

# 基于双向LSTM的双任务学习残差通道注意力机制手写签名认证

栾方军, 陈昱岑, 袁 帅\*

沈阳建筑大学计算机科学与工程学院, 辽宁 沈阳

收稿日期: 2024年2月20日; 录用日期: 2024年3月21日; 发布日期: 2024年3月29日

## 摘 要

随着人工智能深度学习的发展, 网络模型对于在线签名认证系统(Online Signature Verification, OSV)的性能有了显著的提升。然而, 如何进一步提高在线手写签名认证的准确性仍然是一个需要解决的问题。为此, 本文提出了一种基于双向LSTM的双任务学习残差通道注意力机制网络模型, 用于改进手写签名认证。该模型使用残差通道注意力机制来学习序列特征的权重以便解决不同通道的权重分配问题, 双向长短期记忆网络来缓解在深度神经网络中增加深度时可能带来的梯度消失和梯度爆炸问题。此外, 引入多任务学习, 包括有监督学习和深度度量学习, 以更好地进行特征学习。最终, 本文提出了一种基于多任务学习的训练方法, 使得OSV系统的准确性进一步提高。所提出的方法在SVC-2004数据集中取得了2.33%的等错误率和97.03%的准确率。实验结果表明, 所提出的方法能够有效地提高OSV系统的身份验证准确性。

## 关键词

签名认证, 多任务学习, 残差通道注意力机制, 双向长短期记忆, 度量学习

# Dual-Task Learning Residual Channel Attention Mechanism for Handwritten Signature Verification Based on Bidirectional LSTM

Fangjun Luan, Yucen Chen, Shuai Yuan\*

School of Computer Science and Engineering, Shenyang Jianzhu University, Shenyang Liaoning

Received: Feb. 20<sup>th</sup>, 2024; accepted: Mar. 21<sup>st</sup>, 2024; published: Mar. 29<sup>th</sup>, 2024

\*通讯作者。

文章引用: 栾方军, 陈昱岑, 袁帅. 基于双向LSTM的双任务学习残差通道注意力机制手写签名认证[J]. 计算机科学与应用, 2024, 14(3): 159-168. DOI: 10.12677/csa.2024.143066

## Abstract

With the continuous progress of deep learning, network models have significantly improved the performance of Online Signature Verification system (OSV). Nevertheless, enhancing the accuracy of online handwritten signature verification remains a challenge yet to be resolved. In pursuit of this goal, this paper proposes a dual-task learning residual channel attention mechanism network model based on bidirectional LSTM to improve handwriting signature verification. The model employs the residual channel attention mechanism to adaptively learn the weights of sequence features, addressing the challenge of allocating weights across different channels. Additionally, it integrates a bidirectional long short-term memory (BiLSTM) network to mitigate issues such as gradient vanishing and explosion, which may arise with increased depth in deep neural networks. In addition, multi-task learning, including supervised learning and deep metric learning, is introduced to better perform feature learning. Finally, this paper proposes a training method based on multi-task learning to further improve the accuracy of OSV system. The proposed method achieves 2.33% equal error rate and 97.03% accuracy on SVC-2004 dataset. The experimental results show that the proposed method can effectively improve the accuracy of OSV system authentication.

## Keywords

Signature Authentication, Multitasking Learning, Residual Channel Attention Mechanism, Bi-LSTM, Measurement Learning

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

生物特征认证正在逐渐成为基于密码安全系统的更可靠替代方案。而签名作为生物特征的一种，不同于基于个人物理属性(如指纹或面部识别等)，而是基于个人行为属性。然而签名也存在一些问题，例如随时间变化而改变或容易被模仿。但是由于公众对其更加广泛接受，签名较适用于一些较低安全性的认证需求。

根据签名数据的输入方法，签名验证可分为离线签名验证和在线签名验证两部分。离线签名验证以签名的图像作为输入，适用于自动验证银行支票和文件上的签名。而在线签名验证则使用压敏片捕获的签名数据，除了提取签名的形状外，还能提取签名的动态特征。此类特征可包括笔画数量和顺序、签名整体速度以及每个点的笔压等，使得在线签名验证更为可靠、难以被仿冒。因此，在线签名验证也被广泛应用于保护小型个人设备(如 PDA、笔记本电脑)、授权计算机用户访问敏感数据或程序，以及个人进出物理设备或建筑物的认证。尽管签名验证已被长期广泛地用于个人认证，但由于类内的细微差异和熟练的伪造等问题，签名验证仍然具有挑战性，一直是一个活跃的研究领域。

在早期，针对 OSV 的研究主要集中在传统的模式识别技术上。在 1974 年，Lin 和 Nemeck 等人提出将签名视为二维图像，并通过提取签名的静态特征，运用 Hadamard 变换进行数据缩减和特征选择，正式开创了离线手写签名验证的研究[1]。

经过几十年的发展，国内外的研究学者们对手写签名验证领域的相关研究越来越感兴趣，相关技术

也变得越来越多样,其研究成果也越来越显著。例如, Snehil G. Jaiswal 等人基于全局和局部特征进行识别,并强调验证结果深受预处理过程的影响[2]。

随着深度学习技术的进步,OSV 技术也得到了应用,研究人员开始考虑采用卷积神经网络来直接学习手写签名图像的特征。在 2012 年, Khalajzadeh 等人尝试应用卷积神经网络提取波斯文签名图像的特征[3]。另外,一些研究者使用胶囊网络代替卷积神经网络进行离线手写签名认证,在低分辨率下取得了更好的性能[4]。还有一些学者使用 12 种签名特征序列作为自动编码器的输入,建立了独立于用户的在线签名认证模型并实现了高准确率[5]。此外, Rantzsch 等人研究了一种三路输入度量学习模型,通过最小化真实签名的距离并最大化真实签名和伪造签名的距离来改进模型准确性[6]。Wei 等人则提出了一种四路输入的逆判别网络模型,通过引入注意力机制来聚焦于签名的笔迹,最终实现了较为出色的性能[7]。

虽然深度学习技术的进步有效提高了 OSV 系统的性能,但是这些基于深度学习的方法都是单任务学习,且由于每个用户提供的签名样本数量有限,这些方法不能很好地学习到签名的判别性特征。为了解决这个问题,本文提出了一种基于双向 LSTM 的双任务学习残差通道注意力机制手写签名认证(Dual-task learning residual channel attention mechanism for handwritten signature verification based on bidirectional LSTM)。本文的主要贡献如下:

首先,利用残差通道注意力机制模型来学习序列特征的权重和双向 LSTM 网络,缓解在不同通道间的权重分配问题和深度神经网络中加深层数导致的梯度消失和梯度爆炸问题。其次,引入多任务学习,包括有监督学习和深度度量学习来进行特征学习。最后,本文提出了一种基于多任务学习的训练方法,进一步提高了 OSV 系统的准确率。

## 2. 方法

### 2.1. 数据集以及预处理

本研究采用公开且可用的 SVC-2004-Task2 数据集[8],其中的签名来自 WACOM Intuos 平板电脑。该数据集包含较少的签名样本,共有 40 个用户,每个用户拥有 20 个真实样本和 20 个熟练的伪造样本。本研究将每个用户的前 15 个真伪签名样本作为训练集,将每个用户的后 5 个真伪签名样本作为验证集。首先,根据文献[9]的指导,提取了 40 多个能够表示签名的全局特征,包括 X 方向和 Y 方向速度的最大值、均值,以及 X 方向和 Y 方向压力的标准差等。其次,我们选择了签名的横坐标(x)序列、纵坐标(y)序列以及压力(p)序列作为表示签名的序列特征。由于签名的特征受硬件设备在采集过程中的影响,因此在预处理过程中需要进行平滑操作和归一化的操作,以消除这些影响。在本研究中,我们使用了五点三次平滑滤波器对签名进行平滑处理,然后对其进行规范化,将签名的尺寸缩放到[0, 1]的范围内。

### 2.2. 算法总体框架

本研究采用一种基于双向 LSTM 的双任务学习残差通道注意力机制模型,提出了一个新的手写签名认证算法。总体算法框架如图 1 所示。该网络采用残差通道注意力机制双向 LSTM 网络模型,并结合有监督学习任务 and 深度度量学习任务进行特征提取和训练。首先,将签名的全局特征和序列特征作为残差通道注意力机制双向 LSTM 网络模型的输入并且对全局特征和局部特征进行特征提取。其次,使用有监督学习任务 and 深度度量学习任务进行签名序列特征训练。两个任务按不同的权重进行学习,最终得到优秀的训练结果。本研究接下来将详细介绍算法的实现细节。




Figure 1. Overall model of the algorithm  
图 1. 算法总体模型

### 2.3. 残差通道注意力机制




Figure 2. Residual channel attention mechanism mode  
图 2. 残差通道注意力机制模型

在深度神经网络中，不同通道之间通常存在着相互依赖和相关性，其中某些特征对某些通道更加敏感，而其他特征对其他通道更加敏感。然而，传统的神经网络可能无法充分捕捉到这些通道之间的重要依赖关系和模式差异，从而无法有效地利用不同通道的特性，进而降低了网络的表达能力和判别性能。另外，通道内部还可能存在着模式差异，不同通道对不同的特征或模式具有不同的响应。然而，传统的

网络未能有效地对这种差异进行建模，导致难以处理通道内的模式差异，最终影响网络的性能。为了解决上述问题，在本研究中，我设计了一种残差通道注意力机制，如图 2 所示。这一机制旨在最大程度地提升网络的表达能力和判别性能，从而充分利用不同通道之间的依赖关系和模式差异，以及处理通道内部的模式差异。

对于之前学过残差网络的人来说，他们可能已经了解到在处理复杂问题时，过浅的神经网络无法达到理想的性能。为了解决这个问题，增加网络的深度成为了解决图像分类问题的最佳方法。然而，增加网络深度很容易导致过拟合，甚至导致在训练集上的准确率下降。为了克服这个问题，残差网络提出了一种新的网络结构，该结构可以对所有网络进行改进，并且真正有效地增加网络的深度。

其中，SE (Squeeze-and-Excitation)模块的灵活性在于它可以直接应用于现有的网络结构中。在本研究中，我们将 SE 模块嵌入到残差学习分支中。通过使用 SENet 改进的 ResNet 网络，无论原始网络的深度如何，都能有效地增加网络的深度，并且实现了显著的实验效果提升。通过引入 SE 模块，网络能够自适应地调整通道的重要性，从而更好地捕捉特征之间的相关性，提高了网络的表示能力，进而取得了更好的分类性能。

残差通道注意力机制是一种引入注意力权重的方法，它能够自适应地调整通道的重要性，以解决传统神经网络中存在的通道间依赖关系和通道内模式差异的问题。这种机制极大地增强了网络的表示能力，同时也具备了自适应性和灵活性，并且能够减少模型的参数数量和计算复杂度。

本研究中我们使用一种基于残差通道注意力机制的模型，通过采用 SE 模块进行处理。通过这一过程，我们能够自适应地调整通道的重要性，进而更好地捕捉特征之间的依赖关系以及通道内部的模式差异。假设输入的特征维度为  $H \times W \times C$ ，特征经过压缩操作，将跨空间维度  $H \times W$  的特征映射进行聚合，生成一个具有特定维度的全局空间信息。在这个过程中，我们采用 sigmoid 函数，并嵌入了一个 ReLU 函数，以限制模型的复杂性并帮助训练。在实现上，我们使用  $W_1$  来降低维度，使用  $W_2$  来递增维度。最后，通过通道加权将输出的注意力权重应用于输入特征。并且把处理之后特征加入到残差网络中获得更好的效果。

具体公式如下：

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (1)$$

$$s = F_{ex}(z, w) = \sigma(g(z, W)) = \sigma(W_2 \text{RELU}(W_1 z)) \quad (2)$$

$$\tilde{x}_c = \text{Fscale}(u_c, s_c) = s_c \cdot u_c \quad (3)$$

$$F_{(x)} = G_{(x)} + \tilde{x}_c \quad (4)$$

这个研究的贡献在于在残差网络中引入 SE 模块，通过将其嵌入到网络结构中，实现了对网络深度的有效增加，并且在图像分类任务上取得了显著的性能提升。这一研究为解决复杂问题和利用深度网络进行图像分类提供了一种有效的方法。

## 2.4. 双向长短期记忆网络

RNN (Recurrent Neural Network, 循环神经网络)被广泛应用于处理序列数据，如自然语言处理(NLP)和语音识别[10]。然而，传统的 RNN 存在一些问题，例如难以捕捉长期依赖关系以及梯度消失或者梯度爆炸等，这导致了其在学习时间序列长期依赖方面的能力非常有限。为了解决这个问题，双向 LSTM 网络(Bidirectional long short-term memory, 双向长短期记忆)作为一种新型变体出现在 RNN 模型中，能够高效地捕捉时间序列上的长期依赖关系。

在本研究中，我们借助双向 LSTM 网络来处理输入的签名序列，其中序列数据分别从前向后和从后向前进行传递。这种双向传递的方式使得模型能够更好地获取全局上下文信息，这对于更好地理解和预测序列数据非常有帮助。此外，双向 LSTM 还拥有更出色的特征表示能力，能够提取更丰富的特征表达，从而提高模型的表达能力。双向 LSTM 模型的详细结构如图 3 所示。现在我们来详细介绍一下 LSTM 模型。

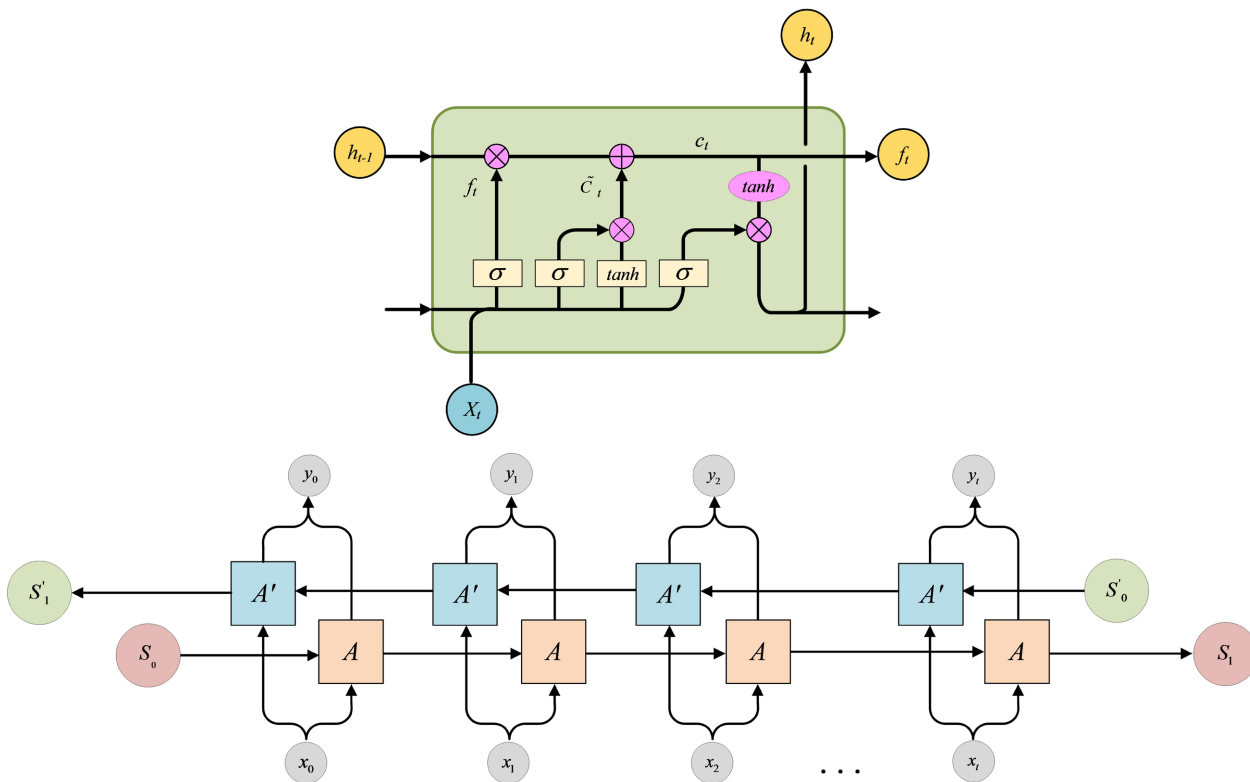


Figure 3. Bidirectional long short-term memory network model  
图 3. 双向长短时记忆网络模型

LSTM 模型包含三个关键结构：输入门(Input Gate)、遗忘门(Forget Gate)和输出门(Output Gate)。这些门控制着信息在 LSTM 单元内的流动，从而决定了哪些信息需要被记住、遗忘或输出。除了以上 3 种结构。还有细胞状态和隐藏状态。假设  $x_t$  表示第  $t$  时间的输入信息，则对应时间上的输出  $h_t$ 。式子中  $h_{t-1}$  表示前一时刻的输出。 $f_t$ ,  $C_t$ ,  $h_t$  分别表示遗忘门，输入门，输出门的输出。 $W$  和  $b$  表示参数， $\sigma$  表示 sigmoid 激活函数， $\tanh$  表示激活函数。 $C_t$  表示细胞状态。

具体公式如下：

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{5}$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{6}$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \tag{7}$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{8}$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \tag{9}$$



$$h_i = o_i * \tanh(C_i) \quad (10)$$

## 2.5. 双任务学习的训练方法

本研究分别构建了两种学习任务的损失函数，即有监督学习任务 and 深度度量学习任务，并将它们结合起来构建用于训练残差通道注意力机制模型的多任务损失函数。每种损失函数的设计如下：

**有监督学习任务：**本研究所构建的模型使用交叉熵损失(cross-entropy loss, CEL)函数来进行网络的有监督学习。有监督学习任务的损失函数如下式所示：

$$J_1 = -\frac{1}{M} \sum_{i=1}^M \sum_{y_i=1}^k y_i \log h(\hat{y}_i) \quad (11)$$

式中， $M$  为样本数量， $k$  为分类数量， $y_i$  为真实标签， $\hat{y}_i$  为网络所预测的分类概率。并且我们把输出结果设置为  $J_1$ 。

**深度度量学习任务：**考虑到在线手写签名类内存在不稳定性，这使得真假签名之间的界限相对模糊。为了使网络能够更好地学习签名序列的判别性特征，本研究采用了联合训练的方式，结合了 Softmax Loss 和 Center Loss。其中，Softmax Loss 用于将不同类别的深度特征分开，而 Center Loss 则能够将同一类别的特征吸引到类别中心。这种结合的方法不仅可以扩大不同类别之间的特征差异，还能减小同一类别内部特征之间的差距。随着 Center Loss 的比重增大，类别内部特征的聚合效果以及分类准确性也会得到提升，结果如图 4 所示。此外，损失函数采用了交叉熵损失函数。其中，向量  $c_{y_i}$  就是第  $y_i$  个类别中心， $x_i$  表示全连接之前的特征， $W$  和  $b$  表示参数。 $m$  表示 mini-batch 大小。如果条件满足  $\delta$  (条件) = 1，则进行更新操作；否则  $\delta$  (条件) = 0。即只有当  $y_i$  和  $c_j$  的类别  $i = j$  的时候才更新  $c_j$ 。

$$L_c = \frac{1}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (12)$$

$$\mathcal{L} = \mathcal{L}_s + \lambda \mathcal{L}_c \quad (13)$$

$$J_2 = -\sum_{i=1}^m \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{W_j^T x_i + b_j}} + \frac{\lambda}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (14)$$

**多任务学习：**在网络的训练过程中，本研究通过将残差通道注意力机制和双向 LSTM 网络进行特征提取实现了不同类型特征之间的信息互补，为两种网络模型的共同学习建立联系。同时，将上述两个任务的损失函数相结合，构建了双任务残差通道注意力机制网络模型的多任务损失函数。该多任务损失函数如下：

并且，设置  $\alpha$  和  $\beta$  为损失函数的权重。到此。研究提出的双任务残差通道注意力机制网络模型构建完成。

$$J_{MTL}(F^a, F^p) = \alpha J_1 + \beta J_2 \quad (15)$$

## 3. 实验分析

### 3.1. 超参数寻优

在这项研究中，我们采用了 Python 3.8 和 TensorFlow 2.3 深度学习库，用于优化、训练和验证神经网络。为了提高双向 LSTM 的双任务学习残差通道注意力机制模型的收敛性能，我们选择了 Adam 优化器，并使用双任务损失函数。通过精心调整 B\_1、B\_2、Epsilon 和 Decay 等参数，我们能够精确控制网络的学习过程。双向 LSTM 的双任务学习残差通道注意力机制模型的详细超参数如表 1 中所列示。对于这项

研究，我们努力保证了代码的兼容性和性能的优越表现，以确保结果的可靠性和鲁棒性。

**Table 1.** Hyperparameter optimization results of model

**表 1.** 模型的超参数寻优结果

超参数	参数值
Epoch	100
Batch Size	4
损失函数	多任务损失函数
$[\alpha, \beta]$	[1, 0.1]
优化器	Adam
B_1	0.9
B_2	0.99
Epsilon	1e-8
Decay	1e-5

### 3.2. 实验结果分析

通过采用双向 LSTM 进行双任务学习残差通道注意力机制模型，我们对 40 位用户的签名样本进行了个别训练，以构建出依赖于用户的签名认证模型。在本研究中，我们以该模型 Softmax 层输出的后验概率作为度量签名准确率的标准。最后实验结果达到了 97.03%。且仅有 9 位用户出现认证错误。如表 2 所示。

**Table 2.** The user statistical results of error verification

**表 2.** 错误认证的用户统计结果

用户序号	2	7	11	12	21	26	30	32	37
错误拒绝数	1	0	1	2	1	1	2	0	1
错误接受数	1	1	0	1	2	2	1	1	0


另外，本研究采用消融实验来进一步分析双向 LSTM 的双任务学习残差通道注意力机制模型的学习性能(模型 3)。我们首先删除双向 LSTM 的双任务学习残差通道注意力机制模型的有监督学习任务来构建基于双向 LSTM 的深度度量任务残差通道注意力机制模型(模型 2)。同时在此任务基础上删除双向 Lstm 网络来构建继续深度度量任务残差通道注意力机制模型(模型 1)。我们根据上述消融实验构建了 3 种实验模型。以上 3 种模型的对比结果如表 3 所示。相比较其他两种模型。双向 LSTM 的双任务学习残差通道注意力机制模型的准确率达到到了 97.03%，等错误率达到了 2.33%，受试者工作特征(receiver operating characteristic, ROC)曲线如图 4 所示。

**Table 3.** Authentication result comparison

**表 3.** 认证结果对比

消融实验方法	准确率(%)	等错误率(%)
模型 1	87.99	12.30
模型 2	95.83	4.77
模型 3	97.03	2.33





**Figure 4.** ROC curve comparison results  
**图 4.** ROC 曲线对比结果

### 3.3. 相关工作对比

为了更深入验证所提出方法的有效性，本研究进行了与其他优秀方法的性能对比实验。我们在数据集上对比相关工作，并将实验结果列于表 4 中。我们所提出的方法取得了 2.33% 的等错误率，在认证性能方面，相较于表中其他的识别方法，本文所提出的双向 LSTM 的双任务学习残差通道注意力机制模型实现了降低等错误率。在认证模型方面，我们通过结合残差通道注意力机制和双向 LSTM 网络，提升了识别能力。据此。我们的方法在 SVC 数据集上表现出色，在认证性能和等错误率方面都取得了显著的改进。这进一步证明了我们所提方法的有效性和潜力，为深度学习算法在签名识别领域的应用提供了有力支持。

**Table 4.** Comparison between the proposed method  
**表 4.** 相关工作对比

文献	方法	等错误率(%)
Sharma (2017) [11]	基于公共阈值的 DTW 模型	7.80
Xia X (2018) [12]	使用特征曲线约束改进的 DTW	2.60
Vorugunti, C, S. (2019) [13]	小样本学习	5.83
He,L (2018) [14]	曲率特征 + 扭转特征 + 豪斯多夫距离	6.61
Vorugunti, C, S. (2020) [15]	特征融合	2.98
本文	本方法	2.33

## 4. 结论

本文提出了一种改进的手写签名认证算法，即双向 LSTM 的双任务学习残差通道注意力机制模型用

于在线手写签名的认证。同时, 通过结合残差通道注意力机制和双向 LSTM 网络, 我们提高了网络对签名中重要信息的捕获能力, 并增强了特征的筛选能力。实验证明, 我们提出的双向 LSTM 的双任务学习残差通道注意力机制模型将错误率降低到了惊人的 2.33%, 显著提升了签名认证的精度。与以往的研究相比, 本研究的方法在性能上展现出了更高的水平, 进一步证实了该方法的先进性。这项研究为在线手写签名认证领域带来了重要的进展, 具有广泛的应用前景。

## 基金项目

国家自然科学基金面上项目(62073227)。

## 参考文献

- [1] Nemcek, W.F. and Lin, W.C. (1974) Experimental Investigation of Automatic Signature Verification. *Systems, Man and Cybernetics*, SMC-4, 121-126. <https://doi.org/10.1109/TSMC.1974.5408537>
- [2] Jaiswal, S.G. and Kasetwar, A.R. (2014) Off-Line Signature Verification Using Global & Local Features with Neural Networks. 2014 *IEEE International Conference on Advanced Communications, Control and Computing Technologies*, Ramanathapuram, 8-10 May 2014, 1525-1531. <https://doi.org/10.1109/ICACCCT.2014.7019361>
- [3] Khalajzadeh, H., Mansouri, M. and Teshnehlab, M. (2012) Persian Signature Verification Using Convolutional Neural Networks. *International Journal of Engineering Research and Technology*, **1**, 7-12.
- [4] Gumusbas, D. and Yildirim, T. (2019) Offline Signature Identification and Verification Using Capsule Network. 2019 *IEEE International Symposium on INnovations in Intelligent Systems and Applications (INISTA)*, Sofia, 3-5 July 2019, 1-5.
- [5] Ahrabian, K. and BabaAli, B. (2019) Usage of Autoencoders and Siamese Networks for Online Handwritten Signature Verification. *Neural Computing and Applications*, **31**, 9321-9334. <https://doi.org/10.1007/s00521-018-3844-z>
- [6] Rantzsch, H., Yang, H. and Meinel, C. (2016) Signature Embedding: Writer Independent Offline Signature Verification with Deep Metric Learning. In: Bebis, G., et al., Eds., *Advances in Visual Computing, ISVC 2016, Lecture Notes in Computer Science*, Vol. 10073, Springer, Cham, 616-625. [https://doi.org/10.1007/978-3-319-50832-0\\_60](https://doi.org/10.1007/978-3-319-50832-0_60)
- [7] Wei, P., Li, H. and Hu, P. (2019) Inverse Discriminative Networks for Handwritten Signature Verification. 2019 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 15-20 June 2019, 5764-5772. <https://doi.org/10.1109/CVPR.2019.00591>
- [8] Yeung, D.Y., Chang, H., Xiong, Y., et al. (2004) SVC2004: First International Signature Verification Competition. In: Zhang, D. and Jain, A.K. Eds., *International Conference on Biometric Authentication*, Springer, Berlin, 16-22. [https://doi.org/10.1007/978-3-540-25948-0\\_3](https://doi.org/10.1007/978-3-540-25948-0_3)
- [9] Vorugunti, C.S., Mukherjee, P. and Pulabaigari, V. (2019) Osvnet: Convolutional Siamese Network for Writer Independent Online Signature Verification. 2019 *International Conference on Document Analysis and Recognition (ICDAR)*, Sydney, 20-25 September 2019, 1470-1475. <https://doi.org/10.1109/ICDAR.2019.00236>
- [10] Bengio, Y., Simard, P.Y. and Frasconi, P. (1994) Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*, **5**, 157-166. <https://doi.org/10.1109/72.279181>
- [11] Sharma, A. and Sundaram, S. (2017) On the Exploration of Information from the DTW Cost Matrix for Online Signature Verification. *IEEE Transactions on Cybernetics*, **48**, 611-624. <https://doi.org/10.1109/TCYB.2017.2647826>
- [12] Xia, X., Song, X., Luan, F., et al. (2018) Discriminative Feature Selection for on-Line Signature Verification. *Pattern Recognition*, **74**, 422-433. <https://doi.org/10.1016/j.patcog.2017.09.033>
- [13] Vorugunti, C.S., Gorthi, P.K.S. and Pulabaigari, V. (2019) Online Signature Verification by Few-Shot Separable Convolution Based Deep Learning. 2019 *International Conference on Document Analysis and Recognition (ICDAR)*, Sydney, 20-25 September 2019, 1125-1130 <https://doi.org/10.1109/ICDAR.2019.00182>
- [14] He, L., Tan, H. and Huang, Z.C. (2019) Online Handwritten Signature Verification Based on Association of Curvature and Torsion Feature with Hausdorff Distance. *Multimedia Tools and Applications*, **78**, 19253-19278. <https://doi.org/10.1007/s11042-019-7264-6>
- [15] Vorugunti, C.S., Pulabaigari, V., Gorthi, R.K.S.S., et al. (2020) OSVFuseNet: Online Signature Verification by Feature Fusion and Depth-Wise Separable Convolution Based Deep Learning. *Neurocomputing*, **409**, 157-172. <https://doi.org/10.1016/j.neucom.2020.05.072>