

# 一种面向鲁棒无线感知的丢包 CSI 恢复技术

来源：深圳市大数据研究院

文稿类型：讨论稿

联系人：赵子健、陈廷尉、孟繁一、蔡智捷、朱光旭

电话：18345167686

邮箱：zhaozj28@mail2.sysu.edu.cn

---

## 1 引言

近年来，Wi-Fi 感知技术备受关注。相较于过去的视觉感知技术，Wi-Fi 感知技术具备了高度隐私性、穿透性以及低成本等优势。目前，Wi-Fi 感知主要利用信道状态信息（Channel State Information, CSI）进行感知。然而，在实际场景中，由于信号强度较弱、频率干扰以及硬件错误等因素的存在，接收器有时无法成功解码数据包，导致数据丢失。这进一步导致收集到的 CSI 数据在时间序列上呈现不均匀分布，直接影响了 Wi-Fi 感知模型的性能。目前，常见的处理方法是对数据进行插值，但传统的插值方法并未针对 CSI 特点进行设计，忽略了发射器、接收器以及载波之间的关系，从而导致插值结果与实际情况存在较大差异。

目前在丢失信道数据恢复方面的研究相对较少。因此，本提案基于 BERT（Bidirectional Encoder Representations from Transformers）模型[1]提出了信道数据恢复模型 CSI-BERT，并通过仿真实验验证了该方法的有效性。实验结果表明，与传统插值方法相比，CSI-BERT 在数据恢复方面具有较高的准确率，并能提升其他 Wi-Fi 感知模型的感知性能。

## 2 CSI-BERT：基于 BERT 的 CSI 恢复技术

BERT模型是一种基于双向编码器结构的预训练自然语言处理模型，具有强大的上下文理解与推理能力。近年来，BERT模型已经在无线感知领域得到广泛应用。BERT模型的文本理解能力主要源于其使用的掩码语言建模（Masked Language Model, MLM）预训练任务。在MLM任务中，输入文本中的一些字符会被替换为掩码符号[MASK]，然后通过自监督的方法训练模型来恢复被掩码的文本。由于MLM任务和CSI数据丢失恢复任务非常相似，并且可以通过自监督的方式训练，无需手工标注数据，因此本提案设计了基于MLM任务的训练方法，用于训练模型来恢复丢失的CSI数据。

本提案方法的工作流程如图1所示。首先，采集数据并使用CSI-BERT模型进行训练。然后，将恢复的数据提供给其他Wi-Fi感知模型训练，用于具体的下游任务。

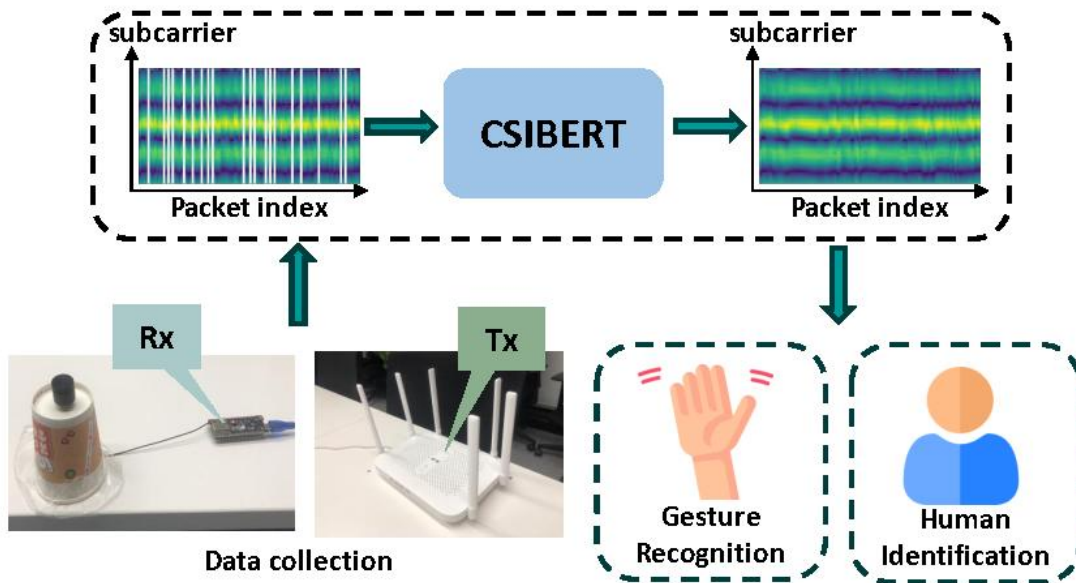


图1 CSI-BERT workflow

下面将介绍CSI-BERT模型的结构和CSI-BERT训练与恢复数据的方法流程。

## 2.1 模型结构

CSI-BERT 模型的结构如图 2 所示。与传统 BERT 模型不同的是，由于 CSI 是连续的数值而非离散的文本符号，因此需要对 BERT 模型进行改进，主要修改部分在于底层的编码层和顶层的输出部分。

CSI-BERT 的编码层包括符号编码层、位置编码层和时间编码层。符号编码层通过线性层对 CSI 进行编码。此外，通过数值分析发现，CSI 在不同时期会有较大的差异。为了解决推理阶段和训练阶段的数据差异可能导致的协变量偏移问题，我们引入了标准化层。标准化层对 CSI 数据在时间维度进行归一化，使得所有输入数据保持相近的分布。位置编码层使用传统 Transformer 位置编码[2]的方式对各个 CSI 的位置信息进行编码。时间编码层将归一化后的时间戳通过位置编码的方式进行编码，因为实际接收到的 CSI 序列不是等间隔的，时间戳编码可以为模型提供更多信息。

CSI-BERT 的顶层包括恢复器和判别器两个独立的部分，它们都以 BERT 最后一层的编码输出作为输入。恢复器通过线性层将 BERT 的编码输出恢复为与原始 CSI 维度相同的格式。由于原始 CSI 通过归一化去除了均值、方差等信息，恢复器需要通过反归一化层将这些信息恢复，可以直接使用标准化层计算得到的均值和方差。为了使恢复的数据更加真实，我们采用对抗学习的方法，引入判别器来判断输入的 CSI 序列是真实序列还是恢复的序列。为了减少训练过程中的内存和计算开销，我们没有使用传统的基于 GAN (Generative Adversarial Network) [3]的对抗学习方式，而是借鉴了 DANN (Domain Adaptation Neural Network) [4]的思想，通过梯度反转层实现对抗。梯度反转层会在反向传播过程中反转判别器的梯度。相比基于 GAN 的方法，这种方式只需要创建一个模型，减小了计算开销和内存占用的问题。

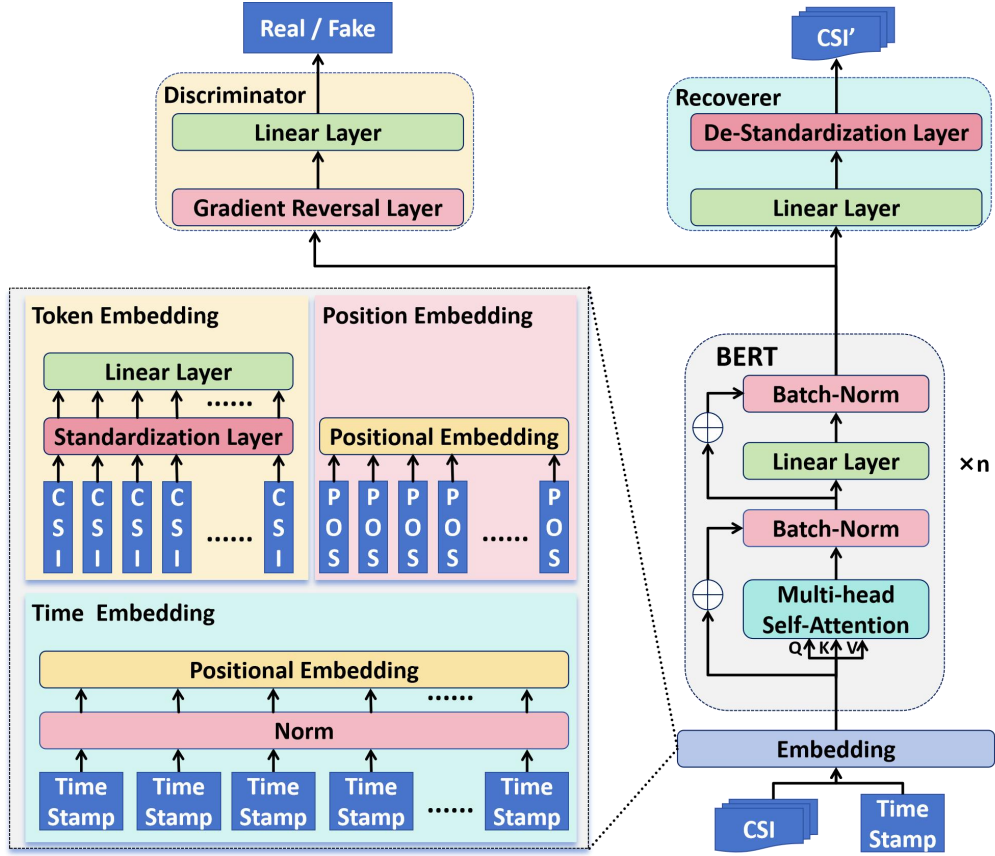


图 2 CSI-BERT 模型结构

## 2.2 方法流程

图3和图4分别展示了CSI-BERT模型在训练和推理阶段的流程。在训练阶段，CSI-BERT采用类似于BERT的预训练方法。原始CSI序列会被随机遮盖，使用[MASK]符号进行占位，并训练模型去恢复遮盖的数据。

然而，CSI-BERT的训练方法与BERT有一些不同之处。首先，由于原始CSI序列可能存在数据丢失的问题，需要在丢失的位置上使用BERT中的[PAD]符号进行占位。在模型的前向传播过程中，BERT的注意力机制会屏蔽[PAD]符号的位置，使得[PAD]符号不参与注意力计算。其次，由于CSI数据是连续的数值，我们使用线性层来替代BERT中的嵌入层作为位置编码层。这样做会导致[MASK]和[PAD]符号的采用不同的数值产生不同的影响，因此无法像BERT那样使用固定的数值表示[MASK]和[PAD]。为了解决这个问题，我们提出了一种随机符号生成的方法。具体来说，每个位置的[MASK]和[PAD]在不同的维度上都是基于高斯分布的随机数，且高斯分布的均值和方差与该维度原始输入的均值和方差相同，即标准化层的计算结果。通过这种方式，训练的难度进一步增加。由于[MASK]符号不是固定的，模型需要学习哪些位置的符号不是真实的，从而进一步提升模型提取信息的能力。最后，在BERT的预训练任务中，[MASK]的遮盖比例通常是固定的15%。然而，实际CSI数据的丢失率是不固定的，实验发现大多数数据的丢失率在15%到70%之间。因此，我们采用了随机的遮盖比例，每次输入模型时会随机遮盖15%到70%的原始数据，并训练模型来恢复。CSI-BERT的损失函数共包含五部分：

$$\begin{aligned}
 L_1 &= MSE(C, \hat{C}) \\
 L_2 &= MSE(\mu, \hat{\mu}) \\
 L_3 &= MSE(\sigma, \hat{\sigma})
 \end{aligned}$$

$$L_4 = \text{CrossEntropy}(\text{Discriminator}(C), 0)$$

$$L_5 = \text{CrossEntropy}(\text{Discriminator}(\hat{C}), 1)$$

其中 $C$ 和 $\hat{C}$ 分别代表原始数据和CSI-BERT恢复的数据， $\mu, \sigma, \hat{\mu}, \hat{\sigma}$ 分别代表原始数据和恢复数据的均值方差。L1~L3为数据的重构损失函数，L4~L5为判别器的损失函数，用于判断数据是真实数据还是CSI-BERT恢复得到的数据。

在推理阶段，采用与训练阶段相似的方法，将[PAD]符号替换为[MASK]符号，然后输入模型。在这里，我们提出了两种数据恢复方式，分别称为"recover"和"replace"。这两种方法的区别在于"replace"方法直接使用CSI-BERT的输出作为恢复结果，这样做可以保证数据的连贯性，但对于没有丢失的数据位置，CSI-BERT的输出和真实数据可能存在少许误差。而"recover"方法则是仅将原始数据中丢失的位置用CSI-BERT的输出值进行替换。

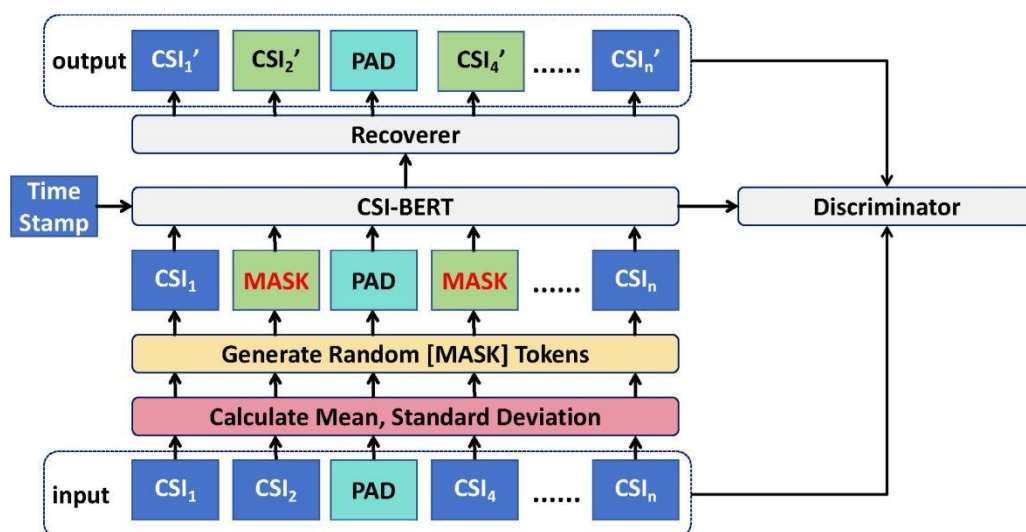


图3 训练阶段

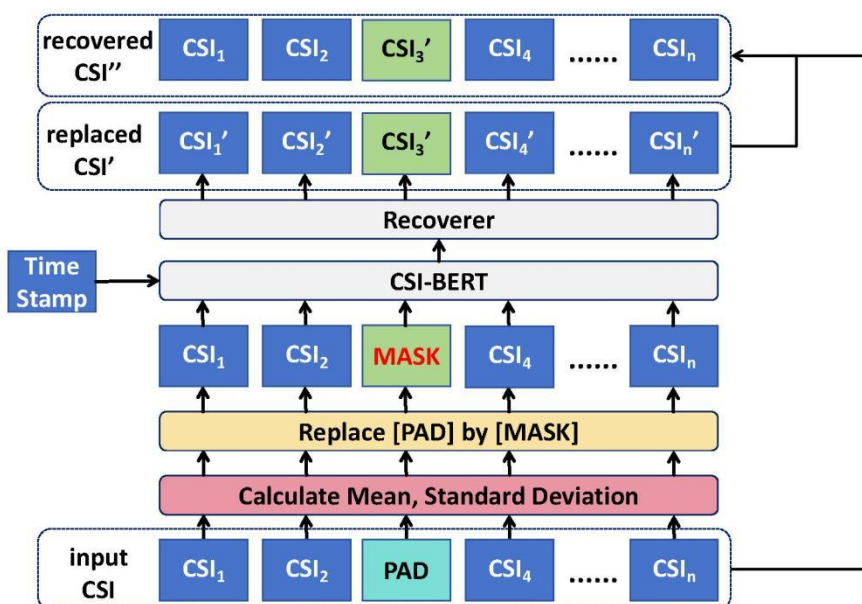


图4 数据恢复阶段

### 3 实验分析

在实验阶段,我们使用 ESP32-S3 采集了手势识别数据集,该数据集采样率为 100Hz,包含 6 个动作 ID 和 8 个人物 ID。数据的总长度约为 48 分钟,可用于手势识别和人员识别两个任务。通过数据分析,我们发现采集到的数据的平均丢包率约为 15%。

为了测试模型的性能,我们在已有数据的基础上进一步随机删除了 15%的数据,并通过模型对删除的数据进行恢复。我们比较了几种不同方法恢复数据与原始数据之间的误差,包括均方误差(MSE)、平均绝对误差(MAE)、对称平均绝对百分比误差(SMAPE)、Frechet 形状相似度(FSS),以及恢复时间。实验结果如表 1 所示,结果显示 CSI-BERT 恢复数据的误差最小,并且可以在最短的时间内完成数据恢复。

方法	MSE	SMAPE	MAPE	FSS	恢复时间 (min)
CSI-BERT	<b>1.7326</b>	<b>0.0902</b>	<b>0.0945</b>	<b>0.9999(replace)</b> <b>0.9979(recover)</b>	<b>0.03</b> (无需 GPU)
线性插值	2.8294	0.1248	0.1344	0.9841	0.64
Kringing	3.6067	0.1627	0.1395	0.9936	45.15
IDW	2.4306	0.1278	0.1167	0.9970	3.30

表 1: CSI 恢复性能指标

为了比较不同数据恢复方法在不同丢包率下的数据恢复性能,我们手动随机删除了 10%至 80%的数据,并测试了不同丢包率下各方法的数据恢复误差。结果发现,CSI-BERT 始终具有最佳的性能。

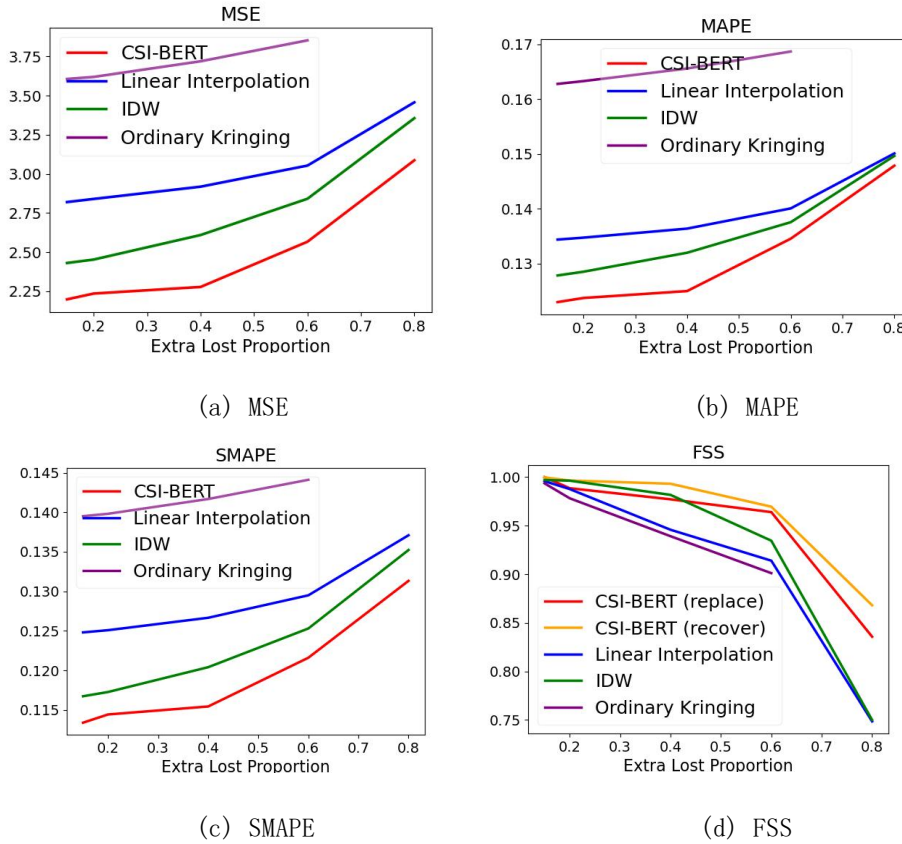


图 5 不同丢包率下 CSI 数据恢复性能



通过CSI-BERT进行数据恢复的主要目的是使得CSI序列更加真实连贯，从而更好地服务于下游任务的模型。因此，我们在表2和表3中比较了不同数据恢复方法下几种不同神经网络在手势识别和人员分类任务中的准确率。结果显示，在大部分情况下，CSI-BERT恢复的数据可以为模型带来最大的分类准确率。此外，CSI-BERT还可以通过类似BERT模型微调的方式用于分类任务，实验结果也表明CSI-BERT在分类任务中具有较高的准确率。

	FFN	CNN	RNN[5]	LSTM[6]	Resnet[7]	CSI-BERT
原始数据	66.93%	55.72%	39.56%	11.97%	70.31%	76.91%
CSI-BERT recover	74.23%	59.39%	48.96%	22.92%	<b>92.57%</b>	71.87%
CSI-BERT replace	<b>86.90%</b>	<b>61.51%</b>	<b>58.80%</b>	<b>52.36%</b>	84.52%	<b>79.54%</b>
线性插值	72.91%	61.51%	45.32%	49.09%	80.75%	74.55%
Kringing	65.62%	57.55%	53.64%	50.00%	88.71%	74.27%
IDW	40.17%	56.77%	48.70%	46.88%	80.32%	67.22%

表 2: 不同数据恢复方法下各模型在手势识别任务的准确率

	FFN	CNN	RNN[5]	LSTM[6]	Resnet[7]	CSI-BERT
原始数据	71.34%	71.14%	66.39%	21.09%	83.76%	93.94%
CSI-BERT recover	97.13%	80.60%	80.51%	<b>35.18%</b>	94.30%	95.05%
CSI-BERT replace	<b>97.65%</b>	79.18%	<b>89.24%</b>	24.22%	<b>97.39%</b>	95.83%
线性插值	81.84%	70.88%	84.45%	26.83%	86.75%	<b>97.92%</b>
Kringing	94.76%	<b>85.38%</b>	86.42%	21.61%	97.32%	95.83%
IDW	83.22%	74.56%	88.54%	33.91%	94.27%	95.20%

表 3: 不同数据恢复方法下各模型在人员识别任务的准确率

## 结论

Wi-Fi 感知任务中，CSI 数据的丢失对模型性能有重大影响。传统的插值方法不是针对 CSI 数据设计，没有充分利用载波、天线间的关系，为了解决这一问题，本提案提出了 CSI-BERT 模型，利用神经网络更好地恢复数据，从而辅助感知模型的性能。CSI-BERT 模型可以通过自监督训练的方式进行训练，无需手工标注数据。此外，在没有 GPU 的场景下，CSI-BERT 模型也能以极快的速度进行数据恢复，因此在实际场景中具有广泛应用的潜力。通过实验证明，与传统的插值方法相比，CSI-BERT 模型具有更小的恢复误差，并且能够为感知模型带来最大的性能提升。

## 参考文献

- [1]J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of deep bidirectional Transformers for language understanding," arXiv preprint arXiv:1810.04805, 2018.
- [2]A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, "Attention is all you need," Advances in neural

- information processing systems, vol. 30, 2017.
- [3]I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative adversarial nets,” *Advances in neural information processing systems*, vol. 27, 2014.
- [4]Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. March, and V. Lempitsky, “Domain-adversarial training of neural networks,” *Journal of machine learning research*, vol. 17, no. 59, pp. 1–35, 2016.
- [5]L. R. Medsker and L. Jain, “Recurrent neural networks,” *Design and Applications*, vol. 5, no. 64–67, p. 2, 2001.
- [6]S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [7]K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770–778, 2016.