

基于 CNN-ISVM 的跨领域书写人自适应手写识别

张墨逸, 叶洪昶, 袁小芳, 陈海燕

(兰州理工大学 计算机与通信学院, 甘肃 兰州 730050)

摘要: 用户书写风格、字形、笔迹、书写方式等方面都会存在差异, 使手写识别应用具有特异性、小样本和多样式的特点, 普适性的模型很难满足, 必须在手写过程中对特定用户的书写进行自适应学习, 使模型更好地服务于人们的个性化需求。针对此问题, 研究者提出基于 CNN-ISVM 的跨领域书写人自适应手写识别方法, 灵活地调整普适化模型, 进行个性化的手写识别。在构造通用模型时, 利用 CNN 作为特征提取器, 对图像进行特征学习和提取, 将提取的特征输入到 SVM 中进行分类。自适应手写识别时, 引入基于错分样本触发的 ISVM 增量学习方法, 使用增量样本和保存好的支持向量集对模型在线学习和更新。在实验中, 当源域由静态手写图片组成, 目标域为 2 组空写数据集时, 每类别增量 5 张样本, 识别率分别达到 92.8%、90.42%。该方法简单易行, 可以在目标域每类样本数据只有 1 张增量样本的情况下进行跨领域书写人自适应学习, 与其它方法相比, 识别率有较明显的提升。

关键词: 手写识别; 书写人自适应; 领域自适应; 增量学习; 卷积神经网络; 支持向量机

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2024)12-0187-07

doi: 10.20165/j.cnki.ISSN1673-629X.2024.0235

Cross-domain Author Adaptive Handwritten Recognition Based on CNN-ISVM

ZHANG Mo-yi, YE Hong-chang, YUAN Xiao-fang, CHEN Hai-yan

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Different people have differences in writing style, font shape, script, writing method and etc., so the hand writing recognition application has the character of specificity, small sample size, and multi-style. The universal model cannot meet the writing requirements of a specific usage, so it is necessary to self-adapt the writing of a specific user in the handwriting process, to make the model better serve people's personalized needs. In order to solve the above problem, we propose a cross-domain handwritten recognition method based on CNN-ISVM, which flexibly adjusts the universal model and carries out individuation handwriting recognition. In the construction of the generalized model, CNN is used as a feature extractor to learn and extract features from handwritten images, then CNN extracted features are input into SVM classifier for classification. In the author adaptive recognition, the wrongly predicted sample is introduced to trigger the incremental processing, which can use incremental set and save support vector set for online learning and updating the model. In experiment, when the source domain is composed of static handwritten images, and the target domains are two in-air handwritten datasets, with incremental images 5 per category, the recognition rates are 92.8% and 90.42% respectively. The proposed method is simple and easy to implement, which can implement cross-domain author adaptive learning when there is only one incremental sample data in the target domain for each class. Compared with other methods, the recognition accuracy of the proposed method is significantly improved.

Key words: handwritten recognition; author adaptive; domain adaptive; incremental learning; convolutional neural networks; support vector machine

0 引言

手写识别包括离线手写、在线手写、空中手写等不同形式。其中离线手写识别使计算机能够认识图片中的手写字符, 其技术已经趋于成熟; 在线手写可以使用

与时序有关的识别技术实现^[1]; 空中手写研究较少^[2], 有使用时序特征^[3], 也有直接使用空间位置特征^[4]。这些领域都属于手写识别, 但是由于输入场景的不同, 获得的样本有明显不同, 属于不同的域。同

收稿日期: 2024-03-23

修回日期: 2024-07-25

基金项目: 国家自然科学基金项目(62161019)

作者简介: 张墨逸(1985-), 女, 副教授, 博士, 研究方向为机器视觉、机器学习、模式识别; 叶洪昶(1999-), 男, 硕士研究生, 研究方向为模式识别与人工智能。

时,由于书写人书写风格、字形、笔迹、书写方式等方面都会存在差异,使得每一次手写识别应用均面临领域特异性、小样本和多样式问题,这使得训练一个具有普适性的手写识别模型变得具有挑战性。

书写人自适应手写识别研究是指对特定的书写进行自适应学习,从而提高目标域的识别率,是解决上述问题的一个主要途径。传统的书写人自适应手写识别研究中,风格自适应研究较多,通常的使用方法有两类。一类是提取与风格无关特征^[5]进行识别,主要为原型分类器^[6], Shakunthala 等人^[7]提出利用 ESDCW 算法对手写字符进行分割处理识别。第二类是使用特定风格样本对原始分类器进行调整^[8],是目前主流的方法,有使用 RugbyNet 网络^[9],有使用 CNN 的快速风格特征提取^[10],也有学者提出 CNN 结合隐马尔可夫模型进行作者感知^[11],也有使用元学习框架^[12],同时 Venugopal 等人^[13]通过融合显著性度量和相似性分数组件对分类器进行调整。随着近些年大模型的兴起,transformer 和 bert 模型也被应用于手写字符识别当中^[14]。付鹏斌团队^[15]结合联机与脱机手写方式,设计了一款基于编码器-解码器结构的双模态识别模型。党小超等人^[16]则提出利用 WiFi 信号中的信道状态信息,通过滑动窗口技术提取特征值,识别空中手写数字。

但是,对这些方法进行分析后发现,其通用性不强,有的方法每个笔迹大约需要 100 个字符样本,才能达到令人满意的效果^[17]。然而针对新的应用,其训练数据总是有限的,需要在相似的大数据集上进行训练,使用领域自适应的方法学习新的应用,提升不同情况下手写识别的泛化性能。

结合 CNN 的特征提取与基于错分的 ISVM 增量学习,该文提出了一种跨领域书写人自适应手写识别方法,该方法在小样本、多风格的手写识别研究中取得了显著的效果。实验结果表明,相较于传统的书写人自适应手写识别方法,该方法能够显著提高分类精度,并具备自适应处理不同样式的能力,从而具备更强的泛化能力和适应性。该方法在实际应用中有助于推广和普及空中手写识别技术。

1 CNN-ISVM 总体框架

基于 CNN-ISVM 的跨领域书写人自适应手写识别算法如图 1 所示,图中的手写数据、增量数据、测试数据交集为空。

首先,通过书写者无关的训练数据集训练出原始的 CNN 特征提取模型,用来提取特征。其次,使用书写者无关的训练数据集提取 CNN 特征,训练原始 SVM 识别模型。再次,使用书写者相关的增量样本提

取 CNN 特征,对原始 SVM 进行错分增量学习,得到学习后新的分类器模型,达到了更新的目的。最后,在识别时,使用与书写者相关的测试样本提取特征后,使用增量学习后的模型分类识别。

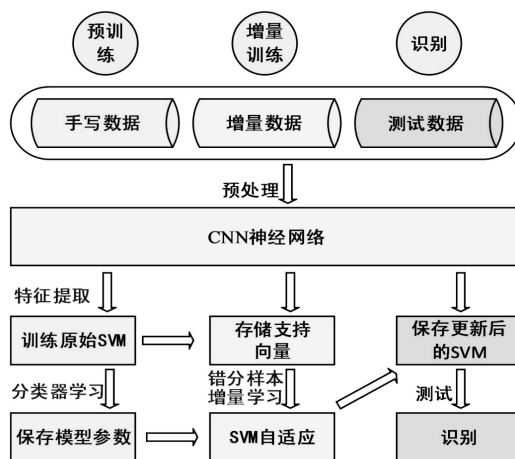


图 1 CNN-ISVM 总体框架

下面分别从 CNN 特征提取、SVM 分类器学习、错分 ISVM 增量学习 3 个方面对关键技术进行描述。

2 CNN 特征提取

手写输入形式较多,有拍摄的手写字符图片、有使用手写笔输入的信号、也有基于计算机视觉的空中手写(文中简称为空写)等,虽然输入的字符相同,但是由于输入环境的不同,获得的样本差异较大,属于不同的域。为了方便研究,研究者使用了 3 个常见的手写图片样本库与 2 个空写的样本数据库。如图 2 所示,分别对应“5.2 节 数据集”中的 5,3,4,1,2。后两行为空写样本,图片中带有时序数据,正方形表示空写的起始书写点,三角为空写的终止点。空写是一笔画时序轨迹,而手写只是图片特征。同时,即使是同样的书写环境,当书写人不同时,由于其书写风格不同,同一字符书写顺序不同,书写特征分布也有显著差异。如图 2 的空写数字“5”,空写时可能会产生冗余部分。




图 2 手写与空写字符样例

2.1 预处理

手写字符预处理:手写数据要进行图像的灰度化、二值化、去噪、规范化,从而能够更好地提取主要特征。经过上述处理后,数据进入到 CNN 神经网络中进行特征提取。

空写字符预处理:获得空写视频帧序列,提取手势骨架,获取指尖作为书写输入点,采集到的数据包括每一帧对应的输入点坐标和帧序列号。获得的空写字符数据为: $x = \{(a_0, b_0), (a_1, b_1), \dots, (a_i, b_i)\}$, 其中 (a_i, b_i) 表示输入点位置坐标, i 表示帧序列数。按时间顺序把空写的输入点连接起来,得到绘制的轨迹二维图。轨迹二维图规范化后,得到空写图片,送入到 CNN 神经网络中进行特征提取。

2.2 CNN 特征提取

在该部分中,使用了一个卷积神经网络作为特征提取器,CNN 模型输入为图片,其输入数据是二维图像,学到的特征为含有 84 个数据的一维向量。CNN 由多个卷积层、池化层和全连接层组成。具体而言,即采用了 3 个卷积层,每个卷积层后面跟随 1 个池化层,最后连接 2 个全连接层。在卷积层中,使用了具有 ReLU 激活函数的 3×3 大小的滤波器,同时进行零填充以保持特征图的大小。池化层采用了 2×2 的最大池化来减小特征图的尺寸。最后,两个全连接层中的 Fc2 将特征映射到 SVM 分类器的输入维度,相关流程见图 3。

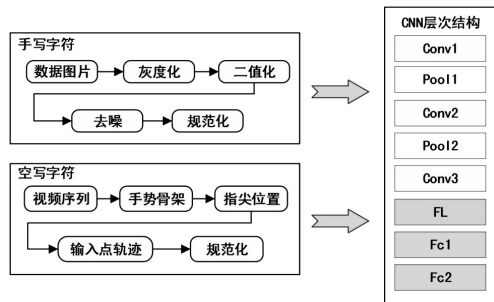


图 3 特征提取示意图

3 SVM 分类器学习

文中方法选择支持向量机(SVM)作为处理数据特征的分类器,SVM 可以在处理相对较小的训练数据集时显著减少过拟合的风险。输入:训练样本集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 包含 n 个样本对 (x_i, y_i) , 其中 x_i 表示输入样本, y_i 表示对应的类别标签 $y_i = \{-1, +1\}$ 。

SVM 方法源自线性可分场景下的最优分类超平面概念。最优分类超平面的设计原则在于,不仅要准确无误地将两类样本划分开,还要确保分类超平面两侧样本间的间隔达到最大化。在线性可分的条件下,可以通过寻找合适的权向量 ω 来实现这一目标,同时保证每个样本点都满足公式 1。

$$y_i [(\omega, x_i) + b] - 1 \geq 0 \quad (1)$$

其中, $i = 1, 2, \dots, n$, n 是输入中的样本对数量。求解上述优化问题,等同于找到 $\|\omega\|^2/2$ 最小。

书写人自适应手写识别的分类对象具有非线性特征,使得它们在特征空间中不能被简单的线性超平面所分割。针对这种非可分问题,可以引入非负松弛变量 ξ_i 来放宽约束条件,从而实现更灵活的分类,约束条件满足公式 2。

$$y_i [(\omega, x_i) + b] \geq 1 - \xi_i \quad (2)$$

则求解 $\min \|\omega\|^2/2$ 的二次规划问题可转化为:

$$\min \left(\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \right) \quad (3)$$

其中, ω 是决策平面的法向量, b 是决策平面的截距, ξ_i 是松弛变量, C 是可调节的惩罚参数, K 是 RBF 核的带宽^[18]。

对于每个类别,都训练一个二分类的支持向量机模型。在训练阶段,将选择一个类别作为正例,而将其余所有类别的样本都视为负例。这样,就会得到每个类别的一个分类模型。在预测阶段,将使用这些模型进行分类,每个模型输出一个置信度,最终选择置信度最高的类别作为预测结果。

4 错分 ISVM 增量学习

在 SVM 中,支持向量是距离决策边界或超平面最近的数据点。它们对于定义决策边界和进行预测非常关键。该文使用支持向量和增量数据更新模型,更新流程见图 4、图 5。通过只考虑支持向量并丢弃非支持向量样本,ISVM 大大降低了计算复杂度和内存需求。相比将 SVM 在整个数据集上重新训练的方法,这种方法只需要保存现有模型的支持向量模型,在新数据不断到达的情况下具有较好的效率^[19]。




图 4 基于错分样本触发的 ISVM 增量学习




图 5 模型更新示意图(星号样本表示增量样本)

以下为错分 ISVM 的完整求解过程,即使用增量样本 (x_{batch}, y_{batch}) 和支持向量来更新和求解新的 SVM 模型。

对于每个类别 J ,维护一个对应的支持向量集 SV_J 与错分向量集 CF_J ,错分向量集初始值为空集,

ω_j 和 b_j 是类别 J 的权重向量和偏置。计算样本点函数间隔如公式 4 所示:

$$\text{margin}_{\text{batch}} = y_{\text{batch}} * (\omega_j^T * x_{\text{batch}} + b_j) \quad (4)$$

(1) 若 $\text{margin}_{\text{batch}} \geq 1$, 则表明该样本远离决策边界, 无需更新。

(2) 若 $\text{margin}_{\text{batch}} < 1$, 继续判断样本点的类别。

(2.1) 若 $y_{\text{batch}} = J$, 则说明该样本点属于类别 J , 然后将其加入到类别 J 的错分向量集 CF_J 中。

(2.2) 若 $y_{\text{batch}} \neq J$, 则表示该样本点不属于类别 J , 无需更新。

(3) 假设 SV_J 中有 u 个构成支持向量的样本点, CF_J 中有 m 个错分样本, 其中 x_i 表示输入特征向量, y_i 表示对应的类别标签, 参数 Y 是增量样本的惩罚系数, 按公式 5 对 SVM 进行更新。

$$\begin{aligned} \min \quad & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^{u+m} \xi_i + Y \sum_{i=1}^{u+m} \max(0, 1 - \\ & y_i(\omega^T \cdot x_i + b)) \\ \text{s. t.} \quad & \xi_i \geq 0, i = 1, 2, \dots, u + m \end{aligned} \quad (5)$$

重复使用上述增量学习的方法, 可以在样本一批批到来时, 不断更新学习器模型, 如图 6 所示。在识别阶段使用已经划分好的书写测试集对模型进行检验。




图 6 迭代更新示意图

5 实验与分析

5.1 实验平台

硬件环境: Intel(R) Core(TM) i5-4210H CPU @ 2.90 GHz; 内存: 8.00 GB; 系统类型: 64 位操作系统。

软件环境: Windows 10 操作系统, Tensorflow 2.5.0 + Python 3.8.0, 每个网络训练 300 个 Epoch, Batch Size 设置为 64, 优化器采用 Adam 优化器, 学习率为 0.001。SVM 正则化系数为 100, 核函数选择 RBF。目标域划分为互斥的增量集和测试集。在实验中, 多次重复实验评估后取平均值作为评估结果。

5.2 评价指标

实验使用交叉验证法进行训练和测试, 最终以准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1 Score) 作为评价指标对模型进行评估。

准确率描述的是模型预测正确 (包括真正例、正负例) 的样本量占总样本量的比例, 衡量了模型在整个数据集上的性能, 计算公式如下:

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (6)$$

精确率计算公式如式 7 所示, 召回率计算公式如式 8 所示。

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (7)$$

$$\text{Rec} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (8)$$

F1 指标旨在平衡这两个指标, 其计算公式如式 9 所示。

$$\text{F1} = 2 \cdot \frac{\text{Pre} \cdot \text{Rec}}{\text{Pre} + \text{Rec}} \quad (9)$$

其中, TP 表示将 True 类型的样本预测为 True 的样本数量, TN 表示将 False 类型的样本预测为 False 的样本数量, FP 表示将 False 类型的样本预测为 True 的样本数量 (误报), FN 表示将 True 类型的样本预测为 False 的样本数量 (漏报)。

5.3 数据集

相关数据集分为两大类, 数据集明细见表 1。第一类是空写数据集, 包含以下:

数据集 1: 实验数据集的动态手势视频库由数字 0~9 的动态手势组成 (kinetic gesture), 每个手势持续时间不同, 约为 3 s~12 s (帧率 $\delta=25$ fps), 获取指尖作为书写输入点, 采集到的数据包括每一帧对应的输入点坐标和帧序列号。

数据集 2: 采用文献 [20] 中制作的数据集。基于 LMC (三维手部感知器)、JavaScript 版本 2、API 设计了一个简单的交互式 web 界面, 用于收集空写的数字 0~9, 采样频率为 60 Hz。

第二类是手写数据集, 使用到以下三种:

数据集 3: 哈尔滨工业大学手写字符识别语料库 (HIT-OR3C)。

数据集 4: 中科院联机手写语料库 (CASIA-OLHWDB1.0)。

数据集 5: MNIST 手写数据集。图像中的数字为 28×28 像素的 0~9 之间的数字。

表 1 数据集明细

数据集名称	总样本	训练集样本	测试集样本
kinetic gesture	300	240	60
AIR	1 200	960	240
HIT-OR3C	4 392	3 513	879
CASIA-OLHWDB1.0	12 896	10 316	2 580
MNIST	70 000	56 000	14 000

该文使用交叉熵损失函数来度量 CNN 模型的分错误。在训练过程中采用 Adam 优化器来最小化损失函数。研究者设置了适当的学习率、动量和权重衰减参数以平衡模型的收敛速度和泛化能力。实验中, 所有的 CNN 特征提取模型均是在中科院手写字数字

据集上学习得到,训练集与测试集分割比为 8 : 2 (相关数据集开源下载:Database Home (ia. ac. cn))。

5.4 消融实验

该文设计了消融实验,得到最优迭代周期和特征提取方法。选择迭代周期分别为 300、500 次进行迭代训练,在数据集 1 中采用三种特征提取方法在 SVM 模型中进行实验对比。从表 2 中可以看到,CNN 特征提取 300 次迭代效果最好。

表 2 迭代次数与特征提取

特征提取	准确率/%	
	300 次迭代	500 次迭代
风格特征 ^[3]	83.53	83.51
八方向 ^[21]	80.47	80.48
CNN	86.92	85.52

表 3 是在数据集 2 中有目的地去除 CNN-ISVM 模型的某些部分获得的准确率,通过进行两两组合的消融实验,评估模型各个部件识别性能的独立贡献,验证了模型设计中各个组件的必要性和合理性。

表 3 模型组件消融性能分析

编号	CNN	SVM	ISVM	准确率/%
1	√	-	-	70.35
2	-	√	-	57.56
3	-	-	√	69.32
4	√	√	-	76.06
5	√	√	√	88.86

5.5 原始域与目标域都为手写字符

分别使用数据集 4 中数字图片和数据集 5 作为原始域,使用数据集 3 中数字数据集作为目标域,当增量集分别是每类别 1 张、2 张、4 张、8 张、16 张时,使用该方法进行自适应识别,得到的准确率结果见图 7。




图 7 手写字符跨域自适应识别准确率

图 7 中,菱形标志曲线中,HWDB 表示 CASIA-OLHWDB1.0 数据集,HIT 表示 HIT-OR3C 增量数据集;矩形标志曲线中,MINIST 为初始训练集,使用 HIT 数据集增量测试;三角标志 HIT 曲线表示不使用增量算法,仅用 CNN-SVM 模型在 HIT 数据集上训练和测试;横坐标表示增量样本数,或者训练时每类使用的样

本数。3 种方法测试集大小相同。这个结果充分表明了在手写字符自适应识别领域来说,提出的 CNN-ISVM 算法是可行的,在按类别增量到 8 张时,模型达到拟合,对比不使用增量算法来看,不仅具有较高的识别率,且需要的训练样本也大大减少。

5.6 原始域为手写而目标域为空写

使用数据集 4 中手写数字集作为原始域,数据集 1、2 中的空写数字集作为目标域。

实验中,使用两种方法来原因手写到空写的迁移。初始化 CNN-SVM 模型部分都一致,在增量学习部分,将空写数据集分割为互斥的增量集合和测试集合。第一种方法使用按类别增量,即每种类别同时增量同样样本数,然后进行增量学习,第二种方法,不再固定类别,进行随机增量学习。

表 4 和表 5 是文中两种增量方法在数据集 1、2 上对比近些年书写人自适应手写识别主流方法的识别准确率。表头中的数字,随机增量时,数字乘以类别数为总共随机增加的样本数;在按类别增量时,指每个类别增加的样本数;其它算法中,指目标域中每个类别参与学习样本数。

表 4 各方法在数据集 1 上的准确率

方法	数据集 1 准确率/%				
	1	2	3	4	5
BFX-ISVM	52.95	71.71	76.29	83.07	85.2
CNN-BYS ^[2]	54.82	69.22	77.52	78.84	81.6
FWA-SE ^[3]	60.89	72.42	83.61	86.15	88.8
文中方法 1	63.85	79.65	83.47	90.76	92.8
文中方法 2	49.65	75.66	83.25	89.15	90.64

表 5 各方法在数据集 2 上的准确率

方法	数据集 2 准确率/%				
	1	2	3	4	5
BFX-ISVM	46.77	58.31	62.8	65.74	68.93
CNN-BYS ^[2]	51.96	64.8	71.45	76.54	80.04
FWA-SE ^[3]	58.39	66.18	71.45	77.01	83.85
文中方法 1	81.14	82.56	84.64	88.1	90.42
文中方法 2	70.55	81.16	86.49	87.77	88.86

表中 BFX-ISVM 是指手写字符识别中常用的用八方向特征提取加 SVM 增量学习,这种算法通过从八个不同方向捕捉字符的形态信息,能够更全面地理解字符的结构与特点,从而有较高的手写字符识别准确率;CNN-BYS^[2]指 CNN 结合贝叶斯模型自适应学习,CNN 负责从原始图像中提取深层次的特征,而贝叶斯模型则负责根据这些特征进行概率推理和自适应学习。使得模型能够在识别手写字符时,不仅考虑到字符的形态特征,还能根据数据分布动态调整模型参

数,提高识别的鲁棒性和准确性;FWA-SE^[3]指快速风格提取模型,能够在短时间内准确地捕捉字符的书写风格,从而帮助识别系统更好地理解字符的书写特点和规律。这种快速且准确的风格提取能力考虑了多种书写风格和场景,使得模型在各种情况下都能保持稳定的识别性能。

由表 4 和表 5 可见,文中方法在小样本情况下表现出了显著的优势,识别率位居首位,在有限的条件下也能实现较高的识别准确率。FWA-SE 紧随其后,性能略低;CNN-BYS 排名第三,BFX-ISVM 模型准确率最低。当使用随机增量学习(文中方法 2)时,虽然并不是每个增量类别都有特定人的书写样本,但本方法仍能从类别缺失的增量样本中学习数据集中书写人的风格,表现出较高的识别效果。然而,在每个类别仅增量 1 张或随机增量 10 张的情况下,方法 2 的识别率略低于方法 1 的识别率。这可能是因为在学习到的数据特征还不够多的情况下,方法 2 的随机性可能导致模型对某些类别的分类能力下降。但随着增量样本的增加(如每个类别 5 张,方法 2 随机增量 50 张),两种方法的准确率趋于相同,这进一步证明了文中方法在小样本情况下具有显著的优势,能够准确识别手写字符。

图 8 为针对不同书写者做自适应识别的对比结果,图中的方法从左至右按顺序依次是表 4 中的文中方法 1、BFX-ISVM、CNN-BYS、FWA-SE。使用的各方法中每类别增量 2 张,测试集为相应书写人的书写样本共 100 张。可以看出,文中方法 1 在使用特定人的样本做增量时,效果突出。




图 8 针对不同书写者的识别率

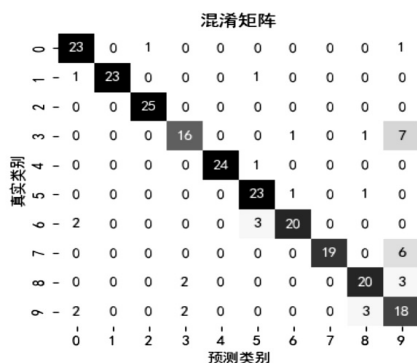


图 9 文中方法混淆矩阵

图 9 是利用文中方法 1 每类别增量 5 张时得到的混淆矩阵,可以看出,数字“3”和“9”、“6”和“9”书写轨迹具有一定的相似性,存在一定程度误判。

5.7 多类别手写字符书写人自适应实验

和数字识别相比,英文字母的识别更具挑战性,因为字母的形状和结构更加复杂。实验中增加识别的类别数,将方法扩展到小写英文字母识别上,原始域为数据集 4 小写英文字母数据集,目标域为数据集 3 小写英文字母数据集 HITCHAR。

表 6、表 7 为在数据集 3 上识别英文字母的准确率,表中的表头含义与表 4、表 5 中相同。在表 7 中,文中方法 1 在每个类别增量 16 张时,方法 2 随机增量 416 张时,已经有较高的识别准确率;FWA-SE 在每类别学习 32 张时略低于文中方法识别率;其它常见模型在每个类别学习 100 张左右时仍然低于文中的两种方法。

表 8 列出了英文字母识别中各方法其它指标对比,参数与表 6 中相同,从表中看出文中方法的精确率、召回率、F1 得分仍然高于其它模型。

表 6 数据集 3 英文字母识别准确率

方法	HITCHAR 准确率/%			
	1	2	4	8
BFX-ISVM	41.24	44.33	49.36	55.87
CNN-BYS ^[2]	34.96	37.96	46.85	56.87
FWA-SE ^[3]	39.62	49.38	60.87	80.91
文中方法 1	75.53	81.54	85.58	87.99
文中方法 2	75.5	79.62	83.14	86.3

表 7 数据集 3 英文字母识别准确率(续)

方法	HITCHAR 准确率/%			
	16	32	64	100
BFX-ISVM	62.09	67.56	72.46	75.69
CNN-BYS ^[2]	71.18	80.74	86.89	87.88
FWA-SE ^[3]	88.49	90.05	94.62	95.97
文中方法 1	90.63	93.54	95.57	97.82
文中方法 2	90.17	92.05	95.02	97.20

表 8 英文字母识别中各方法其它指标(每类 16 张增量)

方法	精确率/%	召回率/%	F1 得分
BFX-SVM	64.27	62.19	62.37
CNN-BYS ^[2]	75.35	70.93	71.77
FWA-SE ^[3]	88.26	88.06	88.05
文中方法 1	91.71	91.58	91.59
文中方法 2	90.87	90.38	90.46

6 结束语

该文旨在解决跨领域书写人自适应手写识别问

题,通过引入错分增量学习方法,建立 CNN-ISVM 跨领域自适应模型,取得了令人满意的结果。这种方法使得模型在面对新的错分样本时进行在线学习和更新,而不必重新训练整个模型,逐步地适应新的特征分布和类别,提高识别的准确性和泛化能力。实验结果表明,该方法能够适应新的目标域,提高识别的准确性。相比传统重新训练的方法,该方法具有更低的计算成本、更快的响应速度和更高的准确率。未来的研究可以进一步探索如何优化该方法并应用于更广泛的自适应识别任务中。

参考文献:

- [1] 甘吉. 手写文字识别及相关问题算法研究[D]. 北京:中国科学院大学,2021.
- [2] ALAM M S, KWON K C, ALAM M A, et al. Trajectory-based air-writing recognition using deep neural network and depth sensor[J]. *Sensors*,2020,20(2):1-16.
- [3] CHOUDHURY A, SARMA K K. Trajectory-based recognition of in-air handwritten assamese words using a hybrid classifier network[J]. *International Journal on Document Analysis and Recognition*,2023,26:375-400.
- [4] CHEN S, WANG Y, LIN C T, et al. Semi-supervised feature learning for improving writer identification[J]. *Information Sciences*,2019,482:156-170.
- [5] MURASE K, NAKATSUKA S, HOSOE M, et al. Handwriting feature extraction method for writer verification independent of character type by using AdaBN and AdaIN[C]//International workshop on advanced imaging technology. Yogyakarta:Spie,2020:11-14.
- [6] DU J, ZHAI J F, HU J S, et al. Writer adaptive feature extraction based on convolutional neural networks for online handwritten Chinese character recognition[C]//International conference on document analysis and recognition. Nancy: IEEE,2015:841-845.
- [7] SHAKUNTHALA B S, ULLAS H S, PILLAI C S. Unconstrained handwritten kannada word recognition using ESD-CW method[C]//2023 international conference on data science and network security. Karnataka:IEEE,2023:1-5.
- [8] LI Xudong, ZHAO Caiyun, ZHANG Haiyang. RugbyNet: an efficient CNN architecture for offline unconstrained handwritten Chinese character recognition[C]//Fourth international conference on artificial intelligence and electromechanical automation. Nanjing:SPIE,2023.
- [9] 韩克平. 基于卷积神经网络的深度增量学习方法研究[D]. 天津:天津财经大学,2020.
- [10] WANG Z R, DU J. Fast writer adaptation with style extractor network for handwritten text recognition[J]. *Neural Networks*,2022,147:42-52.
- [11] WANG Z R, DU J, WANG J M. Writer-aware CNN for parsimonious HMM-based offline handwritten Chinese text recognition[J]. *Pattern Recognition*,2020,100:102-107.
- [12] BHUNIA A K, GHOSE S, KUMAR A, et al. Metaht: towards writer-adaptive handwritten text recognition[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Montreal: IEEE, 2021: 15830 - 15839.
- [13] VENUGOPAL V, SUNDARAM S. Online writer identification system using adaptive sparse representation framework[J]. *IET Biometrics*,2020,9(3):126-133.
- [14] GANAI A F, KHURSHEED F. Computationally efficient recognition of unconstrained handwritten Urdu script using BERT with vision transformers[J]. *Neural Computing and Applications*,2023,35:24161-24177.
- [15] 付鹏斌,李树军,杨惠荣. 基于双模编码器-解码器框架的联机手写数学公式识别[J]. *北京工业大学学报*,2024,50(1):50-60.
- [16] 党小超,殷杰,郝占军,等. 基于 CSI 的空中手写数字识别方法[J]. *传感器与微系统*,2022(9):29-33.
- [17] HE S, SCHOMAKER L. Deep adaptive learning for writer identification based on single handwritten word images[J]. *Pattern Recognition*,2019,88:64-74.
- [18] 唐庭龙. 支持向量机增量学习研究[D]. 杭州:浙江工业大学,2018.
- [19] XU J. New incremental learning algorithm with support vector machines[J]. *IEEE Transactions on Systems Man and Cybernetics Systems*,2018,49(11):2230-2241.
- [20] BASTAS G, KRITSIS K, KATSOUROS V. Air-writing recognition using deep convolutional and recurrent neural network architectures[C]//International conference on frontiers in handwriting recognition. Dortmund:IEEE,2020:7-12.
- [21] JAISWAL A, PARMAR A, SACHDEVA N. HOG feature extraction for image forgery detection[J]. *Journal of Survey in Fisheries Sciences*,2023,10(1S):6364-6371.