

基于 CSI 子载波稳定性分析的人体动作识别研究

甘星宇¹
GAN Xingyu

摘要

随着无线网络技术的普及, Wi-Fi 的信道状态信息 (channel state information, CSI) 广泛用于人体动作识别。由于不同子载波的噪声与稳定性差异大, 直接使用全部子载波会显著降低动作识别准确率。因此, 文章提出一种基于改进局部异常因子 (local outlier factor, LOF) 算法的稳定子载波选择方法。首先采用 Hampel 滤波器与平滑滤波器对 Widar 3.0 数据集进行预处理; 其次设计改进 LOF 算法, 利用 CSI 时序数据构建“均值 - 标准差”特征空间, 通过计算局部可达密度与异常因子来剔除分布异常的子载波。在此基础上, 进一步融合统计与投票机制, 量化各子载波在不同动作类别中的稳定性得分, 并通过多数投票机制筛选出在所有类别中均表现出鲁棒性的全局稳定子载波; 最后基于优选子载波提取时频域特征, 构建人体动作识别模型。实验基于精细 KNN 分类器进行验证, 结果表明: 在多用户、跨用户、跨环境场景下, 识别准确率分别达 94.6%、82.4%、91%, 显著提高识别性能, 验证了稳定子载波选择算法的有效性。

关键词

CSI; 信道状态信息; 子载波稳定性分析; 动作识别; 统计特征

doi: 10.3969/j.issn.1672-9528.2026.05.019

0 引言

随着物联网和人工智能技术的快速发展, 智能感知技术广泛应用于智能家居^[1]、智慧医疗^[2-3]及安防监控等领域。传统的感知技术方法主要依赖于摄像头、惯性传感器等专用设备, 存在部署成本高、隐私保护差、使用不便等问题。因此利用环境中无处不在的无线射频信号来感知人类行为成为研究热点。

人体动作识别技术利用雷达^[4-5]、Zigbee^[6-7]、蓝牙^[8]和 Wi-Fi^[9-10]等无线射频信号来实现, 其中 Wi-Fi 信号凭借其基础设施普及率高、成本低廉和天然的隐私保护特性, 成为人体动作识别应用最为广泛的载体。从 Wi-Fi 信号中提取的 CSI 数据能够捕捉细粒度的信道变化, 为动作识别提供丰富的特征信息。但在实际复杂环境中, CSI 数据会受到严重的噪声干扰, 且不同子载波的信道响应特性差异显著, 导致直接使用全部子载波进行动作识别时, 识别模型的稳定性与准确率均不佳。

针对上述问题, 本文提出一种基于改进局部异常因子 (LOF) 算法的稳定子载波选择方法。本文的实验数据与核心算法框架基于文献 [11]。在前期研究中, 该方法曾被命名为 GAF 算法; 而在本研究中, 为了更准确地反映其基于局

部异常因子 (LOF) 的本质, 并体现本文在数学推导上的深化, 现将其统一表述为“改进的 LOF 算法”。该方法可为基于 Wi-Fi 的人体动作识别提供有效的子载波处理方案。

1 Wi-Fi CSI 感知原理与模型

Wi-Fi 信号在传播过程中遇到人体等障碍物时, 传播路径会发生变化, 形成多径传播。当携带传播空间信息的信号在接收端处进行叠加, 形成多径叠加信号。基于 Wi-Fi CSI 的无线感知技术通过分析这种多径效应对 CSI 幅度与相位的影响, 从而实现对人体动作的精准识别^[12-13]。

CSI 是正交频分复用 (OFDM) 系统中描述多径信道频率响应的复数矩阵, 其元素对应不同天线对间的子载波信道增益, 包含幅度与相位信息。基于 Intel 5300 网卡的采集系统可提取 30 个子载波的 CSI 数据, 在 1 发 3 收天线配置下, 每个数据包为 $30 \times 3 = 90$ 维的 CSI 数据流, 构成了描述信道动态特性的高维时序矩阵。

该模型通过建立“环境 - 人体 - 信道”的关联机制, 将人体动作映射为 CSI 时序信号, 为后续动作识别任务提供物理层数据基础。

2 系统架构

为实现高准确率、鲁棒性强的人体动作识别, 本研究设计并实现了一种基于 CSI 子载波稳定性分析的人体动作识别

1. 湖南中医药大学湘杏学院 (湘阴校区) 湖南岳阳 414615

系统。如表 1 所示，该系统主要由四个模块组成：数据预处理模块、稳定子载波选择模块、特征提取模块以及动作识别分类模块。首先利用 Hampel 滤波器去除异常离散的 CSI 数据，利用滑动平均滤波器降低 CSI 数据中的高斯噪声。再利用 CSI 时序数据构建“均值 - 标准差”特征空间，剔除分布异常的子载波；进而融合统计评估与投票机制，筛选出跨动作类别均表现稳健的全局稳定子载波。最后将把时域特征和频域特征结合起来，组成时频域特征簇，作为精细 KNN 分类器的输入。

表 1 人体动作识别算法

人体动作识别算法
输入：CSI 数据（dat 格式）
数据预处理： Step 1→读取数据：读取数据包中的 CSI 字段，构建复数信道矩阵，计算其幅度。 Step 2→Hampel 滤波器：去除 CSI 数据中的异常离散点。 Step 3→平滑滤波器：对 Hampel 滤波后的 CSI 数据降噪。 稳定子载波选择：设计基于改进 LOF 算法的筛选机制，剔除受环境噪声干扰严重的子载波，保留稳定性高的子载波子集。 特征提取：利用幅度提取时域特征；通过 FFT 得到振幅数据，提取频域特征。 动作识别：确定精细 KNN 分类算法中计算样本间距离的方法，按照 rowrank 随机打乱矩阵的行数，取 80% 的数据作为训练集，20% 作为测试集。
输出：动作识别率

3 数据预处理

通过对一个 CSI 数据包进行分析，发现 90 个子载波在时域上的波动趋势很相似。图 1 显示了用户 2 在执行 Sweep 动作时，90 个子载波在时域上的波形变化情况。可以看出信号在不同的传播路径、接收天线的角度和突发噪声等多方面影响，每条子载波之间都存在一定的差异性。




图 1 Sweep 动作的 90 个子载波波形

3.1 异常值检测与处理

该研究采用 Hampel 滤波器对 CSI 数据中的异常离散点进行剔除处理。该算法基于滑动窗口机制，通过中位数的绝对值估计各采样点对中值的标准差，利用中位数替换原始信号中的异常离散点，实现数据去噪，并有效保留信号的边缘特征。图 2 展示了用户 15 执行 Sweep 动作时，对第 68 号子载波幅度数据进行 Hampel 滤波的前后效果对比。图中选取了第 68 号子载波在 [400, 1 550] 采样区间内的 CSI 幅度数据。通过时域对比可见，Hampel 滤波器有效去除了原始信号中的异常离散点（如图中椭圆所示），显著提升了数据的平滑度。




图 2 Sweep 动作经 Hampel 滤波前后对比图

3.2 噪声抑制

该研究利用平滑滤波器对 Hampel 滤波后的数据进行平滑处理。该滤波器通过对邻域内的采样点进行加权平均，从而减少信号中的高频噪声成分，同时保持信号的低频成分，清晰地呈现信号的变化趋势。其中滤波器窗口大小是决定滤波性能的关键参数，通过评价信噪比和均方根误差，将窗口大小确定为 105。图 3 展示用户 15 执行 Sweep 动作时，smooth 滤波前后的效果对比。




图 3 Sweep 动作经滑动平均滤波前后对比图

图3中选取第68号子载波的全部采样点数据,利用Hampel滤波剔除该子载波幅度数据中的异常离散点后,再利用smooth滤波对数据进行降噪处理。结果表明,经过双重滤波处理后,该子载波上的CSI幅度波形显著平滑,高频噪声得到有效抑制。

4 基于改进LOF算法的稳定子载波选择

4.1 改进LOF算法原理与流程

传统的局部异常因子LOF算法通过计算数据点与其邻域的密度差异来检测异常点。该研究针对CSI数据的统计特性,设计了一种结合统计特征映射与物理空间约束的改进LOF算法。通过构建“均值-标准差”特征空间,识别并剔除分布异常的子载波。该研究对LOF算法进行以下改进。

4.1.1 基于特征空间的异常因子判定

按照动作对CSI数据进行分类,提取每类动作所有子载波的CSI幅度序列,分别计算每个子载波幅度的均值和标准差。将第*i*个子载波幅度的均值 Mean_i 和标准差 Std_i 映射为二维特征空间中的点 $P_i(\text{Mean}_i, \text{Std}_i)$,将时序异常检测转化为分布异常检测,符合信号质量评估。

$$\text{Mean}_i = \frac{1}{N} \sum_{j=1}^N |h_{i,j}| \quad (1)$$

$$\text{Std}_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (|h_{i,j}| - \text{Mean}_i)^2} \quad (2)$$

式中: $|h_{i,j}|$ 表示第*i*个子载波在第*j*个采样点的幅度;*N*表示采样总数。

在特征空间中,定义点 P_i 到点 P_j 的可达距离 $\text{Reachdist}_k(P_i, P_j)$ 为两者欧氏距离与 P_j 的第*k*距离的最大值:

$$\text{Reachdist}_k(P_i, P_j) = \max\{\text{dist}(P_i, P_j), k\text{-dist}(P_j)\} \quad (3)$$

式中: $k\text{-dist}(P_j)$ 表示点 P_j 的第*k*近邻的距离。

基于此,计算点 P_i 的局部可达密度 $\text{lrd}_k(P_i)$:

$$\text{lrd}_k(P_i) = \frac{|N_k(P_i)|}{\sum_{P_j \in N_k(P_i)} \text{Reachdist}_k(P_i, P_j)} \quad (4)$$

式中: $N_k(P_i)$ 表示点 P_i 的*k*距离邻域; $|N_k(P_i)|$ 表示其集合大小。

计算每个子载波点的异常因子 $\text{AF}_k(P_i)$,即其*k*-邻域点的平均局部可达密度与自身局部可达密度的比值:

$$\text{AF}_k(P_i) = \frac{1}{|N_k(P_i)|} \sum_{P_j \in N_k(P_i)} \frac{\text{lrd}_k(P_j)}{\text{lrd}_k(P_i)} \quad (5)$$

当 $\text{AF}_k(P_i)$ 显著大于1,说明点 P_i 在此类动作的邻域内密度显著低于周围,判定为该动作下的异常噪声;接近1,表明该子载波在当前动作类别中属于正常分布。计算得到每类动作中正常分布的子载波幅度均值范围和标准差范围。

4.1.2 融合统计与投票的子载波选择方法

为了筛选出在不同动作类别中均表现出鲁棒性的子载波,本研究提出一种融合统计与投票的子载波选择方法。通过量子子载波幅度的统计特性,结合多数投票机制,有效识别出具有跨类别稳定性的子载波,为后续特征提取提供可靠的信号基础。

设共有*M*种动作类别,对于第*c*类动作数据($c=1,2,\dots,M$),基于子载波幅度的统计特性计算其稳定性得分。定义子载波*i*在类别*c*中的稳定性得分 $S_c(i)$ 为:

$$S_c(i) = f(\text{Mean}_c(i), \text{Std}_c(i)) \quad (6)$$

式中: $\text{Mean}_c(i)$ 和 $\text{Std}_c(i)$ 分别表示第*c*类动作中子载波幅度的均值和标准差; $f(\cdot)$ 表示稳定性评估函数。

通过设定预设阈值 τ ,筛选出该类动作中稳定性较高的候选子载波集合 C_c :

$$C_c = \{i | S_c(i) < \tau\} \quad (7)$$

为了挖掘跨类别的通用稳定特征,采用多数投票机制对所有类别的候选集进行融合。对于任意子载波*i*,计算其在所有类别候选集中的投票权重 $f(i)$:

$$f(i) = \frac{1}{M} \sum_{c=1}^M \mathbb{I}(i \in C_c) \quad (8)$$

式中: $\mathbb{I}(\cdot)$ 为指示函数,当条件满足时取值为1,否则为0。

最终将投票权重超过半数的子载波定义为全局稳定子载波,构建最终的稳定子载波集合 $\mathcal{S}$:

$$\mathcal{S} = \{i | f(i) \geq 0.5\} \quad (9)$$

4.2 稳定子载波选择算法的实现

4.2.1 基于统计特征的初步筛选

以多用户数据集中360条CSI数据为样本,利用改进LOF算法计算每类动作的特征分布,根据异常因子 $\text{AF}_k(P_i)$ 得到每类动作的均值和标准差范围,如表2所示。对均值和标准差取交集,得到幅度均值取值区间为(15.8, 28.0),幅度标准差取值区间为(0.1, 1.23)。

表2 每类动作幅度的平均值和标准差的范围

动作	平均值	标准差
Push/Pull 动作	(16.08, 27.95)	(0.127, 0.978)
Sweep 动作	(15.89, 26.30)	(0.491, 1.228)
Clap 动作	(16.16, 26.97)	(0.119, 1.11)
Slide 动作	(16.13, 26.56)	(0.11, 1.106)

根据融合统计与投票方法,从90个子载波中选取了22个, $\mathcal{S}=\{1, 15, 16, 17, 18, 20, 22, 29, 30, 31, 60, 61, 63, 64, 65, 66, 67, 68, 85, 86, 89, 90\}$ 。

4.2.2 基于物理特性的精炼筛选

考虑到MIMO系统中收发天线的空间分布特性,以及OFDM系统中相邻子载波的频率相关性,该研究引入了物理

约束修正机制。通过波形分析发现,每对天线的首尾子载波(如第1、30、31、60、61、90号)受边界效应影响,波形波动大且不稳定,如图4所示。




图4 每对天线的首尾子载波

同一天线对下,相邻连续的子载波受人体动作影响呈现高度相似的波形趋势,而非连续的孤立子载波往往包含噪声。因此,强制剔除首尾子载波,优先选取连续的子载波序列。最终选取了两组最优子载波子集:第15~18号子载波(第一对天线,如图5所示)和第63~68号子载波(第三对天线,如图6所示)。




图5 用户2的Push/Pull动作




图6 用户2的Push/Pull动作

从图5~6可以看出,两组子载波在Push/Pull动作下均表现出清晰且稳定的时域波形,能够有效表征人体动作特征,

为后续的分类识别提供了高质量的数据基础。

5 动作识别模型

5.1 特征提取

CSI数据经过预处理之后,剔除了离散点,消除了大部分噪声,得到相对平滑的数据。经过稳定子载波选择算法,得到相对稳定的子载波。但是,CSI数据仍然缺乏辨识度,不能直接将数据放入分类器中进行识别。本研究拟采用时域分析方法和频域分析方法来分析信号的两个不同方面,提取25个时频域特征值组成特征簇。时域特征值包括最大值、最小值、峰峰值、均值、方差、标准差、均方值、均方根值和方根幅度九个有量纲特征值,峭度、脉冲因子、波形因子、峰值因子、偏度和裕度因子六个无量纲特征值。频域特征值包括振幅最大值、振幅最小值、振幅中位值、振幅平均值、振幅峰值、重心频率、均方频率、均方根频率、频率方差、频率标准差。

5.2 精细KNN分类器

K近邻(KNN)算法是一种基于实例的非参数化监督学习方法,核心机制在于利用特征空间中的距离度量来推断样本类别。经过预处理和稳定子载波选择后的CSI信号被构建为多维特征向量,有效表征人体动作在时域和频域上的动态变化模式。KNN算法通过计算测试样本与训练集中已知动作标签样本之间的欧式距离,有效捕捉CSI特征在多维空间中的局部聚集特性。鉴于CSI信号在不同动作下表现出的数值分布差异,欧氏距离能够精确量化待测样本与标准动作模板之间的相似度,从而依据最近邻原则实现精准分类。

此外,采用精细KNN策略综合考量多个近邻样本的投票权重,进一步增强分类器在面对无线信号多径效应引起的微小波动时的鲁棒性,从而实现对人体动作的精确分类。

6 实验与分析

6.1 实验设置

6.1.1 数据集

本研究采用清华大学研究团队公开的Widar3.0人体动作识别数据集。该数据集是目前无线感知领域内高质量、多维度的公开数据集,能够充分反映环境因子对CSI变化的影响,为动作识别算法的鲁棒性研究提供了坚实的数据基础。数据集涵盖了人体常见的四类典型动作,分别为Push/Pull、Sweep、Clap和Slide,涵盖了上肢运动的主要模式。实验在配备桌椅的普通空教室和宽敞无遮挡的大厅两种不同的物理环境中进行采集,设定了人体站立的5个不同位置(坐标范围覆盖0.455~1.365 m)以及5个不同的脸部朝向角度(范围覆盖-90°~90°)。同时设置了6个不同位置的接收机。

为全面评估模型性能,该研究基于 Widar3.0 构建了三个子数据集,通过多维度数据集的验证来有效评估模型在复杂现实场景下的鲁棒性。多用户数据集包含 11 名用户(用户 1~3、10~17)共 360 条数据,固定了采集环境(教室)及用户姿态参数,用于验证模型在多用户场景下的泛化能力。跨用户数据集为用户 5 的 20 条数据,与多用户数据集保持相同的采集环境和用户姿态参数,用于测试模型对新用户的识别能力。跨环境数据集为用户 2 在大厅环境下采集的 3 750 条数据,涵盖了人体站立位置、面部朝向及接收机位置的所有可能组合,用于测试模型对环境变化和空间位置差异的鲁棒性。

6.1.2 实验环境

实验在 Windows10 上的 MATLAB R2021b 软件进行,处理器为 Intel i7-9700K,内存为 32 GB。

6.2 评价指标

该研究使用精确率(Precision, P)、召回率(Recall, R)、 F_1 -score(F_1)、宏平均(Macro- F_1)评价模型的动作识别效果。

精确率表示在所有被模型预测为正类的样本,实际为正类的比例。即:

$$P = \frac{TP}{TP + FP} \quad (10)$$

召回率表示在所有实际为正类的样本中,被模型正确预测为正类的比例。即:

$$R = \frac{TP}{TP + FN} \quad (11)$$

F_1 表示精确率与召回率的调和平均数。即:

$$F1 = \frac{2P \times R}{P + R} \quad (12)$$

Macro- F_1 对所有类别的 F_1 取算术平均值。即:

$$\text{Macro-}F_1 = \frac{1}{n} \sum_{c=1}^n F_{1c} \quad (13)$$

6.3 实验结果与分析

6.3.1 实验结果

该研究在多用户、跨环境及跨用户三个数据集上进行,实验结果如表 3 所示。结果表明:在多用户数据集上识别性能优秀,精确率、召回率和 F_1 均维持在 0.937 以上,Macro- F_1 达到了 0.946。在跨环境数据集中 Macro- F_1 为 0.910,其中 Slide 动作 F_1 为 0.817,表现一般;Sweep 和 Clap 动作在 F_1 指标上表现优异,均高于 0.96。在跨用户数据集中 Macro- F_1 为 0.824,其中 Sweep 和 Slide 动作保持了较高识别率,Push/Pull 和 Clap 动作的识别率下降至 75%,表明模型泛化能力有待提高。

表 3 实验结果

动作数据集	多用户	跨环境	跨用户
Push/Pull ($P/R/F_1$)	0.937/	0.896/	0.750/
	0.964/	0.889/	0.750/
	0.950	0.892	0.750
Sweep ($P/R/F_1$)	0.950/	0.975/	0.893/
	0.951/	0.962/	0.926/
	0.950	0.968	0.909
Clap ($P/R/F_1$)	0.953/	0.963/	0.750/
	0.942 /	0.967/	0.750/
	0.947	0.965	0.750
Slide ($P/R/F_1$)	0.937/	0.808/	0.889/
	0.924/	0.826/	0.889/
	0.937	0.817	0.889
Macro- F_1	0.946	0.910	0.824

如图 7 所示,Clap 识别正确的次数是 3 444 次,误判为其余三种动作类别的次数为 95、0、23,召回率为 96.7%。总体而言,该方法在同分布场景下达到了较高水平,且在跨域场景下展现了良好的泛化潜力。


真实类	1	2	3	4		
	6415	62	112	628	88.9%	11.1%
	78	3490	1	59	96.2%	3.8%
	95		3444	23	96.7%	3.3%
	576	30	19	2968	82.6%	17.4%
	1	2	3	4	TPR	FNR
	预测类					

图 7 跨环境数据集的混淆矩阵图


(资料来源:文献[11])

6.3.2 消融实验

通过消融实验验证稳定子载波选择模块对动作识别性能的提升效果,实验结果如图 8 所示。从图 8(a)中可以看出,在多用户数据集上使用全部子载波作为精细 KNN 分类器的输入时,各动作的识别率普遍较低。尤其是 Slide 动作识别率仅 75%。而使用改进 LOF 算法筛选出的两个稳定子载波子集时,所有动作的识别率均有显著提升。这表明,通过稳定子载波选择算法,有效剔除了受噪声干扰严重的子载波,保留了对动作敏感的稳定子载波,从而大幅提升了模型的识别性能。改进 LOF 算法在跨环境数据集上的动作识别效果依然保持相对较高的水平,如图 8(b)所示。



(a) 多用户数据集在不同子载波集合上的识别效果对比



(b) 不同数据集在不同子载波集合的识别效果对比

图 8 消融实验结果

(资料来源: 文献 [11])

在多用户数据集上, 通过消融实验对比了单独使用时域特征、单独使用频域特征以及时频域特征簇的识别性能。实验结果如图 9 所示。




图 9 时频域特征的效果对比

(资料来源: 文献 [11])

实验表明单一特征的识别效果存在明显局限性: 仅使用时域特征时, 模型难以有效捕捉动作的频率特性, 导致对周期性动作 (如 Sweep) 的识别率较低; 仅使用频域特征时, 虽然能反映动作的频率分布, 但丢失了时间维度上的动态变

化信息, 对瞬态动作 (如 Clap) 的识别准确率不足 75%。对比可看出, 将时频域特征簇作为分类模型的输入时, 识别性能显著高于使用单一频域或时域特征, 四类动作的识别率均超过了 90%。实验表明, 时频域特征簇结合了动作在时域上的动态变化和频域上的分布特性, 有效提升了分类模型对人体动作识别的准确率。

7 结论

该研究提出了一种基于 CSI 子载波稳定性分析的人体动作识别方法, 通过设计改进 LOF 算法, 选取稳定子载波子集, 结合信号的时域和频域特点, 提取 25 个时频域特征值组成特征簇, 显著提升了动作识别的准确率。通过在多用户、跨环境和跨用户三个数据集上进行实验, 分析实验结果可知: 在多用户数据集上人体动作识别率均超过了 93%, 平均性能优异, 验证了稳定子载波选择算法的有效性; 在跨环境数据集上, Macro- F_1 达到了 91%, 显示出该方法跨域性能良好; 在跨用户数据集上 Macro- F_1 为 82.4%, 说明该方法对新用户的适应性能有待提高。在后续的研究中将重点探索用户无关的特征表达, 进一步提升泛化能力。

参考文献:

- [1]DING J Y, WANG Y. A Wi-Fi-based smart home fall detection system using recurrent neural network[J]. IEEE transactions on consumer electronics,2020,66(4): 308-317.
- [2]XU G A, WANG F F, ZHANG M, et al. Efficient and provably secure anonymous user authentication scheme for patient monitoring using wireless medical sensor networks[J]. IEEE access, 2020, 8: 47282-47294.
- [3]GAO L, ZHANG G F, YU B, et al. Wearable human motion posture capture and medical health monitoring based on wireless sensor networks[J]. Measurement, 2020, 166: 108252.
- [4]BANERJEE D, RANI S, GEORGE A M, et al. Application of spiking neural networks for action recognition from radar data[C//International Joint Conference on Neural Networks (IJCNN). Piscataway:IEEE,2020[2026-04-27]. <https://ieeexplore.ieee.org/document/9206853>.DOI:10.1109/IJCNN48605.2020.9206853.
- [5]ZHAO Y N, ZHANG Z H, ZHANG Z L. Multi-angle data cube action recognition based on millimeter wave radar[C//2020 Chinese Control And Decision Conference (CCDC). Piscataway: IEEE, 2020: 4983-4987.
- [6]MA H, LIU H. Research on human motion recognition system based on MEMS sensor network[C//2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Piscataway: IEEE, 2019: 2530-2534.

一种 AI Agent 驱动的意图网络设计与实现

周洪利¹

ZHOU Hongli

摘要

面对网络环境日益异构化与配置需求复杂化的挑战,传统基于脚本或模板的自动化配置方法存在灵活性差、语义理解能力不足的问题。意图网络作为一种变革性的网络架构范式,通过将上层业务意图自动编译为底层网络策略,重构了网络管理模式。针对传统意图网络语义理解匮乏与大模型事实幻觉的问题,文章提出一种由 AI Agent 驱动的神经符号协同意图网络架构,该架构通过引入基于思维链的意图解析机制和语义-物理双重锚定机制从源头阻断幻觉,并构建基于 MCP 网关的内生安全与遥测闭环体系,有效解决了运维开环难题。实验结果表明,在非确定性生成任务中,意图解析精度与幻觉抑制效能上取得了显著提升。同时,端到端原型验证了底层确定性控制逻辑的闭环连通性,为智能网络管理提供了工程实践参考。

关键词

AI Agent; 意图网络; 软件定义网络; 神经符号协同

doi: 10.3969/j.issn.1672-9528.2026.05.020

0 引言

近年来,物联网、云计算等互联网业务的快速发展,促使网络流量呈现快速增长。这不仅对带宽、延迟、服务质量等指标提出了更高要求,也对网络配置方法提出了新的挑战。在传统网络架构中,由于软硬件耦合紧密、配置方式相对简单,导致灵活性不足。软件定义网络^[1]是一种新的网络架构,具有转控分离、集中控制、开放可编程等特点,提升了网络管理的灵活性。但是软件定义网络也面临着策略制定高度依

赖专家经验和自动化程度不足等问题。意图网络(intent-based networking, IBN)是一种新型的网络范式,又称为基于意图的网络或意图驱动网络,其基本思想是解析用户输入的业务需求,并将这些业务需求转化为可执行的网络配置。目前,IBN 已逐渐成为网络领域的研究热点。不过,当前多数 IBN 方案在处理自然语言意图时,仍依赖预定义的静态模板或者简单的关键词匹配,难以应对模糊、复杂的真实业务场景。

大语言模型的产生和发展,特别是 AI Agent 的出现,为意图网络的研究注入了新的动力。本文在梳理意图网络、软件定义网络、大语言模型及 AI Agent 研究现状的基础上,提

1. 江苏省未来网络创新研究院 江苏南京 211100

- [7] TUFEK N, YALCIN M, ALTINTAS M, et al. Human action recognition using deep learning methods on limited sensory data[J]. IEEE sensors journal, 2019, 20(6): 3101-3112.
- [8] KIM S, JEONG J, SEO S G, et al. Remote recognition of moving behaviors for captive harbor seals using a smart-patch system via bluetooth communication[J]. Micromachines, 2021, 12(3): 267.
- [9] LIU J, LIU H B, CHEN Y Y, et al. Wireless sensing for human activity: a survey[J]. IEEE communications surveys and tutorials, 2019, 22(3): 1629-1645.
- [10] WANG Z J, JIANG K K, HOU Y S, et al. A survey on human behavior recognition using channel state information[J]. IEEE access, 2019, 7: 155986-156024.

- [11] 甘星宇. 基于 Wi-Fi 子载波优化选择的人体动作识别研究[D]. 长沙: 湖南工商大学, 2022.
- [12] 苏健, 郑毓煌, 陈思光. CGAC: 一种基于 CSI 的人体动作识别方法[J]. 南京邮电大学学报(自然科学版), 2024, 44(6): 12-24.
- [13] DIAZ G, SOBRON I, EIZMENDI I, et al. Channel phase processing in wireless networks for human activity recognition[J]. Internet of things, 2023, 24: 100960.

【作者简介】

甘星宇(1997—), 女, 湖南汨罗人, 硕士, 研究方向: 无线感知与智能处理, email: 307725172@qq.com.

(收稿日期: 2026-03-24 修回日期: 2026-04-30)