

doi: 10.7690/bgzdh.2026.01.004

基于深度学习的系统用房图像快速识别和分类算法

王海燕, 袁新平, 原 野

(云南电网有限责任公司信息中心, 昆明 650500)

摘要: 针对室内图像识别边界相似区域识别模糊导致识别精度较低的问题, 为实现高精度识别, 引入深度学习算法, 对其图像构成像素关系进行全新设计。具体计算过程包括: 基于深度学习的室内图像凹凸关系分析、图像深度学习融合识别、深度学习特征下室内图像分类编码计算 3 部分。通过上述过程实现图像的高精准识别与分类。实验数据对比结果表明: 该算法具备较高的有效性, 满足了应用性相关要求, 符合算法推广相关标准。

关键词: 深度学习; 室内图像; 快速识别; 分类算法

中图分类号: TP391.41 **文献标志码:** A

Fast Recognition and Classification Algorithm For Housing Images Based on Deep Learning System

Wang Haiyan, Yuan Xinping, Yuan Ye

(Information Center of Yunnan Power Grid Co., Ltd., Kunming 650500, China)

Abstract: In order to solve the problem of low recognition accuracy caused by fuzzy recognition of similar areas in indoor image recognition, a deep learning algorithm is introduced to achieve high-precision recognition, and a new design is made for the pixel relationship of the image. The specific calculation process includes three parts: concave-convex relationship analysis of indoor images based on deep learning, image fusion recognition based on deep learning, and indoor image classification and coding calculation based on deep learning features. Through the above process, the high-precision recognition and classification of images are realized. Experimental data comparison results show that the algorithm has high effectiveness, meets the requirements of application, and meets the standards of algorithm promotion.

Keywords: deep learning; indoor image; fast recognition; classification algorithm

0 引言

随着科技的发展, 人工智能在各行各业都得到了广泛应用, 特别是在室内图像识别领域。经过现阶段多种算法的应用反馈分析发现, 当前算法所得识别效果与预期效果均存在不同程度的差距。其问题主要表现在: 当图像数据量较大时, 现阶段采用的多种算法均不同程度存在局部图像像素特征过大, 前景与背景及景物分布之间特征差异无法收敛的现象^[1-2]。虽然诸多学者与相关研究人员提出多种方法, 试图从不同角度入手, 修正识别过程中的各项参量, 收效甚微。通过对以往数据的对比分析发现, 只需采用深度学习一种算法, 便可实现对室内图像的高精度、高准确率识别与分类。关键在于如何设计算法各项参量分类及每层级像素特征关系学习量的配置。针对上述问题, 笔者进行了过程的详细描述, 并通过实验对其可行性进行了验证。

1 算法设计与计算

1.1 基于深度学习的室内图像凹凸关系分析

根据室内图像物体分布明暗关系, 利用深度学

习算法对其明暗关系下图像凹凸关系进行分析, 并以此关系为图像识别依据进行关系划分。为了保证凹凸关系划分精准, 避免图像分布明暗对其凹凸关系的扰动, 在深度学习算法的基础上将室内场景分割法引入深度学习当中, 其目的主要为了避免现有室内图像识别算法存在的问题:

1) 在图像关系处理过程中常规物体明暗关系预知与周边物体之间的噪声界限不明显, 造成噪声边界扰动, 影响图像识别效果。

2) 识别分割过程中, 由于明暗差异值过小, 造成的主体与背景关系划分模糊问题。

针对上述问题, 提出算法具体优化方法。

定义 1: 室内图像表面明暗关系对应凹凸度关联分析。

假定图像中 n_i 、 p_i 与 n_j 、 p_j 分别对应 s_i 与 s_j , $d_{ij}=p_j-p_i||p_j-p_i||$, $d_{ij}=-d_{ij}$, 在次关系下若将 $\kappa(s_i, s_j)$ 视为 s_i 与 s_j 之间的凹凸系数, 则可成立如下关系:

$$\kappa(s_i, s_j) = \frac{1}{2}(n_i \cdot d_{ij} + n_j \cdot d_{ji})。 \quad (1)$$

在此基础上, $\kappa(\cdot, \cdot)$ 所对应系数值域为 $[-1, 1]$ 。

当 $\kappa > 0$ 时, 则代表图像中分布明暗关系量 s_i 与 s_j 可转化为凸关系; 当 $\kappa < 0$ 时, 则可以断定图像中的物体明暗关系量 s_i 与 s_j 之间可转化的关系为凹关系。此时图像中 κ 所对应系数的绝对值大小决定转换凹凸关系后的凹凸系数大小, 即对应绝对值越大, 凹凸关系转换后的凹凸系数值越大, 反之则代表凹凸关系转换后的凹凸系数值越小^[3-4]。当 $\kappa = 0$ 时, 则代表图像中的物体明暗关系量 s_i 与 s_j 处于同一平面中, 不存在凹凸关系, 即可将其按照背景图像进行相似度处理^[5-6]。

定义 2: 表面凹凸系数值大小确定。

假定图像构成像素中 $N(s_i)$ 代表表明暗系数 s_i 相邻的局部像素集合, $s_j \in N(s_i)$, $\kappa(s_i, s_j)$ 代表 s_i 与 s_j 之间的凹凸关系, 若将 $\kappa(s_i)$ 设定为 s_i 的凹凸系数值, 那么可知:

$$\kappa(s_i) = \sum_{s_j \in N(s_i)} \omega_{ij} \cdot \kappa(s_i, s_j)。(2)$$

式中 ω_{ij} 为凹凸转换关系后的图像加权系数, 其对应值大小直接反映凹凸关系转换量 $\kappa(s_i, s_j)$ 对凹凸像素 $\kappa(s_i)$ 的约束关系。

1.2 图像深度学习融合识别

确定室内图像凹凸关系后, 进一步基于深度学习算法, 对其凹凸关系特征量分布情况进行深度融合识别, 通过凹关系像素分布特征与凸关系像素分布特征之间的相互验证, 对其正确分布位置进行判断, 获得准确图像识别结果, 算法流程如图 1 所示。




图 1 图像深度学习融合识别流程

若室内图像识别过程中出现特殊关系像素, 通过常规像素特征识别并未获得满意效果, 则将其特殊关系像素视为图像中的特殊分布像素。已知凹凸关系像素特征与其不存在相同分布特征, 因此在深度学习过程中不需要对其进行另外特殊学习; 若识别过程中室内图像的凹凸关系中不存在特殊像素分布, 此时深度学习需要将已知凹关系特征像素与凸

关系特征像素融合学习, 通过深度学习多模属性对其特征进行学习判断; 若深度学习算法在室内图像中均未能发现凹凸关系特征像素, 说明该区域为背景区域, 其图像像素在同一平面关系中, 无需进行学习。

经过图像凹凸关系特征的深度学习后, 可以得到图像中高维空间层次中的融合像素关系下凹特征 $P = \{p_1, p_2, \dots, p_l\}$ 与高维空间层次中的融合像素关系下凸特征 $V = \{v_1, v_2, \dots, v_l\}$ 。深度学习多属性融合后的特征向量 D 由上述 2 组向量融合所得, 其融合公式为:

$$D = [P, V]。(3)$$

特征向量 D 通过深度学习算法中 Softmax 分类器对其加以分类决策^[7-8]。Softmax 的输出量对应室内图像中具体像素关系分布正确识别的判别概率^[9-10]。设室内图像像素特征的融合标签为 $y \in \{1, 2, \dots, n\}$, 共包含 n 个系数值, 即代表存在 n 种像素分布关系, 对于某特定分布关系像素区域 x , 其识别结果隶属于状态 a 的识别条件判别概率为:

$$p(y = a | x) = \text{soft max}(z_a^T) = \frac{\exp(z_a^T x)}{\sum_{a=1}^n \exp(z_a^T x)}。(4)$$

式中 z_a 为 a 种像素分布关系的加权系数。

进一步深度学习决策输出的函数表达为:

$$\hat{y} = \arg \max_{a=1}^n p(y = a | x)。(5)$$

为了防止深度学习融合识别过程中出现过拟合现象, 决策分类器在深度决策过程中全新引入 L_2 指标范数^[11-12], 以此确保深度学习融合识别的效率, 引入量关系式为:

$$R(Z) = \|Z\|_2^2 = \sum_i |Z_i|^2。(6)$$

式中 Z 为输出结果的加权系数。

1.3 深度学习特征下室内图像分类编码计算

考虑到识别图像结果的准确度会受不同噪声影响, 因此对其识别结果进行深度学习下的分类编码计算, 通过深度学习图像特征, 构建差异化噪声编码器, 以此实现对识别结果的噪声去除, 获得更为精准的识别结果。具体操作为:

1) 凹凸深度学习自编码器。根据现有图像凹凸深度学习特征数据, 从识别结果的稳定性入手, 针对深度学习过程中隐藏层结构中噪声关联约束, 通过引入原始图像像素信息, 人为引入部分像素噪声

片段，以此获得与隐藏层中噪声结构的差异特征，从而迫使识别结果的原始学习数据将其输入段信息加以重新分布，打破原有学习状态下的原始编码器结构及其限制，在保证输出稳定的基础上，在 MNIST 数据集^[13]上将原始室内图像的学习特征量 x ，融入噪声特征片段后载入 $\tilde{x}$ ，重新构建信息识别载入流 y ，生成包含噪声片段特征的原始图像映射信息 $\tilde{x} \sim q_D(\tilde{x}|x)$ ，偏置系数关系下的编码器函数可以表达为：

$$J_{\text{DAE}}(W, b) = \sum E_{\tilde{x} \sim q_D(\tilde{x}|x)} [L(x, y)]. \quad (7)$$

2) 多属性噪声堆叠编码器。

3) 考虑到深度学习过程中层级数量与其图像识别难易程度相关联，则噪声存在层级数量和多层级分布且重叠分布的情况。针对此类情况，通过深度学习样本中的噪声片段属性堆叠计算，可以有效去除该状态下的全局噪声，提升室内图像识别与分类的精准度。多属性噪声堆叠编码器的网络结构如图 2 所示。




图 2 多属性噪声堆叠编码器的网络结构

为了更好地处理堆叠编码器中的噪声特征片段，通过其噪声能量 RBM 模型作为优化基础模型^[14]。假设其中包含有 m 个已知优化单元与 n 个未知隐藏优化单元，可得噪声编码器的内核能量函数：

$$E(v, h|\theta) = -\sum_{i=1}^m b_i v_i - \sum_{j=1}^n c_j h_j - \sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j. \quad (8)$$

式中： $i, j, v_i \in \{0, 1\}$ ； v_i 为第 i 个已知优化单元的状态； h_j 为第 j 个未知隐藏优化单元的状态 $h_j \in \{0, 1\}$ ； w_{ij} 为 v_i 与 h_j 之间的关系加权系数； v_i 与 h_j 分别为第 i 个已知优化像素点与第 j 个未知隐藏优化像素点的误差系数。

在此基础上，进一步计算 (v, h) 的联合分布编码属性函数：

$$P(v, h|\theta) = \frac{e^{-E(v, h|\theta)}}{Z(\theta)}, \quad Z(\theta) = \sum_{v, h} e^{-E(v, h|\theta)}. \quad (9)$$

可得多属性噪声堆叠编码器似然函数：

$$P(v|\theta) = \frac{1}{Z(\theta)} \sum_h e^{-E(v, h|\theta)}. \quad (10)$$

式中 $Z(\theta)$ 为噪声归一化参量。

根据计算可知，所得系数值越大，表明编码器中包含的噪声特征片段信息数量越多，所得到的噪声优化效果越好。考虑到 $Z(\theta)$ 的引入会直接影响 (v, h) 的联合效果，因此在该阶段编码器属性数量配置上，仅采用一种能量模型作为深度学习基础模型，以此减轻深度学习难度，根据研究指出，其学习采样步值 $k=1$ 时^[15]，所得编码其噪声优化效果所对应的图像识别与分类效果最好。

2 应用测试

通过对比测试实验对提出算法的有效性及其性能可靠性进行测试。设置实验中共计包含验证组与对比组 2 个实验组；验证组由提出方法独立构成；对比组考虑到测试结果的客观性与可靠性，选取基于大数据的图像特征识别算法与边缘差异特征的图像分类算法组成对比组。为了测试过程中叙述方便，分别标记为 E_1 、 E_2 ，对比测试条件下，不同方法的图像识别结果。

2.1 测试样本设定

如图 3 所示，随机抽取 4 张不同的室内图像作为测试样本，测试过程中的测试条件参量由测试工具随机统一配置，以此保证测试结果具有较高的可靠性。




图 3 样本图像

2.2 识别噪声影响测试

分别由验证组与对比组算法对其样本图像进行识别，将识别过程中 0~80 ms 的噪声影响数据分离出来，并生成噪声影响曲线，如图 4—6 所示，根据对比曲线状态，得出测试结论。





图 4 对比组 E_1 噪声影响测试结果图 5 对比组 E_2 噪声影响测试结果

图 6 验证组噪声影响测试结果

根据图 4—6 曲线对比分析:

1) 图 4(a)中噪声曲线波动较大,说明噪声在图像明暗空间中的分布跨度较大,其算法对其抑制不足,因此所受影响较大;

2) 图 4(b)中噪声曲线可以看到明显的收敛痕迹,但是噪声振幅之间的差值较大,说明算法在对噪声抑制过程中存在局部噪声分布特征未识别,因此局部所受影响造成整体噪声控制量下滑,影响范围增大;

3) 图 4(c)中噪声曲线可以看到,该曲线数值分布跨度巨大,说明图像明暗差异较大,同时包含的噪声总量较多,其噪声分布范围已经超出历史控制范围的 47.6%,因此对比组 E_1 算法对该图像的噪声控制效果最差;

4) 图 4(d)中噪声曲线振幅值域分布明显降低,说明 E_1 算法对其抑制相对充分,但后期波动有所增长,表明其噪声控制稳定性欠佳,因此噪声影响范围具有不确定性;

5) 图 5(a)中噪声曲线可以看到, E_2 算法相对 E_1 算法的噪声控制效果有所提升,噪声影响范围最大值对应振幅降低明显,但整体振幅小范围频繁抖动仍然存在,因此其受噪声影响的问题仍然存在;

6) 图 5(b)中噪声曲线可以看到,曲线幅值差异增大,表明 E_2 算法对其噪声存在大范围识别的问题;

7) 图 5(c)中噪声曲线与 E_1 算法曲线记忆保持一致,说明 E_2 算法存在 E_1 算法相同问题,但仔细观察可以发现,整体噪声曲线特征相同的情况下,其幅度有所减小,表明 E_2 算法相较 E_1 算法其特征参量取值窗口更大,但终究未达到噪声全局抑制标准;

8) 图 5(d)中噪声曲线可以看到其情况同上述 7) 分析,因此 E_2 算法该图像噪声影响测试结果为噪声控制局部缺失;

9) 图 6(a)中噪声曲线可以清楚发现,其曲线波动呈平缓状态,振幅间差值波动在可控范围内,表

明验证组算法在图像样本 1 中获得了良好的噪声控制效果；

10) 基于图 6(a)的分析,整体分析图 6(b)、6(c)、6(d)中噪声曲线可以发现,其曲线振幅特征基本一致,噪声分布值域范围明显收窄,整体噪声收敛明显,且在 4 组不同图像特征下获得统一效果,表明验证组算法具有较为稳定的噪声控制能力,为高精度识别奠定数据基础。

综上所述,在该测试项目中,验证组表现最佳,通过该项目测试。

2.3 识别分类结果可信度测试

为了验证提出算法应用效果的稳定性,采用可信度作为判定指标,在指定图像样本中,利用仿真测试工具分别将 4 组图像根据像素特征分割为 24 块子图像样本,并打乱排序位置,以随机的方式下发至验证组与对比组进行识别,识别结果各自对应子图像块序号,具体结果如表 1 所示。

表 1 识别分类结果可信度测试				%
子图像块序号	深度学习算法	E_1 算法	E_2 算法	
A_1	99.70	87.60	84.20	
A_2	99.80	87.50	82.50	
A_3	99.70	87.60	81.20	
A_4	99.70	86.50	81.30	
A_5	99.60	84.50	88.60	
A_6	99.80	86.20	84.20	
B_1	99.70	84.20	87.60	
B_2	99.80	82.50	86.50	
B_3	99.70	81.20	84.50	
B_4	99.70	81.30	86.20	
B_5	99.60	88.60	84.20	
B_6	99.80	84.20	82.50	
C_1	99.70	83.40	85.20	
C_2	99.80	82.70	79.50	
C_3	99.70	85.20	78.90	
C_4	99.70	79.50	78.70	
C_5	99.60	78.90	79.50	
C_6	99.80	78.70	84.20	
D_1	99.70	79.50	82.50	
D_2	99.80	84.20	85.20	
D_3	99.70	87.60	79.50	
D_4	99.70	78.20	78.90	
D_5	99.60	77.40	78.70	
D_6	99.80	72.60	84.20	
可信度($\Delta=1.0$)	0.97	0.78	0.75	

根据表 1 数据分析可知:经过多组图像特征的压力测试,验证组所代表的深度学习算法的图块识别率最高,对应可信度值最接近指标值 1.0;相比之下,验证组中的 E_1 与 E_2 算法均存在识别误差偏大的问题,印证了测试项目的结果。在此环节测试中所得结果,可以证明验证组算法识别结果具有较高的可信度。

2.4 识别效果测试

基于验证组与对比组各自算法,样本图像的识

别效果如图 7—9 所示。




图 7 对比组 E_1 识别效果对比




图 8 对比组 E_2 识别效果对比




图 9 验证组识别效果对比