

# WIFI-CSI 感知学习周报

2025 年 8 月 9 日星期六

## 1. 学习目标

- 1、解析 WIFI CSI 数据并进行滤波处理；
- 2、尝试根据执行动作中 CSI 变化进行动作的分类。

## 2. 学习进展

### 2.1 CSI 数据的处理

原始 CSI 数据中每一个时间点下的 CSI 数据包含 234 个字节的数据，每个字节依次按照第 1 个子载波的实部、第 1 个子载波的虚部、第 2 个子载波的实部、第 2 个子载波的虚部等依次排列，因此共计 117 个子载波。对不同时间下的子载波数据观察可以发现，中间三个子载波为保护间隔，不包含有效 CSI 数据，可以得到有用的 CSI 子载波个数为 114 个。

在 IEEE 802.11n 标准下，当使用 5G 频段，信道 40 时，对应的中心频率为 5.2GHz，子载波频率间隔为 312.5 KHz，由此可以确定各个子载波的频率，子载波频率满足下式：

$$f_n = f_{center} + n \cdot \Delta f \quad (1)$$

上式中， $n$  为子载波相对中心频率的索引， $\Delta f$  为子载波间隔。例如第一个子载波对应的实际频率应为：

$$f_1 = 5200MHz - \frac{117 - 1}{2} \times 0.3125MHz = 5181.875MHz \quad (2)$$

WIFI 信号中对 CSI 的估计一般以 CFR 为标准，WIFI 信号在传播过程中，由于多径传播的影响，信道对不同频率的信号响应不同，导致了频率选择性衰落。不同子载波的 CFR 反映了信道的当前传播状态，由此可以从 CFR 中实现对信道传播环境的分析。周围环境的变化会导致信道响应发生变化，进而实现 WIFI 感知。

CFR 反映了信道在频域的响应，对其进行 IFFT 可以将其转化为 CIR。CIR 反映了信道在时域上对信号的响应，不同时刻下的 CIR 可以直接反映信号在相

应时延下的脉冲响应。CFR 与 CIR 本质上是对同一事物的不同描述，都反映了信道的当前状态，通过对二者进行分析，可以实现对信道状态的描述与环境的感知。

在周围存在人体活动时，由于信号经过人体的不同部位反射存在不同的时延，导致 CSI 出现较大的变化。在人体执行手势时，CSI 各子载波 CFR 谱图、单个子载波 CFR 波形与 CIR 波形如下图所示：




图 1 存在动作时 CSI 数据变化

从上图中可以发现，当环境中有人体执行动作时，从谱图中可以明显看到变化，单个 CFR 与 CIR 波形也有所变化。由于不同子载波具有不同的响应，上图中子载波 CFR 变化不明显。而由于手势距离 WIFI 接收端较近，对 CIR 的时延响应变化较为明显。

由于 CSI 数据本身具有较大的噪声和不稳定，即使在静止状态下 CSI 依然有较大波动，为减少噪声的影响，可以采用滤波方法进行噪声的去除。对向右移动这个手势进行滤波处理，分别采用静止状态 CSI 对消和平滑滤波两种方式对原始 CSI 数据进行处理。从中发现，使用背景对消方法降低了 CSI 数据的均值，但对于波形中的杂波变化依然没有太明显的效果。平滑滤波后的结果显示波形变得平稳，噪音减小且增强了谱图中的变化，故选择平滑滤波作为后续处理方法。不同方法处理结果如下图所示：

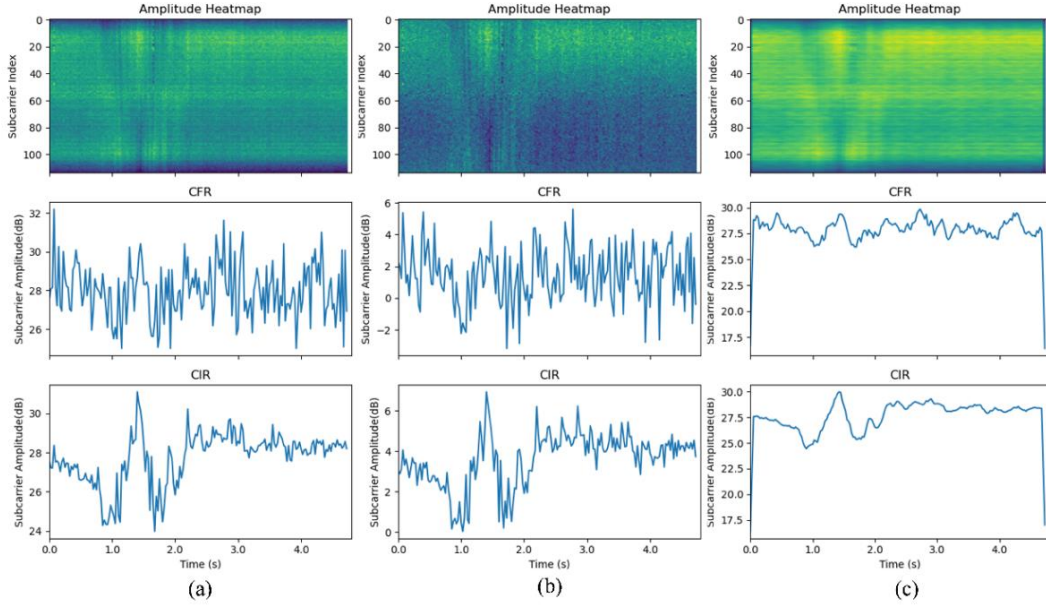


图 2 (a)原始 CSI 数据 (b)背景对消结果 (c)均值滤波结果

对三种状态(静止、向前推、向右挥)下的原始 CSI 数据进行滤波处理, 得到三种状态下的谱图如下图所示:




图 3 三种状态下 CSI 幅度谱图变化

可以看到, 不同状态下的 CSI 谱图有较大的区别, 静止情况下, 谱图较为平稳, 随时间变化不明显, 在向前推手势下, CSI 出现了较为明显的波动, 在向右挥手势下, CSI 出现了更为明显的变化, 且不同频率的子载波的变化明显不同。由此可以推断出, 利用 CSI 进行手势的识别, 应当根据子载波各自变化与不同子载波变化的差异尝试进行分类识别。

## 2.2 PCA 降维与分类

单个样本包含两个维度[子载波维度,时间维度], 在数据集中的参数设置可以得到, CSI 的发送速率为 40Hz, 子载波维度为 114, 即单个样本是一个[114,200]的二维数据, 如果将时间维上的采样点也作为特征, 单个样本将包含 22800 个特征。为简化样本数据, 利用 PCA(主成分分析)将样本的特征维度降维至 2 维, 降

维结果如下：




图 4 CSI 数据降维样本(左)与仅采用均值-方差特征样本(右)数据分布

从上图中可以看到，经过降维后的 CSI 数据不同手势样本之间有明显的差别，相比于仅使用均值-方差作为特征，样本之间有了明显的分层，因此可对降维后的数据进行分类。同样利用 K-means 算法对其进行聚类结果如下：




图 5 K-means 聚类结果

从中可以发现，K-means 聚类效果并不太好，主要是同一类别样本分布不太聚拢。而不同样本之间有明显的分层，可尝试利用支持向量机(SVM)对样本空间进行分割，实现手势的分类。采用线性核函数的 SVM 对样本数据进行训练以及测试结果如下图所示：

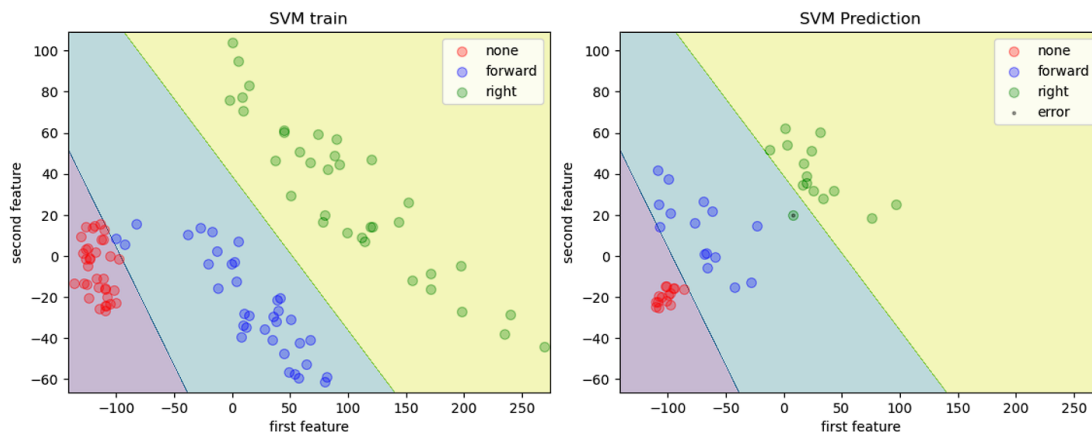


图 6 SVM 训练分类结果(左)与测试分类结果(右)

从上图可以发现，SVM 可以很好地将样本进行划分，测试结果也显示 SVM 的样本空间划分的有效性，仅有一个测试样本未被成功分类。测试结果混淆矩阵如下图所示：




图 7 三分类混淆矩阵

### 2.3 基于 CSI 谱图的 CNN 手势分类

然而 PCA 降维后的数据损失了部分 CSI 的特征，为完整地利用全部 CSI 数据特征，将 CSI 所有子载波的谱图作为图像特征，利用图像处理的方法对手势进行分类。

将 CSI 数据经过滤波后的数据绘制出热力图，并保存为 RGB 图像，部分样本如下图所示：



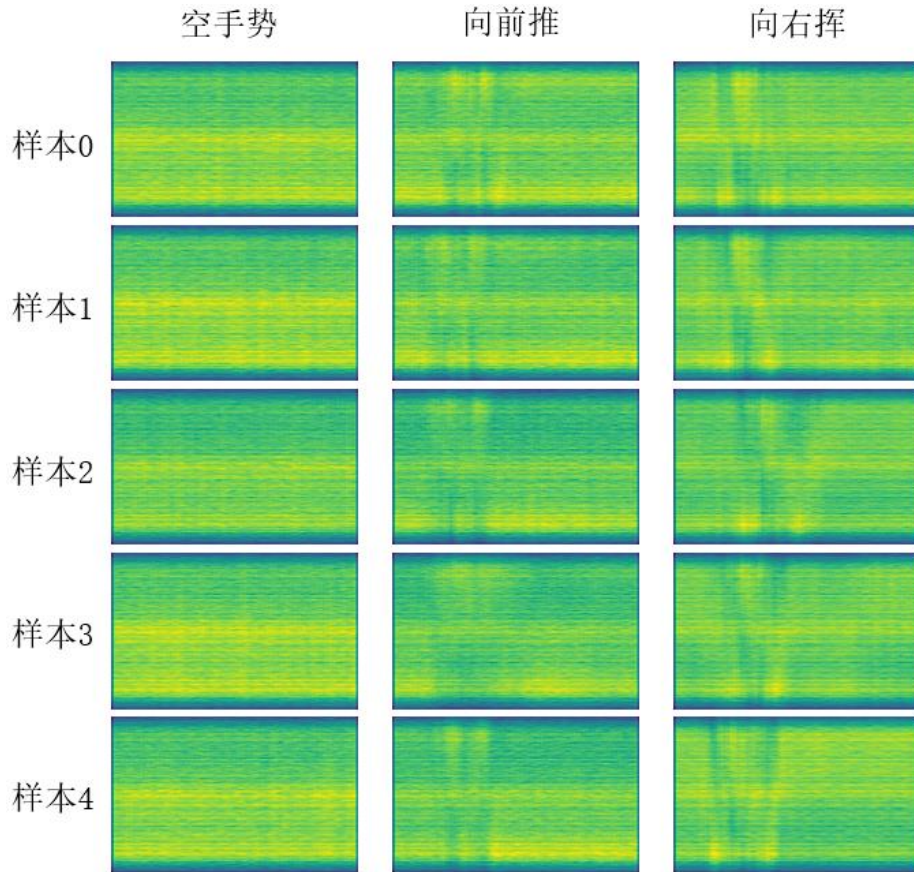


图 8 部分数据样本

由此可以得到单个手势的样本大小为[通道,子载波,时间],即[3,114,200],可按照图像分类方法,利用深度学习对其进行处理。设计一个简单的卷积神经网络,包含两个卷积层,两个全连接层,模型具体设计如下:

```
class Net(nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        self.conv1 = nn.Conv2d(3, 8, 3, 1)
        self.conv2 = nn.Conv2d(8, 16, 3, 1)
        self.dropout1 = nn.Dropout2d(0.5)
        self.fc1 = nn.Linear(14400, 256)
        self.fc2 = nn.Linear(256, 3)
    def forward(self, x):
        x = self.conv1(x)
        x = F.relu(x)
        x = self.conv2(x)
        x = F.relu(x)
        x = F.max_pool2d(x, 2)
        x = self.dropout1(x)
        x = torch.flatten(x, 1)
        x = self.fc1(x)
        x = F.relu(x)
        x = self.fc2(x)
        return x
```

图 9 模型设计

设置优化器为 Adam，学习率 0.001，迭代 30 次，训练结果如下：

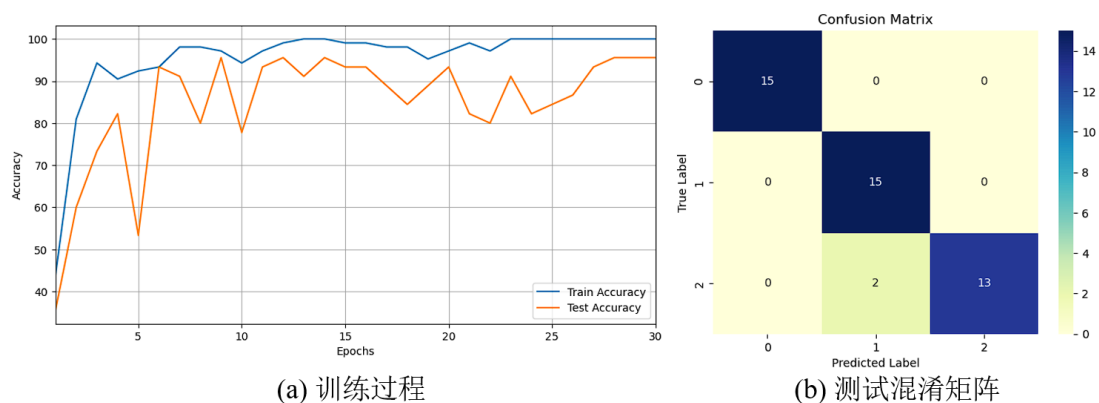


图 10 CSI 谱图训练过程与测试结果

可以发现，所设计的模型可以实现对 CSI 谱图的有效分类，测试集中准确率最高达到 95.5%。

## 2.4 总结与展望

根据上述处理，可以发现利用 CSI 信息可以实现对手势的分类与识别，然而由于 CSI 噪声的存在，需要进行一定的滤波处理，本次仅使用的较为简单的均值滤波，并利用了两种方法实现对三种简单情况的分类。后续主要针对以下方面继续进行改进：

1、CSI 采样率：仅利用均值滤波处理较为粗糙，处理后的数据可能依然包含无关噪声，也有可能将微小的特征滤除，有关文献提出使用小波变化滤除高频噪声，保留人体活动频率(2~60Hz)，利用短时傅里叶变化，将 CSI 数据转为时频图，可以直接反映人体活动造成的多普勒频移随时间的变化关系。但 ESP32 套件默认的 CSI 数据发送速率为 40Hz，显然采样率太低，难以从中提取合适的频率成分，有关研究采用的 CSI 采样速率为 1000Hz，后续应当尝试提高 CSI 数据的发送效率，从中分析多普勒频移。

2、多通道：有关研究将多通道的 CSI 数据与图像数据进行类比，接收天线相对独立，类似于图像独立的颜色通道，子载波与时间序列类比于图像二维数据，从而可以将图像中的处理应用到 CSI 数据中。目前仍然只使用了一个接收天线，另一个接收天线的打印接口隐藏在套件内部，如果要采集两个接收天线的的数据，需要电脑同时连接两个 USB 接口，同时接收 CSI 数据，可能会涉及两个天线 CSI 不同步的问题，需要后续再进行对齐。

### 3.参考文献

- [1] Zhuravchak A, Kapshii O, Pournaras E. Human activity recognition based on wi-fi csi data-a deep neural network approach[J]. Procedia Computer Science, 2022, 198: 59-66.
- [2] Yang, Jianfei. GitHub - Marsrocky/Awesome-WiFi-CSI-Sensing [EB/OL]. <https://github.com/Marsrocky/Awesome-WiFi-CSI-Sensing>