-184 泛分类混淆矩阵
Fig. 9 LMT-184 coarse-grained confusion matrix

然而,在该实验中,复合材料识别准确率只有 83%,显著低于其他类别。分析此现象,主要原因可能在于数据集类别分布的不均衡。LMT-184 数据集共包含 184 个小类,各大类占比如图 10 所示。显然,C1 木材类别的种数最多,达到 88 种,占据总类别数的 47.8%。如此高的类别占比易导致分类器在训练过程中产生类别偏置,使木材类别在决策过程中被赋予更高的先验概率。数据不均衡导致模型在面对具有某些相似特征的样本时,更倾向于将其归类到类别占比更高的木材类,从而影响其他类别的分类精度,特别是 C8 复合材料类。

对同一大类中的不同小类,识别准确率如表 4 所示。和混淆矩阵显示的结果一致,复合材料识别准确率最低,

仅为 75.00%。这一结果可能是因为:1) 复合材料微观结构呈显著多尺度、多相分布特征,多模态场景下,同一大类内部的信号统计特性易出现较大方差,导致类别内分布高度离散,从而削弱分类器对大类宏观标签的聚类能力;2) 复合材料由多种基材组合而成,相比单一组分材料,在多模态信号上更易与其主导材料产生局部同形

(Homomorphism) 特征,使得模型在识别时倾向于将其归类为该主导材料的类别,无法准确地捕捉复合材料的整体特性。

尽管木材类别在数据集中占比最高,但识别准确率并非最优,模型在处理木材样本时误分类严重。进一步分析发现,软木(Softwood,C1S1)类别的识别偏差尤其明显,45.45%的软木样本被分类为硬木(Hardwood,C1S2)。一方面,可能是实验数据中的软木与硬木在某些纹理或物理特性上具有较高的相似性导致的,因此模型决策边

界模糊;另一方面,类别不均衡问题加剧了误分类的趋势。实验数据中,软木类别仅包含 11 种,而硬木类别则多达 77 种,类别数量的较大差异可能导致模型在决策过程中赋予硬木类更高的先验概率,在辨别软木样本时倾向于将其错误划分为硬木。

如表 5 所示,为了体现多模态融合的优越性,分别对 3 个模态进行评估。受益于不确定性理论驱动的证据融合机制,模态内多尺度融合使信息的互补性充分发挥,有效增强了对单模态信息的判别能力。

表 5 LMT-184 单模态与多模态混合融合性能
Table 5 LMT-184 performance of single-modal and multi-modal hybrid fusion

模态尺度	图像				声音			加速度			全部模态/%
	I^{disp}	I^{macro}	I^{illu}	I	s^{Move}	s^{Tap}	s	a^{Move}	a^{Tap}	a	
大类	0.79	0.83	0.82	0.91	0.79	0.76	0.87	0.88	0.91	0.96	99.05
中类	0.68	0.74	0.72	0.81	0.71	0.67	0.78	0.78	0.81	0.90	96.33
小类	0.62	0.64	0.63	0.73	0.63	0.58	0.71	0.75	0.76	0.83	94.70

4 结 论

传统多模态融合方法通常假设不同样本间各模态数据的质量分布均匀,忽略了模态信息可靠性的动态变化。在数据质量异质性较强的情境下,这类静态融合策略难以适应低质量模态,导致融合过程易受噪声干扰或模态缺失影响,尤其在小样本条件下,会显著削弱分类模型的性能。针对上述问题,提出一种面向小样本纹理分类的多模态证据融合框架(SMEF-TC),采用狄利克雷分布对类别概率以及预测不确定性建模,通过证据理论进行融合,使模型能够自适应地调整不同模态在决策中的贡献。在公开纹理数据集 LMT-108 和 LMT-184 上进行了广泛实验,结果表明,SMEF-TC 在面向小样本纹理辨识任务时,相比现有方法更为有效和稳健。在今后的研究中,可进一步优化模型的类别均衡性,探索更精细化的类别平衡调整机制,结合类别加权策略、数据增强方法或在不确定性估计时考虑类别敏感性,以提升模型在复杂数据分布下的泛化能力。

参考文献

[1] 郭锐,熊风光,谢剑斌,等. 基于改进残差池化层的纹理识别[J]. 计算机技术与发展, 2023, 33(9): 37-44.
GUO R, XIONG F G, XIE J B, et al. Texture recognition algorithm based on improved deep residual pooling layer[J]. Computer Technology and Development, 2023, 33(9): 37-44.
[2] 张剑敏,熊鹏文,韦琦,等. 面向纹理识别的便携式触

觉传感器设计[J]. 仪器仪表学报, 2022, 43(10): 66-73.
ZHANG J M, XIONG P W, WEI Q, et al. Design of the portable tactile sensor for texture recognition[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 66-73.
[3] TANG Z R, ZHOU X CH. Multi-modal medical image fusion based on improved parameter adaptive PCNN and latent low-rank representation[J]. Instrumentation, 2024, 11(2): 53-63.
[4] ZHUANG J J, WU X H, MENG D D, et al. A swin transformer and residual network combined model for breast cancer disease multi-classification using histopathological images [J]. Instrumentation, 2024, 11(1): 112-120.
[5] 陈大鹏,朱栋梁,刘佳,等. 基于振动加速度信息的触觉纹理分类方法研究[J]. 仪器仪表学报, 2023, 44(5): 121-130.
CHEN D P, ZHU D L, LIU J, et al. Research on the tactile texture classification method based on vibration acceleration information[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 121-130.
[6] 欧阳杰,张向文,刘沛钊,等. 基于融合纹理特征的轮胎磨损程度检测方法[J]. 电子测量技术, 2024, 47(17): 155-162.
OUYANG J, ZHANG X W, LIU P ZH, et al. Tire wear degree detection method based on fused offset texture features[J]. Electronic Measurement Technology, 2024, 47(17): 155-162.
[7] 聂东研. 材质表面纹理的触觉识别算法研究[D]. 长

- 春:吉林大学, 2022.
- NIE D Y. Research on haptic recognition algorithm for material surface texture[D]. Changchun: Jilin University, 2022.
- [8] 梁丽媛,陈永当,胡梦麒,等. 基于支持向量机的纹理特征识别方法研究[J]. 智能计算机与应用, 2024, 14(4): 168-172.
- LIANG L Y, CHEN Y D, HU M Q, et al. Research on texture feature recognition based on support vector machines[J]. Intelligent Computer and Applications, 2024, 14(4): 168-172.
- [9] 郭锐. 多特征融合的纹理识别方法研究[D]. 太原: 中北大学, 2023.
- GUO R. Research on texture recognition method based on multi-feature fusion[D]. Taiyuan: North University of China, 2023.
- [10] 陈广秋,温奇璋,尹文卿,等. 用于红外与可见光图像融合的注意力残差密集融合网络[J]. 电子测量与仪器学报, 2023, 37(8): 182-193.
- CHEN G Q, WEN Q ZH, YIN W Q, et al. Attentional residual dense connection fusion network for infrared and visible image fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 182-193.
- [11] 熊鹏文,童小宝,宋爱国,等. 基于变分贝叶斯高斯混合噪声模型的机器人跨模态生成对抗网络[J]. 中国科学:信息科学, 2021, 51(1): 104-121.
- XIONG P W, TONG X B, SONG AI G, et al. Robotic cross-modal generative adversarial network based on variational Bayesian Gaussian mixture noise model[J]. Scientia Sinica Informations, 2021, 51(1): 104-121.
- [12] XIONG P W, HE K F, WU E Q, et al. Human-exploratory-procedure-based hybrid measurement fusion formaterial recognition[J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(2): 1093-1104.
- [13] 李天放,孙一宸,于明鑫,等. 结合语义分割与跨模态差分特征补偿的红外与可见光图像融合方法[J]. 电子测量与仪器学报, 2024, 38(7): 34-45.
- LI T F, SUN Y CH, YU M X, et al. Infrared and visible image fusion method integrating semantic segmentation and cross-modality differential feature compensation[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 34-45.
- [14] 张甜愉,吕博,周蓉,等. 基于多特征融合的唇语识别模型[J/OL]. 电子测量技术, 1-10[2025-05-14].
- ZHANG T Y, LYU B, ZHOU R, et al. Lip-reading model based on multi-feature fusion[J/OL]. Electronic Measurement Technology, 1-10[2025-05-14].
- [15] 司坤宇,牛春晖. 基于混合差分卷积和高效视觉Transformer网络的三重多模态图像融合算法[J]. 红外与激光工程, 2024, 53(11): 331-345.
- SI K Y, NIU CH H. A triple multimodal image fusion algorithm based on hybrid difference convolution and efficient vision Transformer network[J]. Infrared and Laser Engineering, 2024, 53(11): 331-345.
- [16] 沈瑜,刘佳英,闫佳荣,等. 基于局部与全局信息协同的双分支多模态医学图像融合[J]. 光学学报, 2025, 45(8):125-139.
- SHEN Y, LIU J Y, YAN J R, et al. Dual-branch multimodal medical image fusion based on local-global information collaboration[J]. Acta Optica Sinica, 2025, 45(8):125-139.
- [17] 任楚岚,于振坤,关超,等. 基于自适应融合技术的多模态实体对齐模型[J]. 计算机应用研究, 2025, 42(1): 100-105.
- REN CH L, YU ZH K, GUAN CH, et al. Multi-modal entity alignment model based on adaptive fusion technology[J]. Application Research of Computers, 2025, 42(1):100-105.
- [18] XIONG P W, HE K F, SONG AI G, et al. A novel multi-modal one-shot learning method for texture recognition[J]. IEEE Access, 2019, 7: 182538-182547.
- [19] 童小宝,熊鹏文,陈志远,等. 基于自适应多核稀疏表示的机器人触觉物体感知研究[J]. 中国科学:技术科学, 2023, 53(12): 2053-2065.
- TONG X B, XIONG P W, CHEN ZH Y, et al. Robotic tactile object perception based on adaptive multikernel sparse representation[J]. Scientia Sinica Technologica, 2023, 53(12): 2053-2065.
- [20] 郭润泽,孙备,孙晓永,等. 无人机弱光条件下多模态融合目标检测方法[J]. 仪器仪表学报, 2025,46(1): 338-350.
- GUO R Z, SUN B, SUN X Y, et al. Multimodal fusion object detection method for UAVs under low light conditions[J]. Chinese Journal of Scientific Instrument, 2025,46(1):338-350.
- [21] LAKSHMINARAYANAN B, PRITZEL A, BLUNDELL C. Simple and scalable predictive uncertainty estimation using deep ensembles[C]. Neural Information Processing Systems, 2017: 6402-6413.
- [22] SOLEIMANY A P, AMINI A, GOLDMAN S, et al. Evidential deep learning for guided molecular property prediction and discovery[J]. Acs Central Science, 2021, 7(8): 1356-1367.
- [23] 黄雨轩. 基于深度学习的纹理识别研究[D]. 南昌:

南昌大学, 2023.

HUANG Y X. Research on texture recognition based on deep learning [D]. Nanchang: Nanchang University, 2023.

[24] SCABINI L, ZIELINSKI K M, RIBAS L C, et al. RADAM: Texture recognition through randomized aggregated encoding of deep activation maps[J]. Pattern Recognition, 2023, 143: 109802.

[25] SCABINI L, ZIELINSKI K M, KONUK E, et al. VORTEX: Challenging CNNs at texture recognition by using vision transformers with orderless and randomized token encodings[J]. ArXiv preprint arXiv:2503.06368, 2025.

[26] MOON J, KIM J, SHIN Y, et al. Confidence-aware learning for deep neural networks[C]. 37th International Conference on Machine Learning, 2021: 7034-7044.

[27] VAN AMERSFOORT J, SMITH L, TEH Y W, et al. Uncertainty estimation using a single deep deterministic neural network [C]. 37th International Conference on Machine Learning, 2021: 9690-9700.

[28] JØSANG A. Subjective logic: A formalism for reasoning under uncertainty[M]. Springer, 2016.

[29] 李保珍,陈科. 多视角证据融合的新闻新闻甄别[J]. 数据分析与知识发现, 2022, 6(21): 376-384.

LI B ZH, CHEN K. Identifying “fake news” with multi-perspective evidence fusion [J]. Data Analysis and Knowledge Discovery, 2022, 6(21): 376-384.

[30] GAL Y, GHAMRANI Z. Dropout as a bayesian approximation: Representing model uncertainty in deep learning[C]. 33rd International Conference on Machine Learning, 2016: 1651-1680.

[31] DEMPSTER A P. A generalization of bayesian inference[J]. Journal of the Royal Statistical Society: Series B (Methodological), 1968, 30(2): 205-232.

[32] 李学钊,王伟,薛冰. 基于梯度算子和注意力的多模态融合目标检测[J]. 仪器仪表学报, 2024, 45(11): 224-232.

LI X ZH, WANG W, XUE B. Multi-modal fusion object detection based on gradient operator and attention [J]. Chinese Journal of Scientific Instrument, 2024, 45(11): 224-232.

[33] 张中华. 基于纹理力触觉和声音信号的材质表面纹理识别[D]. 长春:吉林大学, 2024.

ZHANG ZH H. Texture recognition on material surfaces based on acceleration and sound information[D]. Changchun: Jilin University, 2024.

作者简介



熊鹏文,2009 年于中北大学获得学士学位,2015 年于东南大学获得博士学位,现为南昌大学教授、博士生导师,主要研究方向为机器人传感与控制。

E-mail: steven.xpw@ncu.edu.cn

Xiong Pengwen received his B. Sc. degree from North University of China in 2009, received his Ph. D. degree from Southeast University in 2015. Now he is a professor and Ph. D. advisor at Nanchang University. His main research interest is robotic sensing and control.



胡慕烨,2024 年于东北大学获得学士学位,现为南昌大学硕士研究生,主要研究方向为机器人触觉感知。

E-mail: humuye2024@163.com

Hu Muye received her B. Sc. degree from Northeastern University in 2024. Now she is a master's student at Nanchang University. Her main research interest is robotic tactile perception.



曾成(通信作者),2011 年于南昌大学获得学士学位,2017 年于华中科技大学获得博士学位,现为南昌大学讲师、硕士生导师,主要研究方向为机器人控制、机器视觉、人机交互及遥操作。

E-mail: chengzeng@ncu.edu.cn

Zeng Cheng (Corresponding author) received his B. Sc. degree from Nanchang University in 2011, received his Ph. D. degree from Huazhong University of Science and Technology in 2017. Now he is a lecturer and master's supervisor at Nanchang University. His main research interests include robotic control, machine vision, human-robot interaction and teleoperation.



叶艳辉,2000 年于中北大学获得学士学位,2006 年于华南理工大学获得硕士学位,2016 年于南昌大学获得博士学位,现为南昌大学副教授、硕士生导师,主要研究方向为焊接机器人机构设计、焊缝智能识别及智能控制。

E-mail: yeyanhui@ncu.edu.cn

Ye Yanhui received his B. Sc. degree from North University of China in 2000, received his M. Sc. degree from South China University of Technology in 2006, received his Ph. D. degree from Nanchang University in 2016. Now he is an associate professor and master's supervisor at Nanchang University. His main research interests include mechanism design of welding robots, intelligent weld seam recognition, and intelligent control.