

基于幻象多尺度贝叶斯网络的在线手写签名认证



栾方军, 窦浩铭, 袁帅*

沈阳建筑大学计算机科学与工程学院, 辽宁沈阳 110168

摘要: 针对在线手写签名认证在小样本条件下存在特征表达受限、参数学习不稳定以及分类决策可靠性不足等问题, 提出了一种融合轻量化表征、多尺度特征建模与概率判别机制的认证方法。该方法面向在线签名序列中噪声干扰、特征冗余以及动态信息利用不足等情况, 首先对原始签名序列进行平滑处理, 并结合特征重要性评估与主成分分析完成特征筛选与降维, 构建同时包含全局统计属性和局部动态变化信息的输入表征。在特征提取阶段, 采用 Ghost 特征映射对输入信息进行初始表征, 并结合 InceptionNext-TF 模块与 DASE 模块开展多尺度深层特征建模, 以刻画签名样本在不同尺度下的变化特征。在分类阶段, 引入变分贝叶斯全连接层对输出权重进行分布化建模, 并结合基于贝叶斯优化的自适应参数搜索策略, 对相关超参数进行调整。基于 MCYT-100 和 SVC-2004 Task2 公开数据集的实验结果表明, 在 10-shot 条件下, 等错误率分别为 1.46% 和 3.05%。

关键词: InceptionNext-TF; 变分贝叶斯全连接层; 基于贝叶斯优化的自适应参数搜索策略

DOI: [10.57237/j.cst.2026.02.003](https://doi.org/10.57237/j.cst.2026.02.003)

Ghost Multi-scale Bayesian Network for Online Handwritten Signature Verification

Luan Fangjun, Dou Haoming, Yuan Shuai*

School of Computer Science and Engineering, Shenyang Jianzhu University, Shenyang 110168, China

Abstract: For the problems of limited feature representation, unstable parameter learning, and insufficient reliability of classification decisions in online handwritten signature verification under small-sample conditions, a verification method integrating lightweight representation, multi-scale feature modeling, and probabilistic discrimination is proposed. Aiming at noise interference, feature redundancy, and insufficient utilization of dynamic information in online signature sequences, the method first performs smoothing on the original signature sequences, and then combines feature importance evaluation with Principal Component Analysis to conduct feature selection and dimensionality reduction, thereby constructing an input representation that contains both global statistical attributes and local dynamic variation information. In the feature extraction stage, Ghost feature mapping is adopted for the initial representation of input information, and the InceptionNext-TF module together with the DASE module is used for multi-scale deep feature modeling to characterize variation patterns of signature samples at different scales. In the classification stage, a variational Bayesian fully connected layer is introduced to model the output weights in a distributional manner, and a Bayesian optimization-based adaptive

基金项目: 国家自然科学基金 (62073227); 辽宁省科技厅项目 (2023JH2/101300212).

*通信作者: 袁帅, yuanshuai@sjzu.edu.cn

收稿日期: 2026-03-25; 接受日期: 2026-04-17; 在线出版日期: 2026-04-27

<http://www.computscitech.com>

parameter search strategy is further employed to adjust the relevant key hyperparameters. Experimental results on the public MCYT-100 and SVC-2004 Task2 datasets show that, under the 10-shot setting, the Equal Error Rates are 1.46% and 3.05%, respectively.

Keywords: InceptionNext-TF; Variational Bayesian Fully Connected Layer; Bayesian Optimization-based Adaptive Parameter Search

1 引言

在线手写签名认证通过采集书写过程中的轨迹、压力、速度等动态信息实现身份鉴别,在金融安全、电子政务和移动终端认证等场景中具有重要应用价值。相较于仅利用静态图像信息的离线签名,在线签名能够保留更丰富的时序行为特征,因此在个体书写习惯刻画和身份区分方面具有一定优势。然而,该任务在实际应用中仍面临较大挑战。一方面,伪造签名样本获取困难,正负样本分布往往不均衡,且训练样本规模通常有限,这使得模型训练稳定性与泛化能力受到制约;另一方面,在复杂伪造条件下,真实签名与伪造签名之间常存在较强相似性,也进一步增加了特征建模与有效判别的难度。基于上述问题,近年来研究者围绕时序建模、特征增强与轻量化深度网络设计等方向开展了较多研究,以提升在线签名认证在小样本条件下的特征表达与判别能力。

在这些研究方向中,时序建模是在线签名认证中的核心问题之一,目前循环神经网络及其变体在该任务中应用较为广泛。Tolosana 等人[1]提出了基于孪生架构的循环神经网络在线签名验证系统,并对长短记忆网络(Long Short-Term Memory, LSTM)、GRU 及其双向结构在签名时序建模中的应用进行了研究;Rajib Ghosh 等[2]结合 LSTM 与双向长短时记忆网络(Bidirectional Long Short-Term Memory, BLSTM),进一步提升了复杂伪造场景下的识别性能,说明双向时序建模对动态签名特征刻画具有一定优势。针对小样本条件下的特征学习问题,Vorugunti 等人[3]提出基于深度卷积孪生网络的在线签名验证框架,以增强判别特征提取能力;Ahrabian 等人[4]将注意力机制、自编码器与孪生 LSTM 结合,取得了较好的鉴别效果,在一定程度上改善了有限样本条件下的特征表达能力。此外,Hadar Shavit 等[5]将 SE 模块与 NAS 技术结合,用以提升模型性能与泛化能力;Teressa Longjam 等[6]提出结合 CNN 与 BLSTM 的混合网络,在高水平伪造条件下

表现出较好的验证能力。

尽管现有研究已在在线手写签名认证中取得了一定进展,但在小样本条件下仍面临若干问题:其一,现有方法对局部细节与多尺度动态特征的联合建模仍显不足;其二,在伪造样本稀缺和训练样本有限的条件下,模型训练稳定性与泛化能力仍受到一定制约;其三,部分深度模型计算开销较大,不利于资源受限场景下的实际部署。因此,围绕轻量化结构设计、多尺度动态特征建模以及小样本条件下的稳定判别开展进一步研究,仍具有现实意义。

针对上述问题,提出一种兼顾轻量化特征提取、多尺度动态建模与小样本稳定判别能力的在线手写签名认证模型 GhostInception-VB (Ghost Inception Variational Bayesian Network)。该模型以信号平滑、特征筛选与主成分分析构建输入表示,在此基础上利用 InceptionNext-Tiny with Feature Fusion (InceptionNext-TF) 模块实现多尺度特征提取,并引入对偶注意力挤压激励模块(Dual Branch Attention Cues Squeeze and Excitation Network, DASE) 模块对特征进行自适应重标定,以增强关键判别信息的表达能力;在分类端,进一步结合变分贝叶斯全连接层与基于贝叶斯优化的自适应参数搜索框架(Bayesian Optimization based Adaptive Parameter Search, BO-APS),对模型参数进行优化,从而改善小样本条件下的训练稳定性与认证表现。

2 GhostInception-VB 模型设计

2.1 总体框架

本文构建了一种面向在线手写签名认证的验证框架 GhostInception-VB,其整体流程如图 1 所示,主要由初始特征映射、多尺度特征提取、特征重标定与概率判别等环节构成。首先,输入序列经由 Ghost 模块完成初始映射,在控制计算开销的基础上获得较为充分的

特征响应,并结合激活函数与池化操作形成基础表征。随后,网络通过两级 InceptionNext-TF 与 DASE 模块对特征进行分层提取与逐步强化,其中 InceptionNext-TF 模块主要承担不同尺度特征的建模任务,DASE 模块则对中间表示进行自适应重标定,以提升关键信息的表达程度。通过上述结构的级联作用,模型能够在特征演化过程中兼顾局部变化刻画与整体模式表征。在此基

础上,进一步利用池化与展平操作完成特征聚合,并借助多层全连接结构学习更高层次的判别表示。最后,在输出端引入变分贝叶斯全连接层,对真实签名与伪造签名实施概率判别,同时结合 BO-APS 自适应参数搜索策略对相关超参数进行优化,从而为小样本条件下模型训练的稳定性与认证性能提升提供支持。




图 1 GhostInception-VB 总体模型

2.2 InceptionNext-TF 模块

为兼顾模型表征能力与计算效率,本文在 InceptionNext-TF 模块中引入 Ghost 特征生成机制与多分支并行建模结构。设输入特征表示为 $\mathbf{X} \in \mathbb{R}^{c \times l}$, 其中 c 表示特征通道数, l 表示序列长度。首先,模块通过主卷积对输入进行初始映射,获得基础特征 $\mathbf{Y}$; 随后,在此基础上施加廉价线性变换 Φ , 进一步生成 Ghost 特征 $\mathbf{Y}_{ghost}$, 其形式可表示为

$$\mathbf{Y}_{ghost} = \mathbf{Y} * \Phi \quad (1)$$

其中, $*$ 表示线性映射操作。最终,将基础特征 $\mathbf{Y}$ 与 ghost 特征 $\mathbf{Y}_{ghost}$ 在通道维进行拼接,形成扩展后的输入表示。该设计在尽量保留有效特征表达的同时,降低了传统卷积所带来的冗余计算开销,为后续多尺度特征提取提供了更具效率的输入基础。

在完成 Ghost 投影后,所得特征图被送入四个并行

分支,以实现不同尺度动态模式的联合建模。其中,第一个分支采用 1×1 卷积以促进通道间信息交互,使特征在较低计算代价下完成维度调整与信息混合;第二个分支采用混合深度可分离卷积,用于提取细粒度局部特征,以增强模型对局部波动与短程模式的感知能力;第三个分支引入空洞卷积,通过扩展感受野提升对较大范围动态变化的建模能力;第四个分支采用

池化操作,以抑制局部噪声干扰并保留相对稳定的响应信息。不同分支从局部细节、尺度变化及统计稳定性等角度对输入特征进行补充建模,从而使模块输出具备更为充分的表征能力。

记第 k 个分支对输入特征 $\mathbf{X}$ 的映射结果为 $F_k(\mathbf{X})$, 则各分支输出经通道维拼接、层归一化和随机失活处理后,再与输入特征的投影残差分支进行融合。首先定义各分支拼接结果为:

$$\mathbf{H} = \text{Concat}_{k=1}^4 F_k(\mathbf{X}) \quad (2)$$

则模块输出可进一步表示为:

$$Z = \text{Dropout}(\text{LayerNorm}(H)) + \text{Conv1D}_{\text{proj}}(X) \quad (3)$$

其中, Concat 表示对各并行分支输出特征在通道维进行拼接, $\text{Conv1D}_{\text{proj}}(X)$ 表示输入特征经投影卷积得到的残差映射, Z 为模块最终输出。从结构组成上看, InceptionNext-TF 模块先通过卷积映射与 Ghost 特

征扩展形成输入表示, 随后将特征分别送入卷积分支、深度可分离卷积分支、空洞卷积分支和池化分支, 以完成不同尺度特征的并行提取。各分支输出经通道拼接、层归一化和随机失活处理后, 再与投影残差映射融合形成最终输出。该模块在增强特征表达多样性的同时, 也兼顾了计算开销控制, 其具体结构如图 2 所示。




图 2 InceptionNext-TF 模块

2.3 DASE 模块

尽管前述 InceptionNext-TF 模块已通过多分支、多尺度卷积结构实现了对输入特征的非线性组合建模, 并在一定程度上增强了对动态模式的表征能力, 但其主要作用仍集中于不同感受野下的特征提取, 对于各通道在认证任务中的贡献差异尚未进行显式建模。对于在线手写签名验证任务而言, 真实签名与伪造签名在部分整体统计属性上往往具有较强相似性, 而真正具有区分作用的判别线索通常集中于少数敏感维度或局部动态响应, 其余通道则可能表现为相关性较弱的背景信息, 并对后续判别产生干扰。若缺乏对通道响应的自适应调节, 关键鉴别信息可能在特征传播过程中被削弱, 从而影响分类判别效果。基于此, 本文设计了

对偶注意力挤压激励模块 DASE, 其整体结构由局部分支与多尺度分支两个并行路径组成, 如图 3 所示。需要说明的是, 本文所称对偶注意力并非指模块内部显式构造两套自注意力映射, 而是指通道权重的生成同时依赖两条并行分支所提供的互补注意力证据。

其中, 局部分支主要用于聚合通道统计信息。对于输入特征 X , 首先分别执行全局平均池化和全局最大池化, 得到 z_{avg} 与 z_{max} ; 随后将二者在通道维进行拼接, 并通过一维卷积与激活函数映射得到局部描述符 f_{local} :

$$f_{\text{local}} = \phi(\text{Conv1D}_k([z_{\text{avg}}; z_{\text{max}}])) \in \mathbb{R}^{C/r} \quad (4)$$

其中, ϕ 为 ReLU 激活函数, k 为卷积核大小, r 为通道压缩比。该分支通过联合利用平均响应与极值响应信息, 对各通道的统计显著性及局部相关结构进行刻画, 从而为后续权重生成提供局部注意力证据。

与此同时, 多尺度分支通过并行空洞卷积对不同

感受野下的动态模式进行建模。具体而言,采用膨胀率 $d \in \{1, 2, 4\}$ 的三个卷积分支分别提取多尺度特征,并将其输出在通道维进行拼接;随后,经由 1×1 卷积完成特征融合,并通过全局平均池化得到多尺度描述符 f_{multi} :

$$f_{multi} = \text{GAP}(\phi(\text{Conv1D}_{1 \times 1}(\bigoplus_{d \in \{1, 2, 4\}} \text{Conv1D}_{3, d}(X)))) \quad (5)$$

其中, $\bigoplus$ 表示对不同分支输出特征进行拼接。该分支能够在相对较低的计算复杂度下整合局部邻域与更大范围内的动态变化信息,从而为通道权重生成提供多尺度注意力证据。

在完成双分支特征提取后,将局部分支与多尺度

分支输出进行融合,并通过线性映射与 Sigmoid 函数生成自适应权重,对输入特征实施动态重标定,其表达式为

$$Y = X \square \sigma(W[f_{local}; f_{multi}] + b) \quad (6)$$

其中, σ 表示 Sigmoid 激活函数, $\square$ 表示按通道逐元素相乘, W 和 b 分别为可学习的权重矩阵与偏置项, Y 为重标定后的输出特征。通过上述设计, DASE 模块能够在保持线性复杂度的前提下,对局部统计信息与多尺度动态信息进行联合建模,并以此实现对输入特征的逐通道自适应调节,从而提升关键判别信息的表达能力并减弱冗余响应对认证结果的干扰。




图 3 DASE 模块

2.4 变分贝叶斯全连接层

在完成前端特征提取与特征重标定之后,本文在分类端引入变分贝叶斯全连接层,以替代传统确定性全连接分类结构。传统全连接层通常将权重和偏置视为固定参数,并通过点估计方式完成学习。该方式在样本充足的条件下能够取得较好的拟合效果,但对于在线手写签名认证这类训练样本有限、类内波动明显且伪造样本分布复杂的任务,往往容易出现过拟合以及预测置信度失准等问题。基于此,本文将输出层权重由确定性参数扩展为概率分布形式的随机变量。设全连接层权重 W 服从高斯分布,则有

$$W \square N(\mu, \sigma^2) \quad (7)$$

其中, μ 和 σ 分别表示可学习的均值参数与标准差参数。这样,模型学习的对象不再是单一权重取值,而是参数的分布形态,从而使分类层在输出判别结果的同时具备一定的不确定性表达能力。

在训练过程中,本文采用变分推断思想,以参数化的近似后验分布 $q(W|\theta)$ 去逼近真实后验分布,并通过优化证据下界实现参数学习。对应到实现形式上,整体损失函数由分类风险项与复杂度约束项共同构成,可写为

$$L_{total} = L_{CE}(y, \hat{y}) + \beta \cdot D_{KL}(q(W|\theta) \| p(W)) \quad (8)$$

其中, $L_{CE}(y, \hat{y})$ 用于度量模型预测结果与真实标签之间的差异, D_{KL} 用于约束参数分布与先验分布之间的

偏离程度, β 为两部分目标的平衡系数, $p(W)$ 为标准高斯先验分布。通过引入分类项与分布约束项的联合优化形式, 模型在学习判别边界的同时, 能够对参数空间的复杂度进行适当控制。

由于贝叶斯层中的权重由随机分布采样得到, 若直接参与梯度计算, 将导致反向传播难以稳定实现。为此, 本文进一步引入重参数化技巧, 将随机采样过程改写为确定性参数与噪声变量的组合形式, 即

$$W = \mu + \sigma \cdot \varepsilon, \quad \varepsilon \sim N(0,1) \quad (9)$$

其中, ε 表示来自标准正态分布的噪声变量, $\cdot$ 表示逐元素乘法。通过这种方式, 可以将原本不可微的采样过程转化为可导运算, 从而使分布参数 μ 与 σ 能够通过梯度反向传播进行联合优化。




图 4 变分贝叶斯全连接层

对于在线手写签名认证任务而言, 真实签名与伪造签名之间往往呈现局部相似而整体差异细微的分布特征, 因而输出层参数的不确定性刻画具有一定必要性。基于此, 本文将变分贝叶斯思想引入全连接分类层, 如图 4 所示, 将传统确定性点估计参数扩展为分布式参数表示, 使输出层在完成类别判别的同时, 兼顾对参数不确定性的建模。相较于仅依赖固定参数取值的分类方式, 该设计为复杂边界样本的判别提供了更具约

束性的参数表达形式, 也为后续小样本条件下的稳定训练奠定了基础。

2.5 BO-APS 参数设置

为减弱贝叶斯全连接层在参数初始化阶段可能引入的不确定性影响, 本文进一步构建了基于贝叶斯优化的自适应参数搜索框架 BO-APS, 用于对权重 w 与偏置 b 的分布参数进行联合寻优。相较于依赖经验设定初始参数的方式, 该框架结合历史高性能参数信息, 对搜索区间进行动态调整, 从而使参数搜索过程能够逐步向更具潜力的候选区域收缩。与此同时, 框架中引入早停机制, 以在满足预设条件时终止后续搜索, 从而减少不必要的计算开销。

2.5.1 优质样本筛选与样本库维护

在参数迭代过程中, 系统持续记录不同参数配置及其对应的验证准确率。为提高历史样本对后续搜索的参考价值, 本文仅保留准确率不低于 80% 的参数组合, 并将其存入历史样本库。样本库容量上限设为 500, 当达到上限后, 按照准确率对已有样本进行筛选, 优先保留表现相对较优的参数组合。相关样本信息以持久化方式保存, 用于支持后续统计分析、区间更新及经验复用。

2.5.2 基于 K-Means 的优化策略

在优化早期阶段, 为避免参数搜索过程过于分散, 本文首先对准确率超过 80% 的样本进行标准化处理, 并借助 K-Means 方法进行聚类。在此基础上, 根据各聚类结果的均值与标准差, 对下一轮搜索区间进行更新。考虑到搜索空间过快收缩可能导致潜在优解区域被提前排除, 更新后的区间仍限制在原始搜索范围之内, 以在一定程度上兼顾搜索聚焦性与必要的探索空间。

2.5.3 基于经验回放的区间重用机制

随着优化过程的推进, 当高分样本即准确率大于 90% 的数量超过 200 组后, 可认为当前搜索已积累了一定数量的高质量历史信息。此时, 参数区间的更新不再主要依赖前期聚类结果, 而是依据高分样本群体的均值与标准差重新设定搜索范围, 使后续搜索更多集中于表现较优的区域。

2.5.4 早停策略

为控制优化成本，本文设置了基于验证准确率的早停判据。当模型验证准确率超过 98% 时，后续参数搜索过程可予以终止，并将当前参数组合作为候选结果输出。该策略主要用于减少高性能区域内的重复搜索，从而降低额外计算负担。

3 实验设置

3.1 实验数据集与预处理

本文实验采用 MCYT-100 和 SVC-2004 Task2 两个公开在线手写签名数据集对所提方法进行验证。两者均记录了签名书写过程中的动态轨迹信息，能够较为完整地反映书写者在签名过程中的行为特征，因此被广泛用于在线手写签名认证任务的性能评估。其中，MCYT-100 数据集包含 100 名用户的签名样本，样本规模相对较大，具有较好的代表性；SVC-2004 Task2 数据集是在线签名验证领域中较为常用的公开基准数据集，能够为不同方法之间的实验比较提供统一参考。

由于原始在线签名数据在采集过程中容易受到书写状态、采样设备及局部噪声干扰的影响，若直接用于后续建模，可能会削弱特征表达的稳定性。为此，本文在实验前对原始签名序列进行了统一预处理。首先，对原始序列进行平滑处理，以减弱局部抖动和高频噪声带来的干扰；随后，从签名序列中提取相关统计特征，以表征书写过程中的动态变化信息；在此基础上，进一步结合特征筛选方法去除冗余特征，并通过主成分压缩降低输入维度，形成较为紧凑的特征表示。通过上述处理，原始签名数据在保留主要判别信息的同时，能够在一定程度上减轻噪声与冗余特征对后续模型训练的影响，为实验设置与结果分析提供统一的数据基础。

3.2 实验设置

3.2.1 实验协议

本文在 MCYT-100 与 SVC-2004 Task2 两个公开数据集上开展实验，并在小样本注册条件下对模型性能进行评估。具体而言，实验设置了两种参考样本规模，即 5-shot 与 10-shot，分别表示每位用户采用 5 个和 10 个参考签名样本构建注册模板。在数据划分过程中，采用分层抽样策略以尽量保持不同划分下写者分布的一致性；同时，通过多次重复实验对结果进行统计，以减

弱单次划分所带来的偶然性影响，从而更为稳妥地考察模型在不同小样本配置下的认证表现。

3.2.2 评价指标

为较为全面地评估模型在在线手写签名认证任务中的表现，本文采用准确率 (Accuracy, ACC)、误识率 (False Acceptance Rate, FAR)、误拒率 (False Rejection Rate, FRR) 以及等错误率 (Equal Error Rate, EER) 作为评价指标。在二分类签名认证任务中，模型预测结果可由混淆矩阵表示，其中 TP 表示真实签名被正确判定为真实签名的样本数， TN 表示伪造签名被正确判定为伪造签名的样本数， FP 表示伪造签名被错误判定为真实签名的样本数， FN 表示真实签名被错误判定为伪造签名的样本数。

$$CM = \begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix} \quad (10)$$

在此基础上，准确率用于衡量模型在全部测试样本上的总体判别正确率，其表达式为

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

误识率与误拒率分别用于刻画系统的安全性与可用性，其定义如下：

$$FAR = \frac{FP}{TN + FP} \quad (12)$$

$$FRR = \frac{FN}{TP + FN} \quad (13)$$

考虑到 FAR 与 FRR 之间通常存在一定的权衡关系，本文进一步采用等错误率 EER 作为主要评价指标。EER 定义为在某一决策阈值 T 下，FAR 与 FRR 相等时对应的取值，即

$$EER = FAR_t = FRR_t \quad (14)$$

通常情况下，EER 越低，表明模型对真实签名与伪造签名的综合区分能力越强。因此，后续实验结果分析主要围绕 EER 展开，并结合 ACC 对模型整体表现进行辅助说明。

3.3 实验结果与分析

表 1 给出了所提方法在不同参考样本规模下的整体

认证结果。从结果变化趋势来看,当注册阶段参考签名样本由 5-shot 增加至 10-shot 时,误识率、误拒率和等错误率整体上呈下降趋势,而准确率相应提高。这在一

定程度上表明,在小样本在线手写签名认证任务中,参考样本数量的增加有助于补充用户书写信息,并对模型刻画真实签名与伪造签名之间的差异起到积极作用。

表 1 两数据集签名认证结果

数据集	训练数据	FAR (%)	FRR (%)	ACC (%)	EER (%)
SVC	5	7.13	1.02	95.93	3.93
MCYT	5	1.43	0.73	98.92	3.05
SVC	10	2.33	0.54	98.56	2.79
MCYT	10	0.96	0.56	99.24	1.46

从表 1 所示结果可以看出,所提模型在 5-shot 与 10-shot 两种设置下均保持了较为稳定的认证表现,且随着参考样本规模的增加,整体性能呈现出一定的改善趋势。这表明该方法对小样本注册条件具有一定适应性,也为后续对比实验与消融实验分析提供了结果基础。

图 5 给出了所提方法在 5-shot 条件下的 ROC 曲线。由图可见,两条曲线均分布在对角线左上方区域,说明模型在不同判决阈值下对真实签名与伪造签名具

有一定的区分能力。从曲线变化趋势来看,其形态相对平稳,反映出模型在阈值调整过程中表现出一定的判别稳定性。

从图 5 所示结果可以看出,ROC 曲线从可视化角度对模型在小样本条件下的认证表现进行了补充说明,也在一定程度上体现了所提方法对真实签名与伪造签名的区分能力,并可为后续阈值设置与结果分析提供一定参考。





图 5 SVC 和 MCYT 数据集的 ROC 曲线图

3.4 消融实验

为进一步分析模型中多尺度建模模块、特征重标定模块以及变分贝叶斯分类层对在线手写签名认证性能的影响,本文设计了如表 2 所示的消融实验配置。所有实验均在相同的数据划分、训练轮数、优化器参数及评价协议下进行,以尽量保证比较结果的公平性与可比性。整体上,各配置以 InceptionNext-TF 为基础,分

别引入 MSDC、SE、DASE 以及 VB 全连接层,用于考察不同结构组成对模型性能的影响。

表 3 展示了不同消融配置下模型在两个数据集上的实验结果。总体来看,随着多尺度建模模块、特征重标定模块以及变分贝叶斯分类层的逐步引入,模型性能整体呈现出一定的改善趋势。其中,MSDC 分支的加入说明多尺度空洞卷积结构对特征提取具有一定补充作用;SE 与 DASE 模块的引入则进一步表明,特征重标定机制有助于增强模型对关键信息的表达能力。

表 2 实验配置

编号	配置名称	说明
A0	InceptionNext-TF	基础网络结构
A1	InceptionNext-TF+MSDC	基础网络中加入多尺度空洞卷积分支
A2	InceptionNext-TF+SE	基础网络中加入 SE 模块
A3	InceptionNext-TF+DASE	在基础结构中加入 DASE
A4	InceptionNext-TF+DASE+VB	在 A3 基础上引入变分贝叶斯全连接层

在此基础上，A4 相较于 A3 进一步引入了变分贝叶斯全连接层。由结果变化可以看出，概率化分类层的加入对模型整体判别表现具有一定补充作用。这说明，在完成前端特征提取与增强之后，输出端采用分布式

参数建模方式，可能有助于提升小样本条件下分类层的适应性。总体而言，表 3 的消融结果表明，各组成模块在整体框架中均发挥了一定作用，而完整模型在综合表现上相对更为均衡。

表 3 消融实验

Groups	FLOPs	Params	ACC		EER	
			MCYT	SVC	MCYT	SVC
A0	10.72 M	0.88 M	97.96%	94.50%	4.96%	5.78%
A1	8.76 M	0.67 M	98.34%	96.00%	4.07%	4.53%
A2	10.87 M	0.93 M	98.48%	96.16%	3.95%	4.23%
A3	14.63 M	0.97 M	98.63%	96.18%	3.93%	4.37%
A4	14.9 M	0.97 M	98.92%	95.93%	3.05%	3.93%

图 6 展示了不同参数优化策略在训练过程中的准确率变化情况。可以看出，引入经验区间重用机制后，模型准确率上升更快，整体波动相对较小，并更早接近预设阈值；基于 K-Means 的区间收缩策略表现相对平

稳；而标准贝叶斯优化的波动较为明显。该结果在一定程度上说明，BO-APS 通过结合区间自适应收缩、经验回放与早停控制，有助于提升参数搜索的聚焦性与训练过程的稳定性。




图 6 贝叶斯优化准确率对比图

3.5 对比实验

表 4 展示了本文方法与已有方法在 SVC 2004 Task2 数据集上的对比结果。可以看出，本文方法在 5-shot 与 10-shot 两种设置下均取得了较低 EER，整体

结果处于相对较优水平。其中，5-shot 条件下的结果相较于多数对比方法具有一定优势，10-shot 条件下的结果也与现有较优方法较为接近。这在一定程度上说明，所提方法在 SVC 2004 Task2 数据集的小样本签名认证任务中具有一定的适用性与竞争力。

表 4 SVC-2004 Task2 对比实验

Method	5-shot EER	10-shot EER
DWT-DFT + SVM [7]	4.92%	-
Feature weighting algorithm relief [8]	5.31%	-
Few-Shot learning [9]	5.83%	-
Feature Fusion [10]	-	2.98%
curvature feature + torsion feature [11]	4.38%	-
DWSCNN [12]	3.98%	3.03%
Ours	3.93%	3.05%

表 5 MCYT-100 对比实验

Method	5-shot EER	10-shot EER
Combinational Features + Secure KNN-Regional features [13]	4.65%	-
Information Divergence-Based Matching [14]	3.16%	-
Virtual skeletal arm + DTW [15]	3.24%	-
Feature Fusion [10]	-	1.83%
curvature feature + torsion feature [11]	3.62%	-
DWSCNN [12]	3.11%	1.92%
Ours	2.79%	1.46%

表 5 展示了本文方法与已有方法在 MCYT-100 数据集上的对比结果。由表中结果可见, 本文方法在 5-shot 与 10-shot 两种设置下均取得了相对较低的 EER, 整体表现处于较优范围。从结果分布来看, 在参考样本数量较少的 5-shot 条件下, 本文方法仍能够保持较低的识别误差, 说明所构建的特征提取与判别框架在有限注册信息条件下具有一定的适应能力; 而在 10-shot 条件下, 随着参考样本规模的增加, 模型性能进一步改善, 也反映出该方法能够较好地利用更充分的用户签名信息。

结合表中其他方法可以看出, 本文方法在两种小样本设置下均表现出较为稳定的认证结果, 其中 5-shot 条件下与多数对比方法相比表现较好, 10-shot 条件下在表中可比方法中也具有一定优势。总体而言, 表 5 的结果在一定程度上表明, 所提方法在 MCYT-100 数据集的小样本签名认证任务中具有一定的适应性, 同时也说明该方法在参考样本数量变化时能够保持相对稳定的性能表现。

4 结论

本文提出了一种面向在线手写签名认证的轻量化深度学习框架, 在判别能力与计算效率之间进行了兼顾。模型以 InceptionNext-TF 实现跨尺度特征提取, 并通过 DASE 双分支结构结合池化与空洞卷积对多尺度依赖进行建模, 从而避免了注意力机制中常见的二次复杂度开销。为增强有限注册样本条件下的建模稳定性, 本文进一步引入变分贝叶斯全连接层进行不确定性建模, 并结合 BO-APS 策略对超参数搜索过程进行

优化。

在 MCYT-100 与 SVC 2004 Task2 数据集上的实验结果表明, 所提方法在小样本设置下取得了较好的认证效果: 在 5-shot 条件下, EER 分别为 3.05% 和 3.93%; 在 10-shot 条件下, 进一步下降至 1.46% 和 2.79%。总体来看, 该方法在保持较好验证性能的同时, 也体现出一定的效率优势。

同时, 本文方法仍有进一步完善的空间。例如, 在新的采集条件下, 变分贝叶斯层相关超参数可能对性能产生一定影响; 在跨设备或跨会话场景中, 模型表现也可能存在波动。后续工作将围绕更复杂采集条件下的鲁棒性以及跨数据集泛化能力展开进一步研究。

参考文献

- [1] Tolosana R, Vera-Rodriguez R, Fierrez J, et al. Biometric signature verification using recurrent neural networks [C] // 2017 14th IAPR international conference on document analysis and recognition (ICDAR). IEEE, 2017, 1: 652-657.
<https://doi.org/10.1109/ICDAR.2017.112>
- [2] Ghosh R. A Recurrent Neural Network based deep learning model for offline signature verification and recognition system [J]. Expert Systems with Applications, 2021, 168: 114249.
<https://doi.org/10.1016/j.eswa.2020.114249>
- [3] Vorugunti C S, Mukherjee P, Pulabaigari V. Osvnet: Convolutional siamese network for writer independent online signature verification [C] // 2019 international conference on document analysis and recognition (ICDAR). IEEE, 2019: 1470-1475.
<https://doi.org/10.1109/ICDAR.2019.00236>

- [4] Ahrabian K, BabaAli B. Usage of autoencoders and Siamese networks for online handwritten signature verification [J]. *Neural computing and applications*, 2019, 31(12): 9321-9334. <https://doi.org/10.1007/s00521-018-3844-z>
- [5] Shavit H, Jatelnicki F, Mor-Puigventós P, et al. From xception to NEXcepTion: New design decisions and neural architecture search [J]. *arXiv preprint arXiv: 2212.08448*, 2022. <https://doi.org/10.48550/arXiv.2212.08448>
- [6] Longjam T, Kisku D R, Gupta P. Writer independent handwritten signature verification on multi-scripted signatures using hybrid CNN-BiLSTM: A novel approach [J]. *Expert Systems with Applications*, 2023, 214: 119111. <https://doi.org/10.1016/j.eswa.2022.119111>
- [7] Khoh W H, Ong T S, Pang Y H, et al. Score level fusion approach in dynamic signature verification based on hybrid wavelet-Fourier transform [J]. *Security and Communication Networks*, 2014, 7(7): 1067-1078. <https://doi.org/10.1002/sec.829>
- [8] Yang L, Cheng Y, Wang X, et al. Online handwritten signature verification using feature weighting algorithm relief: L. Yang et al [J]. *Soft Computing*, 2018, 22(23): 7811-7823. <https://doi.org/10.1007/s00500-018-3477-2>
- [9] Vorugunti C S, Gorthi R K S, Pulabaigari V. Online signature verification by few-shot separable convolution based deep learning [C] // 2019 international conference on document analysis and recognition (ICDAR). IEEE, 2019: 1125-1130. <https://doi.org/10.1109/ICDAR.2019.00182>
- [10] Vorugunti C S, Pulabaigari V, Gorthi R K S S, et al. OSVFuse-Net: Online Signature Verification by feature fusion and depth-wise separable convolution based deep learning [J]. *Neurocomputing*, 2020, 409: 157-172. <https://doi.org/10.1016/j.neucom.2020.05.072>
- [11] Tan H, He L, Huang Z C, et al. Online signature verification based on dynamic features from gene expression programming [J]. *Multimedia Tools and Applications*, 2024, 83(5): 15195-15221. <https://doi.org/10.1007/s11042-021-11063-z>
- [12] Zheng J, Chen Z, Huang L, et al. DWSCNN online signature verification algorithm based on CAE-MV feature dimensionality reduction [J]. *IEEE Access*, 2024, 12: 22144-22157. <https://doi.org/10.1109/ACCESS.2024.3355449>
- [13] Doroz R, Kudlacik P, Porwik P. Online signature verification modeled by stability oriented reference signatures [J]. *Information Sciences*, 2018, 460: 151-171. <https://doi.org/10.1016/j.ins.2018.05.049>
- [14] Tang L, Kang W, Fang Y. Information divergence-based matching strategy for online signature verification [J]. *IEEE Transactions on Information Forensics and Security*, 2017, 13(4): 861-873. <https://doi.org/10.1109/TIFS.2017.2769023>
- [15] Diaz M, Ferrer M A, Quintana J J. Anthropomorphic features for on-line signatures [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 41(12): 2807-2819. <https://doi.org/10.1109/TPAMI.2018.2869163>