

基于深度学习的甲骨文图像检测与识别创新应用及改进研究

王泽鑫, 童恒建

(中国地质大学(武汉)计算机学院, 湖北 武汉 430074)

摘要: 甲骨文图像样本量稀少、细节复杂,且分为临摹和拓片两种图像,其检测与识别难度较大。为此,提出一种基于深度学习的甲骨文图像检测与识别方案。具体来说,针对样本量稀少的问题,提出字体图像类的数据增强WDA算法和拓片化处理过程;针对拓片甲骨文字检测数据集的空白,构建Oracle-Detect数据集;针对传统模型识别率低、难以增量识别的问题,提出基于Stacking的集成式甲骨文字识别模型。实验结果表明,该方案对甲骨文的检测mAP达到94%,在临摹甲骨文字识别任务上的准确率达到83%,对拓片甲骨文字的识别准确率达到81%。

关键词: 甲骨文;深度学习;模型集成;数据增强处理

DOI: 10.11907/rjdk.251006

扫描二维码阅读全文:

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)004-0162-06



Innovative Applications and Improvements of Deep Learning in the Detection and Recognition of Oracle-bone Character Images

WANG Zexin, TONG Hengjian

(School of Computer Science, China University of Geosciences, Wuhan 430074, China)

Abstract: The sample size of oracle bone script images is scarce, with complex details and divided into two types: sketches and rubbings, making their detection and recognition particularly challenging. To address this, a deep learning-based detection and recognition solution for oracle bone script images is proposed. Specifically, to tackle the issue of limited sample sizes, a font-image class data augmentation algorithm (WDA) and a rubbing processing procedure are introduced. To fill the gap in the dataset for detecting oracle bone script on rubbings, the Oracle-Detect dataset is constructed. To overcome the low recognition rates and difficulties in incremental recognition of traditional models, a Stacking ensemble-based oracle bone script recognition model is improved. Experimental results demonstrate that this solution achieves a detection mAP of 94% for oracle bone script, an accuracy rate of 83% in recognizing sketch-based oracle bone script, and an accuracy rate of 81% in identifying rubbing-based oracle bone script.

Key Words: oracle-bone characters; deep learning; model integration; data augmentation processing

0 引言

甲骨文是中华文化的瑰宝,见证着五千年文化传承^[1]。习总书记曾指出要重视发展具有重要文化价值和传承意义的“绝学”、冷门学科,如甲骨文等古文字研究等^[2]。然而甲骨文的研究门槛较高,利用计算机技术进行辅助研究不仅能降低普通爱好者的学习难度,而且可以为

甲骨学专家提供专业帮助。

随着计算机视觉技术的发展,怎样使计算机像处理现代文字图片一样处理甲骨文字成为计算机学者和文字语言学者共同关注的课题^[3]。国际上在古文字识别领域取得了显著进展,已成功将计算机技术应用于古埃及象形文字、古代楔形文字等自动识别与分类中。然而,关于甲骨文的许多研究还主要集中在数据预处理与特征提取方面。例如,李锋等^[4]将甲骨文视为由“线”和“点”构成的无向图,

收稿日期: 2025-01-03

作者简介: 王泽鑫(2000-),男,中国地质大学(武汉)计算机学院硕士研究生,研究方向为深度学习、甲骨文图像处理、集成学习;童恒建(1970-),男,博士,中国地质大学(武汉)计算机学院教授、硕士生导师,研究方向为机器学习、深度学习、遥感图像处理与分析、小样本学习、模糊逻辑。本文通讯作者:童恒建。

基于图论实现了二级和三级甲骨文的识别。吕肖庆等^[5]提出一种基于曲率直方图的傅里叶描述子,其具有平移、旋转、尺度不变性,能够较好地实现甲骨文的自动分类。Meng等^[6]设计了一个两阶段识别系统,用于识别约3 000年前刻在牛骨或龟甲上的甲骨文。该系统首先进行降噪处理并提取骨架和线条特征(线点),随后通过两阶段识别流程完成甲骨文的识别。以上方法需要研究者具备甲骨文相关知识,且在少量数据集上进行,稳定性、准确率和增量泛化能力无法满足实际需求。

近年来,卷积神经网络(Convolutional Neural Network, CNN)在图像分类任务中大放异彩,其成功应用极大简化了传统人工特征提取的繁琐流程。受此启发,研究者们开始尝试将CNN引入甲骨文识别任务中。在处理甲骨文时,学者们不再局限于以图论或单个字符为处理对象,而是直接将整个甲骨文图像作为输入。在图像处理领域表现卓越的经典CNN模型,如VGG、ResNet等,在甲骨文识别与分类中均取得了令人满意的效果^[7-8]。此外,随着注意力机制被引入CNN,其凭借能够捕捉图像中长距离依赖关系的独特优势,可有效提取甲骨文复杂的笔画结构以及丰富的细微特征。例如,张颐康等^[9]提出一种基于跨模态深度度量学习的甲骨文字识别方法,通过构建共享特征空间并应用最近邻分类实现了拓片甲骨文与临摹甲骨文之间的跨模态识别。毛亚菲等^[10]提出一种基于改进ResNeSt网络的甲骨文字识别方法,解决了拓片甲骨文字识别中局部细节特征提取能力弱、对部分高相似度甲骨文字识别率较低的问题。

甲骨文作为古老文明的珍贵载体,其检测与识别对于历史文化遗产意义重大。然而,甲骨文数据样本稀缺,且抽象文字识别复杂、增量识别难,这一系列问题严重制约了甲骨文的研究进展^[11]。为此,本文首先针对数据样本量稀少的问题,对收集到的甲骨文字符图像进行WDA(Writing Data Augmentation)和拓片化算法处理,并创建一份高质量的甲骨文检测数据集Oracle-Detect;其次,针对抽象文字识别复杂、难以增量识别的问题,提出基于Stacking的集成模型。本文研究为甲骨文图像的检测与识别提供了较为完整的方案。

1 甲骨文图像特征

甲骨文具有强烈的图画性,由于字体尚未完全定型,文字部分的位置关系经常变化,导致大量异体字出现,有些形似度甚至超过同字的异体字,且笔画粗细不一、黏连,增加了特征提取的难度。此外,由于保存数量有限,可用于检测与识别的样本集非常稀缺,文字出现频率极不平衡,稀有字可能被计算机误判为噪声。甲骨文载体极为脆弱且珍贵,通常使用拓片切片或学者整理的字模作为样本集,依此分为临摹甲骨文图像(见图1)和拓片甲骨文图像(见图2)^[12]。



Fig. 1 Copying oracle bone script images

图1 临摹甲骨文图像




Fig. 2 Rubbings of oracle bone script images

图2 拓片甲骨文图像

2 数据集构建与预处理

2.1 WDA算法

临摹图像由专家根据原始拓片绘制,数据集容易获得,且图像的字体线条均较为清晰,但其存在一些问题:首先是数据样本类别稀缺,许多甲骨文临摹文字中有重复数据;其次是甲骨文字符由线条笔画构成,现有深度学习方法在对其进行处理时往往未能充分利用字符的笔画信息,而传统方法在挖掘笔画信息方面能力有限,成本较高。为解决这些问题,本文提出一种新的数据增强算法WDA,其基于自由形变(Free Form Deformation)的方法(见图3),既关注了线条笔画信息,又减轻了语义损失,从而在有限的样本下也能训练出强大的识别模型^[13]。




Fig. 3 Schematic of free deformation

图3 自由形变示意

对于每张临摹图像,首先利用网格将其划分为多个局部小图像,从而建立局部坐标系。将网格的顶点作为控制点,定义相邻像素的局部位置;其次,生成随机偏移量来移动这些控制点,从而带动相邻像素移动。由于这些控制点会随机偏移,图像的局部信息被扰动和修改,产生了不同的局部变化。

如图4所示,WDA算法主要分为4个步骤:

(1)网格坐标初始化。通过控制点 $\Phi = \{\phi_{i,j}\}$ 在原始图像上覆盖一个网格,网格大小即为控制点数量,其是一个可调的参数(如3×3、5×5、7×7)。

(2)随机偏移量生成。为每个控制点生成随机偏移量,这些偏移量通过在最小与最大偏移值之间的均匀分布中采样得到。最大偏移值是一个超参数,用于控制变形的

程度。随机偏移量表示为:

$$O = [O_{\min}, O_{\max}] \quad (1)$$

(3)原始图像变形。根据生成的偏移量重新计算图像中每个顶点的坐标,并构造出变形后的图像。表示为:

$$T: (\chi_{\phi_i}, \chi_{\phi_j}) \rightarrow (\chi_{\phi_i} + \Delta\chi_{\phi_i}, \chi_{\phi_j} + \Delta\chi_{\phi_j}), \Delta\chi_{\phi_i}, \Delta\chi_{\phi_j} \in O \quad (2)$$

(4)增强图像生成。对于每个原始训练图像,生成其多个WDA增强的图像,并添加到训练集中。表示为:

$$T: (\chi_1, \chi_2) \rightarrow (\chi_1^*, \chi_2^*) \quad (3)$$




Fig. 4 Schematic of WDA algorithm

图4 WDA算法示意

经过WDA算法处理,临摹字的线条笔画随机形变,但保持整体结构信息。在原数据集的基础上生成30倍左右数量的增强图像用于训练深度网络,模型能够学习到甲骨文丰富的线条笔画信息,进而缓解大量重复数据带来的偏差和过拟合问题。

2.2 数据集构建与拓片化处理

拓片图像是直接来自甲骨或龟甲等载体上获取的原始图像,保留了最真实的文字形态和细节,但存在大量噪声,这些噪声与原始的甲骨文刻痕混在一起,难以分辨甲骨文的原始样貌,因此需要先进行甲骨文检测与标注,再将甲骨文单独分割出来进行识别。由于拓片甲骨文检测标注困难,没有太多可以参考的数据集,本文借助SAM(Segment Anything)大模型在训练时通过大规模数据集和半自动数据引擎构建其数据集的思想,利用“全人工一半人工半模型—全模型”3个步骤标注了一个高质量的甲骨文检测数据集Oracle-Detect^[14]。示例见图5。

在检测任务训练初期进行人工对比,标注检测框,并训练检测模型。在任务中期,采用检测模型标注加入工




Fig. 5 Example of Oracle bone inscriptions detection dataset Oracle-Detect

图5 甲骨文检测数据集Oracle-Detect示例

查的方式继续进行数据集构建。在任务后期,利用模型直接检测拓片并提取出坐标信息。数据集详细组织格式见表1。

Table 1 Detailed organizational format of Oracle-Detect dataset

表1 Oracle-Detect数据集详细组织格式

基本信息	文件组织	标注信息
名称: Oracle-Detect	一级目录	-train 标签参数: 0/1
规模: 9 134 幅		-valid 标注框参数: 左上
用途: 检测	二级目录	-lables 点坐标(x,y); 标注框
类型: 拓片甲骨文		-images 相对图片位置(长,宽)

此外,由于拓片甲骨文样本绝大多数未被破译,其数据量很小,深度学习模型很难学习到文字特征,本文对临摹数据集进行拓片化数据增强。具体示例见图6。具体步骤为:①使用仿射变换或透视变换调整临摹甲骨文图像,对其进行拉伸、旋转或平移,使其在视觉上更接近拓片甲骨文图像的形状和布局;②通过添加高斯噪声来模拟拓片甲骨文图像的老化和损坏情况,包括随机噪声和纹理噪声,同时使用纹理合成将临摹甲骨文图像的平滑表面变为具有真实拓片质感的纹理表面;③通过添加裂痕、划痕、磨损以及调整图像颜色,使临摹甲骨文图像看起来更加接近实际的拓片甲骨文图像。

拓片化处理可将临摹甲骨文图像增强为拓片甲骨文图像,不仅扩展了拓片甲骨文样本量,而且降低了样本量差异,有效提高了模型在识别任务中的准确性和泛化能力。



Fig. 6 Example of "yuan" topology

图6 “元”拓片化示例

3 基于Stacking的集成识别模型

很多学者在图像研究中更关注于改进单一模型架构,并不热衷于进行模型集成。然而,在对深度模型逐层可视化的过程中发现,不同层、不同类型模型的关注视野完全不同,有着不同的学习模式。因此,本文在不同类型模型之间采用创新的集成策略。与单一模型相比,集成模型拥有更强的非线性表达能力和学习能力^[15]。集成策略有助于减小不同模型的泛化误差,在一定程度上降低模型学习的偏差和方差,从而增强其增量学习的能力。

传统的Stacking策略具有分层的框架结构,融合了多个基模型和元模型的学习能力(即模型的关注视野),其通过训练元模型聚合多个模型的关注视野,而不是简单利用单一函数去聚合一些独立模型。在传统的集成过程中,基模

型的预测结果成为元模型的训练数据,相应地分为基模型层和元模型层。由于传统模型的性能限制,每一个元模型的输入都是取基模型输出的平均,这种平均权重的方式会导致元模型学习不到最优基模型的关注视野。传统的Stacking集成策略已无法满足性能需求,因此本文提出创新集成策略,构建了基于Stacking的集成识别模型,结构见图7。




Fig. 7 Integrated recognition model based on Stacking

图7 基于Stacking的集成识别模型

3.1 集成策略

3.1.1 数据集

将现有数据集(包括增强后的数据)分为训练集、验证集和测试集,作为基学习层的输入,采用 k 折交叉的方式对训练集进行重复采样。

3.1.2 基学习层

ResNet引入了残差连接,长距离学习能力使其成为一个强有力的基模型,可自动学习到不同方向和尺度的特征组合,进而提取到不同甲骨文图像更具区分性的特征。Vision Transformer可通过自注意力机制更好地建模甲骨文图像的全局结构。Swin Transformer可通过窗口的平移机制获得全局信息,如笔画的形状、间距。

3.1.3 融合层

卷积式学习器接收F1和F2作为输入。甲骨文字符由多个部件组成,具有一定的局部结构性,卷积式学习器强调对局部特征的提取和对图像局部结构的学习。注意力学习器接收F3和F4作为输入,通过注意力机制捕捉图像中的全局特征,建模不同位置之间的长距离依赖关系,从而更好地学习复杂的笔画和结构关系。

3.1.4 元学习层

融合层的预测结果 $\{F1_a, F1_b\}$ 通过结合基学习层的原始标签得到新的训练数据样本,将其作为元学习层的输入数据来训练元学习器。元学习器可以学习到新的数据特征,纠正之前的算法偏差。同时,该层聚合了卷积式学习器的局部视野和注意力学习器的全局视野,拥有更强的表达能力和泛化能力。经过学习的元学习器输出最终预测结果。如图8所示,元学习器为前馈神经网络,结构与融合层的两个学习器相同(融合层学习器未使用softmax作为激活函数),输入层维度为2d,经过两个隐藏层网络,第一层任务适应层采用ReLU作为激活函数,降维传递至

第二层全连接层。




Fig. 8 Meta learner network architecture

图8 元学习器网络结构

3.2 集成加权改进

在Stacking集成方法中,基学习器的输出通常通过加权平均的方式进行组合,权重选择过于固定、简单,不考虑模型之间的相关性和样本的差异性,存在很大的局限性。为此,本文提出一种基于模型表现的加权(Performance-Based Weighting, PBW)Stacking集成算法。PBW是一种简单有效的集成学习策略,主要根据各个基学习器(模型)在任务上的性能来动态调整其权重,即表现较好的模型会被赋予更大权重,反之则会得到较小的权重。

PBW针对每个基学习器在验证集上的表现(融合层和基学习层的加权算法相同)计算每个模型的权重。假设有 n 个基模型,每个基模型的性能指标为 P_i ,则其权重 ω_i 的计算公式为:

$$\omega_i = \frac{P_i}{\sum_{j=1}^n P_j} \quad (4)$$

式中: P_i 为基学习器 i 的性能指标(如准确率、F1分数等); ω_i 为基学习器的权重。通过这种方法将每个基学习器的权重标准化,使得所有模型的权重之和为1。

在加权过程中,为每个评估指标分配一个权重。本文主要针对准确率、F1分数、召回率分配权重,然后计算综合性能。公式为:

$$P_i = \alpha \cdot Accuracy_i + \beta \cdot F1score_i + \gamma \cdot Recall_i \quad (5)$$

式中: α, β, γ 为权重系数,用于控制各个指标的重要性。

每个模型的预测结果(即预测类别)会根据其权重进行加权,最终预测类别由加权投票结果决定。计算公式为:

$$y_{final} = \operatorname{argmax} \left(\sum_{i=1}^n \omega_i \cdot f_i(x) \right) v \quad (6)$$

式中: $f_i(x)$ 为基模型 i 对输入 x 的预测概率; ω_i 为该模型的权重; y_{final} 为最终预测类别。

在加权预测的过程中发现,某些模型对于特定类别甲骨文字符的识别与分类更具优势。在这种情况下需要进一步优化基学习器的选择和权重计算方式,确保每个基学习器的贡献得到充分发挥,进而提高整体识别准确性。

4 实验方法与结果分析

4.1 实验环境与参数设置

本文实验在4张NVIDIA TESLA V100S 32 G GPU上进

行计算加速,128 GB内存,Ubuntu18.04操作系统上进行,模型实现统一使用编程框架Pytorch。模型训练参数设置见表2。在识别模型的集成加权改进中,经过实验调试的PBW参数见表3。

Table 2 Model training parameter settings

表2 模型训练参数设置

网络模型	Batch size	epochs	Learning rate	Optimizer
检测模型 YOLOv5	32	150	0.001	AdamW+cosine LR 调度器
基模型 ResNet(101)	16	100	0.000 1	Adam
基模型 ResNest	16	100	0.000 1	LARS
基模型 Vision Transformer	16	120	0.000 1	LAMB
基模型 Swin Transformer	16	120	0.000 1	AdamW
卷积式学习器	16	120	0.001	AdamW
注意力学习器	16	120	0.001	LAMB
元学习器	32	120	0.001	AdamW

Table 3 PWB parameters

表3 PWB参数

融合学习器	上一层学习器	α	β	γ	ω_i
卷积式学习器	ResNet101	0.45	0.35	0.20	0.565
	ResNest	0.45	0.35	0.20	0.435
注意力学习器	Vision Transformer	0.50	0.30	0.20	0.496
	Swin Transformer	0.60	0.20	0.20	0.504
元学习器	卷积式学习器	0.50	0.25	0.25	0.486
	注意力学习器	0.50	0.25	0.25	0.514

4.2 数据集

考虑到标注质量、样本平衡性、图像质量等因素,对数据集进行筛选,最终获得本实验所用样本,包括临摹1 100类、拓片306类、检测1类。所用到的数据集信息详见表4。

Table 4 Dataset statistical information

表4 数据集统计信息

名称或出处	类型	规模	用途
Oracle-20k ^[16]	临摹甲骨文文字	单字261、总数20 039	识别
HUST-OBS ^[17]	临摹甲骨文文字	单字1 588、总数77 064	识别
OBC306 ^[18]	拓片甲骨文文字	单字306、总数309 551	识别
Oracle-MNIST ^[19]	拓片甲骨文文字	单字10、总数30 222	识别
Lin Meng ^[20]	拓片甲骨文	330幅	检测
Oracle-Detect	拓片甲骨文	9 134幅	检测

4.3 模型有效性验证

为验证 Oracle-Detect 数据集对甲骨文检测的有效性,评价其质量,本文分别采用该数据集和其他相关数据集对 YOLOv5 和 Faster R-CNN 进行微调训练,实验结果如表5所示。可以看出,使用 Oracle-Detect 数据集进行训练的模型检测精度有显著提升。

Table 5 Fine-tune training results

表5 微调训练结果

网络模型	检测类数	mAP50 (未使用 Oracle-Detect 微调)	mAP50 (使用 Oracle-Detect 微调)
Faster R-CNN	1	0.71	0.88
YOLOv5	1	0.77	0.94

为验证基于 Stacking 的模型集成方法在甲骨文识别中的准确性,本文选取集成所用的4个基模型进行比较,既能验证模型集成的有效性,又能验证单一模型的识别和学习能力。使用 WDA 和拓片化增强后的数据集进行实验,包括临摹甲骨文数据集(1 100类)和拓片甲骨文数据集(306类)。由表6可知,单个模型局限于自己的关注视野,对 Top-1 的临摹和拓片图像的最高识别率均为70%,与集成模型相比分别降低了13%和11%。

Table 6 Ablation experiment of integrated recognition model based on Stacking

表6 基于 Stacking 的集成识别模型消融实验

网络模型	识别类数(临摹/拓片)	Top-1(临摹/拓片)	Top-3(临摹/拓片)
ResNet101	1 100/306	0.66/0.64	0.80/0.79
ResNest	1 100/306	0.68/0.67	0.82/0.79
Vision Transformer	1 100/306	0.70/0.68	0.83/0.81
Swin Transformer	1 100/306	0.69/0.70	0.83/0.82
本文模型	1 100/306	0.83/0.81	0.95/0.93

为进一步体现所提数据增强算法和集成模型的优势,分别基于传统的集成策略和未使用数据增强的数据集进行比较实验,结果如表7所示。可以看出,使用 WDA 和拓片化增强可在一定程度上提升准确率,改进集成策略亦是如此。如果融合两个改进点,模型在 Top-3 可以达到95%的临摹识别准确率和93%的拓片识别准确率,证实了所提改进措施的有效性。

Table 7 Validation of the effectiveness of improvement measures

表7 改进措施有效性验证

网络模型	识别类数(临摹/拓片)	Top-1(临摹/拓片)	Top-3(临摹/拓片)
传统 Stacking 集成(未使用 WDA 和拓片化增强训练集)	1 100/306	0.71/0.70	0.80/0.82
传统 Stacking 集成	1 100/306	0.78/0.75	0.89/0.87
本文方法(未使用 WDA 和拓片化增强训练集)	1 100/306	0.79/0.76	0.88/0.86
本文方法	1 100/306	0.83/0.81	0.95/0.93

将本文方法与一些传统机器学习方法进行比较,结果见表8。可以看出,传统机器学习方法的识别准确率低于深度学习网络20%以上,且特征处理较为麻烦。本文方法不仅识别范围广,识别精度也较高。

5 结语

本文立足深度学习技术,围绕甲骨文图像的检测与识别展开研究,提出一套系统性解决方案,并针对甲骨文图像处理中的三大关键问题——数据增强、数据集构建以及增量识别,提出相应的改善策略。具体而言:①创新性引入 WDA 算法,并结合拓片化数据增强技术,为甲骨文研究提供了更为丰富的数据支撑;②构建了高质量数据集 Ora-

Table 8 Comparison between the proposed method and some traditional machine learning methods
表 8 本文方法与一些传统机器学习方法的比较

网络模型	Top-1	说明
SVM	临摹:0.59	仅支持少量甲骨文识别
OBSD(OBS-OCR) ^[21]	临摹:0.41	在多轮解译评估中,识别准确率最高可达 80%
OBSD(PaddleOCR)	临摹:0.30	
融合跨模态信息的 CNN ^[10]	拓片:0.82	支持 241 个拓片甲骨文识别
改进 ResNest	拓片:0.81	支持 277 个拓片甲骨文识别
本文方法	临摹:0.83 拓片:0.81	支持 1 100 个临摹甲骨文和 306 个拓片甲骨文识别

cle-Detect,为甲骨文检测奠定了坚实基础;③提出基于 Stacking 策略的集成识别模型,准确性和泛化能力均表现优异。然而,本文研究仍存在一些不足,如 Oracle-Detect 数据集的覆盖面仍显不足,特别是在不同环境、载体下的多样性仍有待提升。同时,在构建集成模型时未能充分考虑训练过程中不同阶段的特征差异。后续研究需不断丰富数据集,并尝试融合生成式模型进一步攻克甲骨文图像研究领域的难题。

参考文献:

[1] XIE N H. Research on oracle bone inscriptions, a "unique learning" moving from Yin Ruins to the world—a review of the "International Academic Symposium Commemorating the 120th Anniversary of the Discovery of Oracle Bone Inscriptions" in Busan, South Korea [J]. Guanzi Journal, 2020(3):125–128.
谢乃和. 从殷墟走向世界的“绝学”甲骨文字研究——韩国釜山“纪念甲骨文发现 120 周年国际学术研讨会”述评[J]. 管子学刊, 2020(3): 125–128.

[2] LIU G Y. Based on deep learning oracle-bone character detection and recognition[J]. Yindu Journal, 2020,41(3):54–59.
刘国英. 基于深度学习的甲骨文字检测与识别[J]. 殷都学刊, 2020, 41(3):54–59.

[3] TU C N, WANG G, TIAN J, et al. Research on classification algorithms of oracle-bone characters based on deep learning[J]. Modern Computer, 2021, 27(26): 67–72.
涂淳宁,王贵,田吉,等. 基于深度学习的甲骨文分类算法研究[J]. 现代计算机, 2021, 27(26): 67–72.

[4] LI F, ZHOU X L. Graph Theory method for automatic recognition of oracle bone inscriptions[J]. Journal of Electronics & Information Technology, 1996, 22(S1): 41–47.
李锋,周新伦. 甲骨文自动识别的图论方法[J]. 电子与信息学报, 1996, 22(S1): 41–47.

[5] LYU X Q, LI M N, CAI K W, et al. An oracle bone inscriptions classification method based on graphic recognition[J]. Journal of Beijing Information Science & Technology University (Natural Science Edition), 2010, 25(S2): 92–96.

吕肖庆,李沐楠,蔡凯伟,等. 一种基于图形识别的甲骨文分类方法[J]. 北京信息科技大学学报(自然科学版), 2010, 25(S2): 92–96.

[6] MENG L. Two-stage recognition for oracle bone inscriptions[C]//International Conference on Image Analysis and Processing, 2017: 672–682.

[7] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[DB/OL]. <https://arxiv.org/abs/1409.1556>.

[8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.

[9] ZHANG Y K, ZHANG H, LIU Y G, et al. Oracle character recognition based on cross-modal deep metric learning[J]. Acta Automatica Sinica, 2021, 47(4): 791–800.
张颐康,张恒,刘永革,等. 基于跨模态深度度量学习的甲骨文字识别[J]. 自动化学报, 2021, 47(4): 791–800.

[10] MAO Y F, BI X J. Improved ResNeSt network for rubbings of oracle-bone character recognition[J]. Journal of Intelligent Systems, 2023, 18(3):450–458.
毛亚菲,毕晓君. 改进 ResNeSt 网络的拓片甲骨文字识别[J]. 智能系统学报, 2023, 18(3): 450–458.

[11] ZHOU X L, LI F, HUA X C, et al. Research on the computer recognition method of oracle bone inscriptions [J]. Journal of Fudan University (Natural Science), 1996, 35(5): 481–486.
周新伦,李锋,华星城,等. 甲骨文计算机识别方法研究[J]. 复旦学报(自然科学版), 1996, 35(5): 481–486.

[12] WANG M, DENG W, HU J, et al. Unsupervised attention regularization based domain adaptation for oracle character recognition [DB/OL]. <https://arxiv.org/abs/2409.15893>.

[13] SEDERBERG T W. Free-form deformation of solid geometric models [J]. Computer Graphics (SIGGRAPH), 1992, 26: 151.

[14] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 4015–4026.

[15] LI W, PENG Y, ZHANG M, et al. Deep model fusion: a survey [DB/OL]. <https://arxiv.org/abs/2309.15698>.

[16] ZHANG Y K, ZHANG H, LIU Y G, et al. Oracle character recognition by nearest neighbor classification with deep metric learning[C]//2019 International Conference on Document Analysis and Recognition, 2019: 309–314.

[17] WANG P, ZHANG K, WANG X, et al. An open dataset for oracle bone script recognition and decipherment [DB/OL]. <https://arxiv.org/abs/2401.15365>.

[18] HUANG S, WANG H, LIU Y, et al. OBC306: a large-scale oracle bone character recognition dataset[C]//2019 International Conference on Document Analysis and Recognition, 2019: 681–688.

[19] WANG M, DENG W. A dataset of oracle characters for benchmarking machine learning algorithms[J]. Scientific Data, 2024, 11(1): 87.

[20] XING J, LIU G, XIONG J. Oracle bone inscription detection: a survey of oracle bone inscription detection based on deep learning algorithm[C]//Proceedings of the International Conference on Artificial Intelligence, Information Processing and Cloud Computing, 2019: 1–8.

[21] GUAN H, YANG H, WANG X, et al. Deciphering oracle bone language with diffusion models[DB/OL]. <https://arxiv.org/abs/2406.00684>.

(责任编辑:尹晨茹)