

# 基于时间卷积网络的极化码译码算法

李 硕<sup>1</sup>, 王友国<sup>2\*</sup>, 柴 允<sup>1</sup>, 任珈仪<sup>2</sup>

(1. 南京邮电大学 通信与信息工程学院, 江苏 南京 210003;

2. 南京邮电大学 理学院, 江苏 南京 210023)

**摘 要:**针对传统的极化码译码(SC译码)算法实际应用中的用时较长和容错率较差的问题,提出并使用新型人工神经网络——时间卷积网络(temporal convolutional network, TCN)拟合的方式搭建极化码译码模型。与其他人工神经网络不同的是,时间卷积网络属于卷积神经网络(convolutional neural network, CNN),和循环神经网络(recurrent neural network, RNN)的功能相似,其独有的膨胀因果卷积结构和残差链接方法使其擅于分析时间数据,比长短期记忆网络(long short-term memory, LSTM)、门控循环神经网络(gated recurrent units, GRU)之类的规范循环网络更准确、更简单、更清晰,比较适合极化码这样的时间序列。通过调试网络模型参数的方式,对时间卷积网络译码性能影响进行了研究,仿真结果显示,通过合理地调整训练序列数、卷积核的大小和数目可以实现提升极化码译码性能的要求。

**关键词:**极化码; SC译码; 时间卷积网络; 膨胀因果卷积; 残差链接

中图分类号: TP391; TN911

文献标识码: A

文章编号: 1673-629X(2022)03-0054-05

doi: 10.3969/j.issn.1673-629X.2022.03.009

## Polar Codes Decoding Algorithm Based on Temporal Convolutional Network

LI Shuo<sup>1</sup>, WANG You-guo<sup>2\*</sup>, CHAI Yun<sup>1</sup>, REN Jia-yi<sup>2</sup>

(1. School of Telecommunications and Information Engineering, Nanjing University of

Posts and Telecommunications, Nanjing 210003, China;

2. School of Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** Aiming at the problems of long time and poor error tolerance in the practical application of traditional polar code decoding (SC decoding) algorithms, a new type of artificial neural network, temporal convolutional network (TCN), has been declared to build a polar code decoding model. Different from other artificial neural networks, TCN belongs to CNN, which is similar in function to RNN. It has a unique dilated causal convolutions structure and residual connections method, which is more accurate, simpler and clearer than canonical recurrent networks such as LSTM and GRU, which is more suitable for time series such as polar codes. By adjusting the parameters of the network model, the effect of time convolutional network decoding performance can be observed. The phenomena of simulations have proven that by reasonably adjusting the number of training sequences, the size and number of convolution kernels, the requirements of improving the polar codes decoding performance can be achieved.

**Key words:** polar code; SC decoder; temporal convolutional network (TCN); dilated causal convolution; residual connections

## 0 引 言

随着移动通信系统需求的增加,第五代移动通信系统已经得到了广泛应用,但低时延和高速率仍然是人们不懈的追求<sup>[1]</sup>。极化码属于线性分组码,它的复杂度较低,速率高<sup>[2]</sup>,目前已被选为5G控制信道的编码方案。然而,极化码传统的解码算法迭代计算较多,有效性和可靠性难以均衡<sup>[3]</sup>,因此,迫切需要设计一种高速低延

迟的极化码解码算法。

深度神经网络通过具有非线性处理单元的多层层叠寻找和转换编码结构和噪声特征,与传统的迭代解码相比,深度神经网络的解码器通过单次解码,为低延迟实现提供了基础<sup>[4]</sup>。此外,通过利用现有的深度神经网络平台,可以轻松满足高速需求<sup>[5]</sup>。Lyu<sup>[6]</sup>使用了三种经典的神经网络进行译码尝试,它们的参数大小相同,

收稿日期: 2021-03-13

修回日期: 2021-07-14

基金项目: 国家自然科学基金(62071248, 61179027); 江苏省研究生科研创新计划(KYCX20-0730)

作者简介: 李 硕(1997-),男,硕士研究生,研究方向为信号处理;通信作者: 王友国(1968-),男,博士,教授,研究方向为社交网络信息传输与监控、随机共振理论与应用等。

经测试对比,RNN 具有较好的解码性能,但需要以高计算开销为代价,并且由于学习能力受到限制,导致每种类型的神经网络都存在一个饱和长度。郭锐<sup>[7]</sup>尝试通过调控神经网络的 batch 和 epoch 参数,利用 CNN 对极化码长码进行译码,在低信噪比下 CNN 性能略优于传统译码算法,但在高信噪比下 CNN 的性能会逐渐下降。徐想<sup>[8]</sup>针对神经网络译码器对于极化码长码的训练效果不佳的问题,设计了分区神经网络译码算法,降低了译码器译码时延。

通过利用传统的 CNN 和 RNN 作为工具对极化码的译码研究在时间效率上取得了不错的效果,但为了推广到更多更复杂的场合中,还需要更广泛且高效的技术。近年来许多改进的研究陆陆续续被提出,其中 Shaojie Bai 等人<sup>[9]</sup>设计了新型架构,将其命名为时间卷积网络,它与 RNN 的功能相似,相比传统的 CNN,可以进行大规模并行处理,缩短了训练和验证的时间,减小了梯度消失的可能性。该文将尝试使用 TCN 进行极化码的译码,并通过调试 TCN 的各式参数,探讨对译码性能的影响。

## 1 极化码译码简介

### 1.1 极化码

极化码由 Arikan 提出<sup>[10]</sup>,它在二进制离散无记忆信道的条件下,当码长  $N$  趋近于无限长的时候,可以产生信道极化的现象。它是信道合并与信道分裂两种信道操作的结果,在这两种操作下,原本相同的  $N$  个分裂信道产生了极化现象,使它们的信道容量趋近于 0 或趋近于 1,从而在理论上逼近了香农极限。

### 1.2 极化码译码

极化码的传统解码方式为连续消除 (successive cancellation, SC) 译码算法,它采用蝶形算法,特点是当前第  $i$  位的码字的判定需要第  $i-1$  位的估计值,串行执行,通过译码器进行逐次迭代递归求解似然比的方式进行解码,其中似然比见式(1),判决式见式(2)<sup>[2]</sup>。

$$L_N^{(i)}(y_1^N, \hat{u}_1^{i-1}) = \frac{W_N^{(i)}(y_1^N, \hat{u}_1^{i-1} | 0)}{W_N^{(i)}(y_1^N, \hat{u}_1^{i-1} | 1)} \quad (1)$$

$$\hat{u}_i = \begin{cases} 0, & \text{if } L_N^{(i)}(y_1^N, \hat{u}_1^{i-1}) \geq 1 \\ 1, & \text{if } L_N^{(i)}(y_1^N, \hat{u}_1^{i-1}) < 1 \end{cases} \quad (2)$$

通过这样的方式,SC 的译码算法可将当前位的估计值直接判决为“0”或者“1”,虽然算法复杂度较低,但它仅能保证局部最优化,无法进行并行解码,且当前位码字的判决需要前一位的估计值,容错性较差。Vardy 等人<sup>[11]</sup>提出了改进算法,可保留  $L$  条译码路径进行可靠性选择。Niu 等人<sup>[12]</sup>进一步加入了循环冗余校验码,相比 SC 译码算法,大幅度提升了译码准确性,但需要更多

的译码时延和存储空间,大大增加了复杂度。

## 2 TCN 介绍及译码器结构

### 2.1 TCN 背景

RNN 之所以擅长处理时序相关的问题,正是因为它循环自回归的结构,非常适合处理时间序列。传统的 CNN 由于卷积核大小的限制,无法收获时间较长的相关信息。但经过人们不懈的研究发现,一些特定的 CNN 结构也会有不错的效果。TCN 作为一种特殊的卷积神经网络,通过一维全卷积网络 (1-dimensional fully convolutional networks, 1-D FCN) 结构和膨胀因果卷积结构,实现了每个时间的输入都有对应的输出,并且保证了历史数据的完整性,在目前多种任务中可以实现超越 RNN 模型的效果<sup>[9]</sup>。

### 2.2 TCN 结构

TCN 采取因果卷积的构造,其特点是对于输出  $t$  时刻的数据  $y_t$ ,其输入时刻只可能是  $t$  或  $t$  时刻以下。因果卷积无法看到未来的数据,它为单向结构,当计算当前时间步的输出时,会自动将超过当前时间步的输入“切掉”,这样严格保证了时序性。同时,TCN 还使用了 1-D FCN 的结构代替了全连接,减少了不必要的计算和空间<sup>[13]</sup>,更使得每个输出层都可以保持和输入层一样的时间长度被继续传递,维持了相同的时间步,不论在哪一层,每个时间步的输入与输出均一一对应。其中,当处理第一个时间步时,由于没有任何历史的信息,TCN 默认其历史数据全是 0。以卷积核大小为 2 的单次卷积操作为例,TCN 的卷积运算如图 1 所示,在任意  $t$  时刻,卷积操作输出  $y_t$  为:

$$y_t = \omega_1 x_{t-1} + \omega_2 x_t \quad (3)$$

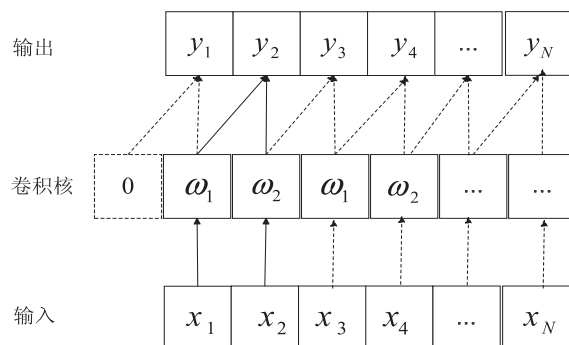


图1 TCN 的卷积操作

假设在因果卷积中,一个输出与输入的  $N$  个时间点都存在关联,则构成的 TCN 深度为  $N-1$ ,当  $N$  很大时,TCN 深度过大,会使得网络结构过于复杂,因此提出改进结构膨胀因果卷积<sup>[9]</sup>,通过引入膨胀因子  $d$ ,可以克服这一问题。设卷积核大小为 2,扩展值为  $\{1, 2, 4, 8\}$ ,膨胀因果卷积的 TCN 示意图如图 2 左半部分所示。

此外,为了应对一些很深的复杂模型,使 TCN 在深

层条件下不会丢失信息,采用残差网络的连接方式,其结构框图如图 2 右半部分所示。它替代了 TCN 层与层之间的简单连接,与 ResNet 的残差块结构相似<sup>[14]</sup>。卷积核接收到的信息也会分为两部分,左侧是参加多次卷积核处理后获得的信息,包括两层的膨胀因果卷积和非线性映射,并在每层加入 WeightNorm 和 Dropout 防止过拟合;右侧则是底层的局部信息的直接连接内容通过

自设的卷积层进行简单的变换,两者相加,这样使得输出的内容具有丰富并清晰的底层信息,不容易遗失细节特征,是训练深层网络的有效方法。总的来说,将膨胀因果卷积和残差链接两种技术一起使用,可使处理的数据值保证精确度和特征,兼顾训练,速度可观,再将改进的 TCN 模型的最顶层连接至最顶部隐藏层进行输出<sup>[15]</sup>。

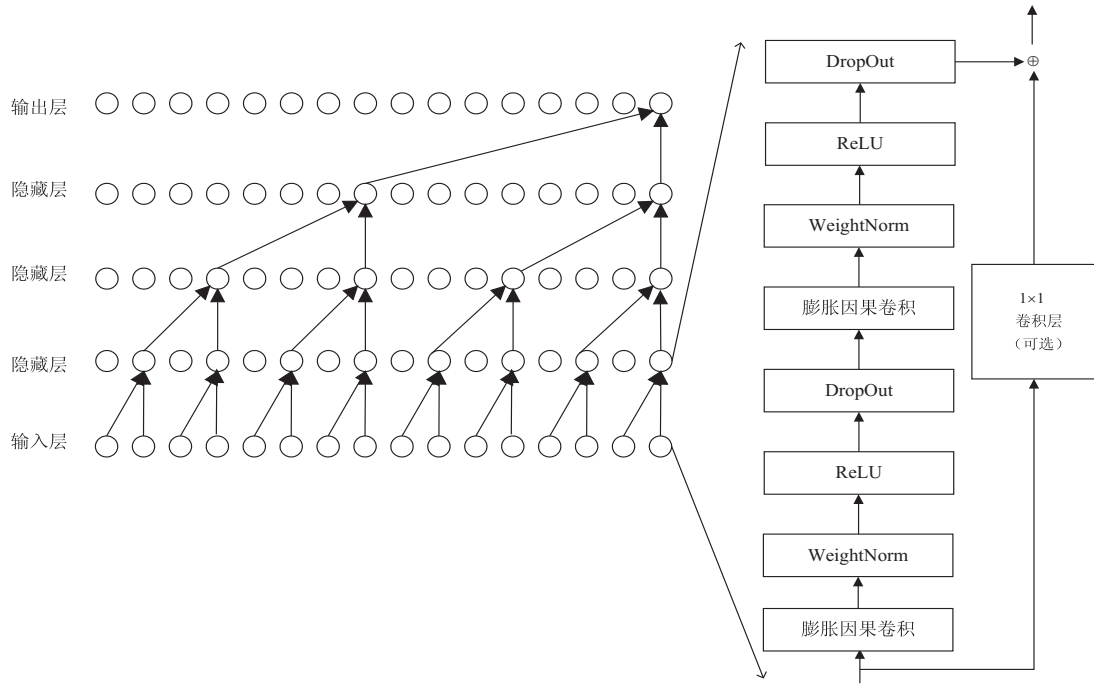


图 2 膨胀因果卷积与残差模块示意图

### 2.3 极化码译码器结构

TCN 的极化码译码算法架构如图 3 所示。



图 3 TCN 译码器架构

信源发射器发送长度为  $K$  的信息序列  $\mathbf{x}$ ,  $\mathbf{x}$  通过极化码编码成为码长为  $N$ , 码率为  $1/2$  的极化码  $\mathbf{u}$ 。通过 BPSK 调制将码字  $\mathbf{u}$  映射到符号向量  $\mathbf{s}$ , 其中假设调制后的信号是在加性高斯白噪声 (AWGN) 信道中传输的。在信号接收端接收符号向量  $\mathbf{y}$ , 可以写成  $\mathbf{y} = \mathbf{s} + \mathbf{n}$ , 其中  $\mathbf{n}$  为噪声向量,  $\mathbf{n} \sim N(0, \sigma^2 \mathbf{I}_N)$  为  $1 \times N$  的向量。接下来就是参考  $\mathbf{x} \rightarrow \mathbf{y}$  的训练集, 来建立  $\mathbf{y} \rightarrow \hat{\mathbf{x}}$  去拟合  $\hat{\mathbf{x}}$ 。

估计信息位  $\hat{\mathbf{x}}$  是通过 TCN 解码接收符号向量  $\mathbf{y}$ ,  $\hat{\mathbf{x}} = [\hat{x}_0, \hat{x}_1, \dots, \hat{x}_{K-1}]$ ,  $\mathbf{x} = [x_0, x_1, \dots, x_{K-1}]$ ,  $\mathbf{y} = [y_0, y_1, \dots, y_{N-1}]$ , 将所有可能的集合  $\mathbf{x}$  和  $\hat{\mathbf{x}}$  记为  $\mathbf{X}$ , 所有可能的集合  $\mathbf{y}$  记为  $\mathbf{Y}$ 。解码算法的目的在于找到满足最大后验估计 (MAP) 的最佳映射函数, 表达式为:

$$f^*(\mathbf{y}) = \underset{\mathbf{x} \in \mathbf{X}}{\operatorname{argmax}} P(\mathbf{x} | \mathbf{y}) \quad (4)$$

### 3 仿真结果与分析

该文使用交叉熵函数 (binary\_crossentropy) 作为损失函数, 并通过 Adam 算法<sup>[16]</sup>优化神经网络参数, 能够

对不同参数调整合适的学习速率, 使得学习速率在一定的范围内移动, 达到最小化损失函数的目的。

数据预处理: 训练数据大小为  $4 \times 10^6$ , 设置信息比特数目为  $K$ , 通过极化码编码将  $K$  个信息比特混入冻结比特, 调制并添加设置好信噪比 (固定) 的高斯噪声, 将添加噪声后的数据作为训练数据, 信源数据作为标签, 反复训练; 测试集同理, 数据大小为  $2 \times 10^4$ 。为了解决庞大的数据输入的问题, 使用 minibatch 和 epoch 参数限制输入数据的大小。为加快 TCN 的训练速度, 提高收敛速度, 卷积层使用批量归一化函数。

参数设置: 训练阶段输入为 (16, 8), 码率为  $1/2$ , 序列数为  $4 \times 10^5$ , 测试阶段输入序列为  $2 \times 10^4$ 。minibatch 设置为 1, epoch 设置为 45。随机抽取  $2 \times 10^4$  组  $16 \times 1$  个序列, 在训练阶段的信噪比设置为 3 dB, 测试阶段的信噪比设置为 0 ~ 5 dB, 间隔为 0.2 dB。默认残差块数目为 4, 每个残差块有三层卷积层, 每层有 175 个卷积核, 卷积核大小为 5。




图4 TCN译码器在训练过程中损失函数的变化




图5 基于TCN的极化码译码性能 ( $N=16, K=8$ )

图4为训练时损失函数的变化,可以看出当训练样本的迭代次数在50之前时,损失函数下降较明显,学习速度较快;当训练样本的迭代次数超过50以后,损失函数基本保持稳定,网络性能趋于收敛状态。TCN的译码性能如图5所示,可以看出随着测试信噪比的不断增加,译码的准确率也逐渐变得越来越可观,证明了TCN模型作为极化码译码的有效工具的可行性。为了探究TCN模型各个参数对译码性能的影响,接下来控制其他参数不变,探究各个参数对误码率的影响。

(1)仅调整TCN内的卷积核大小(分别为1、2、3、4、5)进行TCN译码性能对比,效果如图6(a)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,并且卷积核大小越小,译码性能越好,译码性能提升越明显。



(a)不同卷积核大小




(b)不同卷积核个数


图6 不同卷积核大小和数目下的TCN译码性能

(2)仅调整TCN的残差块内卷积核的数量(分别为100、125、150、175、200)进行译码性能对比,效果如图6(b)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,并且卷积核数量和译码性能是正相关的,其中当卷积核数目在100~175的范围内,通过提升卷积核数目改进TCN的译码效果明显。

(3)仅调整TCN内的残差块数量(分别为1、2、4、6)进行译码性能对比,效果如图7(a)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,但是它们的性能相差不大,残差块为6时的译码性能要略低于残差块为1时的译码性能,并且每增加一个残差块都会大大增加复杂度,提高内存需求,因此在实际设计进行极化码译码时,不宜设计过多残差块。



(a)不同残差块个数



(b)不同输入信噪比

图7 不同残差块个数和输入信噪比下的TCN译码性能



(4) 仅调整 TCN 训练阶段的输入信噪比(分别为 1 dB、3 dB、5 dB、10 dB、15 dB、20 dB)进行译码性能对比,效果如图 7(b)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,输入信噪比大小为 3 dB 左右时,译码性能较佳,增加输入信噪比并不会对译码性能有较好的改善。

(5) 仅调整 TCN 训练参数 epoch 的值(分别为 5、15、25、35、45、65、85、105)进行译码性能对比,效果如图 8(a)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,在 epoch 值从 5 至 15 时对译码性能提升明显,当 epoch 值超过 15 时,对译码性能的影响不大。

(6) 仅调整 TCN 的训练序列数(分别为  $1 \times 10^5$ 、 $2 \times 10^5$ 、 $3 \times 10^5$ 、 $4 \times 10^5$ )进行译码性能对比,效果如图 8(b)所示。可以看出它们都会随着信噪比的增加而逐渐降低误码率,当训练序列数小于  $2 \times 10^5$  时,译码性能相差较小;当训练序列数超过  $2 \times 10^5$  时,译码性能会大幅度提升,当训练序列数为  $4 \times 10^5$  时,译码效果较好。

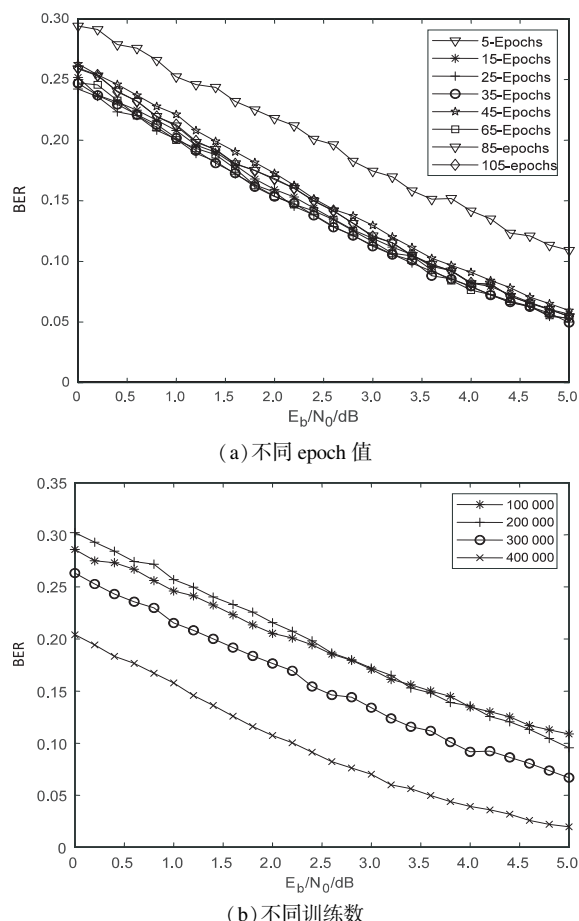


图8 不同 epoch 值和训练数下的 TCN 译码性能

通过对六种网络模型参数的调试,可以在原有的基础上实现 TCN 对极化码译码的性能提升,其中对训练序列数、卷积核的大小和数目进行适当调试可取得较好的译码增幅效果,使得 TCN 在极化码译码的应用推广又前进了一步。

## 4 结束语

该文提出了基于 TCN 的极化码译码模型,利用 TCN 内特有的膨胀因果卷积和残差块结构,实现了对极化码较好的译码,并通过调试 TCN 的各式参数,探讨对译码性能的影响。该文主要探讨了极化码为短码时的时间卷积网络的译码性能,但可以基于此进一步探究当极化码为长码时,TCN 的性能是否会有较大影响。

## 参考文献:

- [1] 沈洁. 第5代移动通信系统展望[J]. 电信科学, 2013, 29(9): 98-101.
- [2] ARIKAN E. Channel polarization: a method for constructing capacity-achieving codes for symmetric binary-input memoryless channels[J]. IEEE Transactions on Information Theory, 2009, 55(7): 3051-3073.
- [3] 王继伟. 极化码编码与译码算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2013.
- [4] 杨梦岭. 基于深度学习的 Polar 码解码方案研究[D]. 天津: 天津大学, 2018.
- [5] 陈先昌. 基于卷积神经网络的深度学习算法与应用研究[D]. 杭州: 浙江工商大学, 2014.
- [6] LYU W, ZHANG Z, JIAO C, et al. Performance evaluation of channel decoding with deep neural networks[C]//International conference on communications (ICC). Kansas City: IEEE, 2018: 1-6.
- [7] 郭锐, 冉凡春. 基于卷积神经网络的极化码译码算法[J]. 电信科学, 2020, 36(6): 119-124.
- [8] 徐想. 基于深度学习的极化码译码算法研究[D]. 北京: 北京交通大学, 2019.
- [9] 季文强. 基于深度学习和不确定性量化的数据驱动剩余寿命预测方法研究[D]. 合肥: 中国科学技术大学, 2020.
- [10] ARIKAN E. Channel combining and splitting for cutoff rate improvement[J]. IEEE Transactions on Information Theory, 2006, 52(2): 628-639.
- [11] TAL I, VARDY A. List decoding of polar codes[J]. IEEE Transactions on Information Theory, 2015, 61(5): 2213-2226.
- [12] NIU K, CHEN K. CRC-aided decoding of polar codes[J]. IEEE Communications Letters, 2012, 16(10): 1668-1671.
- [13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [14] 冯达智. 基于时间卷积网络的飞控时序数据预测技术研究[D]. 成都: 电子科技大学, 2020.
- [15] 刘焯. 基于 LSTM 和 TCN 的室内定位系统研究与实现[D]. 济南: 山东大学, 2019.
- [16] 刘颖超, 张纪元. 梯度下降法[J]. 南京理工大学学报: 自然科学版, 1993(2): 12-16.