

基于双向 LSTM 的手写文字识别技术研究

张新峰, 闫昆鹏, 赵 珣

(北京工业大学信息学部, 北京 100124)

[摘要] 手写文字识别是计算机视觉、自然语言处理领域中的重要问题和研究热点. 本文针对手写文字识别问题, 提出一种基于双向 LSTM 网络的手写文字识别方法. 首先根据数据集特点进行归一化等预处理; 然后使用 CNN 网络对图像的特征进行提取; 接着通过双向 LSTM 网络来记忆手写文字序列的字句关系, 并对文字序列进行预测; 最后使用 CTC-Loss 作为损失函数, 可以让整句标注的训练集在上述网络下收敛. 对比实验表明本文提出的算法模型的有效性.

[关键词] 光学字符识别, 手写文字识别, 深度学习, LSTM 神经网络, CTC-Loss 损失函数

[中图分类号] TP391 [文献标志码] A [文章编号] 1001-4616(2019)03-0058-07

Handwriting Chinese Text Recognition Using BiLSTM Network

Zhang Xinfeng, Yan Kunpeng, Zhao Xun

(Information Department, Beijing University of Technology, Beijing 100124, China)

Abstract: Handwriting recognition is an active research topic in the domain of natural language processing (NLP) and computer vision (CV). Aiming at the problem of handwriting Chinese text recognition, this paper proposed a method using BiLSTM neural network. The method can be used to recognize Chinese text which wrote carefully and neatly. Firstly, according to the student's characteristics of handwriting, make normalized to the section of data. Then, use CNN network to extract image features and use LSTM network to record the context diagram. Finally use the CTC-Loss function to accelerate convergence in our data model. The results illustrate the effectiveness of the proposed method.

Key words: OCR, handwriting recognition, deep learning, LSTM neural network, CTC-Loss function

目前各行各业都在推进无纸化办公. 为了减少人工成本, 经常会用到文字识别的技术, 例如身份证信息检测、税票信息检测等, 来方便后续的大数据分析等相关处理^[1]. 故手写文字识别是至关重要的一项技术. 目前在印刷体文字识别的领域中, 已经有许多算法可以准确地识别印刷字符. 但是与印刷字符不同, 手写体文字字形书写方法多种多样, 笔画错综复杂且不易准确定性. 很多文字具有相同的文字结构不易辨认, 文字数量巨大, 笔画粘连和断开等现象显著且常见, 很大程度上随着个人手写习惯的不同而不同^[2]. 由于这些问题造成了手写体文字识别的准确率较低, 因此文字录入系统需要一套高效的手写文字识别算法, 完整实现端到端的整句识别且识别准确率高, 从而减少人工成本, 实现手写文字的录入.

本文对手写文字识别的已有研究工作进行了调研. 关于光字符识别(OCR)的研究已经进行了很多年. 1965 年, IBM 公司首次实现了 OCR 技术, 但他们呈现的产品仅仅能识别某些特定符号、数字、印刷体英文字母与极少量的特殊文字^[3]. 之后, 统计分类算法得到了广泛的研究, 相似性转移、松弛匹配、决策树和动态规划^[4]等方法在一定程度上取得了成功. 同时, 例如二次判别、神经网络、隐式马尔科夫模型^[5]等算法也都通过适当的改进和变型, 使之适用于中文字符模式识别任务, 这些统计学方法和相关算法在很大程度上加速了手写汉字识别技术的进展. 在此基础上手写体识别逐渐形成了预处理、特征提取、分类器的模式, 后期还加入了语言模型等的限制^[6].

随着 GPU 计算性能的不断提高及 2012 年卷积神经网络在图像识别领域中的各种成果, 国内外在 OCR 的经典问题上提出了很多基于深度学习的方法^[7]. 深度学习算法相较于传统机器学习算法有着不需

人工设计特征、海量数据支撑下具有高的准确率、端到端特性等特点。利用这些特点,深度学习可以解决一些传统机器学习无法解决的问题。目前识别率较高的手写识别系统大都采用卷积神经网络 CNN 作为分类器。随着 Alexnet、GoogleNet、VGG、DeepResidualLearning 等网络的相继提出,通过卷积神经网络方法对单一字符的识别已经取得了非常好的成果^[8-11]。而循环神经网络模型 RNN 提出后,很多序列建模任务如手写识别和语音识别等有了新的解决办法。在此基础上,又提出了长短时记忆模型 LSTM。由于其拥有记忆上下文的能力,被越来越多地应用在序列建模任务上^[12]。RNN 的提出极大地提升了端到端的整句文本识别任务的准确率,但依然还存在着很大的挑战。

本文研究学生手写文字识别,其目的在于学生手写作业及文档的格式化存储,同时对后续的学生作业大数据分析等方面有着重要意义。针对学生手写文字的特点,本文探讨了基于深度卷积神经网络的学生手写文字识别方法。方法主要流程包括以下几方面:首先对训练数据进行归一化等预处理;然后使用 CNN 网络对图像的特征进行提取;接着通过双向 LSTM 网络,来记忆手写文字序列的字句关系,并对文字序列进行预测;最后使用 CTC-Loss 作为损失函数,可以让整句标注的训练集在上述网络下收敛。

1 相关工作

早期的手写识别工作主要通过传统的机器学习方法进行文字识别,其经典研究结构如图 1 所示。




图 1 手写文字识别的传统机器学习方法结构图

Fig. 1 Architecture diagram of traditional machine learning method for handwriting recognition

图 1 包括训练和识别两个部分。其中训练部分主要包括 4 个步骤:

(1) 对训练样本进行预处理,一般包括图像去噪、图像增强、归一化等操作。通过图像的预处理可以使样本特点更突出,有利于后续的训练效果。

(2) 根据手写字符的特点可以设计用于表达不同字符间信息差异的结构特征。也可以利用边缘信息、角度信息等统计特征来区分不同文字间的差异。特征提取是传统机器学习中的关键问题,好的特征可以优化算法的准确性。

(3) 通过筛选有用的特征、去掉其余特征来提升分类的速度。同时可以去除一部分噪声。

(4) 传统机器学习主要有判别式和生成式两种分类器。生成式方法基于概率密度函数,判别式方法通过判别函数直接对数据进行分类。

识别部分与训练部分类似,测试样本需要和训练样本采取同样的处理方法,最后使用已经训练好的分类器分类得到预测的识别结果。

而深度学习较于传统机器学习算法,有以下特点:

(1) 不需人工设计特征。传统的机器算法通常需要复杂的特征工程^[13],首先要根据数据集设计特征,然后对特征做降维处理,而深度学习可以自动提取数据特征而不需要进行特征选择。

(2) 具有高的准确率。机器学习的准确率会随着数据的提升而增加,但到达一定量的数据时,数据的增加对其准确率提升非常缓慢^[14],使得机器学习无法处理海量数据。

(3) 端到端特性。传统机器学习方法在解决文字识别问题时,需要分成多部分来进行,即把问题拆成多个子问题,例如特征提取、降维、分类器等等。而深度学习可以通过集中的方式解决问题^[15]。同时,本文通过深度学习方法解决了传统机器学习方法无法处理文字标签长度不固定的问题。

本文通过以上特点,结合 CNN 网络和双向 LSTM 网络设计了一个深度神经网络模型,用于手写文字的识别。

2 基于双向 LSTM 网络的手写文字识别模型

在文字识别中,CNN 网络的主要作用是特征提取. 由于其强大的特征提取和特征表示能力,CNN 网络在图像识别领域中应用广泛. 本文改进了 CNN 网络提取方法,与之前相比增加了网络深度,并改进了激活函数,使整体识别率有了一定的提升. 同时,手写文字识别与通用物体识别相比有着鲜明的特点,即手写文字序列中字符与字符是存在相关关系的. 通过 RNN 网络可以很好地利用序列之间的联系^[16],对当前字符做出预测.

2.1 基于 CNN 的图像特征提取

在使用 CNN 网络提取特征之前,每一轮训练当中,考虑到 CNN 读取每一幅图像都使用同样的参数. CNN 网络需要对输入做一定的约束,即图像的归一化处理. 数据集及归一化方式在第 3 节做详细介绍.

CNN 的设计参考了 Zhuoyao 等人的网络设计^[17],该网络共由 5 个卷积层组成. 本文在此基础上进行改进,将其主要结构改为由 3 个卷积层组成,其中每个卷积层后接着一个激活层和一个池化层. 同时,本文在其基础上又改进了 CNN 的最后一层,对最后一层的特征维数转换,其目的是便于 LSTM 层的计算. 最后一个池化层后对输出的向量最后的 2 个维度进行合并,并在全连接层前加入 Dropout 层,以防止网络过拟合. 最终 CNN 的输出为 64×32 的向量. 其结构图如图 2 所示.




图 2 CNN 网络结构图

Fig. 2 CNN network architecture

本文卷积核的设置参考了 Kaiming He 等人的研究^[18]. 该方法的主要目的在于优化 PReLU 函数,减轻梯度消失和梯度爆炸而造成的不收敛的问题. 该方法使用方差函数 VAR_{kernel} 来对卷积核进行初始化设置.

$$PReLU = \begin{cases} x_i, & \text{if } x_i > 0, \\ a_i x_i, & \text{if } x_i < 0, \end{cases} \tag{1}$$

$$VAR_{kernel} = 2k^2d/(1+a^2), \tag{2}$$

其中 k 代表卷积核数量, d 代表卷积核尺寸, a 代表 ReLU 函数初始梯度值. 当 $a=0$ 时, PReLU 函数退化为 ReLU 函数.

随着网络的加深,需要更多的卷积核数量来充分提取前一层特征. 卷积核数量的变化会使 PReLU 函数中的参数增加了一部分计算量,但与 ReLU 函数相比同时也保留了全部神经元,从而减少了梯度消失的影响.

2.2 基于 LSTM 的语义信息提取

在文字识别中上下文的信息对识别效果能产生很大的辅助作用^[19]. 通过设计一个双向的 RNN 网络来对文字序列的上下文信息记录,将 CNN 提取到的 64×32 的向量作为 RNN 网络的输入. RNN 的结构图如图 3 所示.

本文的 RNN 结构使用 LSTM 单元. LSTM 单元是一种 RNN 的设计^[20]. 通过引入 3 个门函数来记录序列的上下文信息. 同时本文还使用 GRU 单元做对比实验. GRU 是 LSTM 的一种变体结构,与 LSTM 单元相比,GRU 单元只拥有 2 个门函数,分别是更新门和重置门.

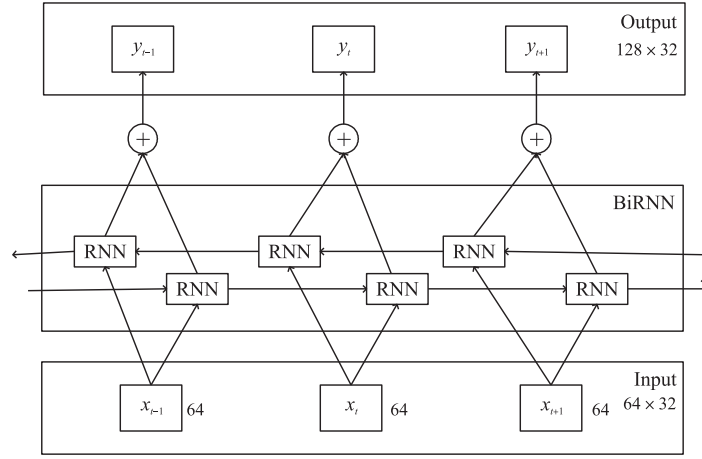


图3 双向 RNN 网络结构图

Fig. 3 BiRNN network architecture

本文的最终模型基于 LSTM 单元,GRU 单元作为对比实验参考了 Wei Liu 等人^[21]的文献。

LSTM 由输入门 i_t 、遗忘门 f_t 、输出门 o_t 3 个门函数和细胞状态组成。

(1) 决定丢弃的信息。该决定通过遗忘门完成,读取当前输入 x_t ,隐藏的输出为 h_t ,则上一状态输出为 h_{t-1} ,计算输入门、遗忘门、输出门的值:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (3)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (4)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o). \quad (5)$$

(2) 第二步确定细胞状态中的信息,即细胞状态候选值 \tilde{c}_t :

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c). \quad (6)$$

(3) 然后根据上一时态和当前候选值计算当前时刻状态值:

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t. \quad (7)$$

(4) LSTM 的最终输出为输出门状态与当前上下文状态的按位相乘,并加入激活函数 \tanh .

$$h_t = o_t \tanh(c_t). \quad (8)$$

本文使用 LSTM 单元,输入长度为 64,双向 LSTM 叠加后输出长度为 128 的向量。

2.3 整体模型结构

本文设计了一个用于手写文字识别的深度学习神经网络,主要由两部分组成。第一部分为一个改进的 CNN 网络,用于提取图像的特征图。第二部分为 LSTM 网络,主要用于提取上下文信息。通过最后的 softmax 得到的向量、标签长度、标签标注内容,计算 CTC-Loss 损失函数。

CTC-Loss 损失函数在语音处理或自然语言处理中常用做翻译层,它是为循环神经网络专门设计的顶层,可以对 LSTM 层的结果进行解码。该层引入一个‘blank’标签,使得 LSTM 层的高纬度输出得以降低维度,并且该层可以计算网络的损失值,为之后的梯度下降法寻优做准备。其优势在于不用切分图像,故不会因为切割而造成图像缺损,可以实现端到端的识别。

数据从 LSTM 层输出进入 CTC 层,假设数据的维度是 T ,每一个时间点的数据都有 L 种可能性,那么整体的序列就会有 L^T 种可能性。其中,每一种可能性称作一个 PATH,其条件概率如式(9)所示:

$$p(l|y) = \sum_{\pi: B(\pi) = l} p(\pi|y), \quad (9)$$

式中, π 、 y 、 l 分别代表 PATH、输入和序列的结果。

由于寻找最大可能性 PATH 的过程中会涉及到庞大的计算量,因此要通过式(10)进行简化运算,每个维度选择可能性最大类为其维度的结果。

$$l^* \approx B(\arg\max_{\pi} p(\pi|y)). \quad (10)$$

最后使用 SGD 梯度下降法最小化 CTC 损失函数,如式(11)所示。

$$o = - \sum_i^X \log p(l_i | y_i), \quad (11)$$

式中, X 、 L 、 y 分别代表训练数据、真实标签序列和输入. 整体网络结构图如图 4 所示.




图 4 手写文字识别网络结构图

Fig. 4 Architecture diagram of handwriting recognition

3 实验设计与仿真

3.1 学生手写文字数据库

本文使用学生手写文字的真实数据集,数据样本如图 5 所示. 数据标签由人工标定,每幅图中字符数量不固定. 数据集共有样本 10 000 张,本文随机选择了其中的 8 000 张图像作为训练集,1 000 张图像作为验证集,1 000 张图像作为测试集. 本文通过对数据的分析,将 8 000 张训练集进行了扩充. 对字符出现频率较小的图像作数据增广处理. 具体增广的方法包括加入噪声和通过伽马变换模拟光照效果. 增广后的数据样本如图 6 所示.

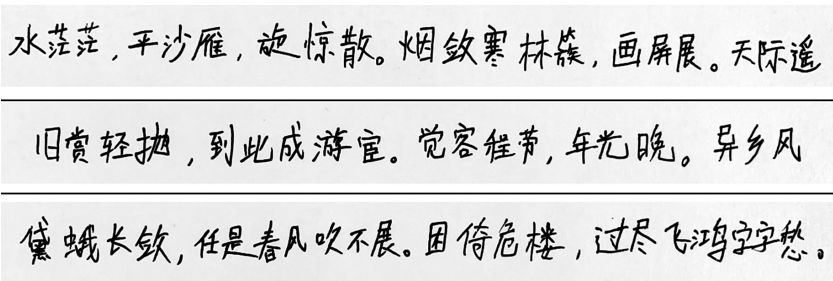


图 5 学生手写文字数据集

Fig. 5 Samples of handwriting by students

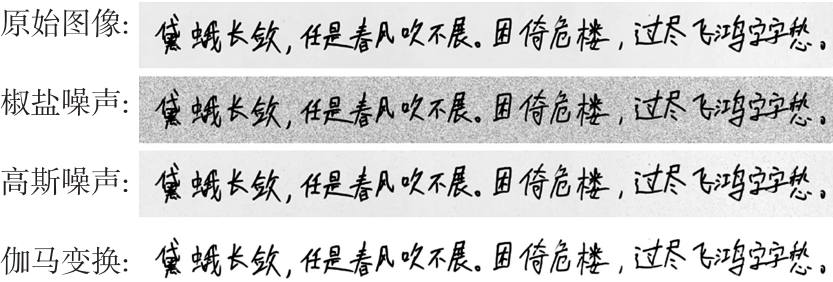


图 6 增广后的数据集

Fig. 6 Enhanced samples

3.2 实验设计与评价指标

实验共有 4 组对比试验. 分别为改进后的 CNN 网络(简称 CNN)、改进的 CNN 网络与单层 GRU 网络相结合(简称 CNN+GRU)、改进的 CNN 网络与单层 LSTM 网络相结合(简称 CNN+LSTM)、改进的 CNN 网络与双向 GRU 网络相结合(简称 CNN+BiGRU)、改进的 CNN 网络与双向 LSTM 网络相结合(简称 CNN+BiLSTM).

实验的测试集共 1 000 幅图像,包括各类字符 18 961 个. 实验的评价指标采用单字测试集召回率(recall)、单字测试集识别准确率(precision)、训练时间(train time)、单幅图片平均测试时间(test time).

3.3 实验结果与分析

本文使用 TensorFlow 深度学习框架进行实验仿真. 实验结果基于本实验室设备得到. 实验硬件设备包括 CPU: Intel Xeon E5 2620v3×2、GPU: Nvidia Titan X×4、内存: 64 G 等.

表 1 为 CNN 改进实验的数据表,本文的工作分别对比了改进后的 CNN 与单向 LSTM 单元的组合. 通过加深网络并改进激活函数后,文字识别结果的召回率有了明显的提升.

表 1 改进 CNN 网络识别结果对比

Table 1 Comparisons based on improved CNN network

名称	召回率/%	准确率/%	训练时间/h	测试时间/s
Lenet	60.25	70.14	10.2	1.5
VGG16	64.48	77.42	12.5	1.5
Zhuoyao ^[17]	66.65	78.92	13.5	1.6
本文算法	67.35	78.83	12.3	1.6

本文同时对数据进行了等间距分割,仅用 CNN 网络进行训练. 其收敛时间最快,且单张的平均测试时间也最快. 但准确率并不理想,综合单字准确率只有 50.25%. 这是由于数据在等间距切分时会造成部分文字的丢失,而使准确率急速下降.

使用 RNN 网络时由于需要记录上下文,每次迭代时,需要将当前轮所有数据全部加载至内存. 内存和带宽对训练速度影响非常大. 但通过上下文语义分析,并与 CTC-Loss 函数相结合后实验的准确率有了明显的提升. 在使用单一方向的 RNN 网络时,即序列方向为单向固定时,使用 LSTM 网络的综合单字准确率达到 78.83%. 将 LSTM 替换为 GRU 单元时,准确率基本与 LSTM 接近,但训练耗时有了 2 h 以上的增加.

如表 2 所示,在使用双向 RNN 结构时,准确率和召回率有了接近 5% 的提升. 使用双向 LSTM 网络时准确率和召回率最高,分别为 76.52% 和 84.21%. 与网络改进前相比召回率有了 3% 的提升,但同时训练耗时也有了一定的增长. 而单张图像的平均测试时间无明显变化. 本文同时与最新的文献做了对比实验,与 Almazan 等人^[22]、Rodriguez 等人^[23]的工作相比,可以看出在同一个数据集下,我们的算法取得了较好的实验结果.

表 2 各种模型性能

Table 2 Performances of various models

名称	召回率/%	准确率/%	训练时间/h	测试时间/s
CNN	44.5	50.25	5.1	0.8
CNN+GRU	66.25	79.32	9.9	1.5
CNN+LSTM	67.35	78.83	12.3	1.6
CNN+BiGRU	70.67	82.19	12.2	1.5
CNN+BiLSTM	73.79	83.00	15.5	1.6
Almazan ^[22]	68.75	69.17	13.5	1.4
Rodriguez-Serrano ^[23]	74.33	81.75	16.2	1.4
本文算法	76.52	84.21	16.5	1.6

4 总结与展望

从传统机器学习方法到深度学习方法,手写文字识别的准确性、鲁棒性都有了很高的提升. 本文通过一种改进的双向 LSTM 网络构建了一个识别模型,在一定程度上对手写识别问题给出了方案,取得了较高的单字识别准确率. 但是在该领域,还存在很多方法有待改进,还有很多问题值得研究.

(1) 训练时间长. 对比 CNN 网络,RNN 收敛所需要的时间非常长,即训练过程非常缓慢. 其主要原因是计算受到内存和带宽的约束,RNN 的每一轮训练需要加载该轮所有样本至内存^[24]. 同样计算资源,RNN 比 CNN 需要更多的内存和带宽. 如何减少 RNN 的训练时间是一个关键的问题.

(2) 相较于传统机器学习,深度学习在鲁棒性方面有很强的优势. 但由于手写文字识别的应用场景不同,算法依旧会受到光照、模糊等影响. 且手写文字的字体差异也会对识别效果造成一定的干扰^[25]. 卷积神经网络的拟合效果已经非常好,但还有提升空间. 此外,本文采用的归一化方法是根据本数据集的特点进行特定尺寸缩放. 在未来的研究中可以根据其他应用场景,使用图像金字塔等方法对图像进行多尺度研究.

(3) 手写文字识别根据应用场景不同可分为脱机和联机两种方式^[26],本文提出的方法是脱机场景下的手写识别. 在未来的研究中可以通过结合联机的方式加入一些更有效的先验知识. 相信通过结合先验知识,可以将手写识别更好地应用于真实场景中去.

(4) 在识别准确率足够的情况下适当简化网络模型,以便深度学习可以用于移动终端设备. 目前深度学习在嵌入式平台已经有了很多应用^[27],但在移动端的软件集成效果还有待提高.

手写识别领域内的挑战还有很多,距离其成熟应用阶段还有一段路要走. 我们需要解决上述问题,为手写识别的进一步发展做铺垫. 相信该领域的发展一定会给未来的生活带来较高的应用价值.

[参考文献]

- [1] 罗笑玲,黄绍锋,欧阳天优,等. 基于多分类器集成的图像文字识别技术及其应用研究[J]. 软件,2015,36(3):98-102.
- [2] 全志楠,林家骏. 文本无关的小样本手写汉字笔迹鉴别方法[J]. 华东理工大学学报(自然科学版),2018,44(6):882-886.
- [3] 刘文壮,李均利. 一种基于隐马尔可夫模型的脱机手写汉字识别方法[J]. 系统仿真技术及应用,2009,11:774-777.
- [4] GUOHONG LI,SHI P. Completeness analysis of feature points on strokes of handwriting Chinese characters[J]. IEEE Trans on computer engineering,2010,32(6):14-16.
- [5] LIU W Z,LI J L. A method for off-line handwritten Chinese character recognition based on hidden Markov model[J]. CCSSTA,2009,11:774-777.
- [6] PRASAD J R,KULKARNI U V,PRASAD R S. Offline handwritten character recognition of gujrati script using pattern matching[C]//International Conference on Anti-counterfeiting. Hong Kong:IEEE Press,2009:611-615.
- [7] 闫喜亮,王黎明. 卷积深度神经网络的手写汉字识别系统[J]. 计算机工程与应用,2017,53(10):246-250.
- [8] MAHPOD S,KELLER Y. Auto-ML deep learning for rashi scripts OCR[EB/OL]. [2018-11-03]. <https://arxiv.org/abs/1811.01290>.
- [9] SANG G L,YUNSICK S,YEON G K,et al. Variations of AlexNet and GoogLeNet to improve Korean character recognition performance[J]. Journal of information processing systems,2018,14(1):205-217.
- [10] CONG K N,CUONG T N,NAKAGAWA M. Tens of thousands of nom character recognition by deep convolution neural networks[C]//The 4th International Workshop on Historical Document Imaging and Processing. Kyoto,2017.
- [11] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]//The IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas:IEEE,2016:770-778.
- [12] SUNDERMEYER M,NEY H,SCHLÜTER R. From feedforward to recurrent LSTM neural networks for language modeling[J]. IEEE/ACM transactions on audio speech & language processing,2015,23(3):517-529.
- [13] GARLA V N,BRANDT C. Ontology-guided feature engineering for clinical text classification[J]. Journal of biomedical informatics,2012,45(5):992-998.
- [14] JORDAN M I,MITCHELL T M. Machine learning:trends,perspectives,and prospects[J]. Science,2015,349(6245):255-260.
- [15] DENG L,YU D. Deep learning:methods and applications[J]. Foundations & trends in signal processing,2014,7(3):197-387.
- [16] WOJCIECH Z,ILYA S,ORIOLO V. Recurrent neural network regularization[EB/OL]. [2015-02-19]. <https://arxiv.org/abs/1409.2329>.
- [17] ZHONG Z,JIN L,XIE Z. High performance offline handwritten Chinese character recognition using GoogLeNet and directional feature maps[EB/OL]. [2015-05-19]. <https://arxiv.org/abs/1505.04925>.
- [18] HE K,ZHANG X,REN S,et al. Delving deep into rectifiers:surpassing human-level performance on ImageNet classification[EB/OL]. [2015-02-06]. <https://arxiv.org/abs/1502.01852>.
- [19] KALAYEH M M,GONG B,SHAH M. Improving facial attribute prediction using semantic segmentation[C]//The IEEE Conference on Computer Vision and Pattern Recognition(CVPR).Honolulu,2017.
- [20] MARTIN J,SAQIB S B,ANDREAS D. Transcription free LSTM OCR model evaluation[C]//International Conference on Frontiers in Handwriting Recognition(ICFHR). Niagara Falls,2018.
- [21] LIU W,WANG Q,ZHU Y,et al. GRU:optimization of NPI performance[EB/OL]. [2018-10-19]. <https://link.springer.com/article/10.1007/s11227-018-2634-9>.
- [22] ALMAZAN J,GORDO A,FORNES A,et al. Word spotting and recognition with embedded attributes[J]. IEEE transactions on pattern analysis and machine intelligence,2014,36(12):2552-2566.
- [23] RODRIGUEZ S J A,GORDO A,PERRONNIN F. Label embedding:a frugal baseline for text recognition[J]. International journal of computer vision,2015,113(3):193-207.
- [24] 杨丽吴,雨茜,王俊丽,等. 循环神经网络研究综述[J]. 计算机应用,2018,38(S2):1-6,26.
- [25] KOZIELSKI M,DOETSCH P,HAMDANI M,et al. Multilingual off-line handwriting recognition in real-world images[C]//International Workshop on Document Analysis Systems. Tours:IEEE,2014:121-125.
- [26] 郭军,蔺志青,张洪刚. 一个新的脱机手写汉字数据库模型及其应用[J]. 电子学报,2000,28(5):115-116.
- [27] 王瀚文. 深度学习在嵌入式设备上的应用综述[J]. 应用能源技术,2018,247(7):54-56.

[责任编辑:丁 蓉]