

# 基于特征金字塔网络与树莓派的护理床智能控制方法研究

杜特, 宋扬

(中国医科大学附属盛京医院, 沈阳 110022)

**摘要:** 为解决传统护理床中存在的效率低、操作复杂等问题, 研究通过特征金字塔进行手势检测, 并引入通道注意力与 Transformer 注意力对特征金字塔进行优化, 并在树莓派的基础上设计了一个护理床控制系统, 然后将优化后的特征金字塔应用于其中, 从而设计出一种结合特征金字塔网络与树莓派的护理床智能控制系统; 结果显示, 改进模型在 COCO 数据集上的准确率可达 95%; 在角度测试误差中, 改进模型的最小误差率为 1.17%, 证明了其精度较高; 在识别率与平均测试时间中, 改进模型的识别率在不同指令中的最高可达 98.7%, 平均测试时间为 0.18 s, 证明了其有效性, 并进一步证明了其准确性; 基于该控制方法的智能护理床能够有效提高老年人的护理质量和舒适度, 为智能护理床的进一步发展提供了新的方向。

**关键词:** 护理床; 控制; 通道注意力; Transformer; 特征金字塔

## Intelligent Control Method for Nursing Beds Based on Feature Pyramid Network and Raspberry Pi

DU Te, SONG Yang

(Shengjing Hospital of China Medical University, Shengyang 110022, China)

**Abstract:** In order to solve the problems of low efficiency and complex operation in traditional nursing beds, this paper studies gesture detection through feature pyramids, and introduces channel attention and Transformer attention to optimize the feature pyramids. Based on Raspberry Pi, a nursing bed control system is designed, and then the optimized feature pyramids are applied in the system, thus designing a nursing bed intelligent control system combining feature pyramid network and Raspberry Pi. The results show that the accuracy of the improved model on the COCO dataset can reach 95%. In the angle testing error, the minimum error rate of the improved model is 1.17%, which proves its high accuracy. In terms of recognition rate and average testing time, the highest recognition rate of the improved model in different instructions can reach 98.7%, with an average testing time of 0.18 s, which proves its effectiveness and accuracy. Intelligent nursing beds based on this control method can effectively improve the nursing quality and comfort of the elderly, providing a new direction for the further development of intelligent nursing beds.

**Keywords:** nursing bed; control; channel attention; Transformer; feature pyramid

### 0 引言

在人口老龄化不断加剧的背景之下, 老年人的身体机能衰退, 日常活动能力受到严重影响, 对护理的需求日益凸显。护理床作为一种常用护理设备, 其能够为老年人提供更好的照顾<sup>[1-2]</sup>。然而, 传统的护理床大多依赖于手动控制, 这不仅耗时耗力, 而且容易出现人为错误<sup>[3-4]</sup>。因此, 亟需设计出一种多功能医用护理床来为老人提供更加安全舒适的环境, 以及为医护人员带来更加便利的操作体验<sup>[5]</sup>。近年来, 物联网与人工智能技术迅速发展, 将其中的先进技术应用于智能护理床, 已经成为护理床研发的新趋势。文献 [6] 中为改善已有护理床识别效果不佳, 无法准确判

断患者的动作的缺点, 设计出了一种基于慢特征分析方法的动作识别模型, 其通过慢特征分析对护理床的信号进行再处理之后再建立识别模型, 结果表明该模型准确率可以达到 87.03%, 具有较高的准确率和效率<sup>[6]</sup>。文献 [7] 中为给患者提供更好的体验和安全性, 设计出一种基于深度多任务学习的智能护理床控制算法, 其通过集成传感器收集数据, 并采用深度多任务神经网络进行分类与识别, 结果显示该算法识别精度较高<sup>[7]</sup>。由于现有技术不能实现护理床与轮椅一体, 文献 [8] 中设计出一种新型护理床椅, 将其多个构件组合, 并根据最小包容面积法计算出各个支撑部件的最佳位置, 有限元仿真结果显示, 该护理床椅稳

收稿日期: 2024-04-13; 修回日期: 2024-05-20。

作者简介: 杜特(1989-), 女, 大学本科。

通讯作者: 宋扬(1988-), 女, 博士。

引用格式: 杜特, 宋扬. 基于特征金字塔网络与树莓派的护理床智能控制方法研究[J]. 计算机测量与控制, 2024, 32(9): 206-212.

定性较高<sup>[8]</sup>。文献 [9] 中针对生活不能完全自理的老人的护理问题, 设计出一种基于综合新产品开发与感性工法的集成技术, 其从不同的角度对护理床进行感性意象分析, 结果显示该技术能够有效优化居家护理床, 用户满意度较高<sup>[9]</sup>。但是这些方法还存在模型较复杂、操作较困难的缺点, 由于老年人的身体特性, 对智能护理床的要求更高, 因此, 护理床的交互设计应该更加灵活、简便。特征金字塔网络 (FPN, feature pyramid network) 是一种用于处理不同信息尺度的技术, 其通过逐渐减小图像的分辨率, 以获取不同尺度的图像。在每个尺度上应用特征检测算子提取图像中的特征, 然后将这些特征组合起来形成特征金字塔, 用于后续的对象检测和识别。树莓派是基于 Linux 内核和 Debian 操作系统开发的开源操作系统, 具有体积小、成本低、便携性好、可编程、可联网等特点<sup>[10]</sup>。通过树莓派能够将检测模型压缩, 提高运行速度。鉴于此, 研究将通过将 FPN 与树莓派结合, 设计出一种结合 FPN 与树莓派的护理床智能控制方法, 旨在通过视觉信号的识别和处理, 实现护理床的自动调节和控制。研究的创新性在于通过通道注意力与 Transformer 注意力对传统 FPN 模型进行了改进, 并将改进模型与树莓派结合, 通过树莓派对改进模型进行压缩, 以进一步提升模型的效率。

## 1 基于树莓派与 FPN 的智能护理床系统

### 1.1 基于多层注意力 FPN 的护理床手势控制模型

在智能护理床的设计中, 迅速、准确识别用户的手势对于提升用户体验和护理效果至关重要。随着深度学习技术的发展, 诸多相关专业人士已将其应用于护理床的手势指令控制中。然而, 传统的护理床手势控制方法模型运算复杂度较高, 并且不能充分识别不同尺度上的特征, 导致识别准确率不足, 并且鲁棒性较差<sup>[11]</sup>。FPN 是一种用于目标检测与语义分割任务的深度学习网络, 其能够在不同层次的特征图之间建立连接, 从而更好地捕捉多尺度特征, 提升检测准确率<sup>[12-13]</sup>。因此研究采用 FPN 进行手势检测, 同时, 在 FPN 网络中引入通道注意力与 Transformer 注意力, 防止通道信息丢失以进一步提高网络性能, 从而设计出一种基于多层注意力 FPN 网络模型。模型整体实现流程如图 1 所示。

图 1 中, 该多层注意力机制由一个 Transformer 特征金字塔模块和一个通道注意力模块组成。首先构建 Transformer 特征金字塔模块, 以 ResNet 为网络主体, 设 FPN 网络生成的特征图为  $\{P_3, P_4, P_5, P_6, P_7\}$ , 不同层级的特征表达式如式 (1) 所示:

$$x_i \in R^{H_i \times W_i \times C}, i = 1, 2, 3, 4, 5 \quad (1)$$

式中,  $x_i$  代表第  $i$  个特征图,  $W$  代表特征图的宽度,  $H$  代表特征图的高度,  $C$  代表通道数。接着使用展平操作对二维特征图进行处理, 将其重塑为一维的 Token 形式, 并添加位置特征以保留位置信息。其中, Token 是指一个具有独立语义的最小单元, 每个 Token 都代表一个独立的单元, 具有一定的语义含义, 且其能够被模型处理<sup>[14]</sup>。下一步, 把所有的 Token 序列输入到模块中搭建模型, 具体计算方法如式 (2) 所示:

$$\begin{cases} T_i \in R^{P \times C} \\ P = H \times W \\ Attention(q, k, v) = Softmax\left(\frac{qk^T}{\sqrt{d}}\right)v \end{cases}, i = 1, 2, 3, 4, 5 \quad (2)$$

式中,  $T_i$  代表 Token 形式的特征,  $q$  代表查询矩阵,  $k$  代表键矩阵,  $v$  代表值矩阵,  $Softmax(\cdot)$  表示 Softmax 函数,  $\sqrt{d}$  代表标准差。传统的 Transformer 的计算复杂度较高, 因此, 研究使用多头注意力对 Transformer 中的注意力模块进行替换, 多头注意力机制表达式如式 (3) 所示:

$$M(LN(T_{i-1})) = concat(D_1, \dots, D_h)W_o^i \quad (3)$$

式中,  $M$  代表多头注意力,  $LN(T_{i-1})$  代表归一化操作,  $concat$  代表向量拼接操作,  $D$  代表多头注意力的输入,  $W_o^i$  代表参数矩阵。通过多头注意力模块替换原有的注意力模块后, Transformer 即由多层感知器与多层多头注意力模块组成, Transformer 的输出如式 (4) 所示:

$$\begin{cases} T_i = M(LN(T_{i-1})) + T_{i-1} \\ T_i = mlp(LN(T_i)) + T_i \end{cases} \quad (4)$$

式中,  $T_i$  代表 Transformer 中第  $i$  层的输出,  $mlp(\cdot)$  代表多层感知器的输出函数。下一步对 Token 序列进行重塑, 将其转换为图像, 具体过程如式 (5) 所示:

$$M_i = Reshape(T_i) \quad (5)$$

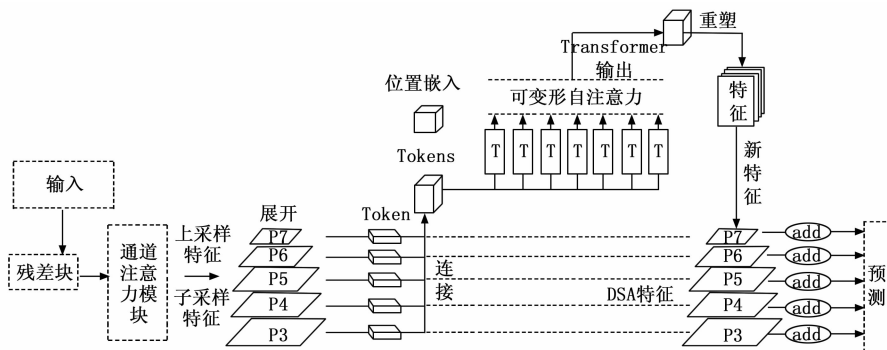


图 1 基于多层注意力 FPN 网络模型实现流程

式中,  $M_i$  代表重塑后的图像,  $Reshape(\cdot)$  代表重塑函数。此时, 特征图为  $\{D_3, D_4, D_5, D_6, D_7\}$ , 最后采用叠加的方式将特征图进行融合, 计算方法如式 (6) 所示:

$$f_i = P_i + P(D)_i, i = 1, 2, 3, 4, 5 \quad (6)$$

式中,  $f_i$  代表叠加之后的特征图,  $P_i$  代表初始特征图,  $P(D)_i$  代表语义特征图。接着进行通道注意力模块的构建, 通道注意力模块的输出图特征与 Transformer 特征金字塔模块中的输出图特征一致, 首先通过平均池化与最大池化操作来融合不同层次之间的特征信息, 计算方法如式 (7) 所示:

$$\begin{cases} g_{avg}(x) = \frac{1}{WH} \sum_{i=1, j=1}^{w, H} x_{ij} \\ g_{max}(x) = \max(x_{ij}) \end{cases}, i \in W, j \in H \quad (7)$$

式中,  $g_{avg}(x)$  代表平均池化操作,  $x_{ij}$  代表不同层次之间特征信息的映射,  $g_{max}(x)$  代表最大池化操作<sup>[15]</sup>。下一步将经过平均池化最大池化之后的特征图送入多层感知器中, 计算方法如式 (8) 所示:

$$f_{w_1, w_2}(y) = W_2 ReLU(W_1 y) \quad (8)$$

式中,  $f_{w_1, w_2}(y)$  代表多层感知器的输出值,  $W_1$  代表第一层感知器的输出权重,  $W_2$  代表第二层感知器的输出权重,  $ReLU(\cdot)$  代表激活函数。然后使用 Sigmoid 激活函数生成最终特征, 计算方法如式 (9) 所示:

$$M = Sigmoid(f_{w_1, w_2}(g_{avg}(x)) + f_{w_1, w_2}(g_{max}(x))) \quad (9)$$

式中,  $Sigmoid(\cdot)$  代表 Sigmoid 函数。至此, 完成基于多层注意力 FPN 的护理床手势控制模型的设计, 然而, 该方法还可能存在目标尺度不平衡的问题。因此, 研究计算出 FPN 网络中不同层级的重叠度, 以推断出不同层级边界框的质量分布。接着重新对不同层级进行加权, 并针对各层构建独立的回归损失函数, 从而实现对不同层级的监督, 重叠度与回归损失函数表达式如式 (10) 所示:

$$\begin{cases} IOU = \frac{|B \cap B_{gt}|}{|B \cup B_{gt}|} \\ L = 1 - IOU + R(B, B_{gt}) \end{cases} \quad (10)$$

式中,  $IOU$  代表重叠度,  $L$  代表损失函数,  $B_{gt}$  代表特征图的真实坐标,  $B$  代表特征图的预测坐标,  $R(B, B_{gt})$  代表特征图的真实坐标与预测坐标的惩罚项。惩罚项的计算方法如式 (11) 所示:

$$R = \frac{d^2(b, b_{gt})}{c^2} \quad (11)$$

式中,  $b_{gt}$  代表某一层级中所有特征图中心点的真实值,  $b$  代表某一层级中所有特征图中心点的预测值,  $d$  代表欧几里得距离,  $c$  代表某一层级中不同特征图的最小距离。最后计算所有层级回归损失的平均值, 将其定为总回归损失, 计算方法如式 (12) 所示:

$$\begin{cases} L_T = \frac{1}{\mu} \sum_{u=1}^u IOU(T) \\ IOU(T) = \frac{\varphi(IOU_i)}{2} L_{IOU} \end{cases} \quad (12)$$

式中,  $L_T$  代表 FPN 网络的总回归损失,  $\mu$  代表 FPN 网络的总层级数量,  $IOU(T)$  代表某一层级的总回归损失,  $\varphi$  代表控制参数, 用于控制重叠度的程度, 其值越大, 说明重叠度对模型的影响越大。

### 1.2 基于树莓派的护理床系统设计

为使模型能够在嵌入式系统中运行, 研究基于树莓派设计了护理床的控制系统。护理床的控制系统包含硬件与软件两部分。其中硬件部分主要包含处理器、温度传感器、水位检测传感器、水温加热、推杆控制、烘干以及清洗等模块。对于系统所需实施的功能, 由于手势检测对系统资源的消耗较高, 研究采用了一种分层控制方案, 即通过上位机和下位机进行合作管理。上位机的功能是图像处理、床体位置的调整以及便盆管理。下位机的功能是数据采集和控制水泵等开关。控制流程见图 2。

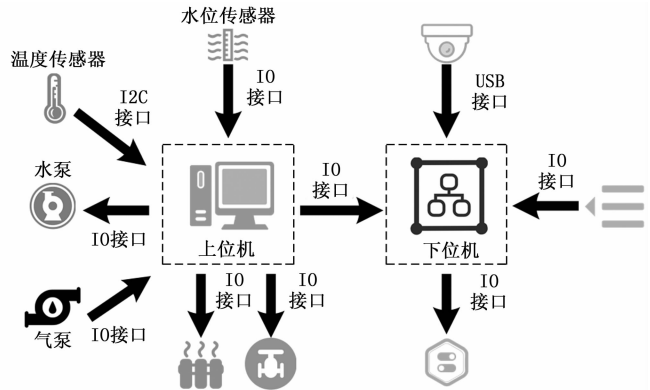


图 2 硬件系统的控制流程

图 2 中, 研究通过树莓派 4B 实现对各模块的控制。树莓派 4B 是树莓派基金会推出的一款单板电脑, 其采用 Broadcom BCM2711 四核处理器, 并配备了 1 GB、2 GB 或 4 GB 的可选用内存, 具有更强大的性能和更多的扩展接口<sup>[16]</sup>。同时, 其支持 4K 高清视频, 具有更快的存储和传输速度。研究采用奥尼 C11 型免驱 USB 摄像头并使用 OpenCV 软件进行图像采集, 该摄像头内置 500 万像素 CMOS 传感器, 能够通过 USB 接口与树莓派连接。

在护理床的电源系统设计中采用了多种电压级别, 包括 220 V 交流电, 24 V、5 V 及 3.3 V 的直流电。220 V 交流电主要为水温加热和烘干模块提供驱动, 之后通过转换模块转换为 24 V, 为其他部件供电。为了适配树莓派 4B 和 STC89C52RC 微控制器的电源需求, 研究分别通过 LM7805CK 和 AMS1117-3.3 V 稳压芯片, 将 24 V 降至 5 V, 再进一步降至 3.3 V, 以确保电压稳定性。

在护理床推杆控制模型设计中, 研究根据不同功能需求, 选择了型号为 JS35DF 的直流 24 V 推杆, 并采用 L298N 双 H 桥驱动模块对推杆进行驱动。该模块能承受高达 46 V 的供电电压, 最大输出电流为 2 A, 并具备过热保护与反馈检测功能, 适合直流及步进电机的大电流驱动。

L298N 允许通过主控制器的 I/O 口设置电平, 从而控制电机的正反转。研究共设计了 3 个推杆, 因此使用六个 GPIO 端口进行信号传递, 其中, GPIO. 21 和 GPIO. 22 用于背部调整, GPIO. 23 和 GPIO. 24 用于腿部调整, 而 GPIO. 28 和 GPIO. 29 控制便盆开关。L298N 的电源使用 24 V 电压, 其输出端 OUT1 和 OUT2 用于控制一个电机, OUT3 和 OUT4 用于另一个电机。

在护理床的清洗模块中, 研究使用 51 系列微控制器控制, 根据树莓派发出的指令启动清洗前的检测与清洗过程, 包括水位监测、温度监测、加热以及清洗等步骤。其中, 水位监测采用电容式传感器来检测关键液位点的变化, 而非连续水位。这种传感器能够通过测量电容的变化来识别水位的高低, 具有 GND (电源接地)、VCC (5 V 供电输入) 和 OUT (信号输出) 3 个端口。当检测到水位时, OUT 端为高电平, 反之为低电平。温度监测采用 GY-906-DCI 型红外温度传感器, 内置 MLX90614ESF-DCI-000-TU 红外温度感测芯片和相关电路, 以便于使用。该芯片通过低噪声放大、模数转换 (ADC) 和数字信号处理 (DSP) 组件, 实现  $-40\text{ }^{\circ}\text{C}$  到  $125\text{ }^{\circ}\text{C}$  范围内, 精度为  $0.02\text{ }^{\circ}\text{C}$  的温度测量<sup>[17]</sup>。红外传感器模块提供 4 个接口: 电源接地 GND、供电 VCC (3.3 V) 以及 I2C 通信的 SDA 和 SCL 线。清洗系统中, 水泵主要功能是对液体进行抽取, 其工作时的电功率为 10 W, 使用 24 V 电压。使用的电磁阀为常闭型, 其工作电压为 24 V。水泵、气泵的控制中, 当 IN1 信号为高电平时, 光耦 EL357N 中的 U2 导通, 使得 MOS 管 Q7 通电, 从而启动水泵。PTC 加热管工作于 220 V 交流电, 额定功率 800 W, 其自调节加热特性保证了加热过程的稳定性。PTC 加热管的控制通过 PWM 信号调节光耦继电器, 从而控制加热时间, 当 PWM 为高电平时加热, 低电平时停止加热。

对护理床的硬件系统设计完成后, 继续对其软件系统进行设计。软件部分主要进行控制算法的植入, 包括对推杆的调节操作、基于传感器反馈的清洁流程以及实现自动清洁等, 在这些软硬件的集成下, 使得护理床能够响应手势指令, 实现护理床床体的多种位置调整, 以及自动执行排泄物清洁、患者隐私体位的温水清洁和干燥等功能。树莓派本身不带闪存, 因此, 用户需要将系统安装在存储卡中。在选择 SD 卡时, 为确保系统的稳定运行, 应该选择至少 8 GB 的存储容量。目前支持树莓派的系统非常多, 如 Ubuntu Core、Raspbian、Windows IoT Core 等。Windows IoT Core 由微软与树莓派合作开发, 能够提供与 Windows 操作系统相似的用户界面和 GPIO 支持; Ubuntu Core 能够提供与传统 Ubuntu 相似的用户体验。而 Raspbian 作为官方最新发布操作系统, 其中预装了 Python、Java 等编程环境及众多实用程序包, 简化了使用过程<sup>[18-20]</sup>。因此, 研究选用 Raspbian 作为操作系统。

研究采用 Python 进行编程, 该语言在 20 世纪 80 年代

末期至 90 年代初期提出, 属于高层次脚本语言, 具有解释型、编译型、交互式以及面向对象的特性。与采用括号区分代码块的语言不同, 其强调代码的可读性, 通过缩进来划分代码的层次, 从而使得代码更易于阅读。摄像头的控制程序需要依赖于 OpenCV 和 PaddleLite 库。OpenCV 是一个开源计算机视觉库, 其支持多个操作系统包括 Linux、Windows、Android 及 Mac OS, 实现了跨平台功能。其主要用 C 语言和部分 C++ 语言编写。PaddleLite 是由百度旗下的飞桨推出的深度学习框架。PaddleLite 采取在树莓派上直接编译的方式, 先更新必要的软件包, 并安装交叉编译所需的 cmake 工具, 从而为编译 PaddleLite 准备环境。在对 PaddleLite 进行编译时, 选择 “tiny\_publish” 模式进行。护理床软件系统的主程序分为床体操作与清洗控制两大部分。床体操作主要是对推杆指令的执行, 而清洗管理则包含了温度监测、水位感测、水温调节、干燥处理及清洗活动的数据采集与执行控制。同时通过摄像头捕获的手势图像启动控制流程, 系统依据各传感器反馈的信息来决定是否激活特定指令。具体流程如图 3 所示。

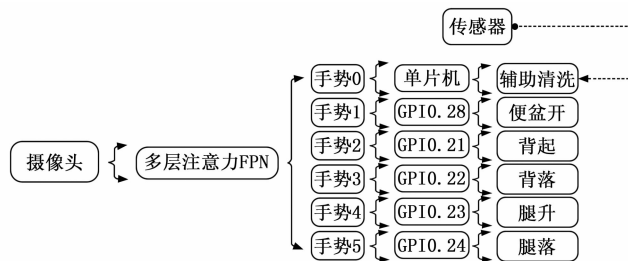


图 3 软件系统控制流程

图 3 中, 首先通过摄像头捕捉数据, 并使用设计的多层注意力 FPN 模型进行手势分析。当使用者作出手势 0 握拳姿势时, 系统识别后执行便盆清洗功能, 当使用者作出手势 1 时 (伸出食指, 其余四指弯曲), 系统识别后控制便盆开启。使用者作出手势 2 时 (伸出食指与中指, 其余三指弯曲), 系统控制背起。使用者作出手势 3 时 (伸出食指、中指和无名指, 其余两指弯曲), 背落功能启动。使用者作出手势 4 时 (除大拇指弯曲外, 其余四指伸出), 床腿升起。使用者作出手势 5 时 (伸出五指), 床腿落下。背部升起与下落的角度设置为  $35^{\circ}$ , 腿升和腿落床体倾斜角度设置为  $60^{\circ}$ 。但手势控制只能使护理床升降固定的角度, 如果想要设置其他角度, 需要进行手动控制。在识别出控制床体姿势调整的指令后, 会调整树莓派通用型输入/输出端口 (GPIO, general-purpose input/output) 电平, 发送信号给电机驱动, 驱使电动推杆完成相应动作, 从而调整床体姿势。若手势指令为启动清洗程序, 则该指令被传递给 STC52 微控制器, 微控制器先检测水位传感器数据, 确认清洗液位和污水处理能力是否符合启动条件, 若条件允许, 则激活电磁阀、水泵、热敏电阻 (PTC, positive temperature coefficient) 加热元件等, 执行清洗动作。选用的推杆

配备有行程限位开关，并考虑了床体各部分的最大形变限制，确保了运动过程的安全性。为提高安全性，系统在接收到相应手势后会使得电动推杆工作 0.5 秒，然后进入再次检测阶段，以便及时纠正错误指令。

在清洗控制模块的设计中，出于安全考虑，系统会先通过水位传感器确认清洗所需的水位条件，只有在条件满足时才启动清洗程序。温度控制分为清洗水温和烘干温度两部分。为简化操作，控制系统默认采用固定的温度设置，以便用户通过手势简便快速控制。同时，研究闭环比例积分微分控制（PID, proportional-integral-derivative control）对温度进行调节，通过脉冲宽度调制（PWM, pulse width modulation）信号的占空比调整来精准控制温度。首先对  $P$  值进行调整，结合红外温度感测模块的反馈、水泵流量、PTC 加热管功率及水的比热容等因素，计算出合适的 PWM 占空比。计算方法如式（13）所示：

$$PWM = \frac{c \times \rho \times v \times \Delta t}{P} \quad (13)$$

式中， $c$  代表比热容， $\rho$  代表密度， $v$  代表单位时间内通过的水流体积， $\Delta t$  代表温差， $P$  代表 PTC 加热管功率。软件编程实现流程如图 4 所示。





图 4 软件编程实现流程

## 2 基于树莓派与 FPN 的智能护理床控制方法结果分析


### 2.1 多层注意力 FPN 模型的性能分析

为验证设计的基于树莓派与 FPN 的智能护理床系统的效果，研究在配备了 Intel Core i9-9900k 处理器、32 GB 运行内存、NVIDIA RTX2070 显卡以及 Windows 10 的操作系统中，使用 python 3.7 进行仿真实验。将模型训练的批量大小设置为 4，设最大迭代次数为 200，初始学习率为 0.001，将衰减系数设置为 0.000 05。COCO 数据集是一个可用于图像检测、语义分割和图像标题生成的大规模数据集，其中有超过 330k 张图像，包含 150 万个目标，80 个目标类别，91 种材料类别。在大规模数据集上对机器学习算法进行测试和评估，能够更好地了解算法在处理数据时的性能和效果。因此，研究首先将设计模型在 Microsoft Common Objects in Context (COCO) 数据集进行训练，计算出不同  $IOU$  值下的精度-召回率（PR, precision-recall）曲线，并与传统的 FPN 模型的 PR 曲线进行比较，对比结果如图 5 所示。

图 5 (a) 展示了传统 FPN 模型在不同  $IOU$  值下的 PR



(a) 传统 FPN 模型



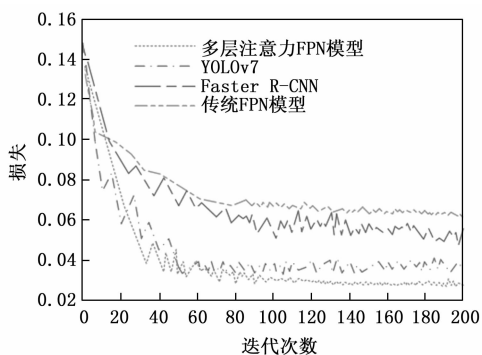
(a) 传统 FPN 模型

- $IOU=0.50$
- $IOU=0.55$
- $IOU=0.60$
- $IOU=0.65$
- $IOU=0.70$
- $IOU=0.75$
- $IOU=0.80$
- $IOU=0.85$
- $IOU=0.90$
- $IOU=0.95$


图 5 不同模型不同  $IOU$  值下的 PR 曲线

曲线，图 5 (b) 为设计的多层注意力 FPN 模型在不同  $IOU$  值下的 PR 曲线。随着  $IOU$  值的增加，传统 FPN 模型与多层注意力 FPN 模型的 PR 值呈逐渐升高的趋势。从图 5 (a) 中可以看出，当  $IOU=0.5$  时，传统 FPN 模型的精确度为 0.22，召回率为 0.07。当  $IOU=0.6$  时，传统 FPN 模型的精确度与召回率分别为 1.0、0.42。当  $IOU=0.7$  时，传统 FPN 模型的精确度与召回率分别为 1.0、0.65。当  $IOU=0.8$  时，传统 FPN 模型的精确度为 1.0，召回率为 0.81。当  $IOU=0.9$  时，传统 FPN 模型的精确度为 1.0，召回率为 0.86。由图 5 (b) 可知，当  $IOU=0.5$  时，多层注意力 FPN 模型的精确度与召回率分别为 0.27、0.12。当  $IOU=0.6$  时，多层注意力 FPN 模型的精确度与召回率分别为 1.0、0.48。当  $IOU=0.7$  时，多层注意力 FPN 模型的精确度与召回率分别为 1.0、0.73。当  $IOU=0.8$  时，多层注意力 FPN 模型的精确度为 1.0，召回率为 0.84。当  $IOU=0.9$  时，多层注意力 FPN 模型的精确度为 1.0，召回率为 0.92。在不同  $IOU$  值下，多层注意力 FPN 模型的 PR 值明显高于传统 FPN 模型，表明其在定位和识别目标方面精确度较高，说明使用基于多层注意力 FPN 模型的护理床能够更好地完成护理任务，证明了该方法的可靠性。下一步计算出多层注意力 FPN 模型在 COCO 数据集上的损失与准确率，并与传统 FPN 模型、Faster R-CNN 以及 YOLOv7 的结果

进行比较, 结果如图 6 所示。



(a) 不同模型的损失



(b) 不同模型的准确率

图 6 不同模型在 COCO 数据集上的损失与准确率

图 6 (a) 为多层注意力 FPN 模型等 4 种模型在 COCO 数据集上训练时的损失, 图 6 (b) 显示了 4 种模型在 COCO 数据集上训练时的准确率。不同模型的损失值均呈降低并逐渐达到稳定的趋势, 不同模型的准确率均呈逐渐上升且逐渐趋于平缓的趋势。从图 6 (a) 中可以看出, 多层注意力 FPN 模型的损失曲线达到平缓状态时, 损失值为 0.024, 传统 FPN 模型、Faster R-CNN 以及 YOLOv7 三种模型的损失曲线达到平缓时的损失分别为 0.63、0.54、0.37, 多层注意力 FPN 模型的损失值明显小于 Faster R-CNN 与传统 FPN 模型, 而略小于 YOLOv7 模型。从图 6 (b) 中可以看出, 多层注意力 FPN、YOLOv7、Faster R-CNN、传统 FPN 四种模型在 COCO 数据集上的准确率分别为 0.95、0.93、0.83、0.78。多层注意力 FPN 模型的准确率显著高于 Faster R-CNN 与传统 FPN 模型, 略高于 YOLOv7 模型。以上结果表明多层注意力 FPN 模型能够有效地减少模型在训练过程中的损失, 提高模型的准确率。

### 2.2 基于树莓派与 FPN 的智能护理床控制方法实际应用效果分析

为验证设计方法在实际应用中的效果, 研究将设计系统植入护理床中进行测试, 首先分别设置不同手势指令下护理床的升起角度, 背部升起角度设置为  $35^\circ$ , 背部下降角度设置为  $-35^\circ$ , 腿升和腿落角度分别为  $60^\circ$  和  $-60^\circ$ , 开便盆角度设置为  $80^\circ$ 。计算出实际测量角度误差, 并与基于 YOLOv7 的护理床的结果进行对比, 如表 1 所示。

表 1 护理床不同指令下角度测试结果

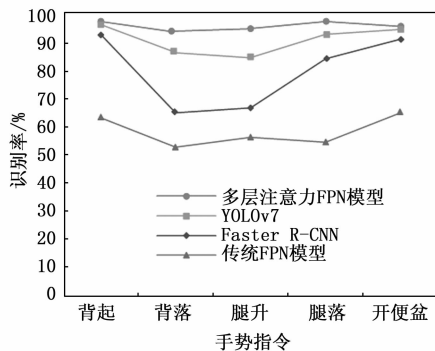
指令	模型	设置角度/ $^\circ$	测量角度/ $^\circ$	偏差/ $^\circ$	误差/ $\%$
背部升起	多层注意力 FPN 模型	35.00	34.10	0.90	2.57
	YOLOv7	35.00	33.40	1.60	4.57
背部下降	多层注意力 FPN 模型	-35.00	-34.10	-0.90	2.57
	YOLOv7	-35.00	-33.40	-1.60	4.57
腿升	多层注意力 FPN 模型	60.00	59.30	0.70	1.17
	YOLOv7	60.00	58.80	1.20	2.00
腿落	多层注意力 FPN 模型	-60.00	-59.30	-0.70	1.17
	YOLOv7	-60.00	-58.80	-1.20	2.00
开便盆	多层注意力 FPN 模型	/	78.90	1.10	1.38
	YOLOv7	/	78.30	1.70	2.13

由表 1 可知, 在背部升起、背部下降、腿升、腿落、开便盆 5 种指令下, 基于多层注意力 FPN 模型的护理床的角度测试误差分别为 2.57%、2.57%、1.17%、1.17%、1.38%, 基于 YOLOv7 的护理床的角度测试误差分别为 4.57%、4.57%、2.00%、2.00%、2.21%。在背起、背落角度测试中, 基于多层注意力 FPN 模型的护理床的误差率比基于 YOLOv7 的护理床的误差率低 2.00%。在腿升、腿落角度测试中, 基于多层注意力 FPN 模型的护理床的误差率比基于 YOLOv7 的护理床的误差率低 0.83%。在开便盆角度测试中, 基于多层注意力 FPN 模型的护理床的误差率比基于 YOLOv7 的护理床的误差率低 0.75%。以上结果表明, 基于多层注意力 FPN 模型的护理床在执行不同指令时误差较小, 进一步证明了该模型的精度较高。最后分别计算多层注意力 FPN 模型、YOLOv7、Faster R-CNN 及传统 FPN 模型对 5 种手势指令的识别率与平均测试时间, 对比结果如图 7 所示。

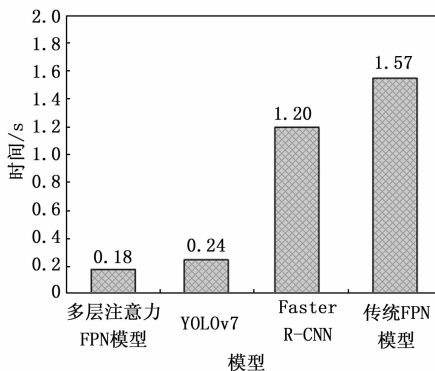
图 7 (a) 展示了不同模型对不同手势指令的识别率, 图 6 (b) 为不同模型的平均测试时间。从图 7 (a) 中可以看出, 多层注意力 FPN 模型对 5 种手势指令的识别率分别为 98.7%、96.2%、96.8%、98.2%、97.3%。YOLOv7 模型对 5 种手势指令的识别率分别为 96.9%、88.2%、85.3%、93.4%、95.8%。Faster R-CNN 模型对不同手势指令的识别率分别为 93.2%、66.4%、68.1%、85.7%、91.6%。传统 FPN 模型对不同手势指令的识别率分别为 63.3%、54.1%、56.9%、54.8%、65.4%。多层注意力 FPN 模型的识别率显著高于其他模型。从图 7 (b) 中可以看出, 多层注意力 FPN 模型、YOLOv7 模型、Faster R-CNN 模型以及传统 FPN 模型的平均测试时间分别为 0.18s、0.24s、1.20s、1.57s。多层注意力 FPN 模型的平均测试时间明显低于其他模型。以上结果证明了多层注意力 FPN 模型的高效性, 并进一步证明了其准确性。

### 3 结束语

随着智能化技术的不断发展, 多功能护理床控制系统的设计成为许多专业人士关注的热点, 为提升护理床的指令识别精度与识别效率, 研究在 PFN 网络中引入通道注意



(a) 不同模型对不同手势的识别率



(b) 不同模型平均测试时间

图 7 不同模型对不同手势的识别率及平均测试时间

力与 Transformer 注意力, 防止通道信息丢失以提高网络性能, 设计出一种基于多通道注意力的 FPN 网络模型, 并基于树莓派设计了智能护理床的硬件与软件, 从而提出一种基于 FPN 与树莓派的护理床智能控制方法。结果显示, 在不同模型不同  $IOU$  值下的 PR 曲线中, 当  $IOU$  值分别为 0.5、0.6、0.7、0.8、0.9 时, 多层注意力 FPN 模型的精确度分别为 0.27、1.0、1.0、1.0、1.0, 召回率分别为 0.12、0.48、0.73、0.84、0.92, 其 PR 值显著高于传统 FPN 模型, 证明其识别精确度较高。在损失与准确率计算中, 多层注意力 FPN 模型的损失曲线趋于稳定时, 损失值为 0.024, 多层注意力 FPN 模型的准确率为 0.95, 其损失值明显低于另外 3 种模型而准确率显著高于其他模型, 证明了其效果较好。在角度误差计算中, 基于多层注意力 FPN 模型的护理床在 5 种手势指令中角度测试误差分别为 2.57%、2.57%、1.17%、1.17%、1.38%, 证明了其精度较高。在平均测试时间计算中, 4 种模型的平均测试时间分别为 0.18 s、0.24 s、1.20 s、1.57 s, 多层注意力 FPN 模型的平均测试时间明显低于其他模型, 证明了其运行效率较高。然而, 研究并未对控制系统的成本进行分析, 后续将在该方面继续进行研究, 在保证系统性能的同时, 降低整体成本。

#### 参考文献:

[1] 李翠玉, 陈智恒. 基于 FDM/FAHP/U-TRIZ 理论的居家多功能康养护理床设计研究 [J]. 家具与室内装饰, 2023, 30

(11): 80-86.

- [2] 吴迪, 赵琢, 陈逢. 基于多 STM32 和 CAN 总线的分布式控制电动护理床设计 [J]. 计算机测量与控制, 2020, 28 (11): 116-121.
- [3] 杨梅, 钟吴诚, 舒天骆. 基于 FBS 扩展模型的适老化产品易用性设计研究 [J]. 包装工程, 2023, 44 (14): 136-144.
- [4] 孙学斌, 俞成涛, 潘澳, 等. 单自由度八杆起背机构的设计与研究 [J]. 机械传动, 2023, 47 (3): 49-56.
- [5] 肖蕾, 程武山. 基于 STM32 的多功能翻身系统设计与控制 [J]. 计算机测量与控制, 2019, 27 (5): 114-117.
- [6] HAMED E, MOHAMED EID N, GHONEIMY HASANIN A. Enhancing situational leadership and emotional intelligence among head nurses and its' effect on their managerial competencies [J]. Journal of Nursing Science Benha University, 2023, 4 (1): 175-190.
- [7] DAVOODNIA V, SLINOWSKY M, ETEMAD A. Deep multi-task learning for pervasive BMI estimation and identity recognition in smart beds [J]. Journal of Ambient Intelligence and Humanized Computing, 2023, 14 (5): 5463-5477.
- [8] 周忠仁, 俞成涛, 周翔宇, 等. 新型护理床椅的背板机构设计及分析 [J]. 机械传动, 2022, 46 (3): 74-80.
- [9] 周红宇, 王宏丽, 陈悦. 基于用户需求的居家护理床设计研究 [J]. 家具与室内装饰, 2022, 29 (2): 66-71.
- [10] 韩书葵, 王振营, 节茂岩. 一种新型护理床的设计与仿真 [J]. 机械设计, 2021, 38 (S2): 160-164.
- [11] HWANG G J, TANG K Y, TU Y F. How artificial intelligence (AI) supports nursing education: Profiling the roles, applications, and trends of AI in nursing education research (1993-2020) [J]. Interactive Learning Environments, 2024, 32 (1): 373-392.
- [12] 徐剑鸥, 罗彩凤, 钟梦诗, 等. 标准化沟通在护理本科生床旁教学中的应用 [J]. 中国护理管理, 2019, 19 (4): 559-563.
- [13] 陈宁峰, 章彰, 戴宇轩. 基于 INPD 与熵权法的居家适老护理床设计 [J]. 包装工程, 2022, 43 (14): 107-114, 138.
- [14] 朱梦琦, 楼艳, 练正梅, 等. 病人参与护理床旁交接班真实体验及期待的质性研究 [J]. 中华护理教育, 2021, 18 (6): 551-555.
- [15] 王巧真, 李新福, 田学东. 远程监护场景下卧床病人异常姿态检测 [J]. 计算机工程与设计, 2021, 42 (4): 1043-1049.
- [16] 赵海鸣, 舒辉波, 万奇龙, 等. 多功能护理床翻折机构设计与运动优化 [J]. 制造业自动化, 2021, 43 (3): 44-49, 93.
- [17] TAK S H, CHOI H, LEE D, et al. Nurses' perceptions about smart beds in hospitals [J]. CIN: Computers, Informatics, Nursing, 2023, 41 (6): 394-401.
- [18] 王晓慧, 向运华. 老年智慧照护服务体系探究 [J]. 学习与实践, 2019 (5): 88-97.
- [19] 薛坤, 祝远虹, 毛安, 等. 基于居家养老模式的适老家具设计研究 [J]. 林产工业, 2020, 57 (12): 61-64.
- [20] 潘国新, 王芳, 曹展宏, 等. 辅助解便护理床的结构设计与分析 [J]. 机械设计, 2023, 40 (7): 92-100.