

基于深度神经网络的Morse码自动译码算法

游 凌^② 李伟浩^{*①②} 张文林^① 王科人^②

^①(战略支援部队信息工程大学 郑州 450001)

^②(盲信号处理国家级重点实验室 成都 610041)

摘 要: 在军用和民用领域, Morse电报一直是一种重要的短波通信手段, 但目前的自动译码算法仍然存在准确率低、无法适应低信噪比和不稳定的信号等问题。该文引入深度学习方法构建了一个Morse码自动识别系统, 神经网络模型由卷积神经网络、双向长短时记忆网络和连接时序分类层组成, 结构简单, 且能够实现端到端的训练。相关实验表明, 该译码系统在不同信噪比、不同码速、信号出现频率漂移以及不同发报手法引起的码长偏差等情况下, 均能取得较好的识别效果, 性能优于传统的自动识别算法。

关键词: Morse码; 自动译码; 深度学习; 频率漂移; 码长偏差

中图分类号: TN919.32

文献标识码: A

文章编号: 1009-5896(2020)11-2643-06

DOI: 10.11999/JEIT190658

Automatic Decoding Algorithm of Morse Code Based on Deep Neural Network

YOU Ling^② LI Weihao^{*①②} ZHANG Wenlin^① WANG Keren^②

^①(PLA Strategic Support Force Information Engineering University, Zhengzhou 450001, China)

^②(National Key Laboratory of Science and Technology on Blind Signal Processing, Chengdu 610041, China)

Abstract: In the military and civilian fields, the Morse telegraph is always as an important means of short-wave communication, but the current automatic decoding algorithms still have problems such as low accuracy, inability to adapt to low signal-to-noise ratio and unstable signals. A deep learning method is introduced to construct a Morse code automatic recognition system. The neural network model consists of convolutional neural network, bidirectional long short-term memory network and connectionist temporal classification layer. The structure is simple and can implement end-to-end training. Related experiments show that the decoding system can achieve good recognition results under different signal-to-noise ratio, code rate, frequency drift and code length deviation caused by different sending manipulation, and the performance is better than the traditional recognition algorithms.

Key words: Morse code; Automatic decoding; Deep learning; Frequency drift; Code length deviation

1 引言

Morse电报通过发送Morse码来传递信息。由于Morse码编码方式简单, 抗干扰能力强, 被广泛地应用在航空通信、海事通信、军事等领域^[1]。人工Morse译码任务量大、难以保证稳定的正确率, 自动Morse译码可以弥补这样的问题。然而实际Morse信号通信中存在着环境噪声干扰大、信号易

发生频率漂移以及手工报拍发时长不稳定等问题, 这给Morse解码带来了许多困难和挑战。

从1970s以来, 有很多机构和学者开始研究Morse码的自动识别, 提出了很多方法^[2-5], 为该领域打下了基础。但这些传统方法对信号质量要求较高, 难以适应实际环境。近年来, 一些文献使用了机器学习中的聚类方法, 比如支持向量机、K均值聚类、模糊C均值聚类(Fuzzy C-Means, FCM)^[6-8], 使识别效果得到了提升, 但信号预处理较繁琐, 且当信噪比较低以及信号的频率和码长不稳定时识别准确率会下降。

深度学习通过训练深层的神经网络, 来实现对数据的表征学习^[9]。自2006年提出起, 该技术获得了广泛的关注并在语音识别、图像识别和自然语言

收稿日期: 2019-08-29; 改回日期: 2020-05-08; 网络出版: 2020-05-28

*通信作者: 李伟浩 liweihao315@gmail.com

基金项目: 国家自然科学基金(61403415), 中国博士后科学基金(2016M602975)

Foundation Items: The National Natural Science Foundation of China (61403415), The Postdoctoral Science Foundation of China(2016M602975)

处理等方面取得了丰硕的成果。文献[10]中利用了隐马尔可夫模型(Hidden Markov Model, HMM)和深度神经网络(Deep Neural Networks, DNN)来识别Morse码,得到了不错的结果,但信噪比的限制还是比较大,且未提到信号传输中频率漂移和手工码时长不稳定的问题。文献[11]中提出了一种结合了卷积神经网络(Convolutional Neural Network, CNN)和循环神经网络(Recurrent Neural Network, RNN)的卷积循环神经网络(Convolutional Recurrent Neural Network, CRNN)来实现基于图像序列的字符识别。受此启发,本文利用该结构,结合连接时序分类(Connectionist Temporal Classification, CTC)方法解决标签和输出的对齐问题,来识别Morse码的时频图。实验表明,该算法在低信噪比、不同码速、频率漂移和手工报码长不稳定等情况下具有较好鲁棒性。

2 数据预处理

2.1 Morse码特点

Morse码发明于1837年,是一种时通时断的信号代码,通过不同的排列顺序来表达不同的英文字母、数字和标点符号。Morse码包括5种:点、划、点之间的间隔、字之间的间隔和词之间的间隔,文献[12]中给出了标准码表。人工Morse译报主要通过识别上面5种码及其出现顺序来判断当前字符。采用机器学习方法进行自动识别,需要首先将Morse音频变换到时间分布上的特征图,该特征图能明显体现几种码的特点及时序。本文选择信号的时频图作为特征图,构建深度神经网络对其进行识别。

2.2 Morse码时频图像

Morse信号的时频图能充分反映信号的时域和频域特征,当信号出现频率漂移以及存在手法偏差时,时频图也能充分体现出这些信息,有利于后面的神经网络能完整地提取并学习信号特征,这是目前对Morse信号的预处理中一种比较普遍的转换方法。本文利用式(1)、式(2)对信号进行短时傅里叶变换得到时频图^[13]

$$X_n(e^{j\omega}) = \sum_{m=-\infty}^{\infty} x(m)w(n-m)e^{-j\omega m} \quad (1)$$

$$P_n(\omega) = |X_n(e^{j\omega})|^2 \quad (2)$$

式中, $x(m)$ 是信号, $w(m)$ 是窗函数, $P_n(\omega)$ 是生成的时频矩阵。

在图1中画出含有内容“ABC”(对应码为: _ _ ... _ . _ .)的标准Morse信号,以及存在频率漂移和码长偏差情况下的时频图。

在时频图上能明显的看到点、划和各类间隔在时间序列上的分布,以及存在频率漂移和码长偏差时特征的变化。时频图中短亮条代表“点”,长亮条代表“划”,其余部分没有语音激活。

3 神经网络结构

神经网络的输入是Morse信号的时频图像,对于图像数据特征的提取一般采用CNN网络。CNN能提取时频图的高层特征,包括Morse信号“点”、“划”的位置、信号的强度以及频率漂移情况等。Morse码的译码主要通过判断“点”、“划”和各种间隔在时序上的排列顺序来实现,RNN网络能捕捉连续帧在前后时间步上的关系并由此做出预测。因此,可以将CNN提取的特征按时间维排列,同一时间步上的不同特征值组合成一帧的特征序列,这些帧序列依次输入RNN层便能根据前后帧的信息来预测当前帧的标签。对于RNN输出的每帧预测结果,还需要一个转录层来将其整合转换成最终的Morse样本的预测标签。文献[11]中将这种能对图像进行特征提取和时序信息建模的结构称为CRNN,本文根据该结构搭建的网络模型如图2所示。

图2中,首先利用CNN对图像进行特征提取,然后利用长短时记忆(Long Short-Term Memory, LSTM)网络来对每个特征序列进行标注,最后通过CTC层转录得到识别结果。该结构将各种网络进行连接,只需一个损失函数便可实现端到端的训练。

3.1 基于CNN的特征提取

首先将Morse信号的时频图通过一个标准的CNN模型来提取信号的特征向量序列^[14]。输入的时频图像素大小都统一为 128×32 ,CNN层的具体设置如表1所示,其中两个卷积层都使用了padding,卷积核大小(a, b, c, d)分别指卷积核高、宽、通道数以及卷积核数。输入时频图经过两个卷积层和最大池化层后时间维长度缩小为32,频率维长度缩小为1,通道维长度扩大为64,本文将同一时间维上的64个通道的特征值连接为1帧,各帧按时间顺序排列,则第 i 帧特征序列是输入图像第 i 个矩形区域的特征映射,如图3所示。

3.2 基于RNN的序列预测模型

本文将CNN层输出的序列化特征通过一个两




图1 Morse信号时频图




图2 神经网络结构

表1 CNN层设置

层名称	对应核大小
卷积层1	(5, 5, 1, 32), 步长=(1, 1)
最大池化层1	(2, 2), 步长=(2, 2)
卷积层2	(5, 5, 32, 64), 步长=(1, 1)
最大池化层2	(2, 16), 步长=(2, 2)




图3 特征序列与时频图的对应

层的双向长短时记忆(Bidirectional Long Short-Term Memory, BLSTM)网络来对每个序列的输出值进行预测。LSTM具有捕获前文信息的能力,且能对任意长度的输入序列进行操作。相比于普通的循环神经网络(Recurrent Neural Network, RNN), LSTM多了3个门结构——输入门、输出门和遗忘门,这种结构允许记忆单元存储上文的信息很长一段时间,所以有效地克服了RNN中的梯度消失和梯度爆炸问题。

单向的LSTM只能依据前文的信息来预测当前信息,而在Morse码的识别中,前后序列的信息对当前码的预测都是有用的。因此,本文在每个循环层采用2个LSTM(1个前向1个后向)组合成1个双向的BLSTM来进行更精确的预测^[15]。

3.3 基于CTC的转录

转录是将循环层对每个特征序列的预测值整合转化为最终标签的过程。Morse译码得到的字符串长度一般比特征序列的长度要短,因为一个字母一

般由特征序列中多帧共同对应,所以需要把对应同一个字母的多帧预测结果合并。

本文采用Graves等人^[16]提出的CTC方法进行最终结果序列的转录,它可以有效地解决不同长度的输入输出序列之间的对齐问题。CTC引入了一个预测路径 $\pi = (\pi_1, \pi_2, \dots, \pi_L)$ 作为帧级别的输入序列的标签,还利用一个“空白”符号来分隔相邻的相同的标签。通过合并两个“空白”符间相同的字符和删除空白符,可以将这些预测路径映射到特定的标签。比如可以将帧级预测标签“-aa-p-p-ll-e-”整合为“apple”(“-”表示空白符)。CTC计算每个帧的标签的条件概率并假设各个帧间条件独立,所以一条CTC路径的概率为

$$p(\pi|x) = \prod_{l=1}^L q_l^{\pi_l} \quad (3)$$

其中, $q_l^{\pi_l}$ 表示输出标签 π_l 在帧 l 处的softmax概率。最终预测标签的概率等于对应的所有CTC路径概率的和

$$p(y|x) = \sum_{\pi \in \phi(y)} p(\pi|x) \quad (4)$$

其中, $\phi(y)$ 表示所有整合后刚好为最终预测标签的CTC路径的集合。

4 实验结果及分析

4.1 实验设置

目前没有通用的用于Morse码识别的数据集,本文在实验中所使用的数据集是利用程序生成的Morse信号。信号长度为4 s,其中含有不多于5个随机英文字符,点划的频率为600 Hz。为尽量模拟真实环境中传输的Morse信号,本文预设了多个码速和信噪比,随机分配给每个信号,数据集的具体组成如表2,其中数目中的“25000/50000”指每个周期从50000样本中随机挑选25000个样本来训练。

输入信号时频图对应信号的时间长度0~4 s,频率宽度500~700 Hz,时频图尺寸统一为128×

32。模型采用的深度学习框架为Tensorflow。CNN层的具体设置如表1所示,循环层中两层的BLSTM的神经节点数都为256。训练过程每个批次(batch)的大小为500个,选用的优化器为RMS-prop,学习率从0.01递减到0.0001。实验所用服务器配置为Intel Xeon CPU 3.20 GHz, Tesla P40 GPU。对于模型性能的衡量,识别准确率指标使用的是字准确率和词准确率,其中字准确率指样本中含有的所有字符识别正确的比例,词准确率指识别正确的样本占总样本数的比例;识别速度指标使用的是每秒帧率(Frame Per Second, FPS)^[17],即每秒能处理的时频图数目。

4.2 多模型识别性能对比

将验证集划分为不同的信噪比和不同的码速,取等量数据分别测试模型的字正确率随信噪比和码速的变化曲线。实验中对比了本文的算法、文献[10]中的HMM-DNN算法以及文献[8]中的FCM聚类算法,结果如图4所示。

图4(a)中,在高信噪比时3个算法都具有较高识别准确率,随着信噪比的降低,尤其是在低信噪比环境下,FCM和HMM-DNN算法的效果明显降低,而本文算法仍能保持较高的准确率,说明了本文算法对低信噪比适应性较强。图4(b)中码速在一定范围内变化,3个算法的识别效果并没有太大波动,说明码速的适当变化对算法的影响不大。码速的变化意味码的持续时间改变,但点划和各类间隔的时长比例仍不变,则FCM算法的码聚类结果不会太大改变,从而效果基本不变。从图4(b)中本文算法和HMM-DNN的结果来看,两者应该也是学

习到的前后码的时长比例关系来进行判断,所以结果随码速变化不大。为综合衡量模型性能,进一步测试了3种算法的识别速度。模型输入的batch大小都为50,时频图的大小和所含字符数等参数已在4.1节中介绍,结果如图5所示。

图5中,本文算法的识别速度相比于另外两者有明显的优势,而FCM和HMM-DNN算法测试速度近似。得益于深度学习框架的良好架构和GPU强大的并行计算能力,本文算法可以快速地按批次处理数据,因此能基本满足工程应用上的实时性要求。FCM算法需要对每次的输入数据进行迭代聚类,而HMM-DNN算法则对每个字符构建模型,并逐个用于判断,这些处理都降低了算法运行速度。

4.3 频率漂移和码长偏差的情况

Morse信号中的频率漂移指发报机长时间连续工作时,其输出频率会出现随机的上下浮动而无法保持固定值的现象。机器发报能保证每个Morse码时长的稳定,但手工发报一般会使每个码的时长出现偏差,且随着发报人手法不同,这个偏差会不同。

实验中,给Morse信号中的每个点划的频率随机加上0~350 Hz/s漂移率(单位时间内的漂移量)的线性漂移,同时给点划长度乘以一个0.9~1.1的随机误差系数,以模拟手工偏差,信号时频图如图6所示。

经过上述处理后,信号识别结果如表3所示。

结果表明,随着频率漂移和码长偏差情况的逐个加入,识别准确率逐渐下降,但是依然能保持在一个较高水平,说明本文算法在一些复杂环境中具有较好的鲁棒性,且能适应不同发报手法的电报。

表 2 数据集组成

	码速(wpm)	信噪比(dB)	数目
训练集	25, 30, 40	40, 30, 20, 10, 6, 3, -3, -6, -8, -10	25000/50000
验证集	25, 30, 40	40, 30, 20, 10, 6, 3, -3, -6, -8, -10	2500
测试集	25, 30, 40	40, 30, 20, 10, 6, 3, -3, -6, -8, -10	2500




图 4 多模型识别准确率对比

4.4 卷积层对识别结果的影响

CNN层可以将图像转化为特征向量序列作为BLSTM层的输入，为研究CNN层对识别结果的影响，实验中将CNN层去掉，直接把Morse时频图中的每一列作为BLSTM的输入序列进行CTC解码识别，比较去掉CNN层前后的译码性能，之后给信号加上4.3节中相同的频率漂移再一次进行比较，实验结果如表4所示。

从表4中结果能看出，去掉CNN后训练模型所需的迭代增多、识别准确率下降，当信号出现频率漂移，准确率下降得更加明显，说明CNN层在本文的整个神经网络架构中发挥着重要的作用。实际上，CNN层能提取信号的高层特征，具有局部感知的作用，能使训练更有效率，加快训练的收敛。对于Morse信号的时频图，CNN能敏感地捕捉到点划的位置，包括出现频率漂移时，CNN能充分提取相关特征，并将该特征传递给之后的RNN层，有利于RNN对时序信息的建模，从而提高了整个网络的识别性能。




图5 多模型识别速度对比




图6 出现频率漂移和码长偏差的Morse信号

表3 频率漂移和码长偏差情况下的译码准确率

	字准确率(%)	词准确率(%)
原始信号	99.92	99.65
频率漂移	96.23	91.71
频率漂移+码长偏差	95.88	90.40

表4 有无频漂时去掉CNN前后译码性能

	迭代次数	字准确率(%)	词准确率(%)
有CNN, 无频漂	23	99.92	99.65
无CNN, 无频漂	42	92.71	73.90
有CNN, 有频漂	26	96.23	91.71
无CNN, 有频漂	47	63.11	20.35

5 结束语

本文在研究了传统Morse码自动识别算法的基础上，引入深度学习的方法构建了神经网络模型作为识别系统，该模型利用Morse信号的时频图作为训练数据，在各种情况下都实现了不错的识别效果。

在实验部分，为尽量模拟实际传输的信号，对数据设置了多个码速和信噪比用于训练。比较了本文算法与传统算法在不同信噪比和码速下识别准确率和速度，测试了在信号出现频率漂移以及不同发报手法造成码长偏差的情况下算法的识别准确率，均获得了优异的效果，验证了本文算法的鲁棒性和实用性。通过比较神经网络去掉CNN层前后的性能，说明CNN层能加快训练的收敛并通过提取图像有效特征来提高模型的性能。本文的算法实现了对Morse码的字级别的识别，而一个样本所含字符序列是随机组合的，未来我们将会继续研究对连续接收的Morse信号能按语义自动逐词或逐句地分割并译码，以及将注意力机制引入本文算法中。

参考文献

- [1] DEY S, CHUGG K M, and BEEREL P A. Morse code datasets for machine learning[C]. The 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT), Bangalore, India, 2018: 1–7. doi: 10.1109/icccnt.2018.8494011.
- [2] SHIH C H and LUO C H. A Morse-code recognition system with LMS and matching algorithms for persons with disabilities[J]. *International Journal of Medical Informatics*, 1997, 44(3): 193–202. doi: 10.1016/s1386-5056(97)00020-8.
- [3] HSIEH M C, LUO C H, and MAO Chiwu. Unstable Morse code recognition with adaptive variable-ratio threshold prediction for physically disabled persons[J]. *IEEE Transactions on Rehabilitation Engineering*, 2000, 8(3): 405–413. doi: 10.1109/86.867882.
- [4] YANG Chenghong, LUO C H, JEANG Y L, et al. A novel approach to adaptive Morse code recognition for disabled persons[J]. *Mathematics and Computers in Simulation*, 2000, 54(1/3): 23–32. doi: 10.1016/s0378-4754(00)00180-4.
- [5] GOLD B. Machine recognition of hand-sent Morse code[J]. *IRE Transactions on Information Theory*, 1959, 5(1): 17–24. doi: 10.1109/TIT.1959.1057478.
- [6] WU Chungmin and LUO Chinghsing. Morse code recognition system with fuzzy algorithm for disabled persons[J]. *Journal of Medical Engineering & Technology*, 2002, 26(5): 202–207. doi: 10.1080/03091900210156904.
- [7] WANG Yaqi, SUN Zhonghua, and JIA Kebin. An automatic decoding method for Morse signal based on clustering algorithm[C]. The 12th International Conference

- on Intelligent Information Hiding and Multimedia Signal Processing, Kaohsiung, China, 2017: 235–242.
- [8] 王亚琦, 孙中华, 贾克斌. Morse报自动译码算法研究[J]. 信号处理, 2017, 33(11): 1451–1456.
- WANG Yaqi, SUN Zhonghua, and JIA Kebin. Research on automatic decoding algorithm of Morse telegraph[J]. *Signal Processing*, 2017, 33(11): 1451–1456.
- [9] LECUN Y, BENGIO Y, and HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436–444. doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539).
- [10] WANG Xianyu, ZHAO Qi, MA Cheng, *et al.* Automatic Morse code recognition under low SNR[C]. 2018 International Conference on Mechanical, Electronic, Control and Automation Engineering (MECAE 2018), Qingdao, China, 2018: 46–51. doi: [10.2991/mecae-18.2018.46](https://doi.org/10.2991/mecae-18.2018.46).
- [11] SHI Baoguang, BAI Xiang, and YAO Cong. An end-to-end trainable neural network for image-based sequence recognition and its application to scene text recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(11): 2298–2304. doi: [10.1109/TPAMI.2016.2646371](https://doi.org/10.1109/TPAMI.2016.2646371).
- [12] 韦醒超. 摩尔斯短波无线通信系统的设计与实现研究[D]. [硕士学位论文], 湖南大学, 2017.
- WEI Xingchao. Research on the design and implementation of Morse shortwave wireless communication system[D]. [Master dissertation], Hunan University, 2017.
- [13] CABAL-YEPEZ E, GARCIA-RAMIREZ A G, ROMERO-TRONCOSO R J, *et al.* Reconfigurable monitoring system for time-frequency analysis on industrial equipment through STFT and DWT[J]. *IEEE Transactions on Industrial Informatics*, 2013, 9(2): 760–771. doi: [10.1109/TII.2012.2221131](https://doi.org/10.1109/TII.2012.2221131).
- [14] SAINATH T N, KINGSBURY B, SAON G, *et al.* Deep convolutional neural networks for large-scale speech tasks[J]. *Neural Networks*, 2015, 64: 39–48. doi: [10.1016/j.neunet.2014.08.005](https://doi.org/10.1016/j.neunet.2014.08.005).
- [15] GRAVES A and SCHMIDHUBER J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. *Neural Networks*, 2005, 18(5/6): 602–610. doi: [10.1016/j.neunet.2005.06.042](https://doi.org/10.1016/j.neunet.2005.06.042).
- [16] GRAVES A, FERNÁNDEZ S, and GOMEZ F. Connectionist temporal classification: Labelling unsegmented sequence data with recurrent neural networks[C]. The 23rd International Conference on Machine Learning, Pittsburgh, USA, 2006: 369–367.
- [17] 刘宏哲, 杨少鹏, 袁家政, 等. 基于单一神经网络的多尺度人脸检测[J]. 电子与信息学报, 2018, 40(11): 2598–2605. doi: [10.11999/JEIT180163](https://doi.org/10.11999/JEIT180163).
- LIU Hongzhe, YANG Shaopeng, YUAN Jiazheng, *et al.* Multi-scale face detection based on single neural network[J]. *Journal of Electronics & Information Technology*, 2018, 40(11): 2598–2605. doi: [10.11999/JEIT180163](https://doi.org/10.11999/JEIT180163).
- 游 凌: 男, 1971年生, 博士, 研究员, 研究方向为信号分析.
- 李伟浩: 男, 1996年生, 硕士生, 研究方向为深度学习、信号分析.
- 张文林: 男, 1982年生, 博士, 副教授, 研究方向为语音信号处理、语音识别、自然语言理解.
- 王科人: 男, 1986年生, 博士, 助理研究员, 研究方向为信号分析、智能信息处理.

责任编辑: 马秀强