



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目： 具有自适应特征压缩的纹理描述符
作者： 任海洋，李兴韞，苏杰田，张帅，张海龙，游国栋
DOI： 10.13364/j.issn.1672-6510.20240223
收稿日期： 2024-11-07
网络首发日期： 2026-01-29
引用格式： 任海洋，李兴韞，苏杰田，张帅，张海龙，游国栋. 具有自适应特征压缩的纹理描述符[J/OL]. 天津科技大学学报.
<https://doi.org/10.13364/j.issn.1672-6510.20240223>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。



DOI: 10.13364/j.issn.1672-6510.20240223

具有自适应特征压缩的纹理描述符

任海洋¹, 李兴轹², 苏杰田¹, 张 帅¹, 张海龙¹, 游国栋¹

(1. 天津科技大学电子信息与自动化学院, 天津 300457; 2. 天津科技大学机械工程学院, 天津 300457)

摘要: 随着计算机视觉技术的发展, 纹理特征分析逐渐成为研究热点。针对大多数深度学习方法不能有效进行纹理特征紧凑表示的问题, 提出一种用于纹理特征紧凑表示的描述符。该描述符利用预训练模型(包括 GoogleNet、AlexNet、ResNet、InspectionResNet)执行差异化纹理特征提取, 将这些卷积神经网络获得的特征进行拼接, 通过基于模糊逻辑的自适应特征压缩方法进行动态压缩, 并使用线性支持向量机对纹理特征进行分类。在多个数据集上进行实验, 通过准确率、精准率等指标将该纹理描述符与其他方法进行对比。结果表明, 该描述符在实现纹理特征紧凑表示的同时比其他分类方法更加有效。

关键词: 纹理特征; 卷积神经网络; 模糊逻辑; 线性支持向量机

中图分类号: TP391.41

文献标志码: A

文章编号: 1672-6510 (2025)00-0000-00

Texture Descriptors with Adaptive Feature Compression

REN Haiyang¹, LI Xingyun², SU Jietian¹, ZHANG Shuai¹, ZHANG Hailong¹, YOU Guodong¹(1. College of Electronic Information and Automation, Tianjin University of Science and Technology,
Tianjin 300457, China;

2. College of Mechanical Engineering, Tianjin University of Science and Technology, Tianjin 300457, China)

Abstract: With the advancement of computer vision technology, texture feature analysis has emerged as a research hotspot. Addressing the challenge that most deep learning methods are not effective in compact representation of texture features, a descriptor for compact texture feature representation is proposed. This descriptor employs pre-trained models (including GoogleNet, AlexNet, ResNet, and InspectionResNet) to perform differentiated texture feature extraction. The features obtained from these convolutional neural networks are concatenated and dynamically compressed using an adaptive feature compression method based on fuzzy logic, and a linear support vector machine is utilized to classify the texture features. Experiments are conducted on multiple datasets, comparing this texture descriptor with other methods based on metrics such as accuracy and precision. The results demonstrate that this descriptor is more effective than other classification methods while achieving compact representation of texture features.

Key words: texture features; convolutional neural network; fuzzy logic; linear support vector machine

纹理是物体表面的固有属性, 通过对纹理特征的分析可以对物体进行识别与分类。随着计算机视觉技术的发展, 纹理分析技术已经被广泛应用于多个领域, 如疾病的分级与分类、地理遥感信息处理、材料的缺陷检测等^[1]。在计算机视觉的早期阶段, 主要基于手工设计的特征进行纹理分析。Aouat 等^[2]利用灰度共生矩阵(gray-level co-occurrence matrix, GLCM)计算了图像中像素强度空间分布的统计特性。这种方法计算简单, 但对尺度和方向的变化敏

感。Pan 等^[3]基于局部二值模式设计了自适应中心像素选择(adaptive center pixel selection, ACPS)方法, 该方法提取了更多中心像素以获取特征信息, 并使用梯度提取器获取非均匀模式的边缘图像, 从而提高了分类性能。Yao 等^[4]提出一种结合基于对象的马尔可夫随机场(object-oriented markov random field, OMRF)的分区全局交替更新(partitioned global alternating update, PGAU)技术, 这是一种基于对象的分割模型, 它将原始图像分割成 4 个部分, 从而

收稿日期: 2024-11-07; 修回日期: 2025-12-27

作者简介: 任海洋(2000—), 男, 河南南阳人, 硕士研究生; 通信作者: 游国栋, 教授, yougdong@163.com

可以轻松分类纹理特征。深度学习的出现极大地促进了纹理分析领域的发展。吕伏等^[5]使用卷积神经网络(convolutional neural networks, CNN)自动从数据中学习层次特征,该过程不需要人工设计特征。Patil等^[6]在纹理分析中采用包括 AlexNet、ResNet 和 GoogleNet 在内的多种 CNN 模型,这些模型已成功应用于纹理分类问题,并能够在不同尺度上捕获特征。Tao 等^[7]提出一种小波多级注意力胶囊网络(WMACapsNet),该网络使用胶囊而不是神经元捕获数据中的层次模式,从而在旋转不变性和泛化能力方面得到了改进。

传统方法已经广泛应用于各种纹理分类问题,然而,它们通常需要人工设计的特征。深度学习方法在各种纹理分析任务中的表现出色,但是,大多数深度学习并不适合进行紧凑的特征表示^[8-10]。特征紧凑性是指通过优化特征表示,使特征集包含尽可能少但信息丰富的特征,同时保持对任务的判别能力。深度学习方法通常通过堆叠大量参数学习复杂的特征映射,导致特征表示中隐含大量冗余信息。此外,深度学习方法依赖大规模数据驱动,通过过参数化(模型参数远大于样本量)提升泛化能力;这种设计鼓励模型记忆复杂数据模式而非提炼本质特征,模型会倾向于学习高维、稀疏的判别特征,而非低维、高信息密度的表示,进一步降低特征表示的紧凑性,从而限制了它们在纹理分析中的性能。特征压缩是实现特征紧凑表示的技术手段之一,特征压缩可以将高维特征映射到低维空间,特征的紧凑表示可以去除冗余,提高特征的信息密度,增强模型的泛化能力。因此,本文提出一种高效的纹理描述符,该描述符使用基于模糊逻辑的自适应压缩方法动态地调整压缩级别,从而实现纹理特征的紧凑表示;将多个 CNN 模型输出的纹理特征进行拼接,并使用线性支持向量机(LSVM)进行分类;在多个数据集上的实验证明了本文方法的有效性。

1 数据收集与处理

为了验证本文方法的有效性,实验选用了 KTH-TIPS、OUTEX 和 Kylberg 纹理数据集进行测试与分析。KTH-TIPS 数据集^[11]包含 10 个纹理类别,共有 810 张图像。OUTEX 数据集^[12]包含 24 个类别,共有 960 张图像。Kylberg 数据集^[13]包含 28 个纹理类别,共有 4480 张图像。

数据预处理:将 KTH-TIPS、OUTEX 和 Kylberg 数据集中图像的格式统一转换为 PNG 格式,图像大

小调整为 224 像素×224 像素,像素值归一化为 0~1 的范围内。3 个数据集中的样本按照 4:1 的比例划分为训练集和测试集。

数据增强:在训练过程中对图像进行随机翻转、裁剪和旋转,以此增加样本多样性。

2 纹理描述符

2.1 特征提取模型

本文提出的纹理描述符的整体框图如图 1 所示,它利用了包括 GoogleNet、AlexNet、ResNet 和 InspectionResNet 在内的多种 CNN 模型的优势。AlexNet 通过浅层大卷积核(11×11、5×5)捕获低频全局纹理(如粗粒度条纹、边缘),提供基础物理特征;GoogleNet 的 Inception 模块融合并行多尺度卷积(1×1、3×3、5×5),解决了单一感受野对细密网格、宽条纹等复杂纹理的感知局限,增强中层特征的尺度适应性;ResNet 凭借残差连接和超深结构,提取高阶语义特征(如周期性模式、材质类别),弥补浅层模型对抽象纹理组合的表征不足;而 InspectionResNet 通过局部注意力机制和轻量化设计,聚焦任务相关的关键纹理区域。四者从浅层到深层的特征层次覆盖、从全局到局部的多尺度感知形成协同,增强了对复杂纹理的鲁棒表达。

GoogleNet^[14]通过 Inception 模块捕获跨多个尺度和分辨率的纹理模式。Inception 模块使用 1×1 卷积进行降维,结合具有不同核大小和步长的多个卷积层,使其能够捕获不同尺度的特征。将这些多尺度特征进行拼接,可增强模型有效辨别纹理模式的能力。全局平均池化操作计算每个特征图在整个空间维度上的像素激活值均值。对特征图 F ,全局平均池化操作可以表示为

$$\tilde{F} = \frac{1}{N} \sum_{i=1}^N F_i \quad (1)$$

式中: \tilde{F} 是特征图经过全局平均池化后得到的像素激活值均值, F_i 表示特征图中位置 i 的值, N 为特征图中元素的总数。

AlexNet^[15]可以学习层次特征,因此在纹理特征提取方面表现出色。该模型可表示为一系列带有激活函数的卷积层、用于空间降维的池化层以及用于捕获高级纹理属性的全连接层。全连接层可表示为

$$\mathbf{x}_F = \sigma(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (2)$$

式中: \mathbf{x}_F 为全连接层的输出, \mathbf{x} 为输入向量, \mathbf{W} 为

权重矩阵, \mathbf{b} 为偏置向量, σ 为 ReLU 激活函数。

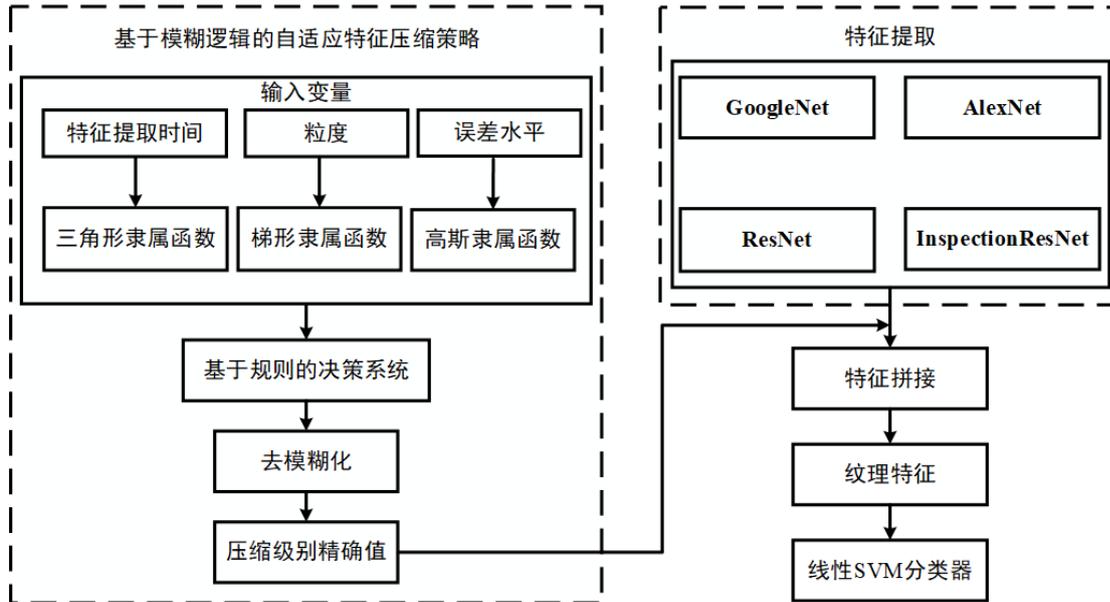


图 1 纹理描述符的整体框图

Fig. 1 Overall block diagram of the texture descriptor

ResNet^[16]通过引入带有跳跃连接的残差块解决梯度消失的问题, 这些跳跃连接允许梯度直接在网络中流动而不会显著衰减。这种架构对构建能够捕获层次特征的极深网络至关重要。残差块可表示为

$$\mathbf{x}_R = H(\mathbf{x}, W) + \mathbf{x} \quad (3)$$

式中: \mathbf{x}_R 为残差块的输出; H 为残差函数, 用于建模残差映射; \mathbf{x} 为残差块的输入; W 为残差块中权重的集合。

InspectionResNet^[17]是 ResNet 模型的一个改进版本, 它在精细特征处理方面表现出色。该模型采用残差块和专为特定区域检测分析而设计的附加层的组合。此外, 该模型还融入了一种注意力机制, 通过这种注意力机制, 模型能够选择性地关注感兴趣的区域。该机制可表示为

$$\mathbf{x}_O = H(\mathbf{x}, W) \cdot \mathbf{x}_A + \mathbf{x} \quad (4)$$

式中: \mathbf{x}_O 为模型在感兴趣区域的输出; H 为一个残差函数, 用于建模残差映射; \mathbf{x} 是残差块的输入; W 表残差块中权重的集合; \mathbf{x}_A 表示注意力向量, 用于调节不同区域的重要性。

使用 $F_G(\mathbf{x})$ 表示 GoogleNet 特征提取函数, 使用 $F_A(\mathbf{x})$ 表 AlexNet 特征提取函数, 使用 $F_R(\mathbf{x})$ 表示 ResNet 特征提取函数, 使用 $F_I(\mathbf{x})$ 表示 InspectionResNet 特征提取函数, 其中 \mathbf{x} 是输入特征。定义 $D(\mathbf{x})$ 为这些模型所提取特征的组合, 其表达式为

$$D(\mathbf{x}) = \begin{bmatrix} F_R(\mathbf{x}) \\ F_A(\mathbf{x}) \\ F_G(\mathbf{x}) \\ F_I(\mathbf{x}) \end{bmatrix} \quad (5)$$

式中: $[\]$ 表示特征拼接。这种方式能够利用模型之间的优势互补, 从而生成一个更加稳健的纹理特征。

2.2 基于模糊逻辑的自适应特征压缩方法

自适应特征压缩方法的核心目标是实现纹理特征的紧凑表示。它提供了根据特定需求(如特征提取时间、粒度以及可接受的误差范围)动态调整特征压缩级别的灵活性。模糊逻辑^[18]是一种在处理不精确性和不确定性方面表现出色的数学方法, 特别适用于复杂的决策制定过程。在自适应特征压缩方法中, 模糊逻辑通过其处理不确定性和模糊性的能力, 使得系统能够根据实时条件动态地调整特征压缩级别。隶属函数定义了输入变量如何映射到模糊集合。

2.2.1 输入变量

本文考虑了 3 个主要的输入变量, 包括特征提取时间(T)、粒度(G)和误差水平(E)。特征提取时间指的是可用于特征提取的时间, 它被分为短、中、长三类, 以反映在不同应用中的时间限制。粒度表示所提取特征的细化程度, 它被分为细、中、粗三类, 代表着纹理特征提取中不同程度的细节。误差水平反映了特征提取结果的变化程度, 它被分为低、中、高三类, 表示输出中允许的误差范围。

2.2.2 隶属函数

对每个输入变量使用特定的隶属函数，以此量化它们与特定类别的关联程度。这些函数将输入值转换为隶属度，范围从 0 (无隶属)到 1 (完全隶属)。特征提取时间的短、中、长类别适用三角形函数，三角形函数因其对称性和线性过渡特性，能清晰划分时间边界(如中时间隶属度快速达到峰值后下降)，契合所提方法对时间的硬性约束要求。特征提取时间的三角形隶属函数图如图 2 所示。

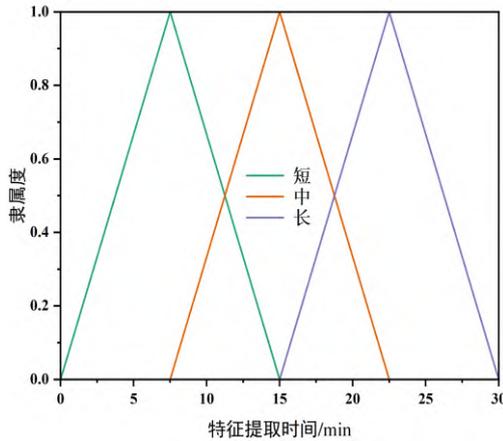


图 2 特征提取时间的三角形隶属函数图

Fig. 2 Triangular membership function graph for feature extraction time

粒度的细、中、粗类别适用梯形函数。粒度在一定范围内波动时，梯形函数顶部平台区能够使隶属度保持稳定，避免分辨率敏感切换，平衡了特征细节与计算效率。粒度的梯形隶属函数图如图 3 所示。

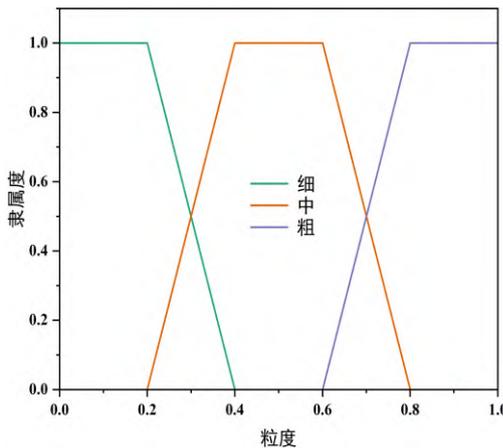


图 3 粒度的梯形隶属函数图

Fig. 3 Trapezoidal membership function graph for granularity

误差水平的低、中、高类别适用高斯函数。误差水平反映了特征提取结果的波动程度，其本质是一个连续的统计量，高斯函数的平滑过渡特性使其

在处理连续变量时更具优势。此外，在实际应用中，误差分布通常符合正态分布规律(即中间密集、两端稀疏的钟形分布)，高斯函数的钟形曲线与这种统计特性高度契合，能够自然地描述误差水平的不确定性。误差水平的高斯隶属函数图如图 4 所示。

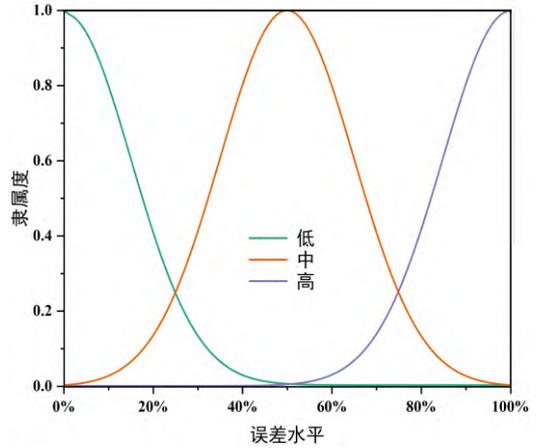


图 4 误差水平的高斯隶属函数图

Fig. 4 Gaussian membership function graph for error margin

2.2.3 基于规则的决策系统

构建一组模糊逻辑决策规则，这些规则明确了输入变量与期望输出(即压缩级别的低、中、高)之间的关系。每条规则都包含了一个条件，并规定了相应的处理流程。这些规则是决策过程的指导原则，使模型能够根据实时输入动态地调整特征压缩级别。这些规则如式(6)、式(7)所示。

$$T \in \begin{cases} \text{短} & 0 < T \leq t_1 \\ \text{中} & t_1 < T \leq t_2 \\ \text{长} & t_2 < T \end{cases} \quad (6)$$

式中： T 为特征提取时间这一输入变量， t_1 、 t_2 为特征提取时间的分类阈值。同理可得对粒度(G)和误差水平(E)的类别分类规则。

$$S_{\text{fuzzy}} \in \begin{cases} \text{低} & 0 < \sum(W_i \times \mu_i) \leq a \\ \text{中} & a < \sum(W_i \times \mu_i) \leq b \\ \text{高} & b < \sum(W_i \times \mu_i) \end{cases} \quad (7)$$

式中： S_{fuzzy} 为输出的模糊压缩级别(低、中、高)； W_i 为每个模糊输出类别的权重； μ_i 为每个模糊输出类别的隶属度； a 、 b 为压缩级别的分类阈值，由式(8)、式(9)得到。

$$a = \frac{1}{3} \sum(\mu_i) \quad (8)$$

$$b = 2a \quad (9)$$

2.2.4 去模糊化

使用去模糊化将输出的模糊压缩级别转换为对应压缩级别的精确值。采用加权平均法,使用每个输出类别的隶属度的加权和计算精确值。去模糊化的公式可以表示为

$$S_{\text{defuzzy}} = \frac{\sum(W_i \times \mu_i)}{\sum W_i} \quad (10)$$

式中: S_{defuzzy} 为对应压缩级别的精确值。

3 实验

3.1 实验设置

实验使用 NVIDIA GeForce RTX 4090 GPU 执行训练过程,采用基于 PyTorch 的深度学习框架,批大小为 128,周期数为 300,使用 Adam 优化器,学习率为 0.001,损失函数使用交叉熵(cross entropy, CE)函数。

3.2 性能指标

采用召回率、准确率、精确率和 F_1 值评估纹理描述符的性能。召回率 (R) 是真正例在所有被预测为正类的样本(即预测为正类的总数)中所占的比例。准确率 S_{accuracy} 衡量的是描述符准确识别类别的能力。精确率 P 是描述符预测为正类的纹理图像中,真正被正确预测为正类的比例,即正确预测的正类数量与纹理描述符做出的所有正类预测总数之比。 F_1 值是精确率和召回率的调和平均数,反映了假正例和假负例之间的权衡情况。

$$R = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \quad (11)$$

$$S_{\text{accuracy}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} \quad (12)$$

$$P = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \quad (13)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (14)$$

式中: N_{TP} 为被正确预测为正类的样本个数, N_{TN} 为被正确预测为负类的样本个数, N_{FP} 为被错误预测为正类的样本个数, N_{FN} 为被错误预测为负类的样本个数。

3.3 性能分析

在 KTH-TIPS、OUTEX 和 Kylberg 数据集上对纹理描述符的性能进行分析,结果见表 1。由表 1 的实

验结果可知,本文提出的纹理描述符在 3 个数据集上均取得了较高的准确率,这验证了该方法在处理不同纹理图像时的有效性与鲁棒性。具体而言,模型在 Kylberg 数据集上取得了最优的分类效果,这主要得益于该数据集较大的样本量使得深度卷积神经网络能够更充分地学习到具有判别力的纹理特征。同时,在样本相对较少的 KTH-TIPS 和 OUTEX 数据集上,该方法依然保持了较高的分类精度,进一步证明了多模型特征融合与自适应压缩策略具有良好的泛化能力,能够适应多变的纹理分类任务。

表 1 纹理描述符在 3 个不同数据集上的对比结果

Tab. 1 Comparison results of texture descriptors across three different datasets

数据集	准确率/%	精确率/%	召回率/%	F_1 值/%
Kylberg	98.24	97.81	96.23	96.87
KTH-TIPS	97.50	96.53	93.36	94.89
OUTEX	96.13	95.97	94.61	95.30

模型在 3 个数据集上的训练损失变化曲线如图 5 所示。从图 5 可以看出,随着训练轮次的增加,训练损失逐渐降低,该图表明所提出的纹理描述符具备高效纹理特征提取的能力。

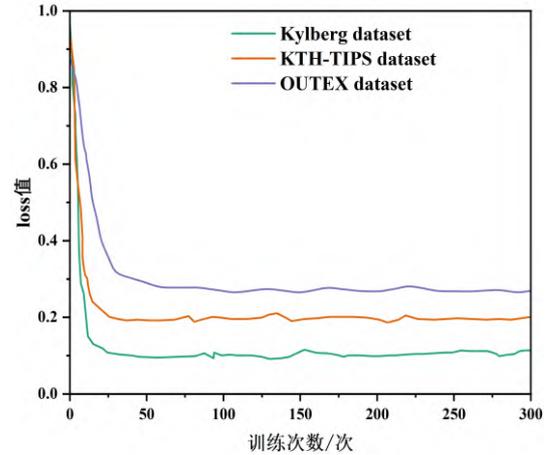


图 5 模型在 3 个数据集上的训练损失变化曲线

Fig. 5 Training loss curves of the model on three datasets

本文提出的纹理描述符采用多种 CNN 模型提取纹理特征,因此在 Kylberg 数据集上使用各种单 CNN 架构和使用纹理描述符的性能进行对比,结果见表 2。由表 2 可知,多种 CNN 架构的组合极大地提高了纹理分类的结果。

表 2 纹理描述符与其他模型的对比结果

Tab. 2 Comparison results of texture descriptors with other models

模型	准确率/%	精确率/%	召回率/%
GoogleNet	85.72	86.81	83.75
AlexNet	88.28	87.36	87.30
ResNet	82.80	83.74	84.53
InspectionResNet	89.61	91.38	90.29
本文方法	98.27	97.84	96.21

为了验证所提出的 4 种模型组合的有效性,在原有 GoogleNet、AlexNet、ResNet、InspectionResNet 这 4 种模型组合(简称 G+A+R+I)的基础上,新增 VGGNet、DenseNet、SENet、MobileNet 这 4 种模型组合(简称 V+D+S+M)进行对比实验,所有实验均基于 Kylberg 数据集,并保持与原模型组合一致的训练参数,结果见表 3。从表 3 中可以看出,相比新组合,原组合在准确率、精确率、召回率和 F_1 值上均取得领先,这是由于新组合中的 VGGNet 和 DenseNet 的深层结构虽然在纹理细节提取方面具有优势,但模型结构复杂且易受噪声影响(如过拟合纹理边缘的局部噪声); MobileNet 的轻量化设计(深度可分离卷积)导致特征维度过度降低,丢失高频纹理细节; SENet 的通道注意力仅调整特征权重,未聚焦空间关键区域,与 InspectionResNet 相比,对纹理位置敏感任务的优化有限。

表 3 不同模型组合的对比结果

Tab. 3 Comparison results of different model combinations

模型组合	准确率/%	精确率/%	召回率/%	F_1 值/%
G+A+R+I	98.24	97.81	96.23	96.87
V+D+S+M	96.50	95.83	94.34	94.67

图像尺寸与光照强度是实际应用场景中影响纹理识别性能的关键变量。其中,输入尺寸的变化本质上改变了图像的空间分辨率,这直接决定了纹理细节的保留程度(低分辨率会导致高频空间信息丢失);而光照强度则通过改变图像的亮度分布与对比度,影响特征的可见性(过暗或过亮均会导致特征失真)。为了评估本文方法在不同条件下的鲁棒性,实验对 Kylberg 数据集中的纹理图像进行处理:在尺寸实验中,采用双线性插值进行下采样,将图像调整为 112 像素×112 像素和 56 像素×56 像素两种尺寸;在光照实验中,通过线性调整像素亮度值(系数分别为 0.5、1.0 和 1.5)来模拟 50%(弱光)、100%(正常)和 150%(强光)3 种光照环境(图 6)。不同输入尺寸与光照强度下的实验结果分别见表 4 和表 5。

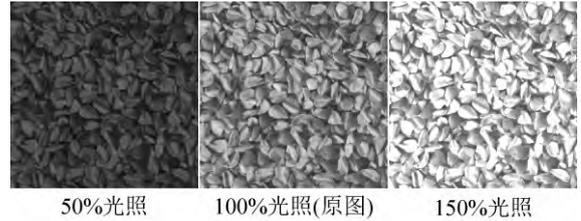


图 6 亚麻籽样本图像的 3 种光照强度

Fig 6 Three types of light intensities for flaxseed sample images

表 4 不同输入尺寸的对比结果

Tab. 4 Comparison results of different input sizes

输入尺寸	准确率/%	精确率/%	召回率/%	F_1 值/%
224 像素×224 像素	98.24	97.81	96.23	96.87
112 像素×112 像素	95.17	94.58	93.72	94.14
56 像素×56 像素	90.32	89.65	88.41	89.02

表 5 不同光照强度的对比结果

Tab. 5 Comparison results of different light intensities

光照强度	准确率/%	精确率/%	召回率/%	F_1 值/%
50%	95.48	94.73	93.96	94.24
100%	98.24	97.81	96.23	96.87
150%	95.83	95.10	94.32	94.32

由表 4 可知,随着输入图像的尺寸从 224 像素×224 像素减小到 112 像素×112 像素和 56 像素×56 像素,准确率从 98.24% 分别降至 95.17% 和 90.32%。当输入尺寸为 224 像素×224 像素时能够充分保留纹理细节,模型利用 CNN 的深层特征(如 ResNet 的高阶语义信息),实现最优性能。当输入尺寸为 112 像素×112 像素时部分细节丢失,准确率下降 3.07%,但仍保持较高性能,说明模型对中等分辨率有一定适应性。当输入尺寸为 56 像素×56 像素时,尺寸的显著降低导致关键信息丢失,准确率下降 7.92%。这是由于过低的空间分辨率导致图像高频纹理细节丢失,且经过 CNN 的多层下采样后,深层特征图的空间分辨率不足,导致关键的纹理结构信息无法被有效表征。浅层模型(如 AlexNet)难以捕获足够的判别性细节特征,而深层模型(如 ResNet)也因有效特征的缺少,导致其深层结构的优势无法发挥。

由表 5 可知,光照强度为 50% 和 150% 时,准确率分别为 95.48% 和 95.83%。在原图的光照条件下,模型通过模糊逻辑压缩有效保留特征判别性。当光照强度为 50% 时,过暗场景导致纹理对比度降低,特征提取难度增加,准确率下降 2.76%。当光照强度为 150% 时,过亮场景使图像泛白,纹理细节模糊,准确率下降 2.41%。这是由于光照变化改变了图像的

亮度分布和灰度统计特性, CNN 虽能学习一定光照不变性, 但模糊逻辑压缩未完全补偿光照引起的特征失真。

3.4 对比分析

将所提出的纹理描述符与其他几种方法进行比较, 以便对纹理描述符的性能进行评估, 这些方法包括: GLCM、ACPS、OMRF-PGAU、WMACapsNet。本文提出的纹理描述符与这些方法, 在 Kylberg 数据集上使用后的对比分析结果见表 6。由于本文提出的纹理描述符在提取纹理特征方面更为有效, 因此它在与多个用于比较的基线方法相比时表现更佳。

表 6 纹理描述符与其他方法的对比结果

Tab. 6 Comparison results of texture descriptors with other methods

方法	准确率/%	精确率/%	召回率/%	F ₁ 值/%
GLCM	85.70	83.82	85.29	83.74
ACPS	90.77	89.37	87.53	92.80
OMRF-PGAU	92.81	89.50	91.03	90.73
WMACapsNet	89.30	88.54	92.11	86.59
本文方法	98.24	97.81	96.23	96.87

本文使用线性支持向量机对纹理描述符提取的纹理特征进行分类, 为了说明其在执行纹理分类方面的效果, 给出了在 Kylberg 数据集上使用线性支持向量机与径向基函数支持向量机(RBF-SVM)、K-最近邻算法(KNN)和随机森林(RF)算法这几种不同机器学习分类器的比较, 结果见表 7。从表 7 可以看出, 线性支持向量机在执行纹理分类方面表现出色, 这得益于其计算效率以及在高维空间中的高效性。

表 7 线性支持向量机与其他分类器的对比结果

Tab. 7 Comparison results of linear support vector machines with other classifiers

分类器	准确率/%	精确率/%	召回率/%	F ₁ 值/%
RF	96.36	96.47	95.92	95.47
KNN	98.13	97.20	95.79	94.19
RBF-SVM	97.24	96.91	95.40	95.91
LSVM	98.24	97.81	96.23	96.87

3.5 消融实验

使用不同 CNN 模型提取纹理特征时的对比结果见表 8。由表 8 可知: 当同时使用 GoogleNet、AlexNet、ResNet 以及 InspectionResNet 进行纹理特征提取时, 所提方法综合利用 4 种模型的优势, 在 Kylberg 数据集上取得最优性能。

表 8 使用不同 CNN 模型提取纹理特征时的对比结果

Tab. 8 Comparison results of texture feature extraction using different CNN models

模型组合	准确率/%	精确率/%	召回率/%	F ₁ 值/%
G	85.63	86.82	83.80	88.51
A	89.16	88.27	87.74	91.67
R	82.93	83.85	85.97	87.36
I	90.13	91.74	91.63	93.25
G+A+R+I	98.24	97.81	96.23	96.87

注: G、A、R、I 分别代表 GoogleNet、AlexNet、ResNet、InspectionResNet。

在 Kylberg 数据集上, 使用不同压缩级别对本文方法进行测试, 结果见表 9。从表 9 可以看出, 当压缩级别为中等时性能表现最好, 这是由于中等压缩级别能够平衡特征维度与判别能力, 低压缩级别虽然保留了更多原始特征, 但冗余信息会对模型的判别能力产生不利影响。高压压缩级别会使特征维度过度降低从而损失判别信息, 导致模型性能下降。

表 9 不同压缩级别的对比结果

Tab. 9 Comparison results of different compression levels

压缩级别	准确率/%	精确率/%	召回率/%	F ₁ 值/%
低	97.82	97.35	95.71	96.52
中	98.24	97.81	96.23	96.87
高	96.58	96.12	94.89	95.49

4 结 语

本文设计了一种纹理描述符, 该描述符将多种 CNN 模型提取到的纹理特征进行拼接并采用基于模糊逻辑的自适应特征压缩方法动态地调整纹理特征压缩级别。在实现了纹理特征紧凑表示的同时, 使用线性支持向量机对最终得到的纹理特征进行分类。通过和其他几种主流方法进行的对比实验证明了该描述符的有效性。该纹理描述符受训练数据的影响较大(如输入图像尺度和光照强度的变化), 因此, 后续仍需一种解决这些限制的技术来进一步增强该纹理描述符的鲁棒性。

参考文献:

- [1] 袁艳鹏,汪宇玲. 纹理特征提取方法综述[J]. 电子技术应用,2023,49 (6):9-17.
- [2] Aouat S, Ait-Hammi I, Hamouchene I. A new approach for texture segmentation based on the Gray Level Co-occurrence Matrix[J]. Multimedia Tools and

- Applications, 2021, 80 (16): 24027-24052.
- [3] Pan Zhibin, Hu Shiqi, WU Xiuquan, et al. Adaptive center pixel selection strategy in local binary pattern for texture classification[J]. Expert Systems with Applications, 2021, 180: 115123.
- [4] Yao Hongtai, Wang Xianpei, Zhao Le, et al. An object-based Markov random field with partition-global alternately updated for semantic segmentation of high spatial resolution remote sensing image[J]. Remote Sensing, 2022, 14 (1): 127.
- [5] 吕伏,韩晓天,冯永安,等. 基于自适应纹理特征融合的纹理图像分类方法[J]. 计算机工程与科学,2024,46(3):488-498.
- [6] Patil D B, Nigam A, Mohapatra S, et al. A deep learning approach to classify and detect defects in the components manufactured by laser directed energy deposition process[J]. Machines, 2023, 11 (9): 854.
- [7] Tao Zhiyong, Wei Tong, Li Jie. Wavelet multi-level attention capsule network for texture classification[J]. IEEE Signal Processing Letters, 2021, 28: 1215-1219.
- [8] 朱贺,杨华,尹周平. 纹理表面缺陷机器视觉检测方法综述[J]. 机械科学与技术,2023,42(8):1293-1315.
- [9] 王军敏,樊养余,李祖贺. 基于深度卷积神经网络和迁移学习的纹理图像识别[J]. 计算机辅助设计与图形学学报,2022,34(5):701-710.
- [10] 梁纬,逯洋,孙卓,等. LNIP 改进算法及其在材料形貌分类中的应用研究[J]. 武汉大学学报(工学版),2023,56(3):353-361.
- [11] Mao Shangbo, Rajan D, Chia L T. Deep residual pooling network for texture recognition[J]. Pattern Recognition, 2021, 112: 107817.
- [12] Yelchuri R, Dash J K, Singh P, et al. Exploiting deep and hand-crafted features for texture image retrieval using class membership[J]. Pattern Recognition Letters, 2022, 160: 163-171.
- [13] 包胜桥,许恢斌,王浩,等. 动态网络分析视角下的纹理分析与分类应用研究[J]. 计算技术与自动化,2021,40(4):84-90.
- [14] 邓宇平,王桂棠. 基于 GoogleNet 网络与残差网络的织物纹理分析[J]. 电子测量技术,2021,44(7):31-38.
- [15] Naik N K, Sethy P K, Devi A G, et al. Hybrid Enhanced Featured AlexNet for Milled Rice Grain Identification[J]. Ingénierie des Systèmes d'Information, 2023, 28(3) :663-668.
- [16] Dinh P H. MIF-BTF-MRN: medical image fusion based on the bilateral texture filter and transfer learning with the ResNet-101 network[J]. Biomedical Signal Processing and Control, 2025, 100: 106976.
- [17] Bagewadi S, Veerashetty S. Fine-grained textural detail enhancement: concatenating convolutional neural network features with adaptive fuzzy logic[J]. Signal, Image and Video Processing, 2024, 18 (5): 4615-4626.
- [18] 周天奕,丁卫平,黄嘉爽,等. 模糊逻辑引导的多粒度深度神经网络[J]. 模式识别与人工智能,2023,36(9):778-792.