

## 自由空间光通信下的 LSTM-SCFlips 译码方法研究

曹阳, 文豪\*, 党宇超

重庆理工大学电气与工程学院, 重庆 400054

**摘要** 针对自由空间光通信下大气湍流引起极化码译码中错误比特难以定位的问题, 提出一种自由空间光通信下的 LSTM-SCFlips 译码方法。首先将极化码串行抵消(SC)译码的对数似然比(LLR)信息序列进行 one-hot 预编码处理, 在不同训练步长下, 分析与学习极化码对数似然比信息序列的特征, 综合考虑神经预测模型的均方根误差和计算复杂度, 选取合适的训练步长, 在提升预测结果精确度的基础上, 进一步消除预测结果过拟合的现象。通过长短时记忆(LSTM)神经网络模型定位 SC 译码的第一个错误位时, 按错误概率大小排序, 依次进行 SC 译码算法的单比特或多比特翻转。仿真结果表明, 在不同的大气弱湍流强度下, 自由空间光通信下的 LSTM-SCFlips 译码方法在以牺牲少量计算资源为前提的情况下能更好地识别最优翻转位, 降低计算复杂度, 同时获得更好的误码率性能。当误码率为  $10^{-4}$  时, LSTM-SCFlips 译码方法最优翻转位的正确识别率被提高 7 个百分点, 且产生了 0.3 dB~1.2 dB 的编码增益。

**关键词** 光通信; 长短期记忆人工神经网络; 极化码; 串行抵消译码算法; 比特翻转; 弱湍流信道

**中图分类号** TN929.12

**文献标志码** A

**doi:** 10.3788/AOS202141.1406004

## LSTM-SCFlips Decoding Method in Free-Space Optical Communication

Cao Yang, Wen Hao\*, Dang Yuchao

*School of Electrical and Electronic Engineering, Chongqing University of Technology, Chongqing 400054, China*

**Abstract** Because of the difficulty in locating error bits in polarization code decoding caused by atmospheric turbulence in free-space optical communication, this paper proposes an LSTM-SCFlips decoding method in free-space optical communication. First, one-hot precoding is performed on the log-likelihood ratio (LLR) information sequence of polarization codes in serial cancellation (SC) decoding, and the characteristics of the information sequence are analyzed and learned in different training step sizes. The root mean square error and computational complexity of the neural prediction model are comprehensively considered, and an appropriate training step size is selected. After the accuracy of the prediction results is improved, the phenomenon of overfitting the prediction results is further eliminated. The LSTM neural network model is used to locate the first error bit of SC decoding and single-bit or multi-bit flips of the SC decoding algorithm according to the error probability are performed. The simulation results show that in different weak atmospheric turbulence intensities, the proposed decoding method can better identify the optimal flip position and reduce the computational complexity on the premise of sacrificing few computing resources. In addition, better bit-error-rate performance is achieved. When the bit error rate is  $10^{-4}$ , the correct recognition rate of the optimal flipped bit of the LSTM-SCFlips decoding method is increased by 7 percentage points, and the coding gain of 0.3 dB–1.2 dB is generated.

**Key words** optical communications; long and short-term memory artificial neural network; polarization code; serial cancellation decoding algorithm; bit flip; weak turbulence channel

**OCIS codes** 060.2605; 010.1330; 060.4510

**收稿日期:** 2020-11-05; **修回日期:** 2021-02-13; **录用日期:** 2021-02-26

**基金项目:** 重庆市教委基金(KJ120827)、重庆市教委科学技术项目(KJ1500934, KJ1709205)、重庆市研究生科研创新项目(CYS18311)、重庆市基础与前沿研究计划项目(cstc2015jcyjA40051)

**通信作者:** \*929388258@qq.com

# 1 引言

自由空间光通信技术是以激光为载波在自由空间中传输数据的通信技术,其得益于具有高度的安全性、巨大的带宽、免许可证频谱和低部署成本等特点,得到广泛的应用<sup>[1-3]</sup>。但大气湍流引起的温度和气压的非规律性变化,使得接收信号的幅值和相位出现随机波动,从而导致光信号在传输中产生较高的误码率,甚至导致信号中断,严重影响了通信系统性能<sup>[4-5]</sup>。为了解决这方面的问题,研究学者将极化码应用于自由空间光通信中<sup>[6]</sup>。

Arikan<sup>[7]</sup>于 2009 年首次提出极化码,通过使用无限码长的串行抵消(SC)译码算法,证明极化码可以满足二进制对称离散无记忆输入信道的容量要求。2016 年,码长较短的极化码被选为 5G 标准移动宽带(eMBB)场景的信道编码方案,但码长较短时,极化码在 SC 译码下的性能并不理想。为了提高 SC 译码的译码性能, Tal 等<sup>[8]</sup>提出串行抵消列表(SCL)译码算法,通过保留列表大小为  $L$  的候选路径来降低误码率。此外,循环冗余校验(CA-SCL)译码算法通过使用循环冗余校验码(CRC)检测错误,使极化码成为一种强大的信道编码方案<sup>[9]</sup>。然而,这些译码算法的算法复杂度随着列表大小的增加而增加。为了避免 SCL 译码存储开销增大,译码性能降低,在文献<sup>[10]</sup>中提出串行抵消比特翻转(SCFlips)译码算法,该算法由标准 SC 译码器和翻转机制组成,使用 CRC 级联极化码来检查初始 SC 译码错误,并在初始 SC 译码失败时允许给定最大的翻转次数,每次新的译码尝试根据对数似然比(LLR)的大小来翻转第一个错误位。然而,SCFlips 算法不能精确地定位错误比特位,需依赖最大翻转次数来纠正 SC 时出现的错误翻转,故会导致译码性能差或者计算复杂度高。针对极化码 SCFlips 算法中错误比特位难以定位的问题,专家与学者作出以下研究。Zhang 等<sup>[11]</sup>提出了一种基于误码率评估的极化码 SCFlips 译码器,通过遗传算法估计非冻结比特的误码率期望值,从而确定 SC 译码的错误位。Erkan 等<sup>[12]</sup>提出基于阈值的比特翻转方案,通过识别一组容易出错的位指数和 LLR 阈值来确定信道错误位的位置。Zhang 等<sup>[13]</sup>利用渐进式 SCFlips 译码器构造出一个包含第一个错误比特的临界集,并将其推广为多比特翻转。Ardakani 等<sup>[14]</sup>提出快速串行抵消比特翻转(Fast-SCFlips)译码方法,用于识别极化码码树的 5 种特殊节点,并运用

5 种译码器对其进行译码。Wang 等<sup>[15]</sup>在文献<sup>[14]</sup>的基础上提出分区快速串行抵消比特翻转(partitioned Fast-SSC-Flips)译码方法,进一步缩短了译码延时。Chandesris 等<sup>[16]</sup>提出了一种动态 SCFlips(D-SCFlips)译码方法,这一方法允许一次进行多个比特位的翻转,与 SCFlips 译码相比,该方法的性能更好,但 D-SCFlips 译码方法需要复杂的指数和对数计算。因此,虽然上述译码改进方法优势明显,但对最优翻转位的定位还有一定的提升空间,且产生了较高的计算复杂度。

面对极化码比特翻转的最优解难以选取的问题,可将深度学习算法与极化码译码相结合。本文将极化码推广到自由空间光通信场景中,提出了自由空间光通信下的 LSTM-SCFlips 译码方法,在不同弱湍流强度条件下,设置长短时记忆(LSTM)神经网络输入层、隐藏层、输出层的参数,计算不同训练步长下 LSTM 基本单元沿时间轴和在网络结构上的误差项,利用适应性矩估计(Adam)优化算法根据 LSTM 基本单元的误差项自适应调整模型权值的参数,完成模型参数的更新,从而选取较优训练步长使预测结果的均方根误差(RMSE,  $R_{MSE}$ )最小并消除过拟合现象。然后,利用 LSTM 神经网络模型定位 SC 译码的第一个错误位,根据错误概率大小排序,依次进行串行抵消译码算法的单比特或多比特翻转。最后,在不同码长、码率以及湍流强度下进行仿真分析。结果表明,在自由空间光通信系统下,LSTM-SCFlips 译码方法对最优翻转位有更高的正确识别率,且能获得更好的误码率性能。

## 2 系统模型

### 2.1 自由空间光通信(FSO)系统模型

自由空间光通信的信道编码、传输和译码模型如图 1 所示。自由空间光通信的通信过程如下: 1)在发射端,先将二进制信息序列进行极化码编码,将码字进行脉冲相位调制(PPM),码字调制到光载波上后经大气信道进行传输; 2)在接收端,光学天线接收光信号,并由光电探测器将光信号转换为电信号,然后经 PPM 解调,最后使用 LSTM-SCFlips 译码器对接收信号进行极化码译码。

### 2.2 大气湍流信道

在激光信号的大气传输过程中,大气湍流会引起激光信号的光强闪烁和光束弯曲,从而影响信号的接收。具有加性高斯白噪声和时变增益的大气传输信道采用强度调制/直接检测,其数学模型描述为<sup>[17]</sup>

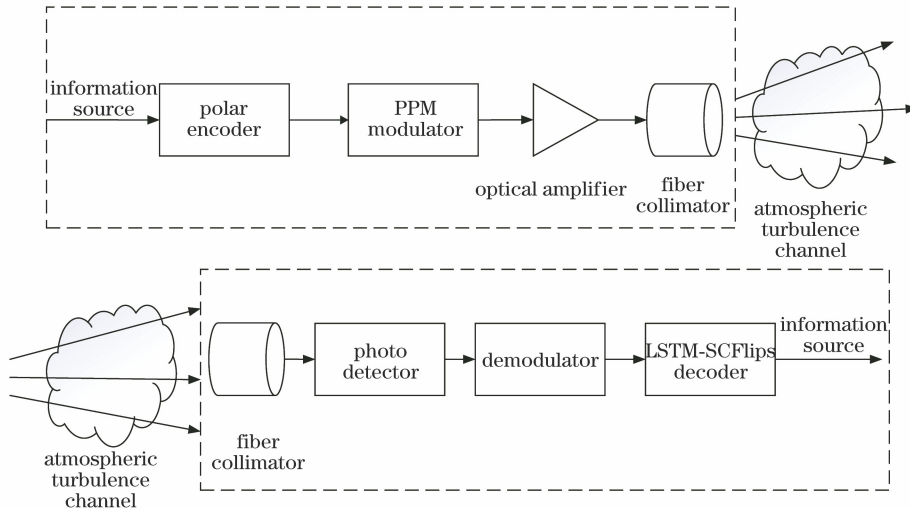


图 1 LSTM 神经网络模型辅助极化码译码的 FSO 系统模型

Fig. 1 LSTM neural network model assisted FSO system model for polarization code decoding

$$y = sx + n_{\text{Gaussian}} = \eta Ix + n_{\text{Gaussian}}, \quad (1)$$

式中,  $x$  是发射信号,  $y$  是接收信号,  $I$  为接收光强,  $s$  为信道的瞬时增益,  $\eta$  为光电转换效率,  $n_{\text{Gaussian}}$  表示均值为 0、方差为  $\sigma_0^2$  的加性高斯白噪声, 且  $n$  与  $s$  相互独立。对数正态分布模型能较好地描述弱湍流条件下的大气信道, 其光强起伏概率密度函数为<sup>[18]</sup>

$$f(I) = \frac{1}{\sqrt{2\pi}\sigma_0 I} \exp\left[-\frac{(\ln I + \sigma_0^2/2)^2}{2\sigma_0^2}\right], \quad (2)$$

其中,  $\sigma_0^2$  表示对数光强起伏方差, 在弱湍流条件下  $\sigma_0^2 < 0.3$ 。

### 3 LSTM 神经网络模型

#### 3.1 LSTM 基本单元

传统的循环神经网络(RNN)只能对部分短信息序列进行记忆<sup>[19]</sup>, 一旦出现类似极化码的长信息序列, 就会出现序列后部的梯度几乎不能反向传播到序列前部的现象, 从而导致梯度消失。然而, 长短时记忆(LSTM)是 Hochreiter 和 Schmidhuber 提出的 RNN 模型中一种新的特殊类型<sup>[20]</sup>, 它通过引入输入门、遗忘门、输出门和记忆单元, 结合求和等逻辑运算, 解决了梯度消失和梯度爆炸的问题。LSTM 基本单元模型如图 2 所示。

LSTM 基本单元主要由输入门  $i_t$ 、遗忘门  $f_t$ 、输出门  $o_t$  以及记忆单元  $C_t$  构成, 输入门表示更新到细胞状态中的信息, 遗忘门表示旧记忆信息的丢弃比例, 输出门表示最终输出的信息,  $C_t$ 、 $\tilde{C}_t$  分别表示当前时刻记忆细胞单元状态和前一时刻记忆细胞单元状态,  $h_t$  表示当前时刻隐藏状态值,  $t$  表示时

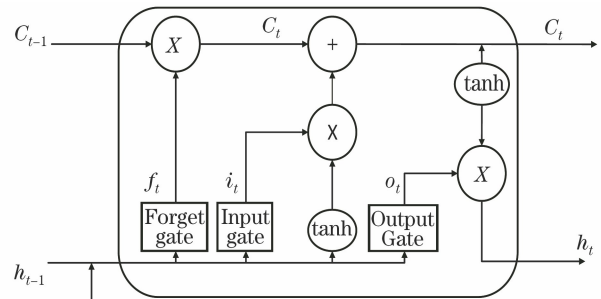


图 2 LSTM 网络内部基本单元

Fig. 2 Basic unit of the LSTM network

间。该模型的数学表达式如下<sup>[21]</sup>：

$$\begin{cases} i_t = \sigma(w_i h_{t-1} + w_i x_t + b_i) \\ f_t = \sigma(w_f h_{t-1} + w_f x_t + b_f) \\ o_t = \sigma(w_o h_{t-1} + w_o x_t + b_o) \\ C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \\ \tilde{C}_t = \tanh(w_c h_{t-1} + w_c x_t + b_c) \\ h_t = o_t \times \tanh(C_t) \end{cases}, \quad (3)$$

式中,  $w_f$ 、 $w_i$ 、 $w_c$ 、 $w_o$  分别表示遗忘门权重、输入门权重、候选值权重、输出门权重,  $b_f$ 、 $b_i$ 、 $b_c$ 、 $b_o$  分别表示为遗忘门偏置、输入门偏置、候选值偏置、输出门偏置,  $x_t$  表示为当前时刻细胞的输入,  $h_{t-1}$  表示为上个时刻隐藏状态值,  $\tanh$  表示为双曲正切激活函数,  $\sigma$  表示为 Sigmoid 函数。

LSTM 基本单元内部计算过程如下: 1) 在  $t$  时刻, 3 个门单元接收当前时刻的状态信息  $x_t$ 、前一个时刻的隐藏信息  $h_{t-1}$  以及记忆细胞的状态  $C_t$ , 通过逻辑运算对接收信息进行处理, 再确定 Sigmoid 函数是否激活; 2) 将以上的处理结果与遗忘门的信

息进行叠加,产生新的记忆细胞状态  $C_t$ ; 3) 经过非线性逻辑运算输出结果  $h_t$ 。

### 3.2 基于 LSTM 的神经网络预测模型

LSTM 神经网络预测模型的结构如图 3 所示,

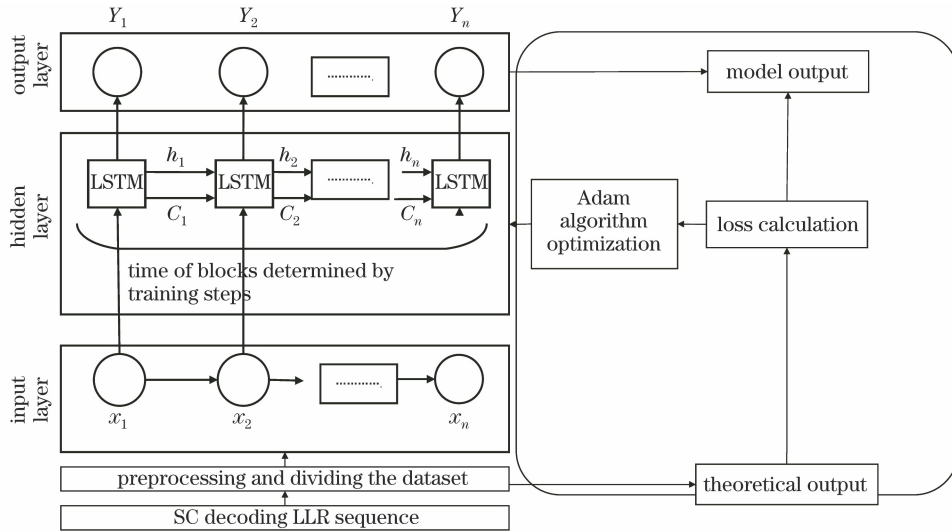


图 3 基于 LSTM 网络预测模型框架

Fig. 3 LSTM network prediction model framework

1) one hot 预编码。本文预编码主要用于撤销错误翻转。在译码过程中,模型根据所观察到的状态选择动作。因此,应对设定的状态和动作进行编码。

(1) 状态编码:  $\alpha$  表示 SC 解码器中输出的 LLR 序列;  $\tilde{\alpha}$  表示一个状态,由 LSTM 输出的错误概率来决定。

(2) 动作编码: 撤销错误翻转是撤销一个“错误”的翻转并回到之前的状态,故需在一个向量中添加一个位来表示“撤销操作”。本研究采用 one hot 编码,编码中只有一位为 1,而其他所有位为 0。对于长度为  $L+1$  的二进制向量,前  $L$  位与  $L$  个非冻结位相对应,最后一位用于“撤销”上一次翻转。

2) 输入层。输入层变量为经过 One hot 编码预处理后的极化码 SC 译码 LLR 序列。

3) 隐藏层。在基于 LSTM 的预测模型中,每个隐藏层包括多个 LSTM 单元。随着 LSTM 单元个数的增加,理论上网络预测的泛化能力随之提升,但是其网络训练复杂度和训练时长也会增大,模型成本也随之增加。同时,在隐藏层中存在一个超参数训练步长,它决定了用于预测最优翻转位的输入序列的长度。训练步长设置过小,会导致训练程度不够,预测准确度低;训练步长设置越大,预测拟合程度越高,但当训练步长过大时,预测结果可能会出现过拟合现象,导致模型的时间成本和计算成本增加。本研究通过大量数据集在不同的训练步长下进

其主要由输入层、隐藏层、输出层组成。在预测模型中,损失函数采用 RMSE 函数,优化算法采用 Adam 算法,并在 Keras 框架下完成对模型的搭建,其模型的具体参数如下。

行分析比较,筛选出预测效果较好的网络预测模型。

4) 输出层。输出层变量为每一个信息比特的译码错误概率。

5) 损失计算。LSTM 模型通常采用 RMSE 来反映预测结果的准确程度,其计算公式为

$$R_{\text{MSE}} = \sqrt{\frac{1}{s} \sum_{i=1}^s (v'_i - v_i)^2}, \quad (4)$$

式中  $v'_i$  代表预测值,  $v_i$  代表真实值,  $s$  代表预测个数。

6) 优化算法。由于传统的梯度优化算法只能保持单一的学习效率,本研究采用 Adam 优化算法<sup>[22]</sup>根据梯度的一阶矩估计和二阶矩估计来自适应调整学习效率,其算法的参数设定如下。步长因子  $\alpha=0.001$ ,一阶矩估计的指数衰减率  $\beta_1=0.9$ ,二阶矩估计的指数衰减率  $\beta_2=0.999$ 。

### 3.3 大气湍流信道下的 LSTM 模型训练

在自由空间光通信系统中,构建 LSTM 神经网络模型,其模型训练步骤如下。

1) 通过 LSTM 基本单元的门机制和记忆单元分别计算出其输出值,即  $f_t, i_t, C_t, o_t, h_t$ 。

2) 计算每个 LSTM 基本单元的误差项。LSTM 基本单元误差项的反向传播主要分为两个方向:沿时间轴的反向传播和沿网络结构上一层反向传播。



针对 LSTM 沿时间轴反向传播的误差项,定义在  $t$  时刻 LSTM 的损失函数  $\delta_t: \delta_t = \frac{\partial E}{\partial h_t}$ ,  $E$  为 LSTM 的 RMSE。根据链式法,可得  $t$  时刻 LSTM 的损失函数为

$$\delta_{t-1} = \frac{\partial E}{\partial h_{t-1}} = \frac{\partial E}{\partial h_t} \frac{\partial h_t}{\partial h_{t-1}} = \delta_t \frac{\partial h_t}{\partial h_{t-1}} \quad (5)$$

根据(3)式,对  $h_t$  求偏导(其  $w$  为权值矩阵),可得

$$\delta_{t-1} = \delta_{o,t} w_{oh} + \delta_{f,t} w_{fh} + \delta_{i,t} w_{ih} + \delta_{c,t} w_{ch} \quad (6)$$

(6)式为上一个时刻  $t-1$  反向传播的误差项,将其推广到一般情况,用  $m$  时刻代替  $t-1$  时刻,则在任意  $m$  时刻的 LSTM 的损失函数可表示为

$$\delta_m = \prod_m^{t-1} \delta_{o,m} w_{oh} + \delta_{f,m} w_{fh} + \delta_{i,m} w_{ih} + \delta_{c,m} w_{ch} \quad (7)$$

针对 LSTM 沿网络结构上一层反向传播的误差项,定义在  $l-1$  层的 LSTM 的损失函数为

$$\delta_t^{(l-1)} = \frac{\partial E}{\partial N_t^{(l-1)}}, \quad (8)$$

若此层 LSTM 的输入为  $x^{(l)} = \tanh^{(l-1)}(N_t^{(l-1)})$ ,其中  $\tanh$  表示双曲正切激活函数,同理对其求偏导可得

$$\delta_t^{(l-1)} = (\delta_{f,t} w_{fx} + \delta_{i,t} w_{ix} + \delta_{o,t} w_{ox} + \delta_{c,t} w_{cx}) \tanh^{(l-1)}(N_t^{(l-1)}) \quad (9)$$

3) 梯度下降 Adam 算法根据 LSTM 基本单元的误差项  $\delta_m, \delta_t^{(l-1)}$  来计算每个权值的梯度,从而自适应地调整模型权值的参数,完成一次模型参数的更新。

4) 不断完成上述的迭代,当预测结果维持在一定 RMSE 范围内时,神经网络模型训练完成。

### 3.4 大气湍流信道下的 LSTM-SCFlips 译码方法

为提高自由空间光通信中极化码 SC 译码最优翻转位的准确率,提出一种自由空间光通信下的 LSTM-SCFlips 译码方法。LSTM-SCFlips 译码方法包括两个阶段:构建并训练 LSTM 神经网络阶段与神经网络辅助译码阶段,3.1~3.3 节已经完成较优步长下的 LSTM 神经网络模型的构建与训练。因此,本节主要介绍的是神经网络辅助译码阶段,其译码执行流程如图 4 所示。

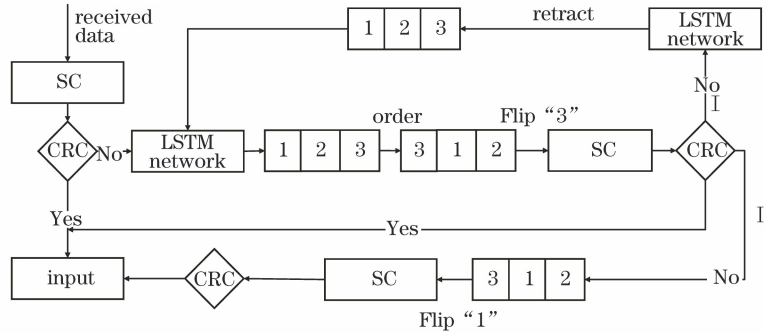


图 4 LSTM-SCFlips 译码方法执行流程图

Fig. 4 Execution flow chart of LSTM-SCFlips decoding method

1) 计算非冻结位的译码错误概率:使用 SC 译码器对接收到信息进行译码,如果译码成功,则直接输出译码结果,否则将使用 LSTM 网络计算每一个非冻结位的错误概率。其计算过程为:每个 LLR 序列经 one hot 预编码处理后被划分为若干子序列,再将子序列依次送入 LSTM 网络,经隐藏层后,将最终的长状态转换为一个向量,即信息位的错误概率,如{1,2,3}。

2) 翻转错误比特:根据错误概率的大小对信息序列进行排序,如{3,1,2},然后再对错误概率最高的位(“3”)进行比特翻转,若 SC 译码后通过 CRC 校验,则输出译码结果。

3) 错误翻转的判定:若步骤 2)中没有通过

CRC 校验,则将判定此次翻转是否为错误翻转。因此,需要将第一次的 LLR 序列再次输入神经网络中,若此次网络输出的比特错误概率最大值大于第一次神经网络输出所有值,则判定此次翻转为错误翻转,撤销上一次的比特翻转(I),并按照第二次比特错误概率顺序执行比特翻转;否则,上一次翻转被视为“正确”翻转进行多比特翻转(II)。

4) 多比特翻转:下一次尝试继续翻转下一个错误信息位(“1”),直至满足 CRC 校验或尝试次数达到最大翻转次数  $T$ 。

## 4 仿真与分析

为验证本文所提自由空间光通信下 LSTM-

SCFlips 译码方法的可行性,模拟不同弱湍流强度下的大气信道,开展不同译码方案、码长和码率的系统仿真。模拟参数如表 1 所示。

表 1 模拟参数

Table 1 Simulation parameters

Parameter	Value
Length of polar code	1024/2048
Code rate	0.25/0.5/0.75
Turbulence intensity	0.1/0.2/0.3
Number of CRC bits	8
Wavelength /nm	1550
Modulation	4-PPM
Transmission distance /km	2

针对不同湍流强度下的湍流信道会对通信系统传输码字造成不同程度的误码率影响,即湍流强度越大,造成的误码率越高,需要增加数据集的大小(训练步长)来训练神经网络模型,以应对恶劣的大气湍流环境,从而建立预测性能更好的神经网络模型。因此,大气湍流信道的特征用不同的对数光强起伏方差  $\sigma_0$  来体现,神经网络的数据集用训练步长来体现。本研究选用 (512, 1024) 的极化码,采集  $5 \times 10^6$  条信息序列样本,将 80% 的信息序列样本作为训练集,20% 的信息序列样本作为验证集,其中训练集分为 10 个训练步长,每个训练步长为  $4 \times 10^5$  个样本。在不同强度的弱湍流信道下,对模型的训练步长进行讨论与分析。

不同弱湍流强度下网络模型的均方根误差分布如图 5 所示,在不同弱湍流强度下,随着网络训练步长的增大,均方根误差越来越小,其网络模型的稳定性也越好,当网络训练步长足够大时,均方根误差几乎稳定不变,稳定性达到上限。在弱湍流强度为  $\sigma_0 = 0.2$  条件下,当训练步长数由 1 增加为 2 时,预




图 5 弱湍流信道下的均方根误差分布

Fig. 5 Root mean square error distribution in a weak turbulence channel

测均方根误差下降 5.45%,此时预测均方根误差下降幅度最大。当训练步长数 1 递增至 7 时,其预测均方根误差下降为 23.36%,且随着训练步长的增加,其预测均方根误差下降趋势变缓。尤其在训练步长数为 7~10 时,其预测均方根误差几乎稳定不变,预测训练模型的训练效果达到饱和。在湍流强度逐步增强的情况下,预测均方根误差尽管出现了小幅度上升,但随训练步长增加的变化趋势大致相同,这意味着可使用同一分析方法对不同湍流强度下的译码性能进行分析。

同时,由图 6 可得不同弱湍流强度下网络模型的训练时长分布,当弱湍流强度  $\sigma_0 = 0.2$  时,随着训练步长的增加,其时长逐渐上升,训练时长从 4.25 s 增至 5.15 s,即训练步长数从 1 增至 10,随着训练步长数的增加,虽然网络模型的准确度逐渐上升,但同时导致计算成本和时间成本增加。因此,由图 5 和图 6 可知,当不同湍流下的神经网络模型在训练步长为 6~10 之间时,其均方根误差变化缓慢,但其描述计算复杂度的训练时长仍显著上升,因此,应选取一个合适的训练步长,建立一个预测准确性较高同时满足低计算复杂度的神经网络预测模型。




图 6 弱湍流信道下的训练时长

Fig. 6 Training time in weak turbulence channel

为了综合考虑神经模型的预测准确性和训练成本,将网络训练成本的增加量百分比与 RMSE 的减小量百分比的比值作为衡量神经网络预测模型的性能指标,表达式为<sup>[23]</sup>

$$\epsilon'_i = \frac{t_{i'+1} - t'_i}{R_{MSE,i'} - R_{MSE,i'+1}} \cdot \frac{R_{MSE,i'}}{t'_i} \quad (10)$$

式中,  $i'$  为训练步长数,  $t$  为训练步长时间。由(10)式可以看出,当预测模型的均方根误差几乎稳定不变,而其训练时长显著增加时,性能指标  $\epsilon'_i$  会发生突变,当前的训练步长可视为较优步长。因此,神经网络预测模型的性能指标  $\epsilon'_i$  的物理意义为:通过分析神经网络预测模型的性能指标  $\epsilon'_i$  突变值,来寻找神经网络较

优的训练步长,从而建立最优的神经网络模型。

在不同弱湍流强度下,不同步长数的网络模型的性能指标如图 7 所示。在弱湍流强度  $\sigma_0 = 0.2$  的条件下,当训练步长数由 6 增加至 7 ( $i' = 6$ ) 时,网络模型的均方根误差由 0.08601 降低为 0.08431,训练时长由 4.75 s 增加至 4.82 s,网络模型的性能指标由 144 增加至 2446,则可视在此过程中,其均方根误差几乎稳定不变,而训练时长持续增长。从 (10) 式来看,性能指标  $\epsilon'_i$  分子有较大的差值,而  $\epsilon'_i$  的分母几乎为 0,故  $\epsilon'_i$  在训练步长为 7 时会发生突变。因此,把训练步长为 7 视为在弱湍流强度  $\sigma_0 = 0.2$  条件下网络模型的较优步长,同理可得,弱湍流强度  $\sigma_0 = 0.1$  和  $\sigma_0 = 0.3$  条件下网络模型的较优步长分别为 6 和 9。通过以上步骤即可完成不同湍流信道下神经网络模型的构建。

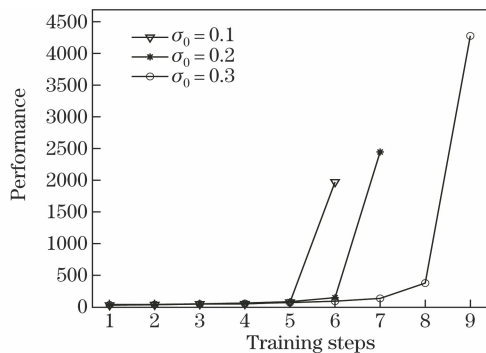


图 7 弱湍流信道下的 LSTM 网络性能

Fig. 7 Performance of LSTM network in weak turbulence channel

为研究 LSTM 神经网络对最优翻转位的识别性能,需要采用较优训练步长的神经网络预测模型对极化码最优翻转位进行预测。图 8 给出湍流强度为  $\sigma_0 = 0.2$  的大气信道下,不同方案正确识别最优翻转位的性能比较。

如图 8 所示,LSTM-SCFlips 译码方法的最优翻转位正确识别率明显优于 D-SCFlips 译码方法和传统的 SCFlips 译码方法。当翻转次数仅为 1 次时,LSTM-SCFlips 译码方法的正确识别率为 55%,文献 [14] 中 D-SCFlips 方法的正确识别率仅为 48%,传统的 SCFlips 译码方法的正确识别率仅为

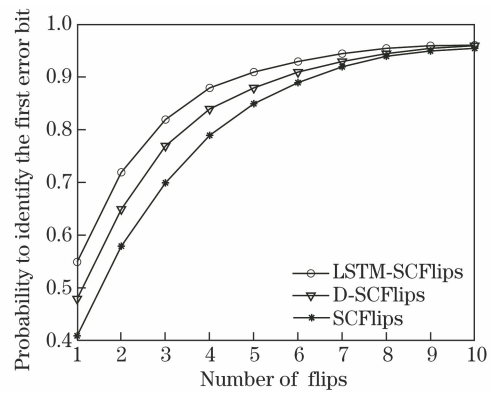


图 8 弱湍流信道下 ( $\sigma_0 = 0.2$ ) 最优翻转位的正确识别率

Fig. 8 Correct recognition rate of optimal flip position in weak turbulence channel ( $\sigma_0 = 0.2$ )

41%。当翻转次数为 5 次时,LSTM-SCFlips 译码方法的正确识别率为 91%,文献 [14] 中 D-SCFlips 方法的正确识别率仅为 88%,传统的 SCFlips 译码方法的正确识别率仅为 85%。随着翻转比特次数的增加,其正确识别率逐渐上升,当翻转次数足够大时,3 种译码方法的正确识别率都趋于一个极值,其最优翻转位的正确识别率几乎都接近 95%~96%。其原因是神经网络 LSTM 每次错误翻转,都会对错误翻转的特征进行监督学习,更新数据库,同时翻转的次数增加,会使译码成功概率累积。

为了对不同神经网络模型的预测效果作出评估,当大气湍流信道  $\sigma_0 = 0.2$  时,在不同的训练步长条件下,计算不同模型下的均方根误差,如表 2 所示。随着训练步长数的增加,不同模型下的均方根误差均逐渐下降,在训练步长达到较优步长数时,其均方根误差趋于稳定,预测效果较优。在训练步长为 5~7 之间,LSTM 模型、RNN 模型、SVM 模型的预测均方根误差分别下降 2.85%、1.78%、1.87%;在训练步长为 7~10 之间,LSTM 模型、RNN 模型、SVM 模型的预测均方根误差分别下降 1.58%、0.08%、0.03%。同时,相比于 RNN 模型和 SVM 模型,LSTM 模型在不同训练步长下的均方根误差均更小,在较优训练步长下,LSTM 模型的预测效果较优,拟合程度较好,对最优翻转位的预测效果较优。当训练步长数为 5 时,LSTM 模型的

表 2 弱湍流信道下 ( $\sigma_0 = 0.2$ ) 不同模型均方根误差对比

Table 2 Comparison of RMSE of different models under weak turbulence channel ( $\sigma_0 = 0.2$ )

Model	$i' = 5$	$i' = 6$	$i' = 7$	$i' = 8$	$i' = 9$	$i' = 10$
LSTM	0.0893	0.0861	0.0842	0.0841	0.841	0.0838
RNN	0.1263	0.1237	0.1218	0.1217	0.1215	0.1215
SVM	0.1151	0.1126	0.1108	0.1104	0.1105	0.1107



均方根误差较 RNN 和 SVM 模型分别下降 29.29% 和 22.41%；当训练步长为 7 时，LSTM 模型的均方根误差较 RNN 和 SVM 模型分别下降 30.87% 和 24.01%。因此，在不同的训练步长下，LSTM 神经网络模型较 RNN 模型、SVM 模型均可获得更佳的预测效果。

为了进一步验证本文所提自由空间光通信下的 LSTM-SCFlips 译码方法的性能，模拟湍流强度为  $\sigma_0=0.2$  下的大气信道，开展不同码长和码率的系统仿真。由图 9 可知：1) 在码长  $N=1024$ ，码率  $K=0.25$  时，LSTM-SCFlips 译码方法较 D-SCFlips 译码方法略有提升，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法较 D-SCFlips 译码方法约产生 0.3 dB 的编码增益。2) 在码长  $N=1024$ ，码率  $K=0.5$  时，LSTM-SCFlips 译码方法较 D-SCFlips 译码方法性能提升增强，且明显优于传统的 SCFlips 译码方法，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法较 D-SCFlips 译码方法约产生 0.8 dB 的编码增益，较 SCFlips 译码方法约产生 2.1 dB 的编码增益。3) 在码长  $N=2048$ ，码率  $K=0.5$  时，LSTM-SCFlips 译码方法明显优于 D-SCFlips 译码方法性能，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法较 D-SCFlips 译码方法约产生 0.4 dB 的编码增益。4) 在通信误码率为  $10^{-4}$  的条件下，当码长  $N=1024$ ，码率由 0.5 变为 0.25 时，LSTM-SCFlips 译码方法约产生 5.4 dB 的编码增益；当码率  $K=0.5$ ，码长由 1024 变为 2048 时，LSTM-SCFlips 译码方法约产生 1.2 dB 的编码增益。因此，随着码长的增加或者码率的降低，误码率性能都有所改善，其原因是随着码长的增加，极化码的极化程度越高，其子信

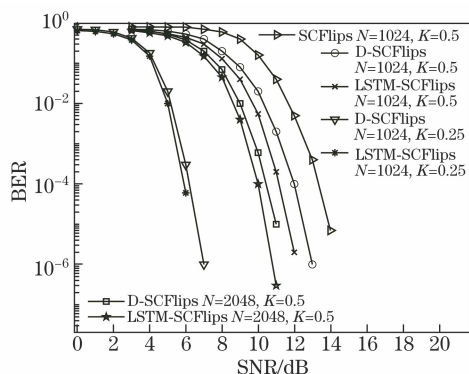


图 9 弱湍流信道下 ( $\sigma_0=0.2$ ) 的不同比特翻转译码方案性能对比图

Fig. 9 Performance comparison chart of different bit flipping decoding schemes under weak turbulence channel ( $\sigma_0=0.2$ )

道的巴斯参数越低，可靠性越高；另一方面，随着码率的降低，极化码构造中选取未完全极化的比例降低。综上，在不同码长和码率的情况下，LSTM-SCFlips 译码方案均能获得更大的编码增益。

为证明在不同弱湍流强度下此译码算法的可行性，在湍流强度 ( $\sigma_0^2 < 0.3$ ) 的大气弱湍流模型下进行仿真分析，从图 10 可知：1) 在弱湍流强度  $\sigma_0=0.1$  的情况下，低信噪比 ( $\text{SNR}, R_{\text{SN}} < 4$ ) 时，两种译码方案的误码率性能几乎相同，随着信噪比的增加，系统的误码率性能明显提高，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法的译码性能相比于 D-SCFlips 译码方法约产生 0.3 dB 的增益。2) 在弱湍流强度  $\sigma_0=0.2$  的情况下，相比于 D-SCFlips 译码方案，LSTM-SCFlips 译码方法的译码性能提升略微增强，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法的译码性能相比于 D-SCFlips 译码方法约产生 0.8 dB 的增益。3) 在弱湍流强度  $\sigma_0=0.3$  的情况下，LSTM-SCFlips 译码方法的译码性能提升较 D-SCFlips 译码方法明显增强，在误码率为  $10^{-4}$  时，LSTM-SCFlips 译码方法的译码性能相比于 D-SCFlips 译码方法约产生 1.2 dB 的增益。因此，在不同大气弱湍流强度下，LSTM-SCFlips 译码方法的译码性能相比于 D-SCFlips 译码方法均可获得更大的编码增益，且随着湍流强度的增强，其编码增益愈加明显，但其误码率性能逐渐下降，在湍流强度太大时，可以采用降低码率或者增加码长来提高编码增益。

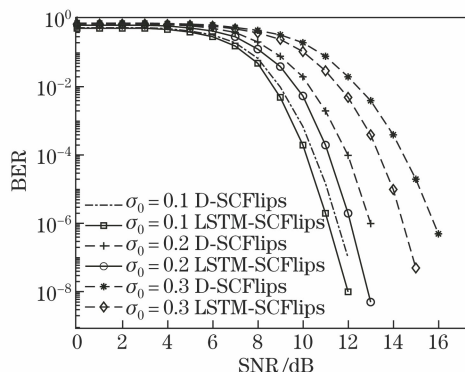


图 10 不同湍流强度下译码性能对比图

Fig. 10 Comparison of decoding performance under different turbulence intensities

为分析与比较不同比特翻转译码算法的译码复杂度，列出不同比特翻转译码算法中每帧的平均解码时长。由表 3 所示，LSTM-SCFlips 译码方法平均译码时长明显优于 D-SCFlips 译码方法，并接近



于传统的 SCFlips 译码方法,在信噪比为 1 dB 时, LSTM-SCFlips 译码方法的译码时长较 D-SCFlips 译码方法短 0.026 s,时长缩短量约占平均译码时长的 1/3,且较传统的 SCFlips 译码方法仅增加 0.004 s。随着信噪比的增加,不同极化码比特翻转译码方法的平均译码时长逐渐降低,且之间的差距逐渐缩小,当信噪比为 3 dB 时,传统的 SCFlips 译码方法较 LSTM-SCFlips 译码方法和 D-SCFlips 译

码方法分别仅缩短 0.002 s,0.0001 s,不同极化码比特翻转译码方法中每帧的平均解码时长几乎一致。其原因是随着信噪比的增加,其译码错误的概率降低,译码结果直接通过 CRC 校验输出,可以避免不同方法下比特错误位的识别与翻转。由于译码的复杂度与译码的平均时长呈正相关的关系,故 LSTM-SCFlips 译码方法较 D-SCFlips 译码方法有更低的译码复杂度。

表 3 不同极化码比特翻转译码方法中每帧的平均解码时长

Table 3 Average decoding time of each frame in different polarization code bit flipping decoding methods unit: s

Method	$R_{SN}=1$ dB	$R_{SN}=1.5$ dB	$R_{SN}=2$ dB	$R_{SN}=2.5$ dB	$R_{SN}=3$ dB
D-SCFlips	0.078	0.053	0.040	0.037	0.032
LSTM-SCFlips	0.052	0.046	0.038	0.035	0.031
SCFlips	0.048	0.039	0.033	0.031	0.029

## 5 结 论

针对大气湍流引起的自由空间光通信系统性能衰落问题,提出了自由空间光通信下的 LSTM-SCFlips 译码方法,通过构建较优训练步长下的 LSTM 神经网络,实现对极化码最优翻转位的精准定位,可以进行极化码的单比特或多比特翻转译码。针对不同的大气弱湍流强度进行仿真分析,在湍流强度为  $\sigma_0=0.2$ 、误码率为  $10^{-4}$  时,较 D-SCFlips 译码方法, LSTM-SCFlips 译码方法的最优翻转位正确识别率提高 7%,且有 0.8 dB 的编码增益;当减小湍流强度( $\sigma_0=0.1$ )和增大湍流强度( $\sigma_0=0.3$ )时,编码增益分别为 0.3 dB、1.2 dB;当增加码长( $N=2048, k=0.5$ )和降低码率( $N=1024, k=0.25$ )时编码增益分别为 1.2 dB、5.4 dB。同时,在信噪比为 1 dB 时, LSTM-SCFlips 译码方法的译码时长较 D-SCFlips 译码方法短 0.026 s,时长缩短量约占平均译码时长的 1/3,且较传统的 SCFlips 译码算法仅增加 0.004 s。仿真结果表明,在同一大气湍流下, LSTM-SCFlips 译码方法在合理分配计算资源的前提下,获取了更好的译码性能,为译码方法在实际应用中提供了保障。

## 参 考 文 献

[1] Zhang J Q, Zhai Y W, Fu S Y, et al. Propagation properties of radially-polarized vector beams under a turbulent atmosphere[J]. Acta Optica Sinica, 2020, 40(11): 1101001.  
张建强, 翟焱望, 付时尧, 等. 径向偏振矢量光束在大气湍流下的传输分析[J]. 光学学报, 2020, 40(11): 1101001.

[2] Li X Y, Zhang P, Tong S F. Bit error rate performance for modulating retro-reflector free space optical communication system based on adaptive threshold under atmospheric turbulence[J]. Chinese Journal of Lasers, 2018, 45(6): 0606001.  
李晓燕, 张鹏, 佟首峰. 大气湍流影响下基于自适应判决门限的逆向调制自由空间光通信系统误码率性能分析[J]. 中国激光, 2018, 45(6): 0606001.

[3] Wang H Q, Li Y T, Cao M H, et al. Layered optical spatial modulation in turbulent channels [J]. Acta Optica Sinica, 2019, 39(7): 0706001.  
王惠琴, 李亚婷, 曹明华, 等. 湍流信道中的分层光空间调制[J]. 光学学报, 2019, 39(7): 0706001.

[4] Liu M W, Li Y C. Propagation of OFDM-OAM optical signal in atmospheric turbulence [J]. Acta Optica Sinica, 2019, 39(7): 0706002.  
刘旻雯, 李迎春. OFDM-OAM 光信号在大气湍流中的传输[J]. 光学学报, 2019, 39(7): 0706002.

[5] Cao M H, Wu X, Wang H Q, et al. Performance of faster-than-nyquist optical communication system under Gamma-Gamma atmospheric turbulence [J]. Chinese Journal of Lasers, 2020, 47(9): 0906003.  
曹明华, 武鑫, 王惠琴, 等. Gamma-Gamma 大气湍流下超奈奎斯特光通信系统性能[J]. 中国激光, 2020, 47(9): 0906003.

[6] Fang J F, Bi M H, Xiao S L, et al. Polar-coded MIMO FSO communication system over Gamma-Gamma turbulence channel with spatially correlated fading [J]. IEEE/OSA Journal of Optical Communications and Networking, 2018, 10(11): 915-923.

[7] 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.
- [8] Tal I, Vardy A. List decoding of polar codes [J]. *IEEE Transactions on Information Theory*, 2015, 61(5): 2213-2226.
- [9] Niu K, Chen K. CRC-aided decoding of polar codes [J]. *IEEE Communications Letters*, 2012, 16(10): 1668-1671.
- [10] Afisiadis O, Balatsoukas-Stimming A, Burg A. A low-complexity improved successive cancellation decoder for polar codes [C] // 2014 48th Asilomar Conference on Signals, Systems and Computers, November 2-5, 2014, Pacific Grove, CA, USA. New York: IEEE Press, 2014: 2116-2120.
- [11] Zhang X T, Liu Y Z, Chen S P. BER evaluation based SCFlip algorithm for polar codes decoding [J]. *IEEE Access*, 2019, 8: 3042-3054.
- [12] Ercan F, Condo C, Gross W J. Improved bit-flipping algorithm for successive cancellation decoding of polar codes [J]. *IEEE Transactions on Communications*, 2019, 67(1): 61-72.
- [13] Zhang Z Y, Qin K J, Zhang L, et al. Progressive bit-flipping decoding of polar codes: a critical-set based tree search approach [J]. *IEEE Access*, 2018, 6: 57738-57750.
- [14] Ardakani M H, Hanif M, Ardakani M, et al. Fast successive-cancellation-based decoders of polar codes [J]. *IEEE Transactions on Communications*, 2019, 67(7): 4562-4574.
- [15] Wang X M, Wang T, Li J, et al. Improved multiple bit-flipping fast-SSC decoding of polar codes [J]. *IEEE Access*, 2020, 8: 27851-27860.
- [16] Chandesaris L, Savin V, Declercq D. Dynamic-SCFlip decoding of polar codes [J]. *IEEE Transactions on Communications*, 2018, 66(6): 2333-2345.
- [17] Cao Y, Zhang X, Peng X F, et al. Cascade scheme based on multiple-input multiple-output in spatial optical communication [J]. *Acta Optica Sinica*, 2018, 38(1): 0106003.
- 曹阳, 张勋, 彭小峰, 等. 空间光通信中基于多输入多输出的级联码方案研究 [J]. *光学学报*, 2018, 38(1): 0106003.
- [18] Cao Y, Li Y, Li X H. Research on construction method of polarization code in wireless optical communication [J]. *Acta Optica Sinica*, 2020, 40(21): 2106003.
- 曹阳, 李岳, 李小红. 无线光通信中极化码构造方法研究 [J]. *光学学报*, 2020, 40(21): 2106003.
- [19] Sun R, Huang Q H, Lu W M, et al. Video-based person re-identification via combined multi-level deep feature representation and ordered weighted distance fusion [J]. *Acta Optica Sinica*, 2019, 39(9): 0915006.
- 孙锐, 黄启恒, 陆伟明, 等. 联合多级深度特征表示和有序加权距离融合的视频行人再识别方法 [J]. *光学学报*, 2019, 39(9): 0915006.
- [20] Hua X, Wang X Q, Wang D, et al. Multi-objective detection of traffic scenes based on improved SSD [J]. *Acta Optica Sinica*, 2018, 38(12): 1215003.
- 华夏, 王新晴, 王东, 等. 基于改进 SSD 的交通大场景多目标检测 [J]. *光学学报*, 2018, 38(12): 1215003.
- [21] Cornia M, Baraldi L, Serra G, et al. Predicting human eye fixations via an LSTM-based saliency attentive model [J]. *IEEE Transactions on Image Processing*, 2018, 27(10): 5142-5154.
- [22] Khan A H, Cao X W, Li S, et al. BAS-ADAM: an ADAM based approach to improve the performance of beetle antennae search optimizer [J]. *IEEE/CAA Journal of Automatica Sinica*, 2020, 7(2): 461-471.
- [23] Li X L, Ma L F, Zhao X Y, et al. Multi-time scale electric heating load forecasting based on long short-term memory network [J]. *Journal of Electric Power System and Automation*, 2021, 33(4): 71-75.
- 李香龙, 马龙飞, 赵向阳, 等. 基于 LSTM 网络的时间多尺度电采暖负荷预测 [J]. *电力系统及其自动化学报*, 2021, 33(4): 71-75.