

城市环境中的远程无人机无成像识别现场演示

Junran Guo,^{1,†} Tonglin Mu,^{1,†} Keyuan Li,¹ Jianing Li,¹ Ziyang Luo,¹ Ye Chen,¹ Xiaodong Fan,¹ Jinquan Huang,¹ Minjie Liu,¹ Jinbei Zhang,¹ Ruoyang Qi,^{2,*} Naiting Gu,^{3,**} and Shihai Sun^{1,***}

¹*School of Electronics and Communication Engineering, Sun Yat-sen University, Shenzhen, 518107, Guangdong, P.R.China*

²*China Academy of Space Technology Beijing, 100094, Beijing, P.R.China*

³*College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073, China*

[†]*The authors contributed equally to this work.*

**qry15@tsinghua.org.cn*

***gnt7328@163.com*

****sunshh8@mail.sysu.edu.cn*

Abstract: 检测小型物体，例如无人机，在长距离下存在一个具有广泛安全、监控、环境监测和自主系统影响的重要挑战。传统的基于成像的方法依赖于高分辨率图像采集，但往往受限于范围、能耗和成本。相比之下，数据驱动的单光子单像素激光雷达（D²SP²-激光雷达）提供了一种无需成像的替代方案，可以直接实现目标识别，同时减少系统的复杂性和成本。然而，其检测范围通常仅限于几百米。在这里，我们引入了残差神经网络（ResNet）与 D²SP²-激光雷达的新颖集成，结合改进的观测模型，在城市环境中将检测范围扩展到 5 km，同时实现了无人机姿态和类型的高精度识别。实验结果表明，我们的方法不仅超越了传统的基于成像的识别系统，而且在长距离、低信噪比（SNR）的弱信号条件下，也达到了 94.93% 的姿态识别准确率和 97.99% 的类型分类准确率。这些发现突显了无需成像的方法在现实场景中实现稳健长距离小型目标检测的潜力。

1. 介绍

无人机的普及已经改变了空防 [1]、搜救 [2] 和安全 [3] 等领域的应用，实现了快速响应并提升了态势感知能力。然而，在大规模和复杂环境中越来越多的应用带来了显著挑战，尤其是在远距离检测与跟踪方面。可靠地识别长距离无人机的能力对于民用和国防应用都至关重要，但现有的检测技术仍受制于范围、功耗效率和成本等方面的限制。

视觉成像 [4–7]，如 RGB 或强度图像，在长距离场景中受到限制。需要极长的焦距以防止由衍射极限引起的横向分辨率下降。对于雷达系统 [8]，如相控阵 [9–11]、调频连续波雷达 [12–15] 或脉冲多普勒雷达 [16–18]，高功耗和成本是长距离检测的主要瓶颈。单光子光探测和测距（LiDAR）技术由于其扩展的操作范围和目标识别 [19–21] 的高精度而最近受到了广泛关注。如图 1 所示，现有的单光子 LiDAR 目

标识方法主要可以分为基于图像的方法和非成像的方法。对于基于图像的方法，首先使用阵列单光子探测器（SPD）或单像素 SPD 重建深度或反射率图像，然后借助深度学习 [22,23] 识别目标。阵列-SPD 系统 [22–27] 面临衍射极限施加的物理限制，并且高分辨率 SPD 阵列仍然存在显著的技术挑战和高昂的成本。利用光栅扫描 [19–21]，计算单像素成像（SPI）[28–31] 和鬼成像（GI）[32–34]，有可能使用单像素 SPD 重建图像。它存在一些限制。光栅扫描方法受限于每个像素的积分时间，这限制了对快速移动动态目标的检测。另一方面，SPI 或 GI 需要额外的组件，如空间光调制器（SLMs）或量子纠缠光源，这引入了高系统复杂性和增加的成本。同时，在无成像的方法中，直接从单像素 SPD 捕获的测量数据识别和检测目标。尽管最近已经基于 SPI [35–41] 和 GI [42–44] 展示了无成像方法，但由于它们依赖于 SLMs 进行主动调制，仍面临成本增加和系统复杂性的问题。




图 1. 单光子激光雷达目标识别方法的结论。

因此，实现具备长距离探测能力、低成本和低功耗的无人机检测与识别仍然是一个重大挑战。最近，一种数据驱动的单光子单像素激光雷达（D²SP²-LiDAR）因其能够不使用额外成像组件和调制器的情况下捕获目标的有效信息而受到广泛关注 [45–50]，如 SLM（图 2 b）、电位计（图 2 c）或阵列传感器（图 2 d）。研究显示，使用 D²SP²-LiDAR 可以重建场景的深度图像 [46–48,50]，识别并定位墙后的人员 [45]，并在 200 m [49] 的距离上区分不同姿态和类型的无人机，揭示了一种有前景的低成本目标识别方法。

这里，为了进一步提高小目标检测的距离和准确性，我们提出了一种无需成像且基于数据驱动的方法，该方法将 D²SP²-激光雷达（图 2 a）与残差神经网络（ResNet）集成起来，在不使用传统成像组件的情况下实现了远距离无人机的检测和分类。我们的方法绕过了额外组件的限制，直接从飞行时间（ToF）数据中提取目标特征。并在城市环境中的现场实验展示了该方法的应用，将检测范围显著扩展到从前几百米的限制至 5km，同时保持了对无人机类型 97.99%和无人机姿态识别 94.93%的高度分类准确性。仿真和实验结果均证实了我们的方法在弱信号条件下的鲁棒性，突显其在远程监控和自主系统等实际应用中的潜力。




图 2. **a** 演示 D²SP²-激光雷达。 **b** 单像素成像的目标识别。 **c** 采用电磁计数器的光栅扫描成像。收发器由脉冲激光和单像素 SPD 组成。 **d** 使用阵列 SPD 成像。 **e** 不同单光子目标检测方法的距离、成本和功耗比较。我们的工作显示，在长距离场景中，尽管成本低且功耗低，但仍能保持高精度。

2. 方法

2.1. 观测模型

考虑图 2 **a** 中的检测方法，目标被一个具有时间形状 $s(t)$ 的脉冲激光照射，回波光子由与激光同步的时间数字转换器 (TDC) 控制的单像素 SPD 收集。目标的回波信号可以通过将 $s(t)$ 与目标响应函数 $h(t) = \sum_i a_i \delta(t - 2d_i/c)$ 进行卷积来描述。这里， a_i 是衰减效应系数， $\delta(t - 2d_i/c)$ 代表回波信号的往返时间偏移， c 是光速， i 表示目标反射面的索引，其中 d_i 是从物体表面到 D²SP²-激光雷达系统的距离。结合系统的时间抖动 $J(t)$ ，我们可以获得撞击 SPD 的回波信号 $e(t)$

$$e(t) = J(t) * s(t) * h(t) + B_b. \quad (1)$$

这里 $*$ 表示卷积运算。 B_b 表示来自阳光和城市照明的背景噪声光子，其在时间上遵循均匀分布 [51]。我们首先考虑单个脉冲持续期间的情况。因此，第 k 个时间槽中检测到的回波信号的平均光子数可以表示为

$$N_k = \int_{k\Delta t}^{(k+1)\Delta t} (\eta e(t) + B_d) dt = \int_{k\Delta t}^{(k+1)\Delta t} \eta e(t) dt + B, \quad (2)$$

其中 η 是 SPD 的探测效率， B_d 是 SPD 的暗计数， Δt 是时间槽的宽度， B 代表包含 B_d 和 B_b 的噪声。理想情况下，考虑到 SPD 的检测过程，时间直方图中每个时间间隔的检测概率遵循泊松分布 [52]，在每个时间间隔内，第 k 个区间至少检测到一个光子的概率由

$$p_0(k) = 1 - \exp(-N_k). \quad (3)$$

给出。然而，由于系统不在低通量模式下工作 [51]，其中平均计数率限制在最多为照明周期的 1%~5%，因此需要考虑 SPD 的死时间 t_d 。然后，可以计算对应于死时

间的箱数为 $\text{bin}_d = \lfloor t_d / \Delta t \rfloor$ ，其中 $\lfloor \cdot \rfloor$ 是一个取整操作。然后检测概率应该重写为递归形式 [53]

$$P(k) = \begin{cases} p_0(k) \left[1 - \sum_{i=k-\text{bin}_d}^{k-1} P(i) \right], & k \geq \text{bin}_d \\ p_0(k) \left[1 - \sum_{i=0}^{k-1} P(i) \right], & 0 < k < \text{bin}_d \\ p_0(0), & k = 0 \end{cases} \quad (4)$$

进一步，从多个累积检测中制定时间直方图，可以视为伯努利试验 [54]。因此，时间直方图中第 k 个区间检测到的光子数可以表示为

$$\tau(k) = \sum_{i=1}^{N_{\text{pulse}}} \tau_i(k), \quad \tau_i(k) \sim \text{Bernoulli}(P(k)). \quad (5)$$

其中 N_{pulse} 是在累积时间内发射的脉冲数量。而 $\tau_i(k)$ 是单次脉冲持续时间内在第 k 个区间检测到的光子数，服从成功概率为 $P(k)$ 的伯努利分布。

2.2. 残差神经网络

由于其强大的局部关联捕捉能力和保持顺序的能力，一维卷积神经网络 (CNN) 通常被用作大多数传统一维信号处理中的特征提取器，增强了诸如时间序列分析 [55]、语音处理 [56]、生物医学信号处理 [57] 和电机故障诊断 [58] 等多种任务。然而，由于泊松过程引起的波动和无人机的不稳定性，需要提取更深更稳定的特征来进行无人机识别。此外，由于深度神经网络中的梯度消失或爆炸问题，传统 CNNs 的训练过程往往很慢，甚至可能无法收敛。相比之下，ResNet 在计算机视觉 [59] 和 1D 信号 [60] 处理中展现出了非凡的特征提取能力。在本工作中，我们没有使用 CNNs，而是将 ResNet 的 1D 版本引入到 D^2SP^2 -激光雷达中用于无人机识别，这样可以有效地提取时间直方图中的有意义特征。




图 3. **a** 整体的 1D-ResNet 架构。该网络由特征提取器和线性分类器组成。时间直方图被送入特征提取器以生成特征，然后线性分类器将这些特征映射到姿势数量或类型上。**b** 残差块的详细结构，它由两个 1D 卷积块和一个将输入与卷积输出相加的捷径组成。

一维残差网络（1D-ResNet）的整体架构如图 3 **a** 所示，它由特征提取器和线性分类器组成。特征提取器是由一组残差块堆叠而成的，其结构如图 3 **b** 所示。残差块由一维卷积、批量归一化以及修正线性单元（ReLU）激活函数构成，并且输入与输出之间连接了一个捷径。这个捷径有助于促进梯度流动，使得训练更加高效，并缓解了深层网络中梯度消失的问题。预处理步骤包括归一化和移位不变变换 [49]，经过这些处理后的时间直方图（具有 1024 个区间）直接通过特征提取器生成精炼的特征。然后，这些特征由线性分类器映射到各类别的概率，该分类器也是一个全连接（FC）层。

2.3. 合成数据生成

对于基于 AI 的任务，数据集扮演着重要角色并直接决定了网络的性能。但是，在长距离场景下的无人机识别中，数据集是缺失的。因此，为了评估我们的模型和训练网络，我们建立了一个通用模型来生成合成仿真数据集，在该数据集中，目标的深度图是通过将 3D 模型导入场景并在渲染系统中设置相机生成的。然后我们可以基于观察模型计算目标的 $h(t)$ 。考虑对称模糊问题 [50] 和图 2 **a** 中所示的检测方法，我们通过沿 x 轴 (θ_x) 和 z 轴 (θ_z) 旋转目标创建了一个包含 18 种不同姿态的合成数据集，如图 4 所示。




图 4. 无人机模型在仿真中生成的姿态，显示为深度图。

表 1. 生成合成数据集所使用的参数

Parameters	值	
	比较数据集	距离数据集
Target distance (km)	×	1, 3, 5, 6.25, 7.5, 8.75, 10
Signal noise ratio	1, 0.1, 0.01, 0.005, 0.001	×
Noise level	×	0.005, 0.05, 0.1, 0.5, 1
Dead time (ns)	900	
Laser pulse width (ps)	10	
Laser repetition rate (MHz)	1	
Number of pulses	1000000, 100000, 50000, 25000	
Time jitter (ps)	150	
Bin width (ps)	10	

然后，基于每个姿态的 $h(t)$ ，我们可以根据方程 5 生成时间直方图。考虑到实际的激光脉冲和 SPD，时间和抖动 $J(t)$ 以及时间形状 $s(t)$ 均服从高斯分布。 B 设置为常数，在阳光环境中这是合理的。此外，对于远距离目标，我们假设目标的所有

反射表面共享相同的衰减效应系数，并且目标位置的波动可以忽略不计。然后，生成两个合成数据集——比较数据集和距离数据集，参数列表在表 1 中给出。

比较数据集用于评估不同神经网络在无人机姿态分类中的性能，其中生成了具有不同信噪比和光脉冲数量 (N_{pulse}) 的 100 个时间直方图。此处信噪比定义为目标反射的光子平均数 N_s 与背景噪声产生的光子数 N_n 的比率，即 $SNR = N_s/N_n$ 。通过改变 N_{pulse} ，我们可以生成具有不同 N_s 和 N_n 的时间直方图，而改变信噪比可以控制时间直方图的信号质量，从而模拟背景噪声严重和目标反射弱的情景。

距离数据集用于进一步研究距离对神经网络性能的影响以及系统在长距离场景中运行的可能性。我们通过将无人机定位在 1 到 10 公里的不同距离来生成此数据集。具体来说，我们选择从 5 km 到 10 km 的精细区间以更好地研究距离增加的影响。在生成过程中，假设激光完全照亮了每个距离处的无人机，并且照明面积和激光功率相同。然后可以使用 LiDAR 方程 [61] 计算达到目标的平均光子数，该方程为

$$N_t = \lambda_t N_e \frac{A_t}{A_l}, \quad (6)$$

其中 λ_t 代表发射器和大气透射系数， A_t 是目标的有效面积。对于每个距离，我们假设系统的发射光子数 (N_e) 和目标的照射面积 (A_l) 相同，因此 N_t 也相同。然后，可以计算从目标反射的平均光子数为

$$N_s = \eta \lambda_r N_t \frac{A_r}{\Omega_r d^2} = \eta \lambda_r N_t \frac{A_r}{\pi d^2}, \quad (7)$$

其中 λ_r 是包含接收器透过率、大气透过率和目标反照率的系数。 η 是 SPD 检测效率， A_r 是接收器的有效面积。 Ω_r 是反射光的立体角，可以假设为漫反射时设为 π 。 d 是目标和 SPD 之间的距离。因此，根据方程 7，我们有

$$N_s = a \frac{N_e}{d^2}, \quad (8)$$

其中 a 总体代表系数的影响。方程 8 表明，我们可以通过调整平均信号光子计数 N_s 来模拟系统在不同距离下的性能。在仿真中，假设在 5 的距离处 km N_s 设置为 5000，为了简化起见 a 设置为 1，则我们可以使用方程 8 计算其他距离条件下的 N_s 。此外，我们将不同级别的噪声光子引入直方图中，以评估网络在不同噪声条件下的鲁棒性。请注意，只要接收有效面积 (A_r) 保持不变 [62]，所有距离条件下的噪声光子数量几乎相同，因此我们将噪声水平 N_{np} 定义为每脉冲的平均噪声光子数，这意味着总噪声光子数是 $N_n = N_{np} N_{pulse}$ 。这里 N_{pulse} 是脉冲激光发射的脉冲数，由样本采集时间决定。同样地，对于每个噪声水平和脉冲数的组合，我们生成 100 个时间直方图用于训练和测试。

3. 结果

3.1. 仿真结果

为了评估我们 D²SP²-激光雷达系统的性能和能力,使用上述生成的比较数据集和距离数据集来模拟不同条件下无人机姿态分类的准确性。这里的仿真包括两个主要任务。一个是通过与其他神经网络在各种具有挑战性的条件(如信噪比和光子计数)下进行比较,评估我们的 1D-ResNet 网络的性能。另一个是测试我们系统在一系列距离、噪声水平和脉冲数量下的能力,确保我们的系统即使在长距离场景、低信噪比和光子计数条件下也能保持高分类准确性。

对于第一个任务,即不同神经网络的比较,我们基于对比数据集进行了十折交叉验证,在此过程中,将数据集划分为十个子集,其中一个用作测试集,其余九个用于训练。该过程重复进行十次,确保每个子集恰好一次被用作测试集。然后我们将这十个结果取平均值,以全面评估模型的鲁棒性和准确性。通过在仿真中系统性地改变信噪比和 N_s ,我们可以验证我们的方法面对实际挑战(如来自远处无人机的微弱回波信号以及潜在背景噪声干扰)时的可行性。

此外,我们构建了用于无人机姿态分类的 1D-ResNet,在 PyTorch [63] 中实现。用于比较的另外两个网络也已实现。一个是基于 [49] 架构实现的 1D-UNet,另一个是多层感知器 (MLP),由三个全连接层构成。所有神经网络均在 NVIDIA 4090 GPU 上训练,并使用具有默认参数的学习率 0.001、 $\beta_1 = 0.9$ 和 $\beta_2 = 0.999$ 的自适应矩估计 (Adam) 优化器进行优化。这里, β_1 和 β_2 是在使用 Adam 优化器时第一和第二时刻估计的指数衰减率。此外,采用交叉熵作为损失函数以指导训练过程,并将批量大小设置为 128。

不同 N_s 和信噪比下的详细仿真结果如图 5 a~d 所示,所有信噪比和 N_s 下的平均测试准确率列于图 5 e 中。结果显示我们的 1D-ResNet 在所有信噪比和 N_s 条件下均优于 MLP 和 1D-UNet,显示出从时间直方图中提取更稳定和有用信息的高能力。随着信噪比和 N_s 的降低,三个神经网络的准确性都会下降,这与预期一致。事实上,当 N_s 和信噪比较低时,在时间直方图中区分信号和噪声变得困难。然而,我们的 1D-ResNet 网络在所有信噪比和 N_s 条件下仍能达到高达 82.47% 的平均准确率(图 5 e),显示出我们网络具有高鲁棒性和实际应用的各种环境中的潜力。




图 5. 不同神经网络对无人机模型 18 种姿态的平均准确率（见图 4）。**a~d** 是不同反射光子数的结果， $N_s = 5000, 500, 250, 125$ 。**e** 是平均测试准确率对比，在所有信噪比和 N_s 下进行平均。

对于第二个任务，即长距离无人机检测测试，我们评估了上述三个神经网络的无人机分类平均准确率。使用上面生成的距离数据集，我们也进行了一次十折交叉验证以评估不同范围内的性能退化情况。如图 6 **a** 所示，随着距离增加，所有神经网络对于 18 种姿态的无人机模型的平均分类准确率呈现逐渐下降的趋势，这是预期之中的现象，因为目标反射的光子数量会随着距离的增加而显著减少。实际上，如公式 8， $N_s \propto 1/d^2$ 所示，其中 d 是系统与目标之间的距离。尽管存在这种下降趋势，我们的 1D-ResNet 在所有距离条件下仍然表现优于其他网络。并且它在 5 km 距离范围内保持相对较高的分类准确率，并展示了其对于扩展范围应用的鲁棒性。然而，在超过 5 km 的距离后，由于信号光子数量显著减少，性能可能会进一步下降。图 6 **b~e** 还显示了我们的 1D-ResNet 在不同噪声水平下的性能。如预期的那样，当噪声水平较高时，信号在时间直方图中变得与背景噪声无法区分，导致平均准确率相对较低。因此，需要较长的积分时间或改进的信号处理技术来补偿这种下降。




图 6. **a** 不同距离下无人机模型 18 种姿态的不同神经网络的平均准确率。**b~e** 是在不同噪声水平下，我们的 1D-ResNet 与 1D-UNet 和 MLP 相比的详细准确率，分别为 $N_{pulse} = 1000000, 100000, 50000, 25000$ 。

3.2. 实验结果

一项现场实验在一个城市内部环境中进行，以进一步评估我们的方法在长距离的真实世界环境中的表现，这包括识别 12 种不同的无人机姿态和分类三种不同类型的无人机。该实验在深圳光明区进行，时间为 2024 年 12 月 17 日至 18 日以及 22 日至 24 日晚上 7:00 至 9:00，平均能见度约为 10 km，温度约为 16 °C。风速范围为 0.4 到 4.1 m/s，相对湿度范围为 29%到 48%。如图 7 所示，为了检测远程无人机 **a**，我们开发了一个紧凑的 D²SP²-激光雷达系统，如 **b** 和 **c** 所示。该系统使用中心波长为 1550.13 nm、线宽为 0.18 nm 的脉冲激光。平均功率约为 400 ~ mW，脉宽为 8 ~ ps，重复率为 1 ~ MHz。发射器和接收器各自使用了扩束镜和准直镜进行构建，导致发散角为 250 微弧度。远程目标反射的光子由一个自由运行的 InGaAs/InP SPAD（来自 QuantumCTek 的 QCD600B）检测到，其时间抖动为 80 ~ ps，死时间为 900 ~

ns，探测效率为 25%。激光和 SPAD 之间的同步是通过 TDC（来自 Swabian 的 Time Tagger Ultra）实现的，在我们的实验中，其时间间隔被设定为 $10 \sim \text{ps}$ 。系统的总时间抖动约为 $100 \sim \text{ps}$ 。




图 7. 真实世界实验。**a** 远程无人机目标距离为 5 公里。**b** D²SP²-激光雷达系统。两个扩束镜和准直器组合并分别形成接收器和发射器。两台摄像机用于捕捉并校准系统到目标。**c** 系统概述。**d** 目标距离为 5 km 的无人机的照片，由焦距为 300 mm 的系统摄像头拍摄。**e** DJI 悟 3 Pro。**f** DJI 悟 Air 2。**g** DJI 幻影 4 RTK。**h** 数据集收集的示意图。无人机在 3 个不同的高度和 4 个不同的偏航角下被操控，最终形成 12 种姿态。**i** 在白天由另一架无人机拍摄的无人机 12 种不同姿态的特写照片，以及系统以 1 秒积分时间获取的相应的时间直方图。

为了改变无人机的姿态，在三个不同的高度控制了 DJI Mavic Air 2 (图 7 h) —— 100 m、200 m 和 300 m —— 以实现俯仰角的变化。在每个高度，设置了四个不同的偏航角，总共产生了 12 种不同的姿态 (图 7 i)，同时收集了相应的时序直方图，积分时间为 1 s (图 7 i)。对于无人机的每一种姿态，我们收集 300 个时序直方图，然后按照 2:4:4 的比例将其划分为训练集、验证集和测试集。我们在相同的超参数下训练了 1D-ResNet，这些超参数在第 3.1 节中有描述，只是将批量大小改为 32。1D-ResNet 能够以 94.93% 的平均分类准确率成功区分姿态，突显了它从距离目标 5 km 处反射的真实世界时序直方图中提取有意义特征的能力。详细结果由图 8 a 中的混淆矩阵显示。

对于无人机类型分类实验，我们使用上述类似的设置，在所有无人机的飞行高度一致为 200 m。对于每种类型的无人机—DJI Mavic 3 Pro、DJI Mavic Air 2 和 DJI

Phantom 4 RTK（图 7 e, f, g）—在该高度设置了四种不同的姿态以收集相应的时间直方图。对于每种类型无人机的每个姿态，我们收集了 300 个时间直方图，然后将它们按 2:4:4 的比例分为三个子集用于训练、验证和测试。分类结果以混淆矩阵的形式显示在图 8 b 中，表明 1D-ResNet 可以在距离为 5 ~ km 处精确预测无人机的类型，平均准确率为 97.99%。为了对比，在相同条件下拍摄的无人机视觉图像见图 7 d，该图像是由焦距为 300 ~ mm 的相机捕捉到的。




图 8. 实际实验结果。**a** 对 DJI Mavic Air 2 的 12 种不同姿态在距离 5 ~ km 范围内的分类性能，以混淆矩阵形式展示。**b** 对 3 种不同无人机各自 4 种姿态在距离 5 ~ km 范围内的分类性能，以混淆矩阵形式展示。

在上述实验中，DJI Mavic Air 2 和 DJI Mavic 3 Pro 收到的目标光子计数的均值约为 2~5 千赫兹，而 DJI Phantom 4 RTK 则为 20 千赫兹。因此，为了进一步评估系统在低光子计数情况下的鲁棒性，我们通过执行二项式稀疏 [64] 直接从实验数据生成低光子时间直方图，在此过程中使用二项式选择将实验时间直方图中的光子比例拆分以创建一个弱版本，包含更少的光子。具体而言，使用分割比率 1、0.5、0.1 和 0.05 随机从原始直方图中选择光子。同样地，我们使用十折交叉验证来比较 1D-ResNet 与 1D-UNet 和 MLP。并且使用第 3.1 节中的相同超参数训练这些网络直到收敛。如图 9 a 所示，在所有分割比率下，1D-ResNet 在准确性方面优于其他模型，尤其是在弱信号条件下，这展示了其优越的鲁棒性、泛化能力和特征提取能力。不同神经网络在所有分割比率下的平均准确率汇总于图 9 b 中。结果表明稳健性和准确性有所提高，同时将无人机的检测范围扩展到 5 km 与 D²SP²-激光雷达。




图 9. **a** 不同分割比例下各种神经网络的平均准确率。**b** 不同神经网络的准确率，在所有分割比例下的平均值。

4. 结论与讨论

D²SP²-激光雷达已经展示了在长距离场景中检测目标的巨大潜力，同时具备低成本和无成像识别的优势。我们成功使用 D²SP²-激光雷达在 5 km 的距离上实现了无人机姿态和类型的识别，将检测范围扩展到新的极限。具体来说，我们利用 1D-ResNet 基于紧凑系统收集的时间直方图来识别无人机的姿态和类型。所提出的 1D-ResNet 的鲁棒性和准确性优势已经通过与 1D-UNet 和 MLP 的仿真和实验对比得到了验证。结果显示，在鲁棒性和准确性方面，1D-ResNet 优于其他神经网络，尤其是在低信号条件下表现尤为突出。这一进步突显了 1D-ResNet 在提取时间直方图中有意义特征的有效性，即使是在长距离场景中也能够实现更远的检测范围，为更大范围内更精确和鲁棒的无人机检测铺平道路。然而，在低信噪比条件下进行分类需要有关有效信号在时间直方图中的位置的先验信息，在现实世界实验中当信号被噪声淹没时这是无法解决的问题。因此，我们将专注于开发用于提取时间直方图中埋藏信号的算法。此外，在实验中我们发现仅依赖 D²SP²-激光雷达检测空域中的无人机仍具有挑战性，因为系统的视野相对较小。而且由于无人机动态特性，相对较长的积分时间可能会引入运动模糊。未来的工作将集中在开发可以覆盖广大空域的 D²SP²-激光雷达系统以及进行更快、更准确和鲁棒识别的算法。

此外，我们相信未来的优化有可能进一步扩展检测范围。例如，目前系统在实际实验中可以达到 90% 以上的准确率，激光脉冲能量为 400 nJ。基于此条件，并考虑到距离衰减效应，我们可以进一步计算出，在太空场景下探测到如此数量的光子，例如在 500~600 km 的距离处，将需要激光脉冲能量为 4~5.76 mJ。此外，实现高级降噪算法 [51]，或利用自适应光子阈值 [65] 也可以进一步扩展检测范围。我们的发现证实了所提出的方案对于长距离无人机识别是可行的，同时也指出了在极远距离

场景中可能改进的地方。

确认. 作者感谢来自 QuantumCTeck 的刘畅在系统构建方面的友好帮助。

资金支持. 本工作得到深圳市科技计划（资助编号 JCYJ20220818102014029）和国家自然科学基金（资助编号 62171458）的支持。

披露. 作者声明没有利益冲突。

数据可用性声明. 支撑本文结果的数据目前不公开，但可以在合理请求下从作者处获取。

参考文献

1. A. Rossiter, “Drone usage by militant groups: exploring variation in adoption,” *Déf. & Secur. Anal.* **34**, 113–126 (2018).
2. B. Mishra, D. Garg, P. Narang, and V. Mishra, “Drone-surveillance for search and rescue in natural disaster,” *Comput. Commun.* **156**, 1–10 (2020).
3. N. Dilshad, J. Hwang, J. Song, and N. Sung, “Applications and challenges in video surveillance via drone: A brief survey,” in *2020 International Conference on Information and Communication Technology Convergence (ICTC)*, (IEEE, 2020), pp. 728–732.
4. D. Lee, W. G. La, and H. Kim, “Drone detection and identification system using artificial intelligence,” in *2018 International Conference on Information and Communication Technology Convergence (ICTC)*, (IEEE, 2018), pp. 1131–1133.
5. B. Taha and A. Shoufan, “Machine learning-based drone detection and classification: State-of-the-art in research,” *IEEE access* **7**, 138669–138682 (2019).
6. A. G. Haddad, M. A. Humais, N. Werghi, and A. Shoufan, “Long-range visual uav detection and tracking system with threat level assessment,” in *IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society*, (IEEE, 2020), pp. 638–643.
7. X. Zhang and K. Kusriani, “Autonomous long-range drone detection system for critical infrastructure safety,” *Multimed. Tools Appl.* **80**, 23723–23743 (2021).
8. A. Coluccia, G. Parisi, and A. Fascista, “Detection and classification of multirotor drones in radar sensor networks: A review,” *Sensors* **20**, 4172 (2020).
9. L. Tang, H. Wang, Z. Feng, *et al.*, “Small phased array radar based on ad9361 for uav detection,” in *2019 IEEE MTT-S International Microwave Biomedical Conference (IMBioC)*, vol. 1 (IEEE, 2019), pp. 1–3.
10. F. Feng, H. Wang, Z. Feng, *et al.*, “The design of a phased array radar for detecting unmanned aerial vehicle,” in *2019 International Conference on Microwave and Millimeter Wave Technology (ICMMT)*, (IEEE, 2019), pp. 1–3.
11. J. Yang, X. Lu, Z. Dai, *et al.*, “A cylindrical phased array radar system for uav detection,” in *2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP)*, (IEEE, 2021), pp. 894–898.
12. S. Rahman and D. A. Robertson, “Classification of drones and birds using convolutional neural networks applied to radar micro-doppler spectrogram images,” *IET radar, sonar & navigation* **14**, 653–661 (2020).
13. I. Roldan, C. R. del Blanco, Á. Duque de Quevedo, *et al.*, “Dopplernet: A convolutional neural network for recognising targets in real scenarios using a persistent range–doppler radar,” *IET Radar, Sonar & Navig.* **14**, 593–600 (2020).
14. A. Hanif, M. Muaz, A. Hasan, and M. Adeel, “Micro-doppler based target recognition with radars: A review,” *IEEE Sensors J.* **22**, 2948–2961 (2022).
15. A. N. Sayed, O. M. Ramahi, and G. Shaker, “Frequency-modulated continuous-wave radar perspectives on unmanned aerial vehicle detection and classification: A primer for researchers with comprehensive machine learning review and emphasis on full-wave electromagnetic computer-aided design tools,” *Drones* **8**, 370 (2024).
16. C. Wang, J. Tian, J. Cao, and X. Wang, “Deep learning-based uav detection in pulse-doppler radar,” *IEEE Trans. on Geosci. Remote. Sens.* **60**, 1–12 (2021).
17. J. Gong, J. Yan, D. Li, and D. Kong, “Detection of micro-doppler signals of drones using radar systems with different radar dwell times,” *Drones* **6**, 262 (2022).
18. J. Tian, C. Wang, J. Cao, and X. Wang, “Fully convolutional network-based fast uav detection in pulse doppler radar,” *IEEE Trans. on Geosci. Remote. Sens.* **62**, 1–12 (2024).
19. A. M. Pawlikowska, A. Halimi, R. A. Lamb, and G. S. Buller, “Single-photon three-dimensional imaging at up to 10 kilometers range,” *Opt. express* **25**, 11919–11931 (2017).

20. Z.-P. Li, X. Huang, Y. Cao, *et al.*, “Single-photon computational 3d imaging at 45 km,” *Photonics Res.* **8**, 1532–1540 (2020).
21. Z.-P. Li, J.-T. Ye, X. Huang, *et al.*, “Single-photon imaging over 200 km,” *Optica* **8**, 344–349 (2021).
22. G. Mora-Martín, A. Turpin, A. Ruget, *et al.*, “High-speed object detection with a single-photon time-of-flight image sensor,” *Opt. express* **29**, 33184–33196 (2021).
23. S. Scholes, A. Ruget, G. Mora-Martín, *et al.*, “Dronesense: The identification, segmentation, and orientation detection of drones via neural networks,” *IEEE Access* **10**, 38154–38164 (2022).
24. J. Tachella, Y. Altmann, N. Mellado, *et al.*, “Real-time 3d reconstruction from single-photon lidar data using plug-and-play point cloud denoisers,” *Nat. communications* **10**, 4984 (2019).
25. S. Chan, A. Halimi, F. Zhu, *et al.*, “Long-range depth imaging using a single-photon detector array and non-local data fusion,” *Sci. reports* **9**, 8075 (2019).
26. P.-Y. Jiang, Z.-P. Li, W.-L. Ye, *et al.*, “Long range 3d imaging through atmospheric obscurants using array-based single-photon lidar,” *Opt. Express* **31**, 16054–16066 (2023).
27. G. Mora-Martín, S. Scholes, R. K. Henderson, *et al.*, “Human activity recognition using a single-photon direct time-of-flight sensor,” *Opt. Express* **32**, 16645–16656 (2024).
28. M. F. Duarte, M. A. Davenport, D. Takhar, *et al.*, “Single-pixel imaging via compressive sampling,” *IEEE signal processing magazine* **25**, 83–91 (2008).
29. M. P. Edgar, G. M. Gibson, and M. J. Padgett, “Principles and prospects for single-pixel imaging,” *Nat. photonics* **13**, 13–20 (2019).
30. J. Huang, Z. Li, D. Shi, *et al.*, “Scanning single-pixel imaging lidar,” *Opt. express* **30**, 37484–37492 (2022).
31. K. Song, Y. Bian, K. Wu, *et al.*, “Single-pixel imaging based on deep learning,” *arXiv preprint arXiv:2310.16869* (2023).
32. X. Zou, X. Huang, C. Liu, *et al.*, “Target recognition based on pre-processing in computational ghost imaging with deep learning,” *Opt. & Laser Technol.* **167**, 109807 (2023).
33. A. Ruget, C. Moodley, A. Forbes, and J. Leach, “Translated object identification for efficient ghost imaging,” *Opt. Express* **32**, 41057–41068 (2024).
34. A. Abbas, J. Mu, Z. Mengyue, *et al.*, “Target recognition in ghost imaging from traditional to advance; a brief review,” *Opt. & Laser Technol.* **184**, 112450 (2025).
35. S. Lohit, K. Kulkarni, and P. Turaga, “Direct inference on compressive measurements using convolutional neural networks,” in *2016 IEEE international conference on image processing (ICIP)*, (IEEE, 2016), pp. 1913–1917.
36. P. Latorre-Carmona, V. J. Traver, J. S. Sánchez, and E. Tajahuerce, “Online reconstruction-free single-pixel image classification,” *Image Vis. Comput.* **86**, 28–37 (2019).
37. Z. Zhang, X. Li, S. Zheng, *et al.*, “Image-free classification of fast-moving objects using “learned” structured illumination and single-pixel detection,” *Opt. express* **28**, 13269–13278 (2020).
38. Y. Zhu, J. Shi, X. Wu, *et al.*, “Photon-limited non-imaging object detection and classification based on single-pixel imaging system,” *Appl. Phys. B* **126**, 21 (2020).
39. L. Peng, S. Xie, T. Qin, *et al.*, “Image-free single-pixel object detection,” *Opt. Lett.* **48**, 2527–2530 (2023).
40. Z. Guo, Z. He, R. Jiang, *et al.*, “Real-time three-dimensional tracking of distant moving objects using non-imaging single-pixel lidar,” *Remote. Sens.* **16**, 1924 (2024).
41. Y. Yu, Z.-H. Yang, Y.-X. Liu, *et al.*, “Long-range fast single-pixel localization of multiple moving targets,” *IEEE Sensors J.* (2024).
42. Y. Hualong, Z. Leihong, and Z. Dawei, “Non-imaging target recognition algorithm based on projection matrix and image euclidean distance by computational ghost imaging,” *Opt. & Laser Technol.* **137**, 106779 (2021).
43. X. He, S.-M. Zhao, and L. Wang, “Handwritten digit recognition based on ghost imaging with deep learning,” *Chin. Phys. B* **30**, 054201 (2021).
44. J.-N. Cao, Y.-H. Zuo, H.-H. Wang, *et al.*, “Single-pixel neural network object classification of sub-nyquist ghost imaging,” *Appl. Opt.* **60**, 9180–9187 (2021).
45. P. Caramazza, A. Boccolini, D. Buschek, *et al.*, “Neural network identification of people hidden from view with a single-pixel, single-photon detector,” *Sci. reports* **8**, 11945 (2018).
46. A. Turpin, G. Musarra, V. Kapitany, *et al.*, “Spatial images from temporal data,” *Optica* **7**, 900–905 (2020).
47. A. Turpin, V. Kapitany, J. Radford, *et al.*, “3d imaging from multipath temporal echoes,” *Phys. Rev. Lett.* **126**, 174301 (2021).

48. C. Liang, C. Luo, B. Deng, *et al.*, “Non-scanning terahertz 3d imaging based on data-driven,” *Opt. Express* **30**, 29329–29339 (2022).
49. Y. Hong, Y. Li, C. Dai, *et al.*, “Image-free target identification using a single-point single-photon lidar,” *Opt. Express* **31**, 30390–30401 (2023).
50. T. Lai, X. Liang, Y. Zhu, *et al.*, “Single-pixel 3d imaging based on fusion temporal data of single-photon detector and millimeter-wave radar,” *Chin. Opt. Lett.* **22**, 022701 (2024).
51. J. Rapp and V. K. Goyal, “A few photons among many: Unmixing signal and noise for photon-efficient active imaging,” *IEEE Trans. on Comput. Imaging* **3**, 445–459 (2017).
52. P. Gatt, S. Johnson, and T. Nichols, “Geiger-mode avalanche photodiode lidar receiver performance characteristics and detection statistics,” *Appl. optics* **48**, 3261–3276 (2009).
53. Z. Li, J. Lai, C. Wang, *et al.*, “Influence of dead-time on detection efficiency and range performance of photon-counting laser radar that uses a geiger-mode avalanche photodiode,” *Appl. optics* **56**, 6680–6687 (2017).
54. D. G. Fouche, “Detection and false-alarm probabilities for laser radars that use geiger-mode detectors,” *Appl. optics* **42**, 5388–5398 (2003).
55. J. C. B. Gamboa, “Deep learning for time-series analysis,” arXiv preprint arXiv:1701.01887 (2017).
56. A. Mehrish, N. Majumder, R. Bharadwaj, *et al.*, “A review of deep learning techniques for speech processing,” *Inf. Fusion* **99**, 101869 (2023).
57. S. Kiranyaz, T. Ince, O. Abdeljaber, *et al.*, “1-d convolutional neural networks for signal processing applications,” in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, (IEEE, 2019), pp. 8360–8364.
58. J. Chuya-Sumba, L. M. Alonso-Valerdi, and D. I. Ibarra-Zarate, “Deep-learning method based on 1d convolutional neural network for intelligent fault diagnosis of rotating machines,” *Appl. Sci.* **12**, 2158 (2022).
59. K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, (2016), pp. 770–778.
60. P. Tchatchoua, G. Graton, M. Ouladsine, *et al.*, “1d resnet for fault detection and classification on sensor data in semiconductor manufacturing,” in *2022 International Conference on Control, Automation and Diagnosis (ICCAD)*, (IEEE, 2022), pp. 1–6.
61. F. u. Liu, Y. He, W. Chen, *et al.*, “Simulation and design of circular scanning airborne geiger mode lidar for high-resolution topographic mapping,” *Sensors* **22**, 3656 (2022).
62. J. J. Degnan, “Photon-counting multikilohertz microlaser altimeters for airborne and spaceborne topographic measurements,” *J. Geodyn.* **34**, 503–549 (2002).
63. A. Paszke, S. Gross, F. Massa, *et al.*, “Pytorch: An imperative style, high-performance deep learning library,” *Adv. neural information processing systems* **32** (2019).
64. M. Hayman, R. A. Stillwell, and S. M. Spuler, “Optimization of linear signal processing in photon counting lidar using poisson thinning,” *Opt. Lett.* **45**, 5213–5216 (2020).
65. M. Chen, Z. Shi, W. Chen, *et al.*, “An adaptive photon count reconstruction algorithm for sparse count and strong noise count data with low signal background ratio,” *IEEE Trans. on Comput. Imaging* (2024).