



研究与开发

基于深度学习的6G可见光通信多址接入解调方法

邵鑫玉, 姚瑶, 王亮

(江苏商贸职业学院, 江苏 南通 226011)

摘 要: 发光二极管的调制带宽较窄, 导致可见光通信系统的容量受限, 通过多址接入技术可提高频谱效率和终端用户数量。然而, 可见光通信系统多址接入的用户间存在较强的干扰。针对此问题, 利用可见光通信系统接收信号间的相关性, 提出一种基于深度神经网络的多址接入多用户检测与信号还原方法。基于稀疏码多址接入给出了可见光通信系统的发送端模型与接收端模型, 采用时域卷积网络学习长序列的信号间时域相关性, 再传入密集层学习信号序列的空间域映射关系, 最终在可见光通信系统的接收端还原所有用户的信号。实验结果表明, 该方法有效提高了可见光通信系统多址接入的通信性能, 在不同通信距离、信噪比、发送速率下均能发挥积极作用。

关键词: 可见光通信系统; 多址接入; 解调技术; 短距离无线通信; 卷积神经网络

中图分类号: TN929.1

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024203

Deep learning based demodulation method for multiple access of visible light communication in 6G

SHAO Xinyu, YAO Yao, WANG Liang

Jiangsu Vocational College of Business, Nantong 226011, China

Abstract: Because the modulation bandwidth of the light emitting diode is narrow, the capacity of the visible light communication system is limited, the spectral efficiency and number of endpoint user can be improved by the multiple access technique. However, there is strong inter-user interference among multiple access users in the visible light communication system. In view of this problem, by utilizing the correlation among received signals of the visible communication system, a multiple user detection and signal recovery method of multiple users for multiple access based on deep neural network was proposed. The transmitter model and the receiver model of the visible light communication system were presented based on sparse code multiple access, the temporal convolutional network was adopted to learn the inter-signal temporal correlation of the long sequence, the output sequence was delivered to dense layer to learn the spatial mapping relationship of the signal sequence, in the end, signals of all users were recovered in the receiver of the visible light communication system. Experimental results indicate that the proposed signal recovery method improves the communication performance of the visible light communication system multiple access effectively, and the proposed method can play an active role under the condition of different communication distances,



different signal noise ratios and transmit speeds.

Key words: visible light communication system, multiple access, demodulation technology, short range wireless communication, convolutional neural network

0 引言

随着 6G 时代的到来, 可见光通信 (visible light communication, VLC) 作为其中一项重要的无线通信技术^[1], 在室内环境^[2]和 underwater 环境^[3]均具有广泛的应用前景。然而, 发光二极管 (light emitting diode, LED) 的调制带宽较窄, 导致 VLC 的系统容量有限。

多址接入技术^[4]是提高频谱效率和终端用户数量的一个有效方式, 贾科军等^[5]与童育龙等^[6]通过非正交多址接入 (non-orthogonal multiple access, NOMA) 大幅提高了 VLC 的系统容量。NOMA 主要包含串行干扰删除和功率复用两种方式, 其中功率复用在可见光通信系统中的应用最为广泛^[7]。

目前针对 VLC 多址接入的研究主要集中于提高系统容量上, 文献[8]设计 NOMA 间不均等的子载波功率分配和基于差异化请求速率的 NOMA 组内功率分配算法, 通过混合功率复用机制来提高系统容量。文献[9]提出了一种适用于室内可见光通信的混合调制方案, 该方案通过将频谱高效的多维无载波幅度相位调制与功率高效的多脉冲位置调制相结合, 利用多脉冲位置调制的不同脉冲时隙信息控制幅度相位调制信号的传输。这两种方法通过结合多个分配机制来缓解多址接入的用户间干扰, 此类方法虽然利用多址接入技术提高了系统容量, 但混合分配方式在系统的发送端和接收端都需要增加相应的处理模块, 应用难度较大。

为了缓解多址接入用户间干扰造成的信号非线性失真问题, 本文提出一种深度神经网络 TCDense 模型, 利用该模型降低可见光通信系统

多址接入的误码率。TCDense 模型使用时域卷积网络 (temporal convolutional network, TCN)^[10]层学习稀疏码多址信号在时间域的相关性, 密集层学习信号序列的空间域映射关系, 对多址接入的非线性失真进行精准预测, 利用 TCDense 模型的非线性拟合能力对多用户信号进行还原。相较于其他多址接入的多用户检测方法, 本文方法具有以下 3 点优势: ①可兼容不同的多址接入方式, 且仅需在接收端增加训练的 TCDense 模型即可对多用户信号进行还原; ②可与不同的信道均衡器合作, 进一步提升 VLC 系统的通信性能; ③能有效缓解多址接入信号在传输过程中的非线性失真, 进而降低系统的误码率。

1 可见光通信系统多址接入模型

1.1 多址接入的发送端模型

稀疏码多址 (sparse code multiple access, SCMA) 技术^[11]在频域将用户数据扩散到所有资源块 (或子载波) 上, 可大幅降低每个资源块上叠加的用户数。本文将 SCMA 引入可见光通信系统, 建立 VLC 的多址接入模型。SCMA 首先对每个比特进行编码, 编码比特根据其码本映射成 SCMA 码字, SCMA 码字具有稀疏性, 可扩展到多个资源块上。SCMA 的最大优点是非正交叠加的码字个数可以数倍于资源块数量, 与正交频分多址 (orthogonal frequency division multiple access, OFDMA) 技术^[12]相比, SCMA 可在同等资源量下服务更多的用户, 能大幅提升 VLC 系统的总容量。然而, 用户数过多会导致用户间干扰加重。为保证 SCMA 的用户数低于阈值, 首先将所有用户分组, 用户组之间采用功率复用方式, 即为各用户组分配不同的功率级。用户组内采用

SCMA 方式,即采用稀疏码多址技术将每个用户的数据转换成码字。可见光通信系统多址接入的发送端模块如图1所示。




图1 可见光通信系统多址接入的发送端模块

假设两个用户组采用功率复用,其中强功率组为 U_1 ,弱功率组为 U_2 。同一用户组采用稀疏码多址技术传输多路信号,发送端将比特流映射成多维复数域码字序列。将 U_1 与 U_2 的码字 (code word) 序列分别记为 $CW_1=\{CW_1^1, CW_1^2, \dots, CW_1^N\}$ 和 $CW_2=\{CW_2^1, CW_2^2, \dots, CW_2^N\}$ 。对组内用户进行编码域复用,此过程可表示为:

$$\overline{CW}_q = \left[\sum_{i=1}^Q CW_i^q, \sum_{i=Q+1}^{Q \times 2} CW_i^q, \dots, \sum_{i=N-Q}^Q CW_i^q \right] \quad (1)$$

其中, N 为该用户组发送的码字数量, q 为用户组的索引, Q 为该用户组的用户数量。

式(1)将用户组 N 个码字的序列复用成 (N/Q) 个元素的序列 $\overline{CW}_q$,对 $\overline{CW}_q$ 进行256点

的离散傅里叶逆变换 (inverse discrete Fourier transform, IDFT) 来获得时间域的符号序列。为每个符号添加循环前缀来解决符号间干扰,每一帧添加前导符号来传递帧同步信息。

经上述过程处理获得的时间域符号序列记为 S_q 。为每个用户组分配不同的功率,不同用户组通过功率复用来提高带宽。功率复用的信号序列可表示为:

$$T = \sum_{k=1}^K \sqrt{P_k} S_k \quad (2)$$

其中, P_k 表示第 k 个用户组分配的功率, S_k 表示第 k 个用户组的符号序列, $K=2$ 为用户组的总数量。

基带离散信号序列 T 经上变频器转换成上行频率,再通过直流偏置将信号转换成非负值。LED驱动电路对信号进行强度调制 (intensity modulation, IM),LED发射可见光信号,将可见光信道带宽分成 M 个子载波,每个用户组的信号扩散在 M 个子载波上传输。

1.2 多址接入的接收端模型

可见光通信系统多址接入的接收端模块如图2所示。光电二极管 (photodiode, PD) 检测到SCMA信号,产生的电信号传入下变频器和帧同步模块进行处理。

PD产生的电信号可表示为:

$$Y = \gamma P_t \varepsilon H \text{diag}(T) + \sigma \quad (3)$$

其中, γ 为PD响应, ε 为LED的强度调制指数, P_t 为发射光功率, H 为可见光信道响应, σ 为加性高斯白噪声。

SCMA信号进行信道均衡化处理,输出结果可表示为:

$$Y' = \overline{H}^{-1} Y = \gamma P_t \varepsilon \overline{H}^{-1} H \text{diag}(\sqrt{P_1} S_1), \dots, \gamma P_t \varepsilon \overline{H}^{-1} H \text{diag}(\sqrt{P_K} S_K) + \overline{H}^{-1} \sigma \quad (4)$$

其中,第一项为第一个用户组的符号序列,第 k 项为第 k 个用户组的符号序列,最后一项是噪声 σ




图2 可见光通信系统多址接入的接收端模块

的均衡化结果。

根据式(4), 弱功率用户组通过将强功率用户组和噪声视为干扰可直接分解出弱功率用户组的信号, 然后用总功率减去弱功率用户组的信号, 重复此过程可逐步分解出每个功率级的信号, 即每个用户组的信号。最终, 将每个用户组的信号传入基于 TCDense 模型的多用户检测模块, 检测用户组内的用户, 并对每个用户的信号进行还原。

2 基于 TCDense 模型的多用户检测模块

多用户检测流程如图3所示。首先采集 VLC 通信系统的实际传输数据集, 然后对数据集进行预处理, 最终在训练集上训练 TCDense 网络。TCDense 模型由时域卷积网络、密集层和输出层构成。由于每个用户组在 M 个子载波上传输, 因此 TCDense 模型输入层的节点数量为 M , TCDense 模型输出层节点数量等于每个用户组的用户数量 Q 。所有用户组使用相同的 TCN 模型来检测用户及还原信号。





图3 多用户检测流程

2.1 数据预处理


输入层为 M 个子载波的符号序列, 对所有子载波的符号序列做以下预处理。

步骤1 图4(a)中, 第 m 个子载波输出一个长度为 J 的符号序列 s_m , 通过一个长度为 W 的滑动窗口将每个符号序列分成 J/W 个子序列, 滑动窗口的移动步长设为1。

步骤2 图4(b)中, 通过移动滑动窗口将所有子载波的比特流转换成若干个二维张量。



(a) 步骤1示意图



(b) 步骤2示意图

图4 数据预处理的示意图

2.2 TCDense 模型的 TCN 层设计

TCN、循环神经网络 (recurrent neural network, RNN)^[13]与长短期记忆 (long short term

memory, LSTM) 网络^[14]均为经典的序列处理模型, 与RNN类的序列模型相比, TCN具有两点优势:

- TCN可通过层数、扩展因子与卷积核大小来调节感受野大小, TCN通过扩张卷积可获得比RNN与LSTM更大的感受野, 具有处理更长序列的能力;
- TCN的梯度不在时间方向, 而是在深度方向上, 因此当输入序列长度较长时, TCN的梯度更稳定。由于可见光通信系统的符号序列属于长序列, 因此TCDense模型采用TCN作为序列模型来提取符号序列的前后相关性。

TCN的网络结构如图5所示。TCN包含两个扩展因果卷积模块和一个可选的 1×1 卷积层, 扩展因果卷积块包含一个扩展因果卷积层、一个正则层、一个激活层和一个Dropout层。当输入数据与输出数据的维度不等时, 使用 1×1 卷积层可解决维度不等的问题。由于本文TCN层的输入数据与输出数据均为长度相等的一维序列, 因此TCDense模型取消 1×1 卷积层。




图5 TCN的网络结构

TCN层的计算过程（扩展因子=1,2,4, 卷积核大小=3）如图6所示, 描述了输入序列在TCN内的计算过程, 第1、第2与第3个卷积层的扩展率 d 分别为1、2与4。在第一个扩展因果卷积层, 3个连续的输入元素与 3×3 卷积核进行扩展率为1的卷积运算, 运算结果作为第一个隐藏层。第一个隐藏层与 3×3 卷积核做扩展率为2的卷积运算, 运算结果作为第二个隐藏层。第二个隐藏层与 3×3 卷积核进行扩展率为4的卷积运算, 运算结果作为输出层。




图6 TCN层的计算过程(扩展因子=1,2,4, 卷积核大小=3)

2.3 TCDense模型的密集层与输出层设计

神经网络优化示意图如图7所示。TCN输出层的所有节点与第一个密集层之间建立完全连接, 从而提取全局有用信息。密集层层数、每层节点数量与连接权重为待学习的网络参数。密集层为非线性层, 输出层为线性层, 输出层节点数量与用户数量相等。

每个密集层由一个完全连接运算、一个batch正则运算和一个激活运算构成。密集层第 p 个神经元的完全连接运算可表示为:

$$dl_p = \sum_{i=1}^F w_i x_i + b \quad (5)$$

其中, F 为该神经元的连接数量, w_i 为第 i 个连接权重, b 为连接偏置。




图7 神经网络优化示意图

密集层第 p 个神经元的输出可表示为:

$$\text{dout}_p = \text{ReLU}\left(\text{BN}\left(dl_p\right)\right) \quad (6)$$

其中, $\text{BN}()$ 为 batch 正则运算, $\text{ReLU}()$ 为 ReLU 激活函数。

假设一个密集层的神经元数量为 P , 那么在第 g 次正向传播时该密集层的输出可表示为下式:

$$DL_g = \text{ReLU}\left(\text{BN}\left(H_g \times W_g + b_g\right)\right) \quad (7)$$

其中, H_g 为第 g 次正向传播前一层的输出向量, W_g 为前一层的权重矩阵, b_g 为前一层输出连接的偏置。

2.4 TCDense 模型的损失函数与网络训练

使用均方误差 (mean square error, MSE) 作为损失函数, 计算式如下:

$$L_{\text{MSE}} = \frac{1}{B} \sum_{i=1}^B \left[\left(y'_{i,1} - y_{i,1} \right)^2 + \left(y'_{i,2} - y_{i,2} \right)^2 + \cdots + \left(y'_{i,Q} - y_{i,Q} \right)^2 \right] \quad (8)$$

其中, B 为 batch 的大小, y'_i 为第 i 个样本的网络输出向量, y_i 为第 i 个样本的真实向量, Q 为输出层的节点数量。

使用 Adam 优化器优化 TCDense 模型, 图 7 中灰色阴影描述了神经网络在训练阶段的参数优化过程。神经网络在正向传播时计算当前 epoch

的损失, 将损失从输出层向输入层反向传播, 以最小化损失为目标来更新每个神经元的权重和偏置。

3 实验建立和结果

3.1 实验建立

为了评估所提 TCDense 模型的多用户检测及信号还原性能, 基于图 1 建立发送端模型。发送端使用 I/Q 调制作为上变频器, 将信号转换成上行频率, 离散傅里叶逆变换的点数为 256, 循环前缀为 8 位。使用泰克任意波形生成器作为信号发生器, 对电信号进行 20 dB 增益放大, 直流偏置电压为 3 V。LED 通过强度调制将电信号转换成可见光信号, LED 的线性工作区为 0.5 ~ 4 V, 3 dB 带宽为 40 MHz。

基于图 2 建立接收端模型。采用透镜将可见光集中到雪崩光电探测器 (avalanche photodiode detector, APD) 上, APD 的参数如下: 探测区域为 1 mm, 响应速度为 1 GHz (通常用截止频率描述), 最大转换增益为 2.65×10^9 V/W, 探测波长为 200 ~ 1 000 nm。使用数字示波器起到下变频器、帧同步及功率解复用的功能, 输出所有子载波的稀疏码信号。将稀疏码信号传入 TCDense 模型检测其中的所有用户, 并还原各用户的数据。

3.2 神经网络训练

将用户分成两个用户组, 分别为 U_1 与 U_2 , 用户组之间为功率复用, U_1 分配强功率, U_2 分配弱功率, 每个用户组模拟 6 个数据流 (用户) 扩散在 4 个资源块 (子载波) 上的情况, 即 150% 的子载波过载。强功率组和弱功率组分别独立完成 16 次传输, 每个用户组总共采集了 96 个用户扩散在 64 个子载波上的数据流。

使用 MATLAB 的随机函数生成所有用户的发送数据集, 每个用户发送 500 个随机数。将发送速率固定为 140 Mbit/s, 可见光通信距离固定为 160 cm, 发送电信号的峰峰电压固定为 3 V。

实验采集的训练集、验证集和测试集符号数量分别为76 800、9 600和9 600，其中强功率组与弱功率组的符号数量相等。TCN层的输入节点与输出节点数量等于每个用户组的子载波数量4，TCN的Dropout率为0.1，TCN层的卷积核数量为64。TCDense模型输出层的节点数量等于每个用户组的用户数量6。使用Adam优化器优化TCDense模型，神经网络的batch大小为128，Epoch数量为200，初始学习率为 10^{-3} ，下降因子为 10^{-1} 。TCDense模型密集层的激活函数为ReLU函数，数据预处理的滑动窗口长度为128。

将TCDense模型在总训练集和总验证集上分别进行训练和验证，TCDense模型损失的变化如图8所示。可看出，当epoch<30时，训练损失和验证损失均快速下降，然后训练损失随着epoch数量增加而缓慢降低，当epoch>100时，TCDense模型基本达到收敛。经训练，TCDense模型的密集层层数为4，密集层的节点数量分别为256、256、128、128。




图8 TCDense模型损失的变化

3.3 可见光通信性能实验

为了验证所提方案的性能，选取串行干扰消除 (successive interference cancellation, SIC)^[15]和深度神经网络 (deep neural network, DNN)^[16]方案作比较，且SIC和DNN方案采用本文功率复用和稀疏码复用的混合多址接入方式。串行干扰

消除接收器使用消息传递方法 (message passing algorithm, MPA)^[17]对每个用户组进行多用户检测。SIC^[15]是采用逐级消除干扰策略的多用户检测技术，按信号功率从高至低逐一判决每个用户的信号，再将已判决用户信号消除，直至消除所有多址干扰为止。DNN^[16]建立一个自编码器来生成优化的SCMA码字，并对发送比特流进行重建，通过优化码书质量提高了SCMA解调性能。

首先，测试不同信噪比条件下多址接入的平均误码率结果。将发送速率固定为140 Mbit/s，可见光通信距离固定为160 cm，调节发送电信号的峰峰电压来观察平均误码率的变化情况，不同信噪比条件下的平均误码率结果如图9所示。可看出，在不同信噪比（峰峰电压）条件下，SIC强功率组的平均误码率均低于SIC弱功率组，但强、弱功率组的误码率均较高。这是因为SIC虽然能消除强信号的互相干扰，但误差传播问题致使弱信号间干扰依然较大，导致误码率较高。在电压从0.5 V提高到4.0 V的过程中，DNN的误码率逐渐降低，这是因为信噪比越高，信号失真占比越低，神经网络的估计准确性越高。但所提TCDense模型的下降幅度最大，这是因为TCDense模型使用TCN层学习稀疏码多址信号在时间域的相关性，密集层学习信号序列的空间域映射关系，对多址接入用户间干扰造成的非线性失真进行了精准估计，对非线性失真信号的还原能力更强。而DNN只能捕获功率域和编码域的映射关系，因此对非线性失真信号的还原能力弱于TCDense模型。

其次，测试不同通信距离下多址接入的平均误码率结果。将峰峰电压固定为3 V，发送速率固定为140 Mbit/s，调节可见光通信距离来观察平均误码率的变化情况，不同通信距离下的平均误码率结果如图10所示。可看出，在所有通信距离 d 下SIC的平均误码率均最高，DNN与TCDense模型的误码率较低。而且TCDense模型




图9 不同信噪比条件下的平均误码率结果

的强功率组和弱功率组平均误码率较接近, 可知 TCDense 模型对非线性失真信号的还原能力强于 DNN, 即使弱功率组也达到了较低的误码率。




图10 不同通信距离下的平均误码率结果

最后, 测试不同发送速率下多址接入的平均误码率结果。将峰峰电压固定为 3 V, 可见光通信距离固定为 160 cm, 调节发送信号的速率来观察平均误码率的变化情况, 不同发送速率下的平均误码率结果如图 11 所示。可看出, 在不同速率下 SIC 的平均误码率最高, DNN 与 TCDense 模型的误码率较低。当数据速率高于 120 Mbit/s 时, TCDense 模型的平均误码率最低, 且受速率影响较小。




图11 不同发送速率下的平均误码率结果

4 结束语

多址接入是扩大可见光通信系统吞吐量的有效方案, 但多址接入的用户间存在较强干扰, 导致可见光通信系统性能下降。所提模型 TCDense 模型使用 TCN 层学习稀疏码多址信号在时间域的相关性, 密集层学习信号序列的空间域映射关系, 对多址接入用户间干扰造成的非线性失真进行了精准估计, 对非线性失真信号的还原能力更强。虽然本文讨论了在功率域和编码域的混合复用情况, 但该模型也可简单移植到其他多址接入系统中, 而且可与其他信道均衡化技术合作来提高可见光通信系统多址接入的通信性能。


由于神经网络在场景变化时需要重新训练, 所提方法目前仅适用于静态场景。未来将研究基于强化学习的环境感应机制, 使所提方法可感知和适应场景的变化, 从而进一步扩展本方法的可用范围。

参考文献:


- [1] MAPUNDA G A, RAMOGOMANA R, MARATA L, et al. Indoor visible light communication: a tutorial and survey[J]. Wireless Communications and Mobile Computing, 2020, 10 (2): 1-46.
- [2] 左婷, 王法松, 张建, 等. 室内可见光通信系统中基于压缩感知的空移键控信号检测方法[J]. 电子学报, 2022, 50(1): 36-44.

- ZUO T, WANG F S, ZHANG J, et al. Space shift keying signal detection approach based on compressed sensing in indoor VLC system[J]. *Acta Electronica Sinica*, 2022, 50(1): 36-44.
- [3] 张昊宇, 姚力, 陈超旭, 等. 基于BO-BiGRU的后均衡器在水下高速可见光通信系统中的应用[J]. *电信科学*, 2023, 39(5): 11-19.
- ZHANG H Y, YAO L, CHEN C X, et al. Application of BO-BiGRU based post equalizer in high-speed underwater visible light communication system[J]. *Telecommunications Science*, 2023, 39(5): 11-19.
- [4] 郭晓旭, 徐兆斌, 徐可笛, 等. 大规模星座组网通信的多址接入方式优化[J]. *西北工业大学学报*, 2023, 41(4): 644-653.
- GUO X Y, XU Z B, XU K D, et al. Optimization of multiple access mode for large-scale constellation networking communication[J]. *Journal of Northwestern Polytechnical University*, 2023, 41(4): 644-653.
- [5] 贾科军, 郝莉, 白利军, 等. 基于非正交多址接入的室内可见光通信系统[J]. *光学学报*, 2017, 37(8): 70-80.
- JIA K J, HAO L, BAI L J, et al. Indoor visible light communication system based on non-orthogonal multiple access[J]. *Acta Optica Sinica*, 2017, 37(8): 70-80.
- [6] 童育龙, 张峰, 沈波, 等. 非正交多址可见光通信系统SAMP信道估计[J]. *探测与控制学报*, 2023, 45(2): 79-86.
- TONG Y L, ZHANG F, SHEN B, et al. SAMP channel estimation method of non-orthogonal multiple access visible light communication system[J]. *Journal of Detection & Control*, 2023, 45(2): 79-86.
- [7] LIN B, TANG X, GHASSEMLOOY Z, et al. A NOMA scheme for visible light communications with single carrier transmission and frequency-domain successive interference cancellation[J]. *Optik*, 2019, 183(3): 445-450.
- [8] 刘焕淋, 陈科, 杨健, 等. 模糊逻辑决策室内VLC多址接入与功率分配方案[J]. *北京邮电大学学报*, 2023, 46(6): 61-65.
- LIU H L, CHEN K, YANG J, et al. Fuzzy logic decision multiple access and power allocation scheme for indoor visible light communication[J]. *Journal of Beijing University of Posts and Telecommunications*, 2023, 46(6): 61-65.
- [9] 旭东, 刘莹, 吴楠, 等. 用于VLC的混合多维无载波幅度相位-多脉冲位置调制方案[J]. *中国激光*, 2020, 47(6): 06060041-06060053.
- XU D, LIU Y, WU N, et al. Hybrid multi-dimensional CAP-MPPM modulation scheme for VLC systems[J]. *Chinese Journal of Lasers*, 2020, 47(6): 06060041-06060053.
- [10] 杨瑞朋, 屈丹, 朱少卫, 等. 基于改进时间卷积网络的日志序列异常检测[J]. *计算机工程*, 2020, 46(8): 50-57.
- YANG R P, QU D, ZHU S W, et al. Anomaly detection for log sequence based on improved temporal convolutional network[J]. *Computer Engineering*, 2020, 46(8): 50-57.
- [11] 赵耿, 马艳艳, 马英杰. 基于混沌序列的SCMA码本设计及系统性能分析[J]. *通信学报*, 2019, 40(2): 137-144.
- ZHAO G, MA Y Y, MA Y J. Design of SCMA codebook based on chaotic signal and system performance analysis[J]. *Journal on Communications*, 2019, 40(2): 137-144.
- [12] 李君, 吴明敏, 王秀敏, 等. OFDMA系统资源优化综述[J]. *中国计量学院学报*, 2014, 25(4): 451-458.
- LI J, WU M M, WANG X M, et al. Review of resource optimization in OFDMA systems[J]. *Journal of China Jiliang University*, 2014, 25(4): 451-458.
- [13] 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(2): 1-6.
- YANG L, WU Y X, WANG J L, et al. Research on recurrent neural network[J]. *Journal of Computer Applications*, 2018, 38(2): 1-6.
- [14] SMAGULOVA K, JAMES A P. A survey on LSTM memristive neural network architectures and applications[J]. *European Physical Journal Special Topics*, 2019, 228(1): 2313 - 2324.
- [15] SEFAKO T, WALINGO T. Biological resource allocation algorithms for heterogeneous uplink PD-SCMA NOMA networks[J]. *IEEE Access*, 2020, 9(1): 194950 - 194963.
- [16] LIN J, FENG S, ZHANG Y, et al. A novel deep neural network based approach for sparse code multiple access[J]. *Neurocomputing*, 2020, 382(1): 52-63.
- [17] LIN C. Experimental demonstration of SCMA for visible light communications[J]. *Optics Communications: A Journal Devoted to the Rapid Publication of Short Contributions in the Field of Optics and Interaction of Light with Matter*, 2018, 419 (11): 10-16.

[作者简介]



邵鑫玉 (1989-), 女, 现就职于江苏商贸职业学院, 主要研究方向为信号与信息处理、图像处理等。



姚瑶 (1990-), 女, 现就职于江苏商贸职业学院, 主要研究方向为图像处理、计算机应用技术。



王亮 (1980-), 男, 江苏商贸职业学院副教授, 主要研究方向为计算机网络技术、网络安全等。