

一种基于 WiFi 信道状态信息的课堂行为识别方法^{*}

杨彦侃 马鑫宇 郁 林

(内蒙古科技大学数智产业学院网络安全学院 包头 014010)

摘 要: 学生课堂行为识别在提升教学质量方面具有重要意义。当前主流的研究大多基于视频或传感器技术,然而这些方法存在隐私侵犯、成本高昂等问题,制约了其广泛应用。为此,本文提出了一种基于 WiFi CSI 的学生课堂行为识别方法。该方法首先在真实教室环境中采集了 4 种典型课堂行为(举手、起立、坐下、翻书)的 CSI 信号;然后结合 WiFi CSI 数据特点,采用 Hampel 滤波和小波变换对 CSI 信号进行去噪处理,并设计主成分分析算法融合所有子载波特征。随后,根据融合特征设计局部异常因子检测算法截取 CSI 动作区间,并引入三维映射的方式将截取的 CSI 信号转换成振幅能量图;最后设计了一种基于残差网络的迁移学习模型,对振幅能量图数据集进行特征提取和分类识别。实验结果表明,该方法在阶梯教室和小教室中的准确率分别为 98.89% 和 99.07%,并且在对不同人员的测试中均可达到 98% 以上,证明该方法具有较高的识别精度和较好的鲁棒性,为学生课堂行为识别的研究提供了一种新的思路。

关键词: WiFi;信道状态信息;行为识别;迁移学习;残差网络

中图分类号: TP39;TN99 **文献标识码:** A **国家标准学科分类代码:** 520.60

A classroom behavior recognition method based on WiFi channel state information

Yang Yankan Ma Xinyu Yu Lin

(School of Digital and Intelligent Industry, School of Cyber Science and Technology, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: Student classroom behavior recognition is important for improving the quality of teaching and learning. Most of the current mainstream research is based on video or sensor technologies, however, these methods suffer from privacy invasion and high cost, which constrain their wide application. Therefore, this paper proposes a method of student classroom behavior recognition based on WiFi CSI. This method first collected CSI signals for four typical classroom behaviors (hands up, stand up, sit down and turn over books) in a real classroom environment. Then combined with the characteristics of WiFi CSI data, Hampel filter and wavelet transform are used to denoise the CSI signal, and all subcarrier features are fused by designing principal component analysis algorithm. Subsequently, the CSI action intervals are intercepted according to the fusion features designing the local outlier factor detection algorithm, and the intercepted CSI signals are converted into amplitude energy maps by introducing three-dimensional mapping. Finally, the amplitude energy map dataset is feature extracted and classification recognized by designing a transfer learning model based on residual network. The experimental results show that the accuracy of the method is 98.89% and 99.07% in the step classroom and small classroom, and it can reach more than 98% in the test for different people. It is proved that the method has high recognition accuracy and good robustness, which provides a new idea for the research of student classroom behavior recognition.

Keywords: WiFi; channel state information; behavior recognition; transfer learning; residual network

0 引 言

近年来,随着教育行业智能化改革和建设的加速推进,

智能化教育与教学已成为教育发展的重要方向。教育部印发的《教育信息化 2.0 行动计划》明确指出:“要以人工智能、大数据、物联网等新兴技术为基础,依托各类设备及网络,积

极开展智慧教育创新研究和示范,推动新技术支持下教育的模式变革和生态重构^[1]。课堂是教育教学的核心场所,学生是教学过程中的主体,其课堂行为能够间接反映出学生的学习效果和教师的教学质量。因此,分析学生课堂行为具有实际价值,开展学生课堂行为识别研究至关重要。

目前,学生课堂行为识别的研究主要集中在基于视频^[2-4]和传感器^[5-7]的技术上。然而,视频方法易受到图像遮挡、光线变化等因素的干扰,并且常常引发隐私安全的担忧;传感器方法则需要部署大量专用设备,并且大多情况下要求用户佩戴传感器,导致成本高、便利性差等问题。相比之下,基于 WiFi 信道状态信息(channel state information, CSI)的识别方法能够利用环境中广泛存在的 WiFi 信号,具有非视距、无须携带设备、成本低、易部署、不受光照条件限制、保障个人隐私等一系列潜在优势^[8],已经在活动识别、手势识别、人员识别等方面有了很多应用。然而,本文未检索到将该识别方法应用于学生课堂行为识别的文献。因此,本文将基于 WiFi CSI 的识别方法扩展至学生课堂行为识别领域,结合学生课堂行为数据特点,提出基于 WiFi CSI 的学生课堂行为识别方法,探索其应用潜力。

近年来,基于 WiFi CSI 的识别技术已经取得了一些研究成果,根据所使用的算法不同,大致可以分为两类:使用机器学习算法和使用深度学习算法。使用机器学习算法时,通常需要手动提取特征,例如文献[9]提取 CSI 幅度和相位的平均值、标准差和中位数绝对偏差等特征,使用支持向量机的变体进行驾驶员活动识别;文献[10]提取 CSI 幅度的偏度、均方根和峰值等特征,使用加权 K 最近邻的方法进行手势识别;文献[11]提取 CSI 幅度和相位差的方差、平均绝对误差和四分位数等特征,使用经过遗传算法优化的随机森林方法进行跌倒检测。然而,这些方法的手动特征提取过程复杂,且往往针对特定数据集设计,导致算法的泛化能力不足。相比之下,深度学习算法能够自动提取特征,减轻了对算法泛化能力的影响,例如文献[12]使用多层双向长短期记忆网络结合注意力模型,实现了对六种活动的识别;文献[13]使用一种 3D 卷积神经网络(convolutional neural network, CNN)能够提取与场景无关的特征,实现了跨场景的手势识别;文献[14]使用经过改进的视觉 Transformer 模型结合可学习的位置编码方法,实现了轻量级的人员识别。其中, CNN 作为深度学习的代表模型之一,广泛应用于计算机视觉、自然语言处理等领域。但是,随着网络深度的增加, CNN 会产生梯度消失或梯度爆炸以及网络性能退化的问题。为解决这一问题,微软实验室 He 等^[15]提出残差网络(residual network, ResNet),通过引入残差结构(残差块)有效的克服了这些问题。此外,迁移学习可以把已训练好的模型参数迁移到新的模型来帮助新模型训练,从而加快并优化模型的学习效率,提升模型的泛化能力^[16]。然而目前还未检索到有文献将迁移学习应用于学生课堂行为识别应用中。

综上所述,本文提出了利用迁移学习模型处理 WiFi CSI 数据的学生课堂行为识别方法。该方法根据采集的 CSI 数据特点,设计了一系列的 CSI 数据处理流程,引入了一种基于 ResNet 的迁移学习模型来提取 CSI 振幅能量图的特征并进行分类识别。该方法的提出为学生课堂行为识别的研究提供了一种新的思路。

1 学生课堂行为识别方法

1.1 总体框架

本文提出了一种基于 WiFi CSI 的学生课堂行为识别方法,其总体框架如图 1 所示,包括数据采集、数据处理、训练预测 3 个部分。首先,在真实的教室环境中采集包含学生课堂行为的 CSI 信号;然后,根据 CSI 信号特点,设计 CSI 信号数据处理流程,具体包括 Hampel 滤波、小波去噪、主成分分析(principal component analysis, PCA)子载波融合、局部异常因子(local outlier factor, LOF)动作截取以及将 CSI 信号转化为振幅能量图;最后,设计基于 ResNet 的迁移学习模型对 CSI 振幅能量图进行特征提取与分类识别。

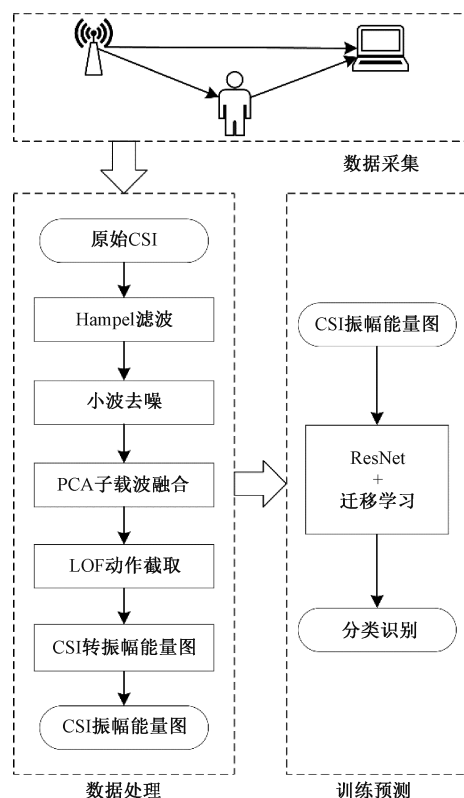


图 1 学生课堂行为识别总体框架

Fig. 1 Overall framework for student classroom behavior recognition

1.2 理论基础

1) WiFi 信号传播模型

在典型的室内环境中,无线信号从发射端发出后,会通

过直射、反射、衍射和散射等多条路径传播,并以多径叠加的信号形式到达接收端。由于传播过程中信号受到物理空间的影响,其携带的特征信息也会反映出环境的变化。WiFi 行为识别的基本原理正是利用信号在传播过程中受到人体的反射、折射、衍射等影响,对信号的正常传播产生扰动,通过分析接收到的信号变化特征来识别人体的行为状态。WiFi 信号传播模型如图 2 所示。




图 2 WiFi 信号传播模型图

Fig. 2 WiFi signal propagation model diagram

2) CSI

CSI 是一种描述无线通信链路信道状态属性的细粒度信息,包含了信号从发射端到接收端传播过程中的多径效应、干扰、衰落以及功率随距离衰减等特征。具体来说, WiFi 信号在传播过程中受到室内空间环境的影响,发生反射、衍射和散射,从而导致信号的变化。CSI 刻画了多径传播,其细粒度的特性能准确反映室内空间环境中的信息。因此,可以从 CSI 中提取信号的变化特征来识别环境中的行为信息。CSI 不仅可以测量多个子载波的频率响应,还可以测量每个子载波的幅度和相位信息。

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{N} \quad (1)$$

其中, \mathbf{H} 为表示 CSI 信息的信道矩阵, \mathbf{Y} 为接收信号向量, \mathbf{X} 为发射信号向量, \mathbf{N} 为噪声向量。根据上式可以估计出信道矩阵 \mathbf{H} 为:

$$\mathbf{H} = \mathbf{Y}/\mathbf{X} \quad (2)$$

通过 Intel 5300 无线网卡可以获得包含 30 个子载波的数据包,每个数据包的一组 CSI 表示为:

$$\mathbf{H} = [H_1, H_2, \dots, H_k, \dots, H_{30}] \quad (3)$$

其中, H_k 表示第 k 个子载波的 CSI。单个子载波的 CSI 可以表示为:

$$H(k) = |H(k)| e^{j\sin\angle H(k)} \quad (4)$$

其中, $H(k)$ 表示第 k 个子载波的幅度, $\angle H(k)$ 表示第 k 个子载波的相位。

1.3 数据处理

1) Hampel 滤波

由于 CSI 信号存在许多非人体行为引起的突变值,例如设备传输速率和传输功率的变化等突发噪声会干扰从

CSI 信号中提取学生课堂行为特征。Hampel 滤波器^[17]能够有效检测并替换这些异常值,它能过滤掉偏离区间 $[\mu - \lambda \times \sigma, \mu + \lambda \times \sigma]$ 的所有离群点,其中 μ 、 λ 和 σ 分别表示平均值、标准偏差和平均绝对偏差。如图 3 所示为一段举手动作的原始 CSI 信号波形,如图 4 所示为 Hampel 滤波后的信号波形,可以明显的观察到突变噪声被有效滤除。




图 3 原始 CSI 信号波形

Fig. 3 Raw CSI signal waveform




图 4 Hampel 滤波后信号波形

Fig. 4 Signal waveform after Hampel filtering

2) 小波去噪

虽然 Hampel 滤波器可以去除 CSI 信号中的离群点,但仍然存在一些未消除的噪声。小波变换^[18]能够在多分辨率和时频局部化方面具有良好的表现,其小波函数的计算公式如下:

$$W_{WT}(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \mu\left(\frac{t-b}{a}\right) dt \quad (5)$$

其中, a 为小波函数的尺度, b 为平移量。

如图 5 所示为小波去噪后的 CSI 信号波形,可以观察到,相较于 Hampel 滤波后的信号,小波去噪后的信号波形更加平滑,同时保留了原始信号的主要特征。




图 5 小波去噪后信号波形

Fig. 5 Signal waveform after wavelet denoising

3) PCA 子载波融合

由于 CSI 包含多条子载波,且每条子载波具有一定差异,导致在后续的动作截取过程会变得复杂。PCA^[19]能够通过线性变换将一组相关变量转化为一组线性无关的变

量,其主要目标是降低数据的维度并提取主要特征,同时尽量减少信息损失。因此,本文利用 PCA 对 CSI 的子载波进行特征融合,以获得第一主成分特征,为后续的动作截取提供依据。

首先,将 CSI 的每个子载波同对应的均值相减,实现数据中心化。其次,计算协方差矩阵以描述不同特征之间的关系。协方差矩阵的对角线元素表示特征的方差,非对角线元素表示不同特征之间的协方差,如下:

$$C = \frac{1}{k} \mathbf{H}^T \mathbf{H} = \frac{1}{k} \begin{bmatrix} \text{conv}(h_1, h_1) & \cdots & \text{conv}(h_1, h_n) \\ \vdots & \ddots & \vdots \\ \text{conv}(h_k, h_1) & \cdots & \text{conv}(h_k, h_n) \end{bmatrix} \quad (6)$$

其中,CSI 矩阵为 $\mathbf{H} = [h_1, h_2, \dots, h_k]$, h_i 表示维度为 k 的第 i 个 CSI 子载波的采样数据。

最后,通过特征分解方法求出矩阵 C 的特征向量,排序后表示为 $\{q_1, q_2, \dots, q_n\}$,根据贡献率大小获取前 j 个特征向量,并构成投影矩阵 E ,与 CSI 矩阵相乘后即可得到方差最大的特征向量^[20]。

如图 6 所示为举手动作的 CSI 信号经过 PCA 处理得到的第一主成分波形,可以观察到,相较于小波去噪后的信号,第一主成分波形的特征变化更加明显,更有利于后面的动作截取和特征提取。




图 6 第一主成分波形

Fig. 6 First principal component waveform

4) LOF 动作截取

当人员静止时,CSI 信号波形保持相对稳定;当人员活动时,CSI 信号波形则会出现相应的波动。为准确判定人员动作区间并且实现动作区间截取,本文设计了 LOF^[21],是一种无监督的异常值检测算法。其基本思想是通过计算数据点周围邻居点的密度来评估该点的异常程度。

首先,计算 CSI 主成分幅值点的 k 邻近距离和 k 距离邻域并计算每个数据点的局部可达密度(local reachability density, LRD)。LRD 表示一个数据点与其 k 个最近邻居点之间的密度,即该点周围邻居点的平均密度。LRD 值越高,表示该点所在区域的密度越大。LRD 的计算公式如式(7)所示。

$$LRD_k(P) = 1 / \left(\frac{\sum_{O \in N_k(P)} \text{reach_dist}_k(P, O)}{|N_k(P)|} \right) \quad (7)$$

其中, $N_k(P)$ 表示数据点 P 的 k 个最近邻近点的集合, $\text{reach_dist}_k(P, O)$ 表示点 P 和点 O 之间的可达距离。

其次,计算每个数据点的 LOF, LOF 值越高,表示该点与其邻居点密度不够匹配,是异常点的可能性越大。LOF 的计算公式为:

$$LOF_k(P) = \frac{\sum_{O \in N_k(P)} \frac{LRD_k(O)}{LRD_k(P)}}{|N_k(P)|} \quad (8)$$

其中, $LRD_k(P)$ 表示数据点 P 的局部可达密度, $LRD_k(O)$ 表示点 O 的局部可达密度。

最后,设定一个阈值,若 LOF 趋近于阈值,则该 CSI 幅值点在稠密区域中,表示没有发生动作行为,若 LOF 远大于阈值,则该 CSI 幅值点距离其他点较远,表示有动作行为发生。选取 LOF 较大的 CSI 幅值特征输出,实现动作截取。

5) CSI 转振幅能量图

CSI 信号由 3 根天线接收,每根天线可以接收 30 条子载波,共计 90 条子载波。现有研究大多仅考虑了其中一根天线上的子载波,而忽略了另外两根天线。虽然每根天线上的子载波在感知人体行为时具有相似性,但相互之间也存在差异,这些差异可能由人体运动时的速度、角度、位置以及外部环境所导致。如果将三根天线上的所有子载波共同分析,将会在很大程度上提高人体行为识别的精度和鲁棒性。因此,本文提出一种通过三维映射将 CSI 信号转换为振幅能量图的方法,并通过深度学习网络模型自动提取振幅能量图的特征语义。

通过 Matlab 中的 surf 函数和 view 函数可以生成能量图。surf 函数能够将数据集映射到图像上,它通过 X 、 Y 和 Z 坐标定义一个具有实色边和实色面的三维曲面。 X 和 Y 坐标描述曲面的每个点, Z 坐标则表示曲面的高度,曲面的颜色随 Z 指定的高度变化。view 函数用来控制三维图形的观察点和视角,参量 az 为方位角和水平旋转角, el 为仰角。如图 7 所示为 3 根天线中所有子载波的 CSI 信号三维曲面图, X 轴表示数据包, Y 轴表示子载波索引, Z 轴表示 CSI 的幅值(即 CSI 的振幅能量),其颜色随幅值变化。黄色越浅表示幅值越高,即能量越高,说明动作幅度越大;蓝色越深则表示幅值越低,即能量越低,说明动作幅度越小。如图 8 所示,是从三维曲面图上方映射到 X - Y 轴平面的振幅能量图,此 X 轴表示数据包, Y 轴表示子载波索引, Z 轴幅值则被映射为二维平面上的颜色像素。

采集到的 4 种课堂行为的 CSI 信号经过预处理后,通过三维映射的方法,全部转换成对应的振幅能量图。为简化数据处理,去掉了横纵坐标系,仅保留图片信息,并以此作为深度学习模型的训练数据集和测试数据集。如图 9(a)~(d)所示,分别展示了举手、起立、坐下、翻书 4 种




图 7 CSI 信号三维曲面图

Fig. 7 3D surface map of CSI signal




图 8 CSI 振幅能量图

Fig. 8 Energy map of CSI amplitude

课堂行为的振幅能量图。从图 9 中可以明显观察到 4 种课堂行为之间存在明显的特征差异,每种课堂行为都具有各自独立的颜色、纹理等特征。这些特征可以被深度学习网络模型充分提取,并根据特征差异进行分类和识别。

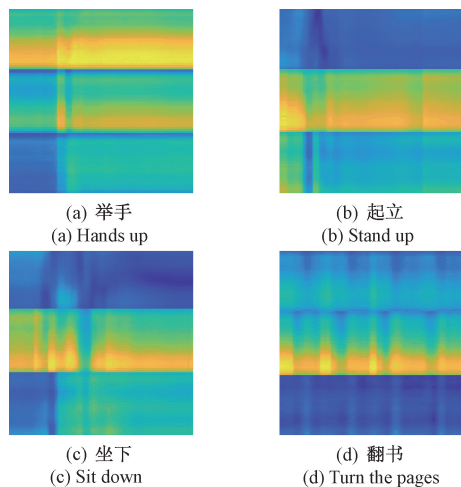


图 9 4 种课堂行为的振幅能量图

Fig. 9 Amplitude energy maps for four classroom behaviors

1.4 训练预测

1) 迁移学习

迁移学习是一种将预先训练好的模型转移到新任务上

的一种训练方法^[22-23]。其优势在于降低数据需求,提高学习效率 and 准确性,同时具有很强的适应性和较低的维护成本。具体而言,迁移学习通常由两个阶段组成:在预训练阶段,通过大量数据进行训练获取一个通用的模型,并将其应用于各种任务中;在微调阶段,将预训练的模型应用到新任务中,并在此基础上进行微调以适应新的要求。

迁移学习的方法根据其侧重点不同,可以分为 4 种:基于实例、基于特征、基于关系和基于模型的方法。本文采用的是基于模型的迁移学习方法,即通过已经训练好的模型来帮助新的任务进行学习。需要说明的是,基于模型的迁移学习并不能直接使用训练好的模型,而是需要事先进行一定的调整,比如删除、增加或替换某一层以及更改相应的参数等,从而适合新任务的训练学习。为此,本文根据课堂行为动作数据特点,设计了一种基于 ResNet 模型的迁移学习方法来识别学生课堂行为动作。

2) ResNet

ResNet 的基本思想是通过引入残差结构(残差块)来解决深度神经网络中梯度消失和网络退化等问题。具体来说,每个残差块的输入被合并到其输出上,即残差块的输出为原始输入加上处理后的信息。这一结构在反向传播计算梯度时,不仅可以传回当前层的梯度,还可以传回下一层的梯度,从而解决了梯度消失的问题。此外,跳越连接还能避免信息的丢失,使得网络具有更强的表达能力。

残差块是 ResNet 的基本单元,由恒等映射 $h(x_l)$ 和残差映射 $F(x_l, W_l)$ 组成,如图 10 所示。恒等映射为图中右侧长箭头部分,通常它将输入直接传递到输出,不进行任何变换。残差映射为图中左侧包含卷积的部分,一般由 2 个或 3 个卷积操作构成。残差块的设计使得网络可以学习到恒等映射和残差映射,从而提高网络的表达能力。




图 10 残差结构

Fig. 10 Residual structure

从数学角度来看,残差块可以表示为:

$$y_l = h(x_l) + F(x_l, W_l) \quad (9)$$

$$x_{l+1} = f(y_l) \quad (10)$$

其中,当 $h(x_l) = x_l$ 时表示恒等映射, x_l 和 x_{l+1} 分别为第 l 个残差块的输入向量和输出向量, $F(\cdot)$ 为残差函

数, $f(\cdot)$ 为激活函数。在卷积网络中, x_i 可能和 x_{i+1} 的特征图的数量不一样, 这个时候就需要使用 1×1 卷积进行升降维, 此时, $h(x_i) = W'_i x$, W'_i 是 1×1 卷积操作。

本文所设计的 ResNet 模型共分为输入、中间残差卷积和输出 3 个部分。其中输入部分包括卷积层(Conv)、批归一化层(BN)、非线性激活函数层(ReLU)和最大池化层(MaxPool)。中间残差卷积部分包括 4 个卷积块, 每个卷

积块由 2 个残差块构成, 每个残差块由卷积层、批处理归一化层和非线性激活函数层堆叠而成, 其中有 3 个残差块在跳层连接中加入了 1×1 卷积进行下采样。如图 11(a)和(b)所示为该网络中的残差基础块。输出部分包括全局平均池化层(GAP)、全连接层(FC)、Softmax 层。总共有 17 个卷积层、1 个最大池化层、1 个全局平均池化层和 1 个全连接层, 如图 11(c)所示为本文设计的 ResNet 模型。

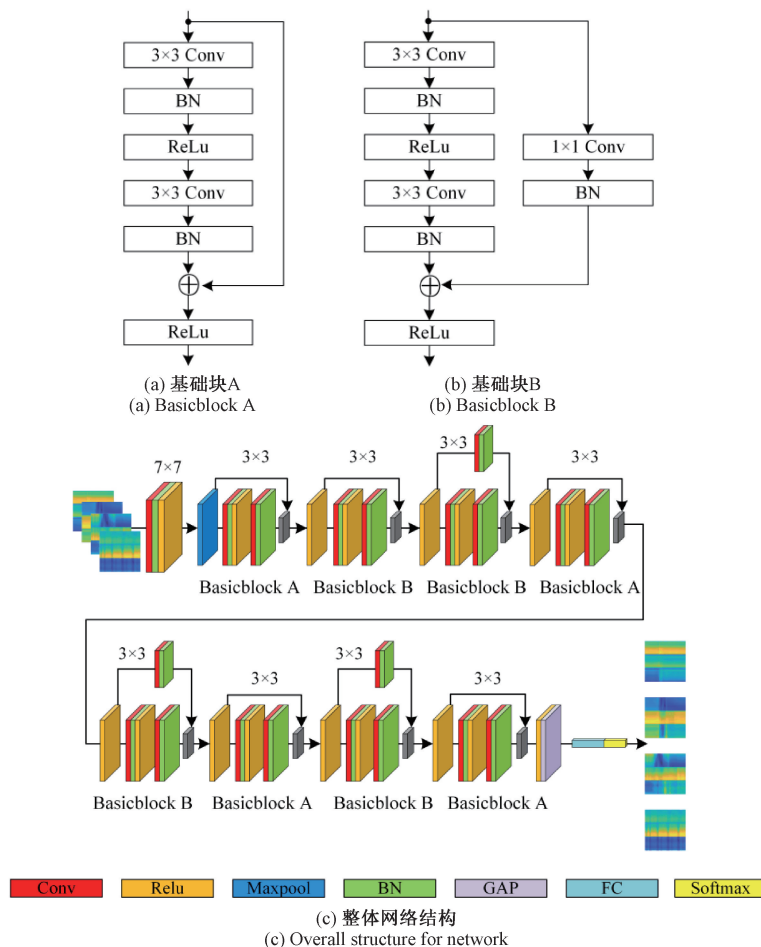


图 11 ResNet 模型结构

Fig. 11 ResNet model structure

原始的预训练 ResNet 模型是基于 ImageNet 大型图像数据集训练的, 拥有良好的参数和性能。然而, 由于其全连接层是基于 1 000 类别的分类, 因此在振幅能量图数据集训练时, 需要先冻结全连接层以上的层, 替换新的全连接层, Softmax 层和分类输出层, 并将全连接层的分类参数改为 4 类, 还需调整相应的训练参数以匹配本数据集的要求。

2 实验与结果分析

2.1 实验设置

1) 数据采集

CSI 数据采集的发送端使用 TP-Link 886N 无线路由

器, 工作在 2.4 GHz 频段; 接收端使用安装 Intel 5300 无线网卡和 Ubuntu 11.04 系统的 ThinkPad X200 笔记本电脑, 并配备了连接网卡的三根全向天线。采用 Linux 802.11n CSI tool AP 模式对网卡固件进行修改, 数据采集频率设置为 100 Hz。

数据采集场景选择在学校普遍存在的阶梯教室和普通小教室。阶梯教室面积为 $12 \text{ m} \times 12 \text{ m}$, 桌椅固定; 小教室面积为 $10 \text{ m} \times 6 \text{ m}$, 桌椅独立不固定。路由器和接收天线分别放置在课桌两侧, 距离为 2 m, 距地高度 80 cm。实验场景平面图如图 12(a)和(b)所示。

数据采集对象为 3 名不同身高体重的学生。实验动作作为举手、起立、坐下、翻书 4 种典型的课堂行为。每名学




图 12 数据采集场景平面图
Fig. 12 Floor plan of the data collection scenario

生分别执行 4 种动作,每个动作大约持续 5 s,每个动作采集 300 组,共计采集 7 200 组数据。此外,为了验证不同距离和采样频率对识别精度的影响,数据还分别在不同距离和采样频率下进行采集。将采集的 CSI 信号数据用 Matlab 进行解析。如图 13(a)~(d)所示,分别为采集的举手、起立、坐下、翻书 4 种课堂行为的原始 CSI 信号波形图,从图 13 中可以看出四种课堂行为的波形存在明显差异。

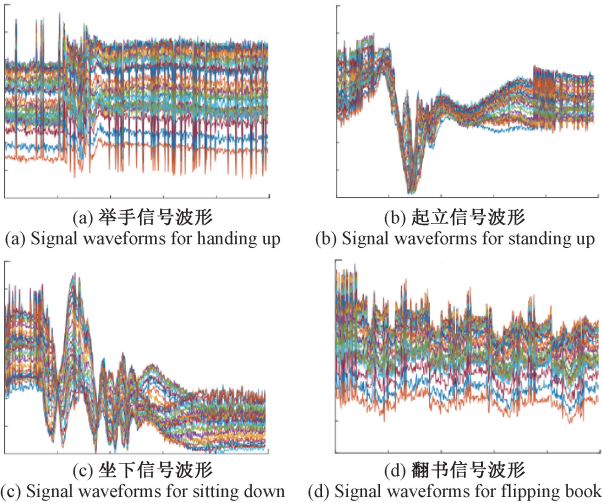


图 13 4 种课堂行为的原始 CSI 信号波形图

Fig. 13 Raw CSI signal waveforms for four classroom behaviors

2) 参数设置

实验数据按照 8:2 的比例划分为训练集和测试集,使用 sgdm 方式进行梯度下降,每次投入 32 张图像进行训练,学习率为 0.000 1,每 10 次迭代输出一次训练参数。

2.2 结果分析

1) 评价指标

本文使用准确率(Accuracy)、精确率(Precision)、召回率(Recall)和 F1 值作为学生课堂行为分类结果的评价标准,评价标准公式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

$$Recall = \frac{TP}{TP + FN} \quad (13)$$

$$F1 = \frac{2 \times P \times R}{P + R} \quad (14)$$

其中, TP 表示真实类别为正类,分类结果也是正类; FP 表示真实类别为负类,分类结果为正类; TN 表示真实类别为负类,分类结果也是负类; FN 表示真实类别为正类,分类结果为负类。

2) 不同教室识别结果

为了验证不同环境对实验结果的影响,数据采集分别选择在阶梯教室和小教室进行,两种教室环境存在不同的多径效应。阶梯教室中 4 种课堂行为的平均准确率为 98.89%,小教室中 4 种课堂行为的平均准确率为 99.07%,其它的识别率如图 14 所示。阶梯教室的平均识别率略低于小教室,其原因可能是阶梯教室中存在更复杂的多径效应,比如阶梯教室有更多的桌椅和其它物体对信号产生干扰,使得识别率略有降低。




图 14 不同教室的平均识别率

Fig. 14 Average recognition rate for different classrooms

如图 15(a)和(b)所示为阶梯教室和小教室的实验结果混淆矩阵。由图可知,阶梯教室中有 0.74% 的举手行为被误判为起立行为,3.70% 的起立行为被误判为坐下行为;小教室中有 3.70% 的起立行为被误判为举手行为。举手和起立行为相互误判的原因可能是由于某些举手行为幅度过大导致与起立行为影响的 CSI 信号变化存在很大相似性。起立行为误判为坐下行为可能是由于起立和坐下行为幅度相似、方向相反,因此两者之间比较容易出现误判的情况。




图 15 不同教室的混淆矩阵

Fig. 15 Confusion matrix for different classrooms

综合来看,两个教室中各行为的识别率都是非常高的。实验结果可以表明,本文提出的方法在不同环境下均具有较高的识别精度,能够适应不同的教室环境,具有较好的环境鲁棒性。

3) 不同学生识别结果

为了验证不同人员对实验结果的影响,实验专门找来身高体重不同 3 名学生进行数据采集,每名学生分别执行 4 种课堂行为动作。3 名学生的平均识别率如图 16 所示,其中学生 1 的平均准确率为 99.17%;学生 2 的平均准确率为 99.44%;学生 3 的平均准确率为 98.61%。由于不同人员的行为幅度、方向和习惯等各有不同,所以识别结果会产生一定程度的波动,但总体来说,其平均识别率仍可达到 98% 以上。




图 16 不同学生的平均识别率

Fig. 16 Average recognition rate for different students

实验结果可以表明,本文提出的方法针对不同人员均具有较高的识别精度,具有较好的人员鲁棒性。

4) 不同子载波数目识别结果

为了验证不同子载波数目对于识别结果的影响,实验时分别选取 10、30、60、90 条子载波进行处理。不同子载波数目的识别率如图 17 所示,10 条子载波的平均准确率为 91.67%;30 条子载波的平均准确率为 94.44%;60 条子载波的平均准确率为 97.96%;90 条子载波的平均准确率为 99.26%。可以看出,随着子载波数目的增多,识别率也会逐渐升高。




图 17 不同子载波数目的平均识别率

Fig. 17 Average recognition rate for different number of subcarriers

因此,本文使用 3 根天线上的全部子载波进行处理,可以大大提高识别精度。

5) 不同采样频率识别结果

高采样频率采集的数据往往会造成数据冗余,增加数据处理的计算量,还容易造成丢包现象;而采样率过低则不能完整的捕捉更细粒度的行为信息。因此,选择合适的

采样频率至关重要。

为了验证不同采样频率对实验结果的影响,实验分别在 20、50、100、200、500 Hz 频率下采集数据。实验结果如图 18 所示,当采样频率为 100 Hz 时,平均准确率达到最高的 98.33%,此时既能使数据冗余量和计算量较小,又能完整的采集到课堂行为信息,识别精度达到较高水平。




图 18 不同采样频率的平均识别率

Fig. 18 Average recognition rate for different sampling frequencies

因此,本文将数据采样频率设置为 100 Hz,以提高识别精度同时减少数据处理量。

6) 不同距离识别结果

由于 WiFi 信号会随着传播距离的增加而减弱,从而对于识别效果产生影响。为了探究不同距离对实验结果的影响,分别在发射端与接收端相距 2、4、6 m 的距离采集数据。实验结果如图 19 所示,2 m 时的平均准确率为 98.33%;4 m 时的平均准确率为 96.67%;6 m 时的平均准确率为 93.33%。可以看出,识别率会随着距离的增加而降低。




图 19 不同距离的平均识别率

Fig. 19 Average recognition rate at different distances

因此,本文设置发射端与接收端距离 2 m,既可以有较大的活动范围,又可以保证较高的识别精度。

7) 不同模型识别结果

为了验证 ResNet 迁移学习模型的性能以及 CSI 振幅能量图在不同模型下的识别效果,训练预测还分别使用 AlexNet^[24]、GoogLeNet^[25]、SqueezeNet^[26] 3 种经典的卷积神经网络模型进行对比实验。实验结果如图 20 所示, AlexNet 的平均准确率为 97.22%;GoogLeNet 的平均准确率为 97.96%;SqueezeNet 的平均准确率为 98.70%;本文的 ResNet 的平均准确率为 99.26%。总体来看,所有网络模型都能达到较高的识别率,但本文的 ResNet 迁移学习模型的识别率均高于其它 3 种网络模型。

实验结果充分说明,ResNet 迁移学习模型具有较好的识别性能,并且 CSI 振幅能量图在不同模型下均具有较高




图 20 不同模型的平均识别率

Fig. 20 Average recognition rate of different models

的识别精度。

3 结 论

本文提出了一种基于 WiFi CSI 的学生课堂行为识别方法。具体来说,首先设计了一系列数据处理流程,引入了三维映射的方式将 CSI 信号转换成振幅能量图;然后设计了一种基于 ResNet 的迁移学习模型,自动提取振幅能量图的高层特征信息,最终实现学生课堂行为的分类识别。实验结果表明,该方法在阶梯教室和小教室中的准确率分别为 98.89% 和 99.07%,并且在对不同人员的测试中均可达到 98% 以上,证明该方法具有较高的识别精度和较好的鲁棒性,为学生课堂行为识别的研究提供了一种新的思路。在未来的研究中,将考虑如何同时对多人的行为进行识别,并且尝试提高发射端与接收端的远距离识别准确率。

参考文献

- [1] 教育部关于印发《教育信息化 2.0 行动计划》的通知[J]. 中华人民共和国教育部公报, 2018(4): 118-125.
Notice of the ministry of 《education on the issuance of the education informatization 2.0 action plan》[J]. Bulletin of the Ministry of Education of the People's Republic of China, 2018(4): 118-125.
- [2] 谭暑秋, 汤国放, 涂媛雅, 等. 教室监控下学生异常行为检测系统[J]. 计算机工程与应用, 2022, 58(7): 176-184.
TAN SH Q, TANG G F, TU Y Y, et al. Classroom monitoring students abnormal behavior detection system[J]. Computer Engineering and Applications, 2022, 58(7): 176-184.
- [3] 闫兴亚, 匡娅茜, 白光睿, 等. 基于深度学习的学生课堂行为识别方法[J]. 计算机工程, 2023, 49(7): 251-258.
YAN X Y, KUANG Y X, BAI G R, et al. Student classroom behavior recognition method based on deep learning[J]. Computer Engineering, 2023, 49(7): 251-258.

- [4] 张立军, 曹江涛, 姬晓飞, 等. 基于深度学习的学生课堂学习状态监测系统[J]. 电子测量与仪器学报, 2024, 38(4): 37-45.
ZHANG L J, CAO J T, JI X F, et al. Design of classroom learning state monitoring system for students based on deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 37-45.
- [5] 岳雨豪. 基于深度学习的课堂行为识别算法研究[D]. 天津: 河北工业大学, 2020.
YUE Y H. Research on classroom behavior recognition algorithm based on deep learning [D]. Tianjin: Hebei University of Technology, 2020.
- [6] YU M, LU B, LI X, et al. Research on children's classroom behavior based on pressure cushion [J]. Journal of Intelligent & Fuzzy Systems, 2021, 40(4): 7939-7949.
- [7] 徐苏杰, 高尚, 张梦坤, 等. 基于 3D 骨骼数据的课堂个人行为识别研究[J]. 计算机与数字工程, 2022, 50(8): 1662-1666, 1685.
XU S J, GAO SH, ZHANG M K, et al. Research on class individual action recognition based on 3D skeleton data [J]. Computer & Digital Engineering, 2022, 50(8): 1662-1666, 1685.
- [8] 鲁勇, 吕绍和, 王晓东, 等. 基于 WiFi 信号的人体行为感知技术研究综述[J]. 计算机学报, 2019, 42(2): 1-21.
LU Y, LYU SH H, WANG X D, et al. A survey on WiFi based human behavior analysis technology [J]. Chinese Journal of Computers, 2019, 42(2): 1-21.
- [9] AKHTAR Z U A, WANG H Y. WiFi-based driver's activity recognition using multi-layer classification [J]. Neurocomputing, 2020, 405: 12-25.
- [10] ZHANG Y J, YUAN B, YANG ZH X, et al. Wi-nn: Human gesture recognition system based on weighted knn [J]. Applied Sciences, 2023, 13(6): 3743.
- [11] HE J A, ZHU W J, QIU L L, et al. An indoor fall detection system based on WiFi signals and genetic algorithm optimized random forest [J]. Wireless Networks, 2024, 30(3): 1753-1771.
- [12] SU J, LIAO ZH L, SHENG ZH G, et al. Human activity recognition using self-powered sensors based on multilayer bidirectional long short-term memory networks [J]. IEEE Sensors Journal, 2022, 23(18): 20633-20641.
- [13] BULUGU I. Gesture recognition system based on cross-domain CSI extracted from Wi-Fi devices combined with the 3D CNN [J]. Signal, Image and

- Video Processing, 2023, 17(6): 3201-3209.
- [14] BIAN J CH, ZHENG M, LIU H, et al. SimpleViTFi: A lightweight vision transformer model for Wi-Fi-based person identification [J]. IEICE Transactions on Communications, 2024, 107(4): 377-386.
- [15] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 27-30, 2016. Piscataway: IEEE, 2016: 770-778.
- [16] 吕游, 封烁, 郑茜, 等. 基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断研究[J]. 仪器仪表学报, 2024, 45(3): 128-143.
- LYU Y, FENG SH, ZHENG X, et al. Research on fault diagnosis of wind turbine icing characteristics based on LeNet5like transfer learning [J]. Chinese Journal of Scientific Instrument, 2024, 45 (3): 128-143.
- [17] FANG Y, LIU W, ZHANG S. Wi-Sensor: Contactless head movement detection during sleep utilizing WiFi signals [J]. Applied Sciences, 2023, 13(13): 7572.
- [18] 牛群峰, 石磊, 贾昆明, 等. 基于改进 ResNet50 的表面肌电信号手势识别[J]. 国外电子测量技术, 2024, 43(4): 181-189.
- NIU Q F, SHI L, JIA K M, et al. SEMG gesture recognition based on improved ResNet50 [J]. Foreign Electronic Measurement Technology, 2024, 43 (4): 181-189.
- [19] 刘苗苗, 樊春玲. 基于 WiFi 信号的老年人居行为识别算法[J]. 电子测量技术, 2023, 46(6): 185-192.
- LIU M M, FAN CH L. Human activity recognition algorithm for elderly home based on WiFi signal [J]. Electronic Measurement Technology, 2023, 46 (6): 185-192.
- [20] 张雷, 张跃, 李明雪, 等. 基于 CSI 的井下人员行为识别方法[J]. 物联网学报, 2020, 4(4): 26-31.
- ZHANG L, ZHANG Y, LI M X, et al. CSI-based underground personnel behavior identification method [J]. Chinese Journal on Internet of Things, 2020, 4 (4): 26-31.
- [21] ZHANG L, LIANG X, SHAN J W, et al. WiFi-based lightweight gesture recognition for coal miners [J]. International Journal of Pattern Recognition & Artificial Intelligence, 2023, 37: 16.
- [22] BOZINOVSKI S. Reminder of the first paper on transfer learning in neural networks, 1976 [J]. Informatica, 2020, 44(3): 291-302.
- [23] 谢平, 赵连洋, 张艺澄, 等. 多源域迁移学习的肌电-惯性特征融合及手势识别[J]. 电子测量与仪器学报, 2024, 38(7): 187-195.
- XIE P, ZHAO L Y, ZHANG Y Y, et al. Multi-source domain transfer learning for electromyography-inertial feature fusion and gesture recognition [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(7): 187-195.
- [24] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [25] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [26] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size [J]. ArXiv preprint arXiv:1602.07360, 2016.

作者简介

杨彦侃(通信作者), 博士, 高级工程师, 主要研究方向为无线传感网络和物联网应用。

E-mail: yyk@imust.edu.cn

马鑫宇, 硕士研究生, 主要研究方向为无线传感网络和物联网应用。

E-mail: 1174591689@qq.com

郁林, 硕士, 主要研究方向为无线传感网络和物联网应用。

E-mail: yl_imust@163.com