

# 基于元学习模型优化器的小样本手写西波文字识别

何翠玲, 梅自艳, 顾玉碟

滇池学院理工学院, 云南 昆明

收稿日期: 2026年3月9日; 录用日期: 2026年5月19日; 发布日期: 2026年5月28日

## 摘要

本文针对手写西波文字因样本稀缺而难以使用传统神经网络进行有效识别的问题, 提出了一种基于元学习的优化框架。该框架以长短期记忆神经网络(LSTM)作为元优化器, 来学习如何优化一个基础的卷积神经网络(CNN)或深度神经网络(DNN)。其核心创新在于结合了两种策略: 1) 通过在MNIST数据集上进行预训练, 实现跨任务的知识迁移; 2) 通过LSTM优化器实现动态的梯度调控策略, 自适应地调整基础网络的参数更新。实验结果显示, 该方法在10类手写西波文字的小样本测试集上, 将CNN的识别准确率从24%显著提升至73%, 并将训练时间缩短至368秒, 远优于传统的数据增强方法。研究旨在为西波文等少数民族濒危文字的数字化保护提供一种高效、可行的小样本学习技术方案。

## 关键词

手写西波文字识别, 小样本, 长短期记忆神经网络, 元学习

# Meta-Learned Optimizer for Few-Shot Handwritten Xibo Characters Recognition

Cuiling He, Ziyang Mei, Yudie Gu

School of Computer Science, Dianchi College, Kunming Yunnan

Received: March 9, 2026; accepted: May 19, 2026; published: May 28, 2026

## Abstract

This paper proposes a meta-learning-based optimization framework to address the challenge of effectively recognizing handwritten Xibo characters using traditional neural networks under extreme sample scarcity. The framework employs a Long Short-Term Memory (LSTM) network as a meta-

**optimizer to learn how to optimize a base Convolutional Neural Network (CNN) or Deep Neural Network (DNN). Its core innovation lies in combining two strategies: 1) Cross-task knowledge transfer achieved through pre-training on the MNIST dataset; 2) A dynamic gradient regulation strategy implemented by the LSTM optimizer to adaptively adjust the parameter updates of the base network. Experimental results demonstrate that on a few-shot test set of 10-class handwritten Xibo characters, this method significantly boosts the recognition accuracy of a CNN from 24% to 73%, while reducing the training time to 368 seconds, far outperforming traditional data augmentation methods. This research aims to provide an efficient and feasible few-shot learning technical solution for the digital preservation of endangered minority scripts like Xibo.**

## Keywords

**Handwritten Xibo Characters Recognition, Few-Shot Learning, Long Short-Term Memory, Meta-Learning**

Copyright © 2026 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

手写西波文字是彝族文化遗产的核心载体，但其数字化保护工作由于传统方法的低效性而面临瓶颈。因此，发展高效、智能的手写西波文字识别技术，不仅是实现古籍数字化存档与永久保存的关键，更是为彝族文明的守护、研究乃至未来创新性发展提供核心动力的战略突破口。目前，手写西波文字的识别研究正面临严峻的小样本挑战。传承者的稀缺导致样本极度匮乏，古籍的老化导致质量退化，而粗放的采集方式则造成信息损毁。这导致可用于监督训练的有效数据集规模极小。因此，传统深度学习模型在此类数据集上不仅难以学习有效特征，也无法克服过拟合与梯度不稳定等训练难题，导致识别性能急剧下降。为克服深度学习对海量标注数据的强依赖性，小样本[1]学习应运而生。小样本学习核心目标是模型通过极少量样本快速识别新类别。根据实现机制的不同，主流方法主要遵循三类技术路线。一类是基于度量学习，旨在通过深度网络将样本映射至具有高度判别性的特征空间，并在该空间中进行相似性比较。代表性方法有基于样本对相似度比较的孪生网络[2]、通过计算类别原型向量进行分类的原型网络[3]以及采用可学习关联模块替代固定度量函数的关系网络[4]。另一类是借助记忆增强机制，通过引入外部记忆单元模拟人类的记忆与联想过程，实现跨任务的知识传递与快速检索，比如记忆增强网络[5]和元网络[6]都通过读写操作从历史经验中提取有效信息以辅助新任务学习。此外，基于优化的方法则聚焦于模型初始参数的元学习，旨在获得一个具备强泛化能力的初始化模型，使其在面对新任务时仅需少量梯度更新即可快速适应。Ravi等[7]首次利用LSTM网络模拟梯度下降过程。Antoniou等[8]提出的模型无关元学习则通过直接优化模型初始参数，构建出一个简洁而通用的学习框架。后续出现的MAML++ [9]和Meta-SGD [10]等工作分别针对学习率设置与更新方向等细节进行改进，进一步提升算法稳定性与性能。然而，现有元学习方法大多在图像质量较高、类别内差异较小的标准数据集上验证有效。在面对手写西波文字这类同时存在复杂结构噪声、严重类内形变及低图像质量的实际场景时，现有方法在特征鲁棒性与度量判别性方面仍面临不足，其适用性有待深入研究和专门优化。

在彝文识别具体研究方面，国内学者已积累一定基础。早期工作主要基于传统模式识别技术，比如基于模板匹配[11]、组合特征分类[12]和字典匹配[13]等方法的探索。近年来，随着深度学习的发展，相关研究逐渐转向数据驱动模式，比如沙马拉毅团队[14]开发的实用识别系统，以及陈善雄等[15]人构建的

系列卷积神经网络模型。尽管这些成果为彝文信息化处理奠定了初步基础，其研究焦点仍普遍集中字形规范，数据相对充足的现代规范彝文。对于手写西波文字这一特殊文本形态，尤其在面临的小样本、低质量及复杂噪声等现实挑战面前，现有方法不是有效的解决方案。因此，针对手写西波文字的小样本识别问题仍存在明显的研究空白，也为本文的研究提供了明确的出发点。

本文提出一种基于 LSTM 元模型优化器的小样本手写西波文字智能识别方法。本研究的核心主要体现在以下方面：首先，构建一个融合深度学习基础模型与 LSTM 元优化器的元学习框架，该框架主要从根本上解决西波文字因样本稀缺导致的模型训练与快速适应难题。其次，通过引入 LSTM 优化器所特有的记忆与门控机制，实现参数更新过程中的动态策略学习与调整，从而在少量样本条件下使得模型更稳定、高效的收敛，并有效缓解梯度异常问题。最后通过自建的手写西波文字小样本数据集上进行系统化实验，验证了本文方法相对于传统深度学习在识别性能上的优越性。

## 2. 元学习模型优化器

在深度学习中，模型训练的目标是最小化训练集上的期望损失。基础学习器的参数为  $\theta$ ，其目标函数通常定义为[16]：

$$J(\theta) = \sum_{i=1}^n \frac{1}{n} L(f(x, \theta), y) \quad (1)$$

$L$  为样本损失函数。梯度下降是求解期望损失最小化的标准方法，其参数更新规则[17]为

$$\theta_t = \theta_{t-1} - a_t \nabla_{\theta_{t-1}} L_t \quad (2)$$

其中  $a$  为学习率。梯度下降过程中，学习率  $a$  和参数初始化  $\theta_0$  的设置至关重要。若设置不当，则会引起梯度消失、梯度爆炸和过拟合问题，导致模型训练性能下降。

观察梯度下降公式，发现参数更新规则和 LSTM 神经网络中记忆细胞单元状态的更新规则高度相似，

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (3)$$

如果  $f_t = 1$ ， $c_{t-1} = \theta_{t-1}$ ， $i_t = a_t$  和  $\tilde{c}_t = \nabla_{\theta_{t-1}} L_t$ ，则 LSTM 神经网络中记忆细胞单元状态的更新规则变为梯度下降公式。

受此启发，我们提出训练元模型优化器学习 LSTM 神经网络记忆细胞单元状态的更新规则。将 LSTM 神经网络的记忆细胞单元状态设置为学习器的参数即  $c_t = \theta_t$ ，且候选单元状态  $\tilde{c}_t = \nabla_{\theta_{t-1}} L_t$  为遗忘门  $f_t$  和输入门  $i_t$  定义参数形式，以便元模型优化器通过更新过程确定最佳值，具体优化见图 1 所示：

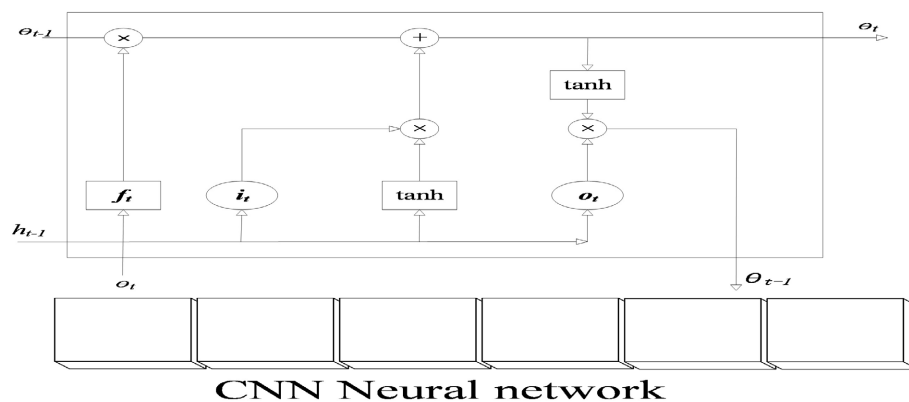


Figure 1. CNN-based meta-optimizer  
图 1. 基于 CNN 的元模型优化器

输入门  $i_t$  对应学习率  $a_t$ ，令

$$i_t = \sigma(w_i \cdot [\nabla_{\theta_{t-1}} L_t, L_t, \theta_{t-1}, i_{t-1}] + b_i) \tag{4}$$

其中， $i_t$  代替了学习率  $a_t$ ，是当前参数值  $\theta_{t-1}$ ，梯度  $\nabla_{\theta_{t-1}} L_t$ ，损失  $L_t$  和先前学习率  $i_{t-1}$  的函数。利用上述信息，元模型优化器能精确地控制学习率，以便在避免分歧的时候可快速训练深度学习神经网络。

在模型训练过程中，当出现梯度消失或爆炸时，深度学习神经网络的优化过程会陷入停滞。这时，深度学习神经网络需要重新调整参数。遗忘先前学习的内容，丢弃当前部分参数，并重置学习状态寻求更优的优化路径。因此，将遗忘门设置成梯度、损失和先前遗忘门值的函数

$$f_t = \sigma(w_f \cdot [\nabla_{\theta_{t-1}} L_t, L_t, \theta_{t-1}, f_{t-1}] + b_f) \tag{5}$$

此外，将 LSTM 的单元初始状态  $c_0$  定义为元模型优化器的参数。不仅学习参数  $\theta_t$  的更新规则，还确定深度学习神经网络的最佳初始权重。通过这一设置，缩短深度学习神经网络训练时间，提升模型优化效率。

元模型优化过程中，元模型 LSTM 网络对包含数万个参数的深度神经网络进行梯度更新时，会出现参数爆炸问题。为解决参数爆炸问题，我们需要采用参数共享。另一方面，由于梯度和损失的不同坐标可能不同，因此我们需要对值进行标准化时需非常小心，以便于元学习模型优化器在训练期间正常使用。在这里，我们采用 Andrychowicz 等[10]人的参数共享方法。

$$x \rightarrow \begin{cases} \left( \frac{\log(|x|)}{p}, \text{sgn}(x) \right) & \text{if } |x| \geq e \\ (-1, e^p x) & \text{otherwise} \end{cases} \tag{6}$$

其中，参数  $p$  用于调节梯度均值项的缩放强度， $p$  的取值需要在消除量纲差异与保留梯度方向信息之间取得平衡，若  $p$  取值过小，则标准化的梯度仍可能保留较大的尺度差异，导致元优化器输入不稳定，若  $p$  取值过大，则可能过度削弱梯度信号，造成有效信息损失。通过实验对比，发现当  $p = 8$  时，实验运行效果最好。具体的参数共享见图 2 所示：

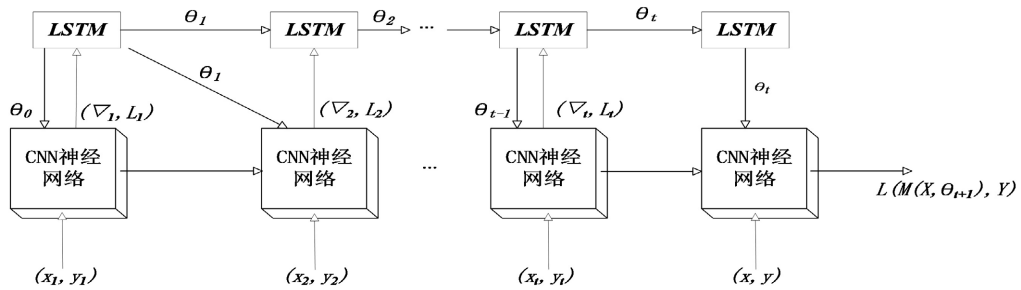


Figure 2. Parameter sharing of meta-optimizer  
图 2. 元模型优化参数共享

LSTM 神经网络通过遗忘门和记忆细胞选择有效参数。并利用梯度更新和反向传播，将参数传递给 CNN 神经网络进行模型训练和优化。当 LSTM 神经网络的遗忘门  $f_t$  关闭时，LSTM 神经网络利用之前所更新的参数进行参数共享并训练。当遗忘门  $f_t$  打开时，LSTM 神经网络利用输入门  $i_t$  参数共享的方式进行参数更新并训练。对训练集  $D$  进行迭代训练时，在每个时间步骤  $t$  上，元模型优化器从神经网络接收  $(\nabla_{\theta_{t-1}} L_t, L_t)$ ，并提出新的参数集  $\theta_t$ 。该过程重复  $T$  个步骤并产生相应损失，然后用于训练 CNN 神经网络。具体训练过程如下：

**算法:** 元模型优化器训练算法

**输入:** MNIST 数据训练集、西波手写文字样本测试集, 神经网络参数  $\theta$ 、优化器参数  $\Theta$

```

1: 随机初始化  $\Theta_0$ 
2: for  $d=1, n$  do
3:   MNIST 数据集随机抽取样本为训练集  $D_{train}$ , 西波手写文字测试集  $D_{test}$ 
4:   初始化神经网络参数  $\theta_0$ 
5:   for  $t=1, T$  do
6:     MNIST 数据训练集  $D_{train}$  中随机抽取批量样本  $X_t, Y_t$ 
7:     计算神经网络训练批次  $t$  时刻的损失  $L_t \leftarrow L(M(X_t; \theta_{t-1}), Y_t)$ 
8:     计算优化器  $t$  时刻输出  $c_t \leftarrow R((\nabla_{\theta_{t-1}} L_t, L_t); \Theta_{d-1})$ 
9:     更新神经网络参数  $\theta_t \leftarrow c_t$ 
10:  end for
11:   西波手写文字图片测试集  $D_{test}$  中抽取样本  $X, Y$ 
12:   计算神经网络测试批次  $t$  时刻损失  $L_{test} \leftarrow L(M(X; \theta_t), Y)$ 
13:   更新优化器参数  $\Theta_d \leftarrow \nabla_{\Theta_{d-1}} L_{test}$ 
14: end for

```

### 3. 实验

#### 3.1. 数据集与预处理


本实验使用两种数据集, 分别为手写西波文字数据集和 MNIST 数据集。手写西波文字数据集: 通过人工拍摄收集, 但原始样本稀缺。收集到的手写西波文字图片通过 Photoshop 软件分割, 共获得 10 个类别, 150 张图像, 具体见图 3 所示:



**Figure 3.** Handwritten Xibo characters

**图 3.** 手写西波文字

分割后的图像整体对比度低、笔画边缘模糊不清, 背景不均匀, 存在水渍、污点或阴影干扰等质量问题。另一方面, 字符区域有效像素占比低。以上质量问题严重降低了图像的信噪比, 使得传统 OCR 方法难以直接进行可靠的特征提取与识别。因此, 为解决上述原始样本稀缺并提升模型在真实场景下的鲁棒性, 我们对所获得的 150 张手写西波文字图片进行反转色、灰度归一化、颜色增强等数据预处理和数据增强处理。所有图片统一压缩到  $28 \times 28$  像素。具体见图 4 所示:



**Figure 4.** Preprocessed Xibo handwritten characters  
**图 4.** 数据处理的西波手写文字

**MNIST** 数据集：作为元训练阶段的辅助数据集，用于预训练基础网络与元优化器，提升模型泛化性能。

### 3.2. 实验设置

为了验证所提出的元学习优化器在小样本手写西波文字识别任务上的有效性，深入分析相对传统方法的优势，本文设计了以下具体四组实验，所有实验均在 10 类别手写西波文字，每类别有 5 张手写西波文字图片的测试集进行评估。具体设置如下：

(1) 基础模型性能评估：在 10 类别手写西波文字，每类别含有 10 张手写西波文字图片，总共 100 张手写西波文字图片的训练集上训练 DNN 神经网络和 CNN 神经网络，以确立传统深度学习方法在此任务上的性能基线。

(2) 数据增强策略验证：为验证单纯增加样本量的识别效果，分别使用数据增强后的训练集，即在每类别含 15 张和 30 张西波手写文字图片的训练集上重新训练上述 DNN 神经网络和 CNN 神经网络，进一步评估模型性能提升与过拟合的缓和程度。

(3) 正则化优化效果对比：在 DNN 神经网络和 CNN 神经网络中引入 Dropout 等正则化层，在不同的训练集，即分别有 100 张，150 张，300 张西波手写文字图片样本集上进行训练，从而验证常见结构优化对缓解小样本过拟合的作用。

(4) 元学习优化器性能验证：利用迁移学习和元学习相结合的方法，先在训练集为 60,000 张手写数字图片的 MNIST 数据集上分别对四层 DNN 神经网络和四层 CNN 神经网络进行预训练。随后，引入两层的 LSTM 神经网络作为元优化器，在元学习框架下学习如何快速优化 DNN 神经网络和 CNN 神经网络参数，具体见表 1~3 所示。最后，将优化后的模型在手写西波文字测试集上直接评估其小样本适应能力。

**Table 1.** Architecture of 4-layer CNN  
**表 1.** 4 层 CNN 神经网络结构

层数	操作	输出形状
1	卷积层	(None, 28, 28, 32)
1-1	池化层	(None, 28, 28, 32)
2	卷积层	(None, 26, 26, 64)
2-1	池化层	(None, 26, 26, 64)
3	卷积层	(None, 24, 24, 32)
3-1	池化层	(None, 24, 24, 32)
4	卷积层	(None, 22, 22, 16)
4-1	池化层	(None, 22, 22, 16)
5	全连接层	(None, 22, 22, 10)

**Table 2.** Architecture of 4-layer DNN  
**表 2.** 4 层 DNN 神经网络架构

层数	操作	神经元
1	全连接层	(28 × 28, 64)
2	全连接层	(64, 32)
3	全连接层	(32, 64)
4	全连接层	(64, 10)

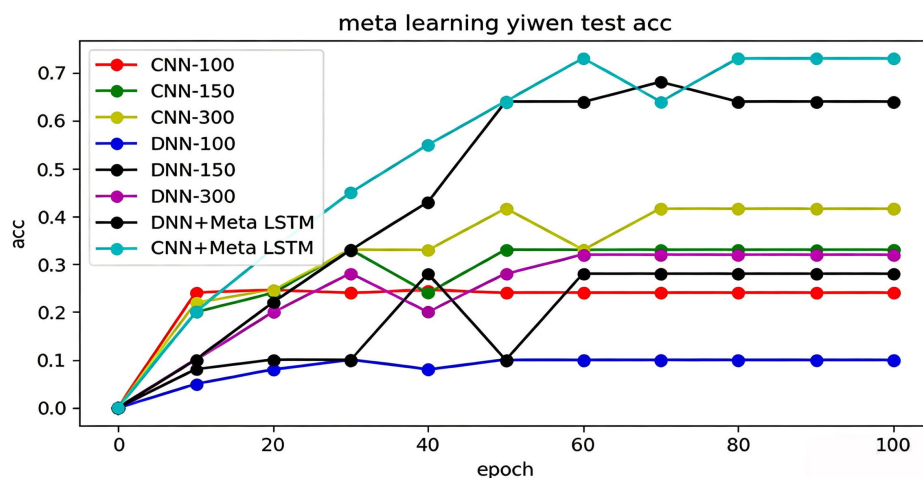
**Table 3.** Architecture of 2-layer LSTM  
**表 3.** 2 层 LSTM 神经网络架构

层数	操作	神经元
1	LSTM 层	(6, 4)
2	LSTM 层	(4, 2)

(5) 参数  $p$  的敏感性实验：实验在 10 类手写西波文字、每类 10 张训练样本的小样本场景下进行，选取  $p = 4, 6, 8, 10, 12$  五个候选值进行对比，记录各取值下的识别准确率及收敛速度。

### 3.3. 实验结果

将以上所有实验设置分别在类别为 10 类别，每类别含有 10 张手写西波文字图片，共 100 张手写西波文字图片训练集上进行训练，总共训练 10,000 次，分 100 轮训练，每轮迭代 100 次。并在每类别有 5 张手写西波文字图片，总共 50 张手写西波文字图片测试集上进行测试。识别精度和训练时间分别见图 5 和表 4 所示：



**Figure 5.** Test accuracy of the model  
**图 5.** 模型测试精度

由以上实验结果可知，传统深度学习方法在小样本手写西波文字识别任务中表现出显著的局限性。基线 DNN 神经网络和 CNN 神经网络在仅 100 张训练样本的条件下，最优识别准确率最高达到 24% (CNN 神经网络)。这一结果表明，在训练数据严重不足时，模型难以学习到具有泛化能力的判别性特征，而是迅速对有限的训练样本产生过拟合，导致其泛化性能急剧下降。

**Table 4.** Training time of different models  
**表 4.** 模型训练时间

神经网络	训练时间
CNN-100	1228.587 s
CNN-150	2403.057 s
CNN-300	5331.043 s
DNN-100	1105.538 s
DNN-150	2236.103 s
DNN-300	3236.103 s
<b>DNN + Meta LSTM</b>	<b>221.787 s</b>
<b>CNN + Meta LSTM</b>	<b>368.678 s</b>

为了提高小样本手写西波文字识别精度，对小样本手写西波文字数据集进行数据增强。将训练样本扩增至 300 张后，CNN 模型的准确率提升至 41.6%。但训练耗时增加了 300%以上。同样，引入 Dropout 正则化仅带来约 2%的性能增益。以上方法虽然在一定程度上抑制过拟合，但未触及模型因样本稀缺而导致泛化能力不足的根本问题，且计算成本大幅上升。

在同等小规模训练集(100 张样本)下，本文引入 LSTM 神经网络元优化器后，DNN 神经网络与 CNN 神经网络的识别准确率分别提升至 64.0%和 73.0%。相比较于基线模型，小样本手写西波文字识别精度取得了超过 40%的绝对提升。同时，训练效率大幅提高，训练时间缩减至基线模型训练时间的 20%。说明，通过元学习机制使优化器掌握“如何学习”的策略，模型能够从少量样本中快速提取可迁移的知识，从而在本质上增强了其在小样本条件下的适应与泛化能力。

由于参数  $p$  用于调节梯度均值项的缩放强度，其取值直接影响元优化器接收到的梯度信息质量，进而影响模型性能。为探究  $p$  的最优取值，我们在保持其他实验设置不变的条件下，在 CNN 基网络上进行参数敏感性分析，结果见表 5 所示。

**Table 5.** Sensitivity analysis of parameter  $p$   
**表 5.** 参数  $p$  对模型性能影响

$p$ 取值	准确率(%)	元训练轮数
4	67.2	40
6	70.5	32
<b>8</b>	<b>73.0</b>	<b>25</b>
10	71.8	28
12	69.4	35

从表 5 可以看出，当  $p = 8$  时，模型取得最高准确率和最快收敛速度，当  $p$  取值过小时，梯度标准化不充分，训练过程出现震荡，收敛缓慢，当  $p$  取值过大时，梯度信号被过度削弱，有效信息损失，性能反而下降。这一结果表明， $p = 8$  能够在消除梯度量纲差异与保留梯度方向信息之间取得最佳平衡。

综上所述，针对小样本手写西波文字识别问题，传统的数据增强与正则化方法提升有限。本文所采用的元学习优化器，通过从一系列任务中学习通用的参数更新策略，能够引导模型在极少样本上实现高效且稳定的收敛，为低资源古籍文字的数字识别提供有效的解决方案。

## 4. 结语

本文针对手写西波文字样本稀缺、识别困难的挑战，提出了一种基于元学习的模型优化器框架。该方法构建了轻量级 CNN 神经网络为基础特征提取器，以 LSTM 神经网络为元优化器的双模型架构，通过参数共享与梯度标准化机制，使元优化器能够学习并生成自适应的参数更新策略。实验结果表明，经元优化器优化后的模型在仅使用 100 张训练样本的条件下，识别准确率显著提升至 73%。同时，训练效率大幅提高，耗时仅为传统深度学习方法的 20%。本文研究说明，将元学习与模型动态优化相结合，能够有效克服小样本学习中的过拟合与泛化不足问题，为手写西波文字这类低资源古籍的数字化识别提高一种切实可行的技术途径。

## 致 谢

本研究得以顺利完成，离不开多方面的支持与帮助，谨此致以诚挚谢意。感谢滇池学院校级科研项目《基于元学习策略的手写彝文智能识别技术与开发》(项目编号: 2024XJ29)的经费支持，为本文的实验开展提供了必要保障。感谢我的导师在选题方向和研究思路上的悉心指导，在论文撰写过程中提出的宝贵建议让我受益匪浅。同时感谢课题组成员梅自艳和顾玉碟在数据采集与实验实施过程中给予的协助，特别感谢西波文字传承人与相关文献收藏机构的无私帮助，正是他们对文化遗产的守护，为本研究提供了珍贵的原始素材。最后，向审阅本文并提出修改意见的各位专家表示衷心感谢。

## 基金项目

《基于元学习策略的手写彝文智能识别技术与开发》，2024XJ29，理工类，校级项目。

## 参考文献

- [1] Wang, Y.Q., Yao, Q.M., Kwok, J., *et al.* (2020) Generalizing from a Few Examples: A Survey on Few-Shot Learning. *ACM Computing Surveys (CSUR)*, **53**, Article No. 63. <https://doi.org/10.1145/3386252>
- [2] Gregory, K., Zemel, R. and Salakhutdinov, R. (2015) Siamese Neural Networks for One-Shot Image Recognition. *The 32nd International Conference on Machine Learning (ICML 2015)*, Lille, 6-11 July 2015.
- [3] Snell, J., Swersky, K. and Zemel, R. (2017) Prototypical Networks for Few-Shot Learning. <https://doi.org/10.48550/arXiv.1703.05175>
- [4] Sung, F., Yang, Y., Zhang, L., Xiang, T., Torr, P.H.S. and Hospedales, T.M. (2018) Learning to Compare: Relation Network for Few-Shot Learning. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 18-23 June 2018, 1199-1208. <https://doi.org/10.1109/cvpr.2018.00131>
- [5] Santoro, A., Bartunov, S. and Botvinick, M. (2016) One-Shot Learning with Memory-Augmented Neural Networks. <https://arxiv.org/abs/1605.06065>
- [6] Munkhdalai, T. and Yu, H. (2017) Meta Network. <https://arxiv.org/abs/1703.00837>
- [7] Ravi, S. and Larochelle, H. (2017) Optimization as a Model for Few-Shot Learning. *2017 5th International Conference on Learning Representations*, Toulon, 24-26 April 2017.
- [8] Antoniou, A., Edwards, H. and Storkey, A.J. (2019) How to Train Your MAML. *2019 International Conference on Learning Representations*, New Orleans, 6-9 May 2019.
- [9] Yu, M. (2018) Diverse Few-Shot Text Classification with Multiple Metrics. <https://arxiv.org/abs/1606.04474>
- [10] Andrychowicz, M., Denil, M., Gomez, S., Hoffman, M.W., Pfau D., Schaul, T. and de Freitas, N. (2016) Learning to Learn by Gradient Descent by Gradient Descent. <https://arxiv.org/abs/1606.04474>
- [11] 王嘉梅, 文永华, 李燕青, 高雅莉. 基于图像分割的古彝文字识别系统研究[J]. 云南民族大学学报: 自然科学版, 2008, 17(1): 76-79.
- [12] 朱龙华, 王嘉梅. 基于组合特征的多分类器集成的脱机手写体彝文字识别[J]. 云南民族大学学报自然科学版, 2010, 19(5): 329-333.
- [13] 朱宗晓, 吴显礼. 脱机印刷体彝文字识别系统的原理与实现[J]. 计算机技术与发展, 2012, 22(2): 85-88+92.

- [14] 沙马拉毅. 计算机彝文操作系统的研制[J]. 西南民族学院学报(自然科学版), 2003, 29(1): 1-8.
- [15] 陈善雄, 王小龙, 韩旭, 刘云, 王明贵. 一种基于深度学习的古彝文识别方法[J]. 浙江大学学报: 理学版, 2019, 46(3): 261-269.
- [16] 伊恩·古德费洛, 约书·亚本吉奥, 亚伦·库维尔. 神经网络与深度学习[M]. 北京: 人民邮电出版社, 2017.
- [17] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020.