光电智能识别与感知

DOI：10.16818/j.issn1001－5868.20260417002

# 面向复杂遮挡环境的双目单光子人体检测算法

陈玉婷，刘　通*，程江华，蔡亚辉，程　榜
（国防科技大学 电子科学学院，长沙 410073）

**摘　要：** 面向城市反恐等高风险场景，亟需在非接触条件下对窗后人体目标实现快速、准确的姿态识别与精确定位，而现有依赖主动激光照射成像后进行图像识别的透窗系统难以处理复杂遮挡下的低信噪比回波数据。为此，基于双目单光子激光透窗系统，提出一种适用于目标回波分类的一维时序直方图的R-UNet网络结构。首先，在前端基于目标回波的噪声特性使用轻量化的残差网络自适应地抑制背景噪声，同时保留高频信号细节。随后，在骨干部分设计两级UNet结构捕捉回波信号中的多尺度时间依赖关系，确保微弱的目标信号特征得到增强。最后，通过末端的全连接头将高层特征映射至标签空间完成分类任务。为验证所提方法的有效性，构建了一个采集自真实场景的综合数据集，包含9种不同的目标类别。实验结果表明，所设计的网络相较于基线网络在保持了超过99%的分类准确率的同时，减少了65.1%的推理时间以及91.59%的参数量，更适合在边缘端进行部署。

**关键词：** 单光子探测；目标检测；姿态识别；激光透窗；深度学习
**中图分类号：** TP391.41　**文章编号：** 1001－5868(2026)05－0787－07

## Binocular Single-Photon Human Detection Algorithm for Complex Occlusion Environments

CHEN Yuting, LIU Tong, CHENG Jianghua, CAI Yahui, CHENG Bang
(College of Electronic Science and Technology, National University of Defense Technology, Changsha 410073, CHN)

**Abstract:** In high-risk scenarios, such as urban counterterrorism, rapid and accurate pose recognition and precise localization of human targets behind windows under noncontact conditions are urgently required. However, existing through-window systems, which typically rely on post-imaging recognition algorithms following active laser illumination, struggle to process low signal-to-noise ratio echo data under complex occlusion conditions. To overcome this challenge, we propose an R-UNet architecture designed for target echo classification using one-dimensional temporal histograms, implemented in a binocular single-photon laser through-window system. Firstly, a lightweight residual network was employed at the front end to adaptively suppress background noise based on the noise characteristics of the target echoes while preserving high-frequency signal details. Subsequently, a two-stage UNet structure was designed within the backbone to capture multiscale temporal dependencies in the echo signals, thereby enhancing weak target signal features. Finally, a fully connected head mapped high-level features onto the label space to complete the classification task. To validate the effectiveness of the proposed method, we constructed a comprehensive dataset comprising 9 distinct target categories collected from real-world scenarios. Experimental results demonstrate that the proposed network achieves

收稿日期：2026－04－17.
基金项目：国防科技大学自主科研基金项目(24-ZZCX-JDZ-11).
*通信作者：刘　通

a classification accuracy greater than 99%. Furthermore, compared with baseline networks, this network reduced the inference time by 65.1% and the parameter count by 91.59%, making it highly suitable for edge deployment.

**Key words**: single-photon detection; target detection; posture recognition; laser transmission through windows; deep learning

## 0 引言

传统透窗探测技术主要包括可见光成像、红外成像和穿墙雷达，这些技术在城市复杂建筑环境下均存在显著局限：可见光成像易受玻璃反射光干扰；红外成像对玻璃的穿透能力弱；穿墙雷达则面临空间分辨率低和部署复杂的挑战。

激光透窗技术是指利用非可见光谱激光穿透玻璃照射目标场景，再由传感器接收其反射光以获取场景信息的技术[1-3]，其在交通监控[4]、城市巷战[5]等领域应用广泛。该方法通常由阵列传感器接收主动激光的回波信号，经过重建算法得到二维或三维图像，再将这些图像输入深度学习模型进行后续特征提取与目标识别。这种“先成像、后处理”的串行处理范式在工程实现上较为直观，但会引入额外的成像误差与信息损失，同时增加整体算法流程的复杂度和计算开销。此外，对于具有特殊光学性质的遮挡物体，如单、双面磨砂玻璃和Low-E玻璃等，其光学阵列传感器接收波长范围大、接收面广，难以精准调整门控设置，因此会受到严重的干扰，最终导致无法成像。

现有的研究表明，通过单光子探测器（Single-Photon Avalanche Detector，SPAD）对返回的激光中光子的飞行时间（Time-of-Flight，ToF）进行测量累积形成的直方图数据中包含有丰富的目标场景信息，可以支持在不成像的前提下对目标场景中的目标物体进行分类。2020年，格拉斯哥大学的Alex团队通过使用多层全连接网络学习视频流数据与飞行时间直方图数据之间的关系，实现了场景图像的模糊重建[6]。2023年，中国科学技术大学的徐飞虎团队验证了通过数据驱动的深度学习的方式，可以在实际测试中采集200 m外无人机的15种姿态直方图，并进行分类，分类准确度达79.2%[7]。

结合以上研究，本文提出一种基于双目单光子飞行时间探测的窗后人体姿态识别与定位系统，在前端对接收光子进行光学滤波和门控控制，并在后端通过构建神经网络的方式对获取的返回光子信号进行窗后人体目标的姿态分类。

## 1 系统构成与原理

ToF技术通过利用发射器与目标物体之间能量脉冲往返的时间差与脉冲在穿透介质中的传播速度，能够解算出目标在三维空间中与探测设备之间的距离，根据信号的调制方式与能量脉冲的检测机制可以分为直接飞行时间（direct-ToF，dToF）和间接飞行时间（indirect-ToF，iToF）两大类[8]。

经典dToF系统的原理与构成如图1所示，通过脉冲激光光源向目标探测场景中发射高频短脉冲，中部的时间数字转换器（Time-to-Digital Converter，TDC）分别接收激光脉冲发射的起始时间戳和单光子探测器探测到信号光子时产生的截止时间戳，从而得到光子的飞行时间，经过进一步计算后获得光子的飞行距离。在一段时间内累积多个飞行时间后得到一个光子飞行时间直方图数据，包含对场景中光子反射表面分布的数学描述，可用于后续的分析和处理。该类系统通常具有高动态范围、抗环境光干扰能力强，以及测量距离相对较远的特点。

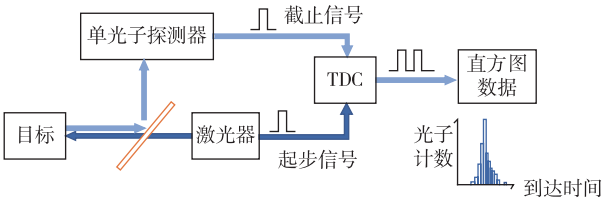



图1 dToF系统原理与构成示意图

根据dToF系统的工作原理搭建一套双目单光子窗后人体目标探测系统，双边探测器同时接收的两路数据对于固定的目标场景回波具有较强的空间一致性，而对于在探测过程中随机产生的探测器本身的热噪声则一致性较弱，因此可以在后续的数据预处理中利用该特性对回波数据进行增强。系统的整体构成如图2所示。

假设目标与探测器和激光器之间的距离足够远且探测器与激光器之间的距离足够近，中央的信

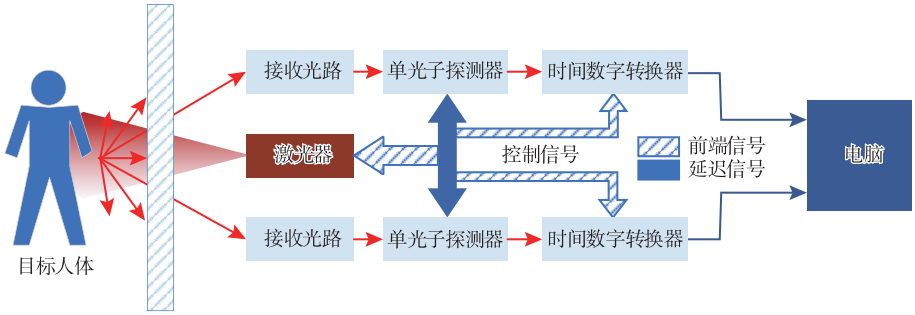



图 2　双目单光子探测系统示意图

号发生器发出两路控制信号，其中一路控制激光器发出脉冲激光的时间，同时将该时间信息传入时间数字转换器中，并为时间数字转换器提供基准时间；另一路控制单光子探测器的开启时间，探测开启时间相较于激光发射时间有一定的延迟，延迟长度取决于探测目标与探测设备之间的距离，最终累积得到的一维直方图数据可以用 $h(n)$ 表示，理想的全反射无延迟情况下，直方图数据中对应位置 $n$ 的时间箱（bin）中的光子数量（即最终累积出的数值）用 $w(n)$ 表示，二者的数学表达为：

$$w(n)=\int_{n\Delta t}^{(n+1)\Delta t} g(t)\times f(t)\mathrm{d}t \tag{1}$$

$$h(n)\sim P\left[\tau(n)+b\right]= P\left\{C\cdot\sum_{i,j,k=1}^{N}\beta(i,j,k)\cdot w\left\{\left[n-\frac{2z(i,j,k)}{c\cdot\Delta t}\right]\right\}+b\right\} \tag{2}$$

公式（1）中 $g(t)$ 表示激光发射的脉冲激光，透过窗户照亮后方的目标场景；数学函数 $f(t)$ 描述经过目标场景中的表面 S 反射回 SPAD 的光子在时间上的不确定性，在该函数中综合考虑了 SPAD 探测器本身的死时间效应以及淬灭复位导致的光子探测概率的变化；$\Delta t$ 表示探测器 SPAD 接收返回光子的持续时间。

累积得到的直方图 $h(n)$ 是 SPAD 对序列上任意时刻 $n$ 探测器对到达的主动信号光子 $\tau(n)$ 和杂散背景噪声光子 $b$ 的泊松观察，使用 $P(\cdot)$ 表示泊松过程，$\tau(n)$ 可认为是到达探测器对应的 $w(n)$ 与激光发射强度系数 $C$ 相乘。

进一步引入光子飞行时间引起的时间延迟，则实际上理想的时间箱 $n$ 中的光子数是 $w\left\{\left[n-\frac{2z(i,j,k)}{c\cdot\Delta t}\right]\right\}$，其中 $z(i,j,k)$ 为目标三维场景中的点 $(i,j,k)$ 与探测器之间的距离，$c$ 为光速。延时后的光子信号与目标场景中的反射率 $\beta(i,j,k)$ 相乘。综合以上考虑，最终得到公式（2）表示非理想情况下基于 ToF 系统的一维单光子飞行时间直方图的数学模型。

而在本研究的激光透窗与窗后人体目标姿态识别的任务中，还需要考虑探测设备和目标之间存在的光学遮挡。对于从场景中的目标表面返回探测器中的光子信号，经过了透射-反射-透射的过程，可以假设从玻璃遮挡的 A 面到 B 面的透射率定义为 $T_{\mathrm{A}\to\mathrm{B}}$，同样地定义从 B 面反向透射回 A 面的透射率为 $T_{\mathrm{B}\to\mathrm{A}}$，则双向等效透射率矩阵为：

$$\boldsymbol{\Gamma}(i,j,k)=T_{\mathrm{A}\to\mathrm{B}}(i,j,k)\cdot T_{\mathrm{B}\to\mathrm{A}}(i,j,k) \tag{3}$$

除了考虑不同方向的透射，还需要考虑玻璃具有一定的厚度和折射率，光在玻璃介质中传播与在大气中传播之间的差异性，以及在粗糙玻璃中经过多次散射导致的脉冲展宽。假设经过玻璃散射后的等效系统脉冲响应记为 $w'(t)$，光学特性导致的附加延迟记为 $\Delta n_g$，此时光子在系统中运行的整体延迟 $d_{i,j,k}=\frac{2z(i,j,k)}{c\cdot\Delta t}-\Delta n_g$，定义光子损失系数为透射率与反射率的乘积，即 $\alpha_{i,j,k}=\boldsymbol{\Gamma}(i,j,k)\cdot\beta(i,j,k)$，则目标场景中的回波可以表示为：

$$\tau_{\mathrm{target}}(n)=C\cdot\sum_{i,j,k=1}^{N}\alpha_{i,j,k}\cdot w'\left(n-d_{i,j,k}\right) \tag{4}$$

假设玻璃所在的平面或曲面由三维体素集合 $G$ 表示，其距离分布为 $z_g(m)$，面向雷达侧的玻璃（A 侧）的等效反射率为 $\beta_g(m)$，则由激光照射在玻璃表面后直接返回光子分布可以表示为光子能量的时间平移和卷积，即：

$$\tau_{\mathrm{glass}}(n)=C\cdot\sum_{m\in G}\beta_g(m)\cdot w\left[n-\frac{2z_g(m)}{c\cdot\Delta t}\right] \tag{5}$$

原有的环境噪声包含的器件噪声和环境光噪声基本不变，需要额外考虑的是太阳光从玻璃表面

反射回探测器的部分以及原目标场景中的杂散光源在遮挡下需经过透射到达探测器，分析后得到此时的噪声模型可以表示为：

$$b' = b_{\text{emit}} \cdot T_{\text{B}\to\text{A}} + b_{\text{env}} + b_{\text{device}} \tag{6}$$

式中，$b_{\text{emit}}$ 表示目标场景中的背景噪声光源发出的噪声光子，如目标场景中的灯光、手电光、火源等；$b_{\text{env}}$ 表示其他环境中的背景噪声光，包括直接到达探测器的光敏区域的光子和由玻璃反射的太阳光光子；$b_{\text{device}}$ 表示 SPAD 器件本身的噪声，包括暗计数、后脉冲等产生的额外计数。由于泊松分布具有可加性，在带有噪声的透窗情况下，单光子探测模型可以表示为：

$$h(n) \sim P\left[\tau_{\text{glass}}(n) + \tau_{\text{target}}(n) + b'\right] \tag{7}$$

## 2 算法设计与网络模型

实验根据分析得到的激光透窗单光子飞行时间探测回波的数学模型，设计了一种针对后续探测目标姿态分类任务的网络，整体网络模型结构如图 3 所示。模型框架主要由三个级联模块构成：用于信号去噪的轻量化残差前端、用于特征提取的精简版 UNet 骨干，以及用于最终分类的多层全连接尾部。下面对各个模块进行详细的分析和介绍，并在后续的章节中对网络中的重要模块做消融实验以进一步分析网络各部分的贡献。

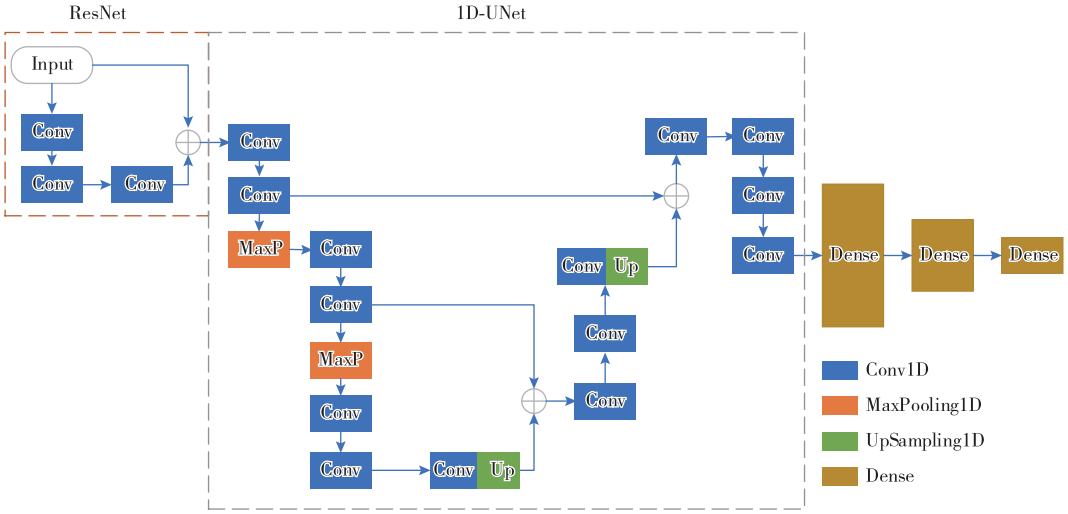



图 3 姿态分类网络模型结构

### 2.1 前端残差去噪模块

结合前文中对回波数据的模型分析，探测器接收到的光子飞行时间回波信号中通常包含三类噪声：一类是由玻璃直接反射回探测器的遮挡噪声，另一类是由环境光中处于探测器响应波段的光子触发探测器产生的背景光噪声，还有一类是由于探测器本身具有暗计数率、后脉冲等特性产生的器件本底噪声。其中第一类噪声可以视为激光对静止的玻璃遮挡结构的探测，在不同的回波信号中具有空间一致性，其余两类噪声则具有较强的随机性。因此，考虑通过数据驱动的方式使得神经网络在前端学习一种结构化方式以去除该类噪声，从而在数据输入到后续的分类网络之前提升信噪比，进一步增大不同姿态类别的回波信号在特征空间中的距离。

前端的去噪模块中包含两个堆叠的残差模块，令 $\boldsymbol{x}_i$ 表示第 $i$ 个残差块的输入，则输出 $\boldsymbol{x}_{i+1}$ 可以表示为：

$$\boldsymbol{x}_{i+1} = F\left(\boldsymbol{x}_i, \{W_i\}\right) + \boldsymbol{x}_i \tag{8}$$

式中，$F(\cdot)$ 表示待学习的残差映射函数。具体而言，每个残差块内部包含 3 个卷积层以及相适应的激活函数。

### 2.2 UNet 骨干网络结构

回波信号经过前端的堆叠残差结构去噪后，理论上可以在后端分类网络训练过程中更新网络参数，学习更适合网络分类的信号重构方向。结合文献[7]中同类任务下的基线网络模型，提出轻量化后的骨干特征提取网络。该网络包含编码器和解码器两个部分，编码器部分通过堆叠的卷积层和下采样模块逐层降低信号特征的空间维度来提取其中的语义特征，并获取更高的感受野。在编码过程中，第 $i$ 阶段的操作可表示为：

$$E_i = \sigma\left\{\text{BN}\left[\text{Conv}\left(E_{i-1}\right)\right]\right\} \tag{9}$$

式中，$E_i$ 代表第 $i$ 层编码器的特征图输出；$\text{Conv}(\cdot)$

表示卷积操作；BN(·)为批量归一化操作；$\sigma(\cdot)$代表激活函数。

解码器部分则负责将特征重建至原始尺度，通过跳跃连接的方式将编码过程中的中间特征与对应的恢复过程中的中间特征相拼接，在解决复杂网络梯度消失问题的同时保留了回波信号中浅层的时间序列中的局部细节特征。解码过程可表示为：

$$D_i=\mathrm{Conv}\left\{\mathrm{Concat}\left[\mathrm{Up}\left(D_{i+1}\right),E_i\right]\right\} \tag{10}$$

式中，$\mathrm{Up}(D_{i+1})$为上采样操作，将语义强但分辨率较低的深层特征图放大，恢复空间尺寸；Concat(·)表示跳跃通道拼接，合并浅层特征和提取后的深层特征。

### 2.3　分类头与损失函数

经过特征提取与合并后的数据通过三层全连接层输出，全连接层的参数量分别设置为 256、128 以及 $N_c$。其中，$N_c$是分类目标数，在每个全连接层后设置 Dropout 层随机丢掉部分参数，迫使模型提升学习能力。

本文使用深度学习多分类任务中的经典评价指标交叉熵作为网络训练时的损失函数，函数的表达式为：

$$L\left(\boldsymbol{p},\boldsymbol{q}\right)=-\sum_{i=0}^{N_c-1}\boldsymbol{p}_i\cdot\log\frac{\exp\left(\boldsymbol{q}_i\right)}{\sum_{i=0}^{N_c}\exp\left(\boldsymbol{q}_i\right)} \tag{11}$$

$$\hat{\boldsymbol{q}}_i=\frac{\exp\left(\boldsymbol{q}_i\right)}{\sum_{i=0}^{N_c}\exp\left(\boldsymbol{q}_i\right)} \tag{12}$$

$$\boldsymbol{p}_i=\begin{cases}1 & ,i=T\\ 0 & ,\mathrm{else}\end{cases} \tag{13}$$

式中，$\boldsymbol{p}_i$表示第 $i$ 类的真实标签值，$i=0,1,\cdots,N_c-1$，$T$为对应类别的目标向量。

具体而言，交叉熵损失函数衡量的是两个概率分布之间的差异，当预测结果中正确类别的概率较高时，交叉熵损失较小；相对地，错误的类别概率较高时，交叉熵损失较大，能够促使模型作出更大的调整。相较于 MSE 等损失函数，交叉熵损失在解决多分类问题的网络训练中能提供更强的梯度信号，从而加速模型的收敛。

## 3　实验与分析

### 3.1　数据集的构建

深度学习模型的准确率与泛化能力在很大程度上取决于训练数据的质量。然而，针对单光子激光透窗探测这一特定任务，目前尚缺乏高质量的公开数据集。为解决这一数据匮乏问题，本研究中搭建了一套双目单光子飞行时间探测的实物系统，在真实场景中进行数据采集，探测系统装置如图 4 所示。

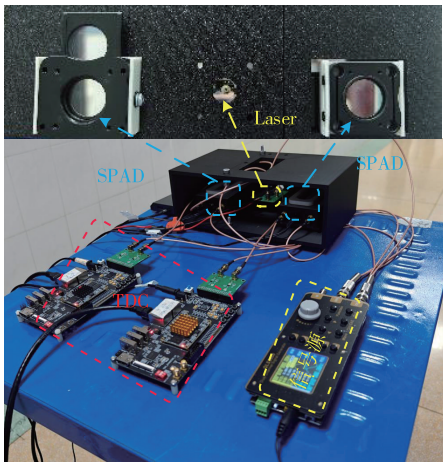



图 4　实验搭建的双目单光子透窗探测系统实物图

为确保所提网络模型真实学习到窗后场景中的目标人体姿态回波形式，采集过程中考虑了不同的特殊玻璃类型以及包含遮挡物的情况。特殊的玻璃类型包括单面磨砂玻璃、双面磨砂玻璃、Low-E 玻璃三种，遮挡物包含仿百叶窗贴膜、轻质窗纱、覆盖水雾三种情况，在有遮挡物的情况下使用的玻璃为普通玻璃，所有玻璃的厚度均为 8 mm，符合绝大多数日常场景，部分遮挡的实际效果如图 5 所示。

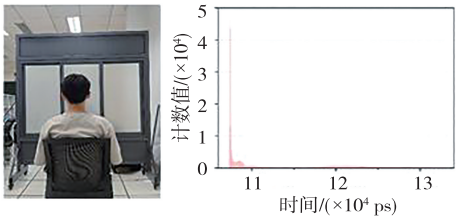



（a）Low-E 玻璃　　（b）磨砂玻璃

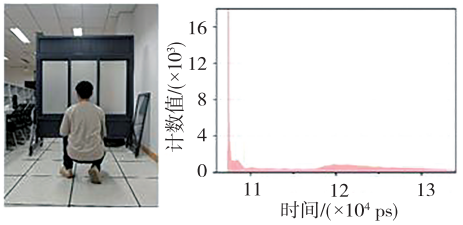
图 5　不同光学遮挡的实际拍摄效果

姿态和目标选取方面，分别对 3 个不同人物的 3 种不同姿态，在 4 个不同距离下采集回波数据，共 36 组实验数据，9 个类别。为了使类别数均衡，根据数据量最少的一组将每个类别的数据按时间顺序转化成 160 个实验数据，共 51 840 个数据以 8∶1∶1 的比例分割为训练集、验证集和测试集用于模型训练和验证。图 6 为单个人物目标不同姿态的回波数据样例，前端的极端峰值为玻璃遮挡反射回的激光回波，其强度大

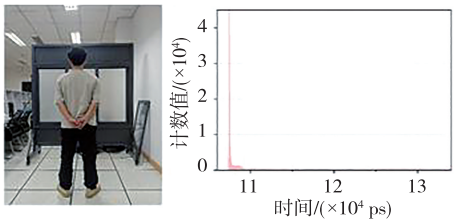
于后方人体目标回波，导致后续返回探测器的能量波动不明显。




（a）样例1




（b）样例2




（c）样例3

图6 回波数据样例

### 3.2 分类实验与结果分析

本实验所使用的服务器环境由表1中给出。

**表1 训练服务器设置**

| 名称 | 信息 |
|---|---|
| CPU | i9-13900K |
| GPU | NVIDIA GeForce RTX4080(16 GB) |
| RAM | 64 GB |
| 框架/环境 | TensorFlow-GPU 2.6.0/Python 3.9.0 |

模型训练轮数设置为100轮，批次大小设置为64，每组数据输入形状设置为(1 024,1)，优化器使用结合了动量优化器和RMSProp的Adam优化器，学习率设置为0.000 1。为避免计算资源的浪费，根据验证集上模型分类的准确率最高值的变化，设置回调函数中的patience值为5，即在5轮训练中，模型在验证集上的准确率未提升则视为模型已经收敛，终止训练并保留准确率最高的模型为最终模型。

将本文模型与其他几种方法进行比较，包括本文的基线模型Image-free网络[7]、先进的一维时间相关序列分类模型ECG classify网络[9]、改进的一维LSTM时间序列预测网络[10]以及适应本文任务场景的一维Transformer网络[11]。

表2中详细列出了本文设计的网络与其他主流一维数据分类网络的对比数据，网络的评估指标包括平均精度值(mAP)、参数量(Parameters)以及单样本推理时间，对于基准的Image-free网络额外测试了浮点运算数(FLOPs)，对比实验的准确率变化在图7中给出。

**表2 本方法在自建数据集上与其他网络方法的对比**

| 网络 | mAP | Parameters | $t$/s |
|---|---|---|---|
| Image-free[7] | 0.993 0 | 11 805 391 | 0.424 |
| ECG classify[9] | 0.443 7 | 25 467 | 0.128 |
| SOTA LSTM[10] | 0.253 7 | 17 546 | 0.260 |
| 1D-Transformer[11] | 0.781 6 | 44 330 | 0.196 |
| 本文 | 0.994 0 | 992 080 | 0.148 |

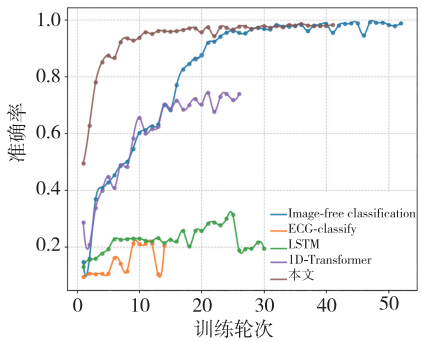



图7 在验证集上不同架构之间的准确率比较

对于ECG classify、LSTM和1D-Transformer网络，尽管网络本身适用于部分任务中的一维数据处理，但在此类任务中表现较差。基准模型Image-free在推理平均精度值上表现良好，但模型体量较大，计算推理和部署消耗较高。相比之下，本文提出的网络在保持了同等平均精度值的同时，参数量从11.8 M缩减至0.99 M(降幅约91.6%)，原本处理单个待分类信号的时间长度由0.424 s缩短至0.148 s，减少了65.1%。

对比实验表明，所提出的网络在分类精度不受影响的前提下，显著降低了计算与存储的成本，具有更高的实时性和部署在边缘端的潜力。

### 3.3 消融实验结果与分析

为验证所提出的模型中各模块构成对网络整体效果的提升作用，分别针对各模块进行消融实验，设置完整网络(Base)、仅前端去噪网络和后端分类网络(Res+Dense)、仅特征提取和分类网络(Unet+Dense)以及去噪并特征提取后直接分类

（Res＋Unet）共 4 组实验，得到的结果如表 3 所示，训练过程中各个网络在验证集上准确率的变化如图 8 所示。

**表 3　消融实验**

| 网络 | mAP | Parameters | 计算量/M |
|---|---|---|---|
| Res＋Dense | 0.706 4 | 40 203 | 11.28 |
| Res＋Unet | 0.921 5 | 705 744 | 566.52 |
| Unet＋Dense | 0.916 1 | 986 575 | 555.89 |
| Base | 0.994 0 | 992 080 | 567.10 |

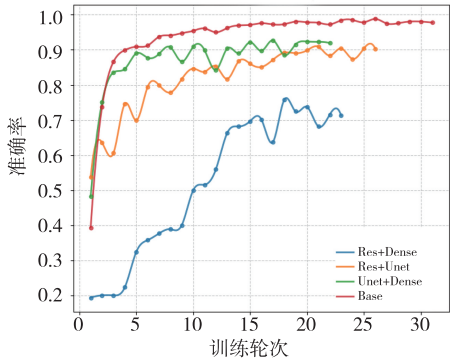



图 8　消融实验中各网络模型在验证集上的准确率比较

结果表明，网络中的各个模块对于提升模型的准确率均有不同程度的贡献。从表 3 中可以看出，完整的网络架构具有最优的检测性能。当移除主干部分的 1D-Unet 网络时，尽管此时的模型具有最少的参数量和最低的计算复杂度，但模型预测准确度相较于完整模型下降了 38.9%，表明骨干网络具有关键的特征提取能力。将完整的网络方案与 Unet＋Dense 和 Res＋Unet 两个方案相对比，计算量分别增加了 0.1% 和约 2%，而 mAP 相较而言分别增加了 7.93% 和 8.57%，在效率上有一定提升。

## 4　结论

针对现有成像式激光透窗系统在窗后非可视人体目标姿态检测与识别任务中存在的运行时间长、资源消耗高、难以应对复杂光学遮挡等问题，设计并制作了一套双目单光子探测系统，并结合具体的数据分析需求，提出了一种轻量化的探测回波人体目标增强检测分类算法，旨在快速、高效地对窗后人体目标姿态进行检测和识别。实验结果表明，相较于基线模型，所提算法在保持了较高的 mAP 的同时，能大幅降低参数量和计算量，更适用于边缘端部署，具有较高的应用价值。未来将在本文算法架构的基础上，对其他遮挡及天气情况进行研究，并将模型部署到嵌入式设备中。

**参考文献：**

[1] Breiter R, Benecke M, Eich D, et al. Extended SWIR imaging for targeting and reconnaissance[J]. Proc. of SPIE, 2018, 10624: 1062403.

[2] 伍智华，程江华，刘　通，等. 激光透窗低质量图像人体姿态识别技术研究[J]. 中国激光，2025，52(6)：268-279.
Wu Zhihua, Cheng Jianghua, Liu Tong, et al. Human posture recognition algorithm for low-quality laser through-window images[J]. Chinese Journal of Lasers, 2025, 52(6): 268-279.

[3] 乔　凯，杨　杰，靳辰飞. 基于时间相关单光子计数的穿透成像激光雷达研究[J]. 红外与激光工程，2022，51(8)：114-126.
Qiao Kai, Yang Jie, Jin Chenfei. Research on penetrating imaging LIDAR based on time-correlated single photon counting[J]. Infrared and Laser Engineering, 2022, 51(8): 114-126.

[4] Artan Y, Bulan O, Loce R P, et al. Passenger compartment violation detection in HOV/HOT lanes [J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(2): 395-405.

[5] Xu K, Jin W, Liu J, et al. Non-line-of-sight imaging based on laser range-gated imaging technology[J]. Infrared and Laser Engineering, 2012, 53(6): 167-174.

[6] Turpin A, Musarra G, Kapitany V, et al. Spatial images from temporal data[J]. Optica, 2020, 7(8): 900.

[7] Hong Y, Li Y, Dai C, et al. Image-free target identification using a single-point single-photon LiDAR[J]. Optics Express, 2023, 31(19): 30390.

[8] Ma J, Zhuo S, Qiu L, et al. A review of ToF-based LiDAR[J]. Journal of Semiconductors, 2024, 45(10): 101201.

[9] Zabihi F, Safara F, Ahadzadeh B. An electrocardiogram signal classification using a hybrid machine learning and deep learning approach[J]. Healthcare Analytics, 2024, 6: 100366.

[10] Mohammed Alsumaidaee Y A, Yaw C T, Koh S P, et al. Detection of corona faults in switchgear by using 1D-CNN, LSTM, and 1D-CNN-LSTM methods[J]. Sensors, 2023, 23(6): 3108.

[11] Naimi S, Bouachir W, Bilodeau G A. 1D-convolutional transformer for Parkinson disease diagnosis from gait[J]. Neural Computing and Applications, 2024, 36(4): 1947-1957.

**作者简介：**

**陈玉婷**（2001—），女，湖南省人，硕士研究生，主要研究方向为单光子回波中目标信号检测和分类；

**刘　通**（1982—），男，河南省人，博士，副教授，主要研究方向为电路与系统和计算机视觉。