数字孪生赋能的多机器人系统轻量级模型共享方案

Kai Xiong、Zhihong Wang、Supeng Leng，*IEEE*会员、Jianhua He

arXiv:2305.02214v1 [cs.IT] 3 May 2023

摘要

制造业多机器人系统是一种工业物联网（IIoT）范式，能够显著节约运营成本并提高生产效率。在该系统中，无人机用于控制和实施协同生产，无需人工干预。这种任务关键型系统依靠三维（3-D）场景识别来提高生产线作业精度并实现自主驾驶。然而，由于无人机配备的感知和计算资源有限，实施 Pointnet 等三维点云学习颇具挑战。因此，我们提出一种由数字孪生（DT）赋能的知识蒸馏（KD）方法，用于生成多个轻量级学习模型，并选择最优模型部署到无人机上。通过在边缘服务器保留无人机的数字副本，DT系统可控制模型共享网络拓扑和学习模型结构，进一步提高识别准确率。此外，我们采用网络演算来构建并求解模型共享配置问题，以实现资源消耗最小化并确保收敛。我们在一个常用的点云数据集上开展仿真实验，以评估所提出的方案。实验结果表明，与单个模型相比，所提出的模型共享方案在计算资源消耗和识别准确率方面表现更优。

索引词

数字孪生、分布式模型共享、知识蒸馏、网络演算、多机器人系统。

I. 引言

THE 无线通信和机器学习技术的发展推动了工业物联网（IIoT）的研究与发展。多机器人系统是工业物联网的一种典型范式，其中，无人机（UAVs）被用于在无人干预的情况下协同实现自动化生产。这可以显著节约运营成本并提高生产效率 [1]。因此，多机器人系统在制造、仓储和采矿等垂直行业领域具有广泛的应用。然而，与许多其他任务关键型工业物联网应用一样，即使是多机器人生产线或露天采矿中的轻微控制和操作错误，也可能造成重大的经济损失和安全问题 [2], [3]。全面感知运行环境对于构建安全高效的多机器人系统至关重要。

无人机自主驾驶的环境感知研究已从使用视觉摄像机转向使用激光雷达传感器 [4]。光学摄像机的缺点在于缺乏深度信息且对光照敏感，而激光雷达传感器能够提供准确的深度信息，并且不依赖光照。人们提出了许多深度学习方法，用于从激光雷达生成的点云数据中感知物体 [5]。然而，现有的点云学习方法（如 Pointnet） [6], 忽略了多智能体协同学习的优势。多样化的应用会为无人机运行产生不同的点云学习结果。这些不同的学习模型可以通过相互共享知识产生多样性增益。例如，在仓储环境中训练点云识别模型以识别货物形状，可以帮助其他无人机进行自主驾驶时实现更好的场景识别。因此，无人机之间的深度学习模型共享可以缓解单个无人机的大量计算开销，并促进训练收敛。

无人机之间的学习模型共享依赖无线通信。遗憾的是，这些云端点学习模型的规模较大，不适合机载训练和无线传输。为降低机载处理和模型共享带来的计算与通信开销，我们利用知识蒸馏（KD）将训练好的深度模型压缩为适合机载处理和模型共享的轻量级模型。KD方法可以在压缩后几乎不损失性能的情况下显著缩小模型大小。事实证明，KD能够将训练好的学习模型中包含非目标标签信息的“暗知识”迁移出来，从而有效提升轻量级模型的性能 [7]。相比之下，网络剪枝、量化和二值化等其他压缩方法不具备这种学习非标签信息的能力 [8]。然而，基于KD的方法有一个副作用：压缩过程计算开销很大，不适用于嵌入式芯片。

K. Xiong、Z. Wang 和 S. Leng 任职于中国电子科技大学信息与通信工程学院（中国成都，邮编 611731）以及中国电子科技大学深圳高等研究院（中国深圳，邮编 518110）。J. He 任职于英国科尔切斯特 CO4 3SQ 的计算机科学与电子工程学院。本文获得中国国家自然科学基金（NSFC）项目（编号：62201122）以及欧盟“地平线 2020”研究与创新计划玛丽·斯克沃多夫斯卡-居里资助协议（编号：824019 和 101022280）的资助。通讯作者为 Supeng Leng，电子邮箱：{spleng, xiongkai}@uestc.edu.cn

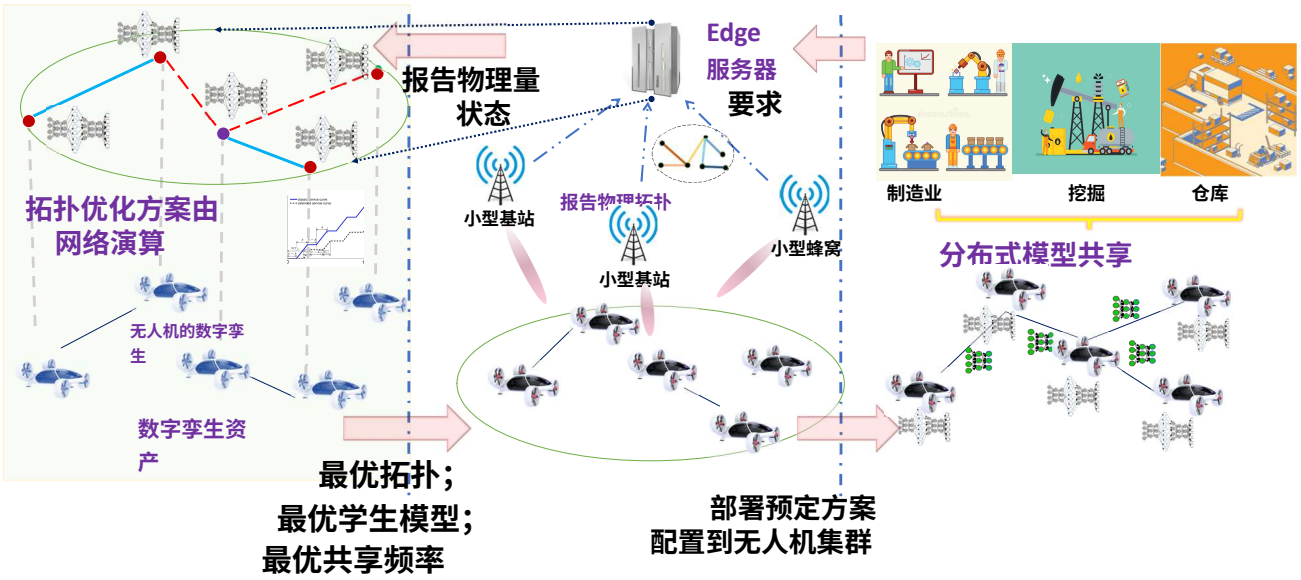

图 1： 多机器人系统中的数字孪生赋能模型共享框架。

因此，为避免嵌入式芯片上的计算开销以及轻量级模型共享造成的性能下降，我们提出了一种借助数字孪生（DT）技术的无人机模型共享方案。部署在边缘服务器上的数字孪生资产获取各无人机的状态，并构建克隆网络。一方面，无人机可以将KD过程卸载至数字孪生侧，以提高计算效率。另一方面，DT系统可以向无人机侧提供最优拓扑配置，以促进模型共享收敛。这是因为与不同无人机进行模型共享，未必能保证所有无人机最终获得相同的可学习参数，从而导致模型共享无法收敛。在这种情况下，无人机无法充分获得协作带来的益处 [9]。因此，数字孪生资产推导出的适当拓扑和资源分配将确保模型共享收敛。

在基于数字孪生的模型共享方案中，基于知识蒸馏的模型训练被卸载到数字孪生域。数字孪生资产利用边缘服务器的强大计算能力，同时执行不同的知识蒸馏操作。知识蒸馏过程结束后，数字孪生系统会为无人机集群选择合适的轻量级模型和拓扑特征。这一选择考虑了模型共享的资源开销和收敛性。无人机从数字孪生系统接收到最优轻量级模型后，会对其进行重新训练，以适应本地环境。相反，无人机必须向数字孪生资产报告其运行状态和连接状态，以便优化克隆网络。总体而言，所提出的基于数字孪生的模型共享方案以适当的通信和计算开销，提高了多机器人系统的场景识别效率。

主要贡献概括为以下三点：

- 我们提出了一种基于数字孪生的模型共享方案，其中DT系统由设备数字孪生和边缘数字孪生组成。设备数字孪生是物理无人机的抽象表示。边缘数字孪生承担克隆网络的功能，以优化无人机集群的学习模型结构和共享网络拓扑。因此，无人机利用边缘服务器的计算资源和全局信息，将模型蒸馏和网络优化从机载芯片中解耦出来。这降低了制造场景下无人机群的运行风险和计算消耗。此外，基于数字孪生的方案通过消除物理信道中传输错误的影响，进一步提升了模型共享性能。仿真结果证明了数字孪生技术在知识蒸馏模型共享方案中的优势。该方案能够实现可靠的场景识别，使无人机能够更加准确、安全地运行。

- 我们设计了三种 Pointnet 轻量级模型，以满足多机器人系统中无人机的不同需求。与仅生成一个轻量级模型且消耗本地设备计算资源的传统知识蒸馏方法不同，所提出的基于数字孪生的方案能够在可学习参数、模型结构和拓扑特征方面实现可调配置。通过利用边缘服务器的计算资源，我们提出了一种算法，用于确定最优轻量级模型和网络拓扑，以提高识别性能。仿真结果表明，最优配置在模型共享时并未采用最深层学习模型。该方案可为资源受限无人机选择合适的学习模型提供参考。

- 我们利用网络演算理论来满足共识收敛的端到端时延要求。该理论揭示了实现分布式一致性时最大节点度与无人机间通信带宽之间的交互机制。基于网络演算分析和识别需求，我们提出了一种分配通信资源和计算资源的共识方案。仿真结果表明，无人机网络资源和拓扑特征决定了模型共享收敛及其性能。

向无人机集群传输 $\hat{\epsilon}(t+1)$ ，其中包含指示的学习结构和模型共享拓扑

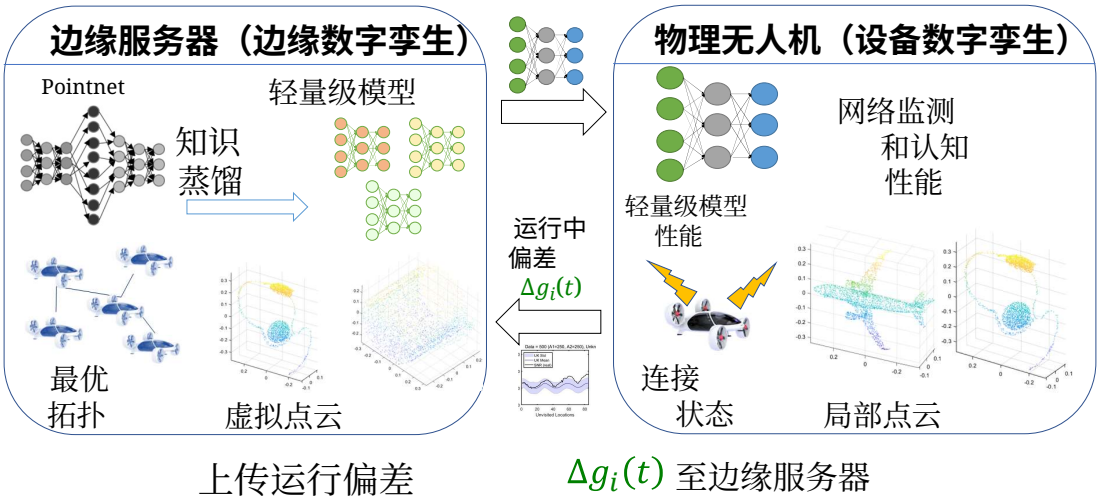

图 2： 数字孪生构建和同步。

本文其余部分安排如下：第二节设计了数字孪生赋能的分布式模型共享方案。第三节介绍分布式模型共享的优化。第四节展示仿真结果并讨论性能。最后，我们在第五节得出结论。

II. 系统模型

本节介绍面向无人机群的数字孪生赋能模型共享框架，以及基于知识蒸馏的模型压缩框架。

A. 数字孪生赋能的模型共享

嵌入式传感器和芯片资源有限的无人机，可能无法充分发挥深度学习模型的潜力，因为这类模型需要大量数据和计算资源。因此，我们提出一种基于数字孪生的方案，以生成用于机载训练和高效模型参数传播的轻量级学习模型。无人机从数字孪生侧获取轻量级学习模型，然后与邻居共享训练后的模型，以提升识别效果。这种基于数字孪生的模型共享方式避免了直接更改物理运行网络所带来的风险。数字孪生资产可在与物理系统实时同步的基础上，对相应的无人机群执行控制操作和优化。在数字孪生赋能的模型共享框架中，我们综合考虑共享模型的性能、大小和网络拓扑。

图1展示了所提出的架构，该架构由物理系统和与之同步的数字孪生体组成。物理系统包含三个主要部分，即多架无人机、用于无人机通信和数字孪生同步的小基站，以及一台边缘服务器。无人机通过机载激光雷达采集三维点云数据，然后利用学习模型进行产品识别和自主驾驶。小基站分布在工作区域内，用于监测和控制无人机与数字孪生资产。边缘服务器可执行教师模型训练、轻量级模型蒸馏和无人机群数字孪生体创建等主要计算任务。

借助数字孪生体，可以在数字孪生侧进行控制与运行评估。我们根据参考文献 [10] 配置数字孪生模型。数字孪生体可分为设备数字孪生 DT^{dev} 和边缘数字孪生 DT^{edge}。 DT^{dev}经过定制，用于以概括性模型模拟物理无人机。 DT^{edge} 旨在收集群体的 DT^{dev}，并通过虚拟仿真和验证为物理系统提供预测与优化。在我们的案例中，设备数字孪生用于描绘无人机状态，而边缘数字孪生则针对映射的设备数字孪生体进行特定优化。所提出的 DT 系统能够以较低的通信开销促进数字孪生同步。

设备数字孪生的任务是监测并总结无人机运动状态、网络连接状态和识别性能的变化。因此，无人机 i 的机载设备数字孪生表示为，

$$DT^{dev}(t,i) = [g_i(t), f_i(t), \Delta g_i(t)], \tag{1}$$

其中， $g_i(t) = [g_i^{kin}(t)\ g_i^{net}(t)\ g_i^{mod(j)}(t)]$ 分别表示无人机的运动状态、网络连接状态以及学习模型 j的识别性能。此外， $f_i(t) = [f_i^{kin}(t)\ f_i^{net}(t)\ f_i^{mod}(t)]$,其中， $f_i^{kin}(t)$表示无人机 i 在时刻 t可用的运动行为，例如位置和加速度。 $f_i^{net}(t)$表示网络修改方式

在时刻 t。而 $f_i^{mod}(t)$表示可应用于无人机 i 在时刻 t的可行学习模型。此外，$\Delta g_i(t) = g_i(t)\hat{} g_i(t)$表示运行偏差，其中 $\hat{} g_i(t)$是从相应边缘数字孪生接收到的时刻 t 的预测状态。

对于边缘数字孪生,它是通过收集多个设备数字孪生而生成的无人机集群副本，定义如下 ，

$$DT^{edge}(t,\Omega) = \left[G_\Omega(t), F_\Omega(t), \hat{G}_\Omega(t+1)\right], \tag{2}$$

其中， $DT^{edge}(t, \Omega)$ 是与无人机设备数字孪生 $DT^{dev}(t, i)$ $i \in \Omega$ 对应的边缘数字孪生。无人机集群 Ω 中 $g_i(t)$ 的集合记为 $G_\Omega(t) = [g_i(t)\ i \in \Omega]$。此外， $F_\Omega(t) = [f_i(t)\ i \in \Omega]$ 表示群组 Ω 中 $f_i(t)$ 的集合。$\hat{}$此外， $G_\Omega(t+1)$ 是 $g(t)$ 在时隙 $t+1$ 的状态预测，也是数字孪生向物理系统 Ω 提供的反馈，用于指导未来活动。

图 2 详细说明了用于模型共享的数字孪生资产。 DT_i^{dev} 部署在无人机 i 上。一方面，无人机 i 会定期通过无线通信向边缘服务器上传其 DT_i^{dev} 状态。另一方面，边缘服务器会在边缘虚拟呈现 $DT^{edge}(t, \Omega)$ 中维护并处理收集到的 DT^{dev}。基于边缘服务器的高性能芯片，边缘数字孪生将推演出最优轻量级模型、连接拓扑和共享频率，以指导物理无人机的行为。

边缘数字孪生模仿无人机的移动，并对流形学习模型和网络配置进行实验。它处理以下任务：i) 基于KD技术为无人机设计并选择最优轻量级模型；ii) 基于平均一致性方案和网络演算理论，找到合适的拓扑，以确保模型共享收敛；iii) 微调模型共享配置，在满足识别要求的同时，最大限度地降低通信与计算资源消耗。其中，生成对抗网络可在边缘服务器中生成用于边缘数字孪生仿真的虚拟训练数据 [11]。通过虚拟仿真和估计，边缘数字孪生将把后续运行时隙 $t+1$ 的无人机状态$\hat{}$prediction $G_\Omega(t+1)$反馈给无人机集群。

相比之下，部署在无人机上的设备数字孪生有三项主要功能：i) 汇总无人机的本地状态；ii) 维护设备数字孪生并与边缘数字孪生同步；iii) 进行机载模型训练并与其他无人机共享。首先，无人机将其 DT^{dev} 设置上传至对应的边缘服务器。之后，无人机只需将其运行偏差 $\Delta g_i(t)$更新至边缘服务器，以实现数字孪生同步。

设备—边缘数字孪生对通过双向无线通信进行交互。如图1所示，小基站收集设备数字孪生信息并将其上报至边缘服务器。反之，小基站向无人机传输最优拓扑、轻量级学习模型和共享频率。因此，必须预留特定带宽资源，以维持设备数字孪生与边缘数字孪生之间的同步。

当通信周期超过允许的最大同步延迟 t^{DT}时，边缘数字孪生与物理无人机（设备数字孪生）将失去同步。在此情况下，运行偏差 $\Delta g = null$ 会从设备数字孪生发送至边缘数字孪生。因此，边缘数字孪生会在没有物理设备输入信息的情况下继续进行虚拟仿真。与此同时，物理无人机无法从另一端的边缘数字孪生获取反馈。结果是，机载设备数字孪生只能根据当前状态推演未来行为，而无法借助来自边缘数字孪生的集群信息。然而，由于缺少全局集群信息和虚拟推演，这种推演并非最优。一旦重新建立同步，设备数字孪生便会将当前主要状态 $g_i(t)$作为运行偏差 $\Delta g_i(t) = g_i(t)$ 传输至 $\hat{}$ 边缘数字孪生。经过边缘数字孪生的群体模仿和虚拟试验后，边缘数字孪生会根据上传的运行偏差 $\Delta g_i(t)$，在 $t+1$ 时给出状态预测 $\hat{} g_i(t+1) \in G_\Omega(t+1)$。边缘数字孪生的预测将指导无人机行为，从而在DT系统与物理实体之间重建闭环控制。

B. 三种知识蒸馏学生模型

如前所述，边缘数字孪生需要向无人机提供合适的轻量级学习模型 $\hat{} g_i^{mod(j)}(t) \in \hat{} G$ ，以实现模型共享。本文将 Pointnet 学习视为教师，通过 KD 压缩生成各种轻量级学生模型。通常，将待压缩的学习模型称为教师模型，而与之对应的模型称为学生模型。Pointnet 是一种用于三维点云识别的经典深度学习方法。其架构 [6] 如图 3 顶部所示。然而，具有 $14.2M$ 可学习参数的 Pointnet 对于资源受限无人机而言，难以在机载环境中进行训练或传输。因此，本文利用部署在边缘服务器上的 KD 技术，将深度学习压缩为轻量化形式。这种轻量级模型能够直接在无人机上实现点云识别。

不同于仅有一个学生模型的现有KD方法 [12] ，我们提出了从同一个Pointnet中蒸馏得到的多个学生模型。具体而言，三个学生模型的可学习参数数量依次减少。这意味着学生模型能够适应多样化的场景。根据模型规模的顺序，三个学生模型分别命名为大学生网络（CSN）、中学生网络（MSN）和主学生网络（PSN）。如图3所示。需要说明的是，三个学生-教师KD压缩过程均由边缘数字孪生执行，因为KD过程会消耗无人机难以负担的大量计算资源。

为了继承教师模型的知识，学生模型的模型结构应与教师模型保持一致。Pointnet，即教师模型，由四个部分组成：输入变换、特征变换、共享多层

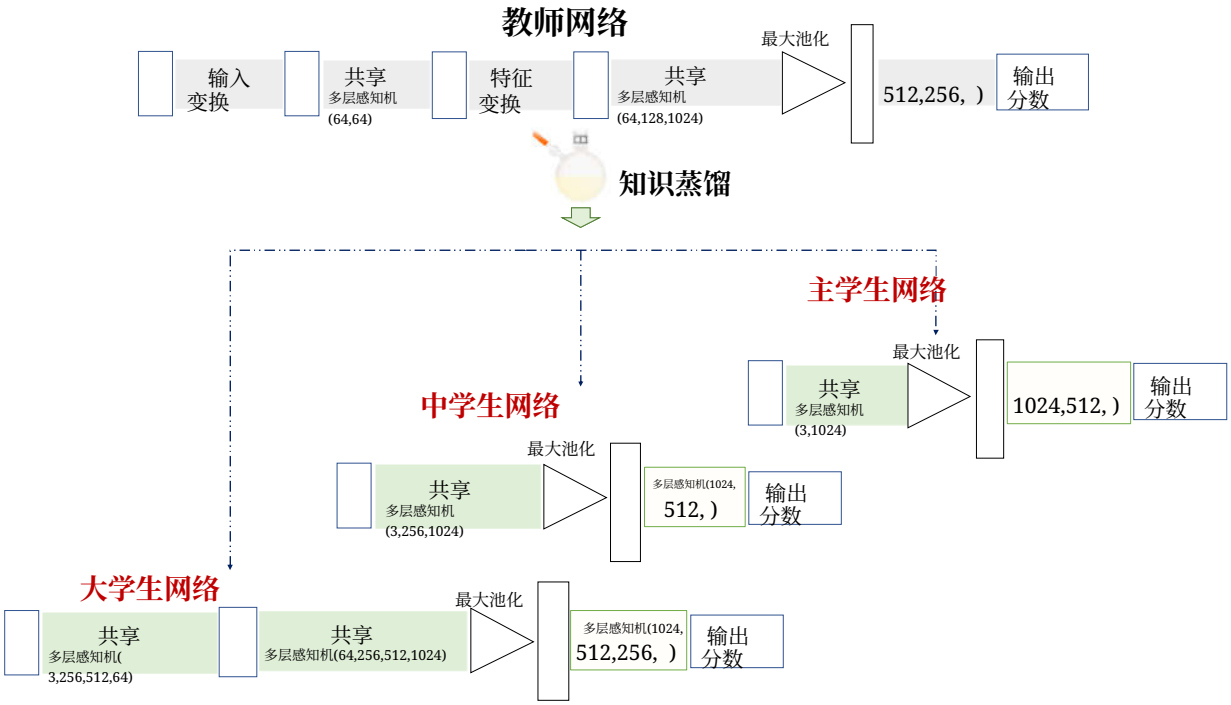

图 3： 点云学习中三种 *KD* 学生模型的示意图。

感知层（多层感知机）以及最终的 softmax 输出。PSN 模型移除了输入组件和特征变换。此外，它还重塑了两个共享多层感知机层。其中一个共享多层感知机层有 3×1024 个维度，另一个则退化为传统的多层感知机，具有 $512 \times K$ 个维度。MSN 与 PSN 大致相似，但 MSN 中共享多层感知机层的大小为 $3 \times 256 \times 512 \times 1024$，大于 PSN。CSN 与 PSN 或 MSN 不同，它增加了一个共享多层感知机模块，如图 3 所示。PSN 的可学习参数数量为 $2.13M$，仅为教师模型的 15%，压缩率接近 7 倍。MSN 的参数数量为 $5.27M$，相较教师模型压缩约 37%。CSN 的参数数量为 $6.24M$，约占教师模型参数量的 44%。

边缘数字孪生构建教师-学生学习模型，并利用虚拟数据以离散时隙的方式执行知识蒸馏压缩。假设教师模型和学生模型都会针对每个点云生成 n 个类别的分数。知识蒸馏的损失函数是预测概率向量$\boldsymbol{Z} = [z_1, z_2, \ldots, z_K]$与通过独热表示 $\boldsymbol{y} = [y_1, y_2, \ldots, y_K]$编码的真实独热标签之间的交叉熵。输入样本被形式化为 $p \sim P_{data}(x)$，表示输入数据分布。设 Z^{*SN} 表示学生模型（$Z^{PSN}/Z^{MSN}/Z^{CSN}$）的逻辑值输出，Z^T表示教师模型的逻辑值。我们首先通过训练教师模型获得逻辑值 Z^T，然后从训练好的教师模型中蒸馏知识，以指导学生模型训练。此外，Hinton 等人 [7]提出了一种典型的蒸馏目标，使学生逻辑值 Z^{*SN} 与教师逻辑值 Z^T对齐：

$$\begin{aligned} min_Z \sum_{i=1}^{n} (1-\alpha)\mathscr{L}(\sigma(Z^{*SN}(\boldsymbol{x}_i)), \boldsymbol{y}_i) \\ +\alpha\tau^2 \mathscr{L}(\sigma(Z^T(\boldsymbol{x}_i), \tau), \sigma(Z^{*SN}(\boldsymbol{x}_i), \tau)), \end{aligned} \tag{3}$$

其中，τ 表示蒸馏温度。α 是权重参数。$\boldsymbol{x}$ 是输入点云数据，$\boldsymbol{y}$ 是真实独热标签。用 $\mathscr{L}$ 表示交叉熵，用于衡量教师与学生逻辑值之间的差距，其定义为

$$\mathscr{L}(z, y) = -\sum_{y_j \in \mathcal{Z}_i} y_j \log z_i - \sum_{y_j \notin \mathcal{Z}_i} y_j \log (1 - z_i). \tag{4}$$

其中，σ 表示深度学习网络的 Softmax 层，它将逻辑值 Z 转换为概率输出，记为：

$$\sigma(\boldsymbol{z_i}) = \frac{exp(\boldsymbol{z}_i)}{\sum_j exp(\boldsymbol{z}_j)}. \tag{5}$$

此外，将 $\sigma(z, \tau)$ 表示为温度增强 Softmax 层，其定义如下，

$$\sigma(\boldsymbol{z}_i, \tau) = \frac{exp(\boldsymbol{z}_i/\tau)}{\sum_j exp(\boldsymbol{z}_j/\tau)}. \tag{6}$$

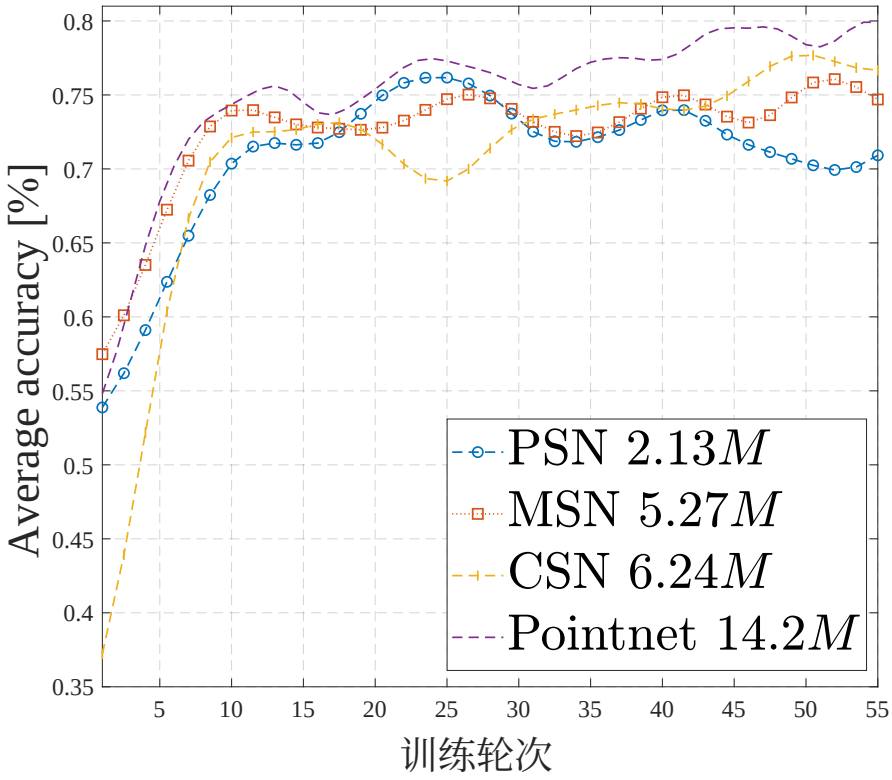

图 4： 教师模型与三个学生模型的性能比较。

根据这些定义，我们为 将两个交叉熵损失紧密整合为式（3），表示学生模型 训练的损失。

图 4 展示了三个学生模型和教师模型在点云识别中的识别准确率。图例中标注了每个模型的可学习参数数量（即模型大小）。教师模型的识别准确率是三个学生模型的上限，因为教师模型具有更深的网络结构和更强的拟合能力。经过 15 个训练轮次后，所有学生模型的识别准确率均低于教师模型的 10%。

在图 4 开始时，CSN 在学生网络中的准确率最差。经过 45 个训练轮次后，其性能超过了其他学生模型。由于 CSN 的模型大小较大，因此需要更多数据和训练时间来消化输入数据与教师知识。相反，PSN 和 MSN 得益于简化的模型结构，能够更快地学习，但长期训练准确率不如 CSN。此外，在本实验中，MSN 与 PSN 的表现相近。不采用模型共享的学生模型性能可作为进一步评估的基线。

C. 分布式模型共享

为了进一步提升多个学生模型的潜在性能，应共享并整合每个学生模型所学习的知识。本节提出了一种低复杂度模型共享方案，以提高学生模型的识别性能并增强学习灵活性。然而，分布式无人机之间共享模型的参数可能无法收敛至稳定值。共享模型之间可学习参数不一致的现象称为不一致。不一致表现为共享不足，即学生模型只能部分获取所有邻居的知识，从而无法充分利用模型共享所带来的多样性增益。因此，关键问题在于实现分布式无人机之间模型共享的一致性共识。一致性共识意味着由不同无人机生成的共享模型具有相同的可学习参数。

考虑具有拓扑结构 $G = (V, E)$ 的无人机 i 的学习模型参数 h_i，其中每架无人机均可通过 $G = (V, E)$ 与其邻居 $N_i = \{j \in V | \{i, j\} \in E\}$ 进行通信。$V = \{1, 2, \dots m\}$ 表示无人机集合。用 $E \in \{V, V\}$ 表示通信链路集合。在这种情况下，Olfati-Saber 等人 [13] 提出了以下线性动态方法，以解决存在无人机间（V2V）通信时延 ϵ 的分布式一致性问题。

$$\dot{h} = -\operatorname{Lh}(t - \epsilon), \tag{7}$$

算法1： 基于知识蒸馏的分布式模型共享

初始化教师网络；PSN；MSN；CSN；
在 DT 中通过最小化式（4）训练教师模型；
对 l: 1 至 M **执行**
    在 DT 中使用式（3）训练 PSN/MSN/CSN；
    通过算法 2 获取最优学生模型和网络拓扑；
    将最优学生模型和拓扑配置传输给无人机；
    对于并行遍历数据批次**执行**
        激活第 i 架无人机，与邻居进行 q 次模型共享 N_i;
        对于 j: 1 到 q **执行**
            如果无人机 i 接收所有 N_i 邻居更新后的模型 $h(t)$**则**
                根据式（10）更新 m参数（模型）；

其中， t 是时间变量。 $L = L(G)$ 是图 G 的拉普拉斯矩阵，定义为 $L = D(G) - A(G)$。 $D(G)$ 是 G 的对角度矩阵，其第 i 个对角元素为 $d_i = |N_i|$，且 $D(G)$ 的非对角元素均为零。$A(G)$ 是一个包含 $0-1$ 个元素的邻接矩阵。因此， L 的元素为

$$l_{ij} = \begin{cases} -1, & j \in N_i \\ |N_i|, & j = i \end{cases}. \tag{8}$$

给定模型 i 的初始学习参数 $h_i(0) = a_i$，所有模型的参数渐近收敛至值 $\bar{a} = \frac{1}{|N_i|}\sum_i a_i$。然而，只有在无人机完全连接时，这一性质才成立。用 ϵ 表示所有 V2V 通信中的最大时延。式（7）收敛的充要条件为 [13]:

$$\epsilon < \frac{\pi}{2\lambda_m}, \tag{9}$$

其中， $\lambda_1 \leq \lambda_2 \leq \cdots \lambda_m$ 表示 L 的特征值。 λ_m 是 L 的最大特征值，可用于表征网络中共识的收敛速度。根据 [13]，中的共识方案，无人机 i 的模型参数积分器设计如下:

$$\begin{aligned} h_i(k+1,t) = h_i(k,t) + \\ \rho \sum_{j \in N_i} \eta_{ij} \left(h_j(k, t-\epsilon) - h_i(k, t-\epsilon) \right), \end{aligned} \tag{10}$$

其中， h_i 是无人机机载模型的可学习参数。用 η_{ij} 表示无人机 i 与 j 之间的通信链路。当 i 与 j 断开连接时， η_{ij} 等于 0。 $\rho \in (0,\ 1)$ 是一个用于表示邻居影响程度的权重。

我们在算法 1 中详细说明基于 KD 的分布式模型共享（KD-DMS）方案的工作流程，其中 M 是 KD 过程的最大训练轮次。 q 是每个训练轮次中的共享次数，由可用带宽、数字孪生通信开销以及应用的识别准确率决定。我们在数字孪生资产中训练教师模型和学生模型，然后将最优学生模型和网络拓扑传输给相应的无人机。无人机 i 的模型整合器在每个模型共享周期中遵循公式（10）。

III. 基于数字孪生的模型优化

基于 KD-DMS 方案，相连的无人机可以就共享学习模型的相同参数达成一致。然而，模型共享收敛的前提是车间通信时延小于共识时延要求。但车间时延由通信和计算资源决定。因此，我们提出一种优化方案，在模型共享操作中保证共识收敛，同时最大限度地降低资源成本。该优化方案在边缘数字孪生上执行。此外，我们利用数字孪生资产中的网络演算分析，确定合适的拓扑特征、共享频率以及通信/计算资源，从而实现高效的无人机模型传播。

A. 分布式模型共享优化

为保证模型共享（即所有共享模型的可学习参数均相同）能够收敛，根据公式（9），车间通信时延 ϵ 不应超过 $\frac{\pi}{2\lambda_m}$。此外，根据格尔戈林定理 [13], ，拉普拉斯矩阵的最大特征值必须满足 $\lambda_m \leq 2d_{max}(G)$，其中 $d_{max}(G)$ 为最大节点度。

拓扑 G。具体而言，将 $\lambda_m = 2d_{max}(G)$ 代入公式（9），即可得到模型共享收敛的一个充分条件，

$$\epsilon \leq \frac{\pi}{4d_{\max}(G)}. \tag{11}$$

这意味着，具有特定拓扑特征 $d_{\max}(G)$ 且能够保证一致性共识的拓扑，具有相应的时延要求 ϵ。

用 $\delta(k)$ 表示第 k 个学生模型的大小。 $k \in \{1,2,3\}$ 分别表示 PSN、MSN 和 CSN。此外，第 k 个学生模型训练的机载计算成本为 $\varphi(k)$。令 $\omega(k,q)$ 表示共享频率为 q 时第 k 个学生模型的识别准确率。此外，共享频率为 q 时第 k 个学生模型的带宽消耗表示为 $C(k,q)$。因此，优化模型形式化为:

$$\begin{aligned} \textbf{P1:} \quad & \min_{\{k,q,d_{\max}(G)\}} C(k,q) + \varphi(k) \\ \text{s.t.} \quad & \text{C1: } D(k,q) \leq \frac{\pi}{4d_{\max}(G)} \\ & \text{C2: } \varphi(k) \leq F \\ & \text{C3: } \omega(k,q) \geq \Theta \\ & \text{C4: } k \in \{1,2,3\},\ q \text{ and } d_{max}(G) \in \mathbb{N}^+ \end{aligned} \tag{12}$$

优化目标是在满足一致性共识和资源约束的同时，最小化带宽消耗 $C(k,q)$ 以及计算/训练成本 $\varphi(k)$。第一个约束 **C1** 是模型共享一致性共识的通信时延约束。在 **C2** 中， F 是无人机可用的机载计算资源。**C3** 规定了无人机应用的识别要求 Θ。 k、 q 和 $d_{max}(G)$ 的取值范围设定为 **C4**，其中 $\mathbb{N}^+$ 是正整数集合。

$P1$ 的优化变量包括学生模型 k、共享频率 q以及拓扑特征，即最大节点度 $d_{\max}$（G）。注意， $d_{\max}$（G）仅影响模型共享协议的收敛，对最终识别准确率没有影响。

B. 网络演算分析

本小节揭示了**C1** 的延迟上界 D（k， q）与通信和计算资源消耗之间的关系。该估算在边缘数字孪生中进行。首先，我们梳理数字孪生同步所造成的资源消耗。数字孪生同步包括无人机向边缘服务器上传的运行偏差 Δg ，以及边缘服务器向无人机下载的ˆ状态预测 G_Ω（$t+1$）。为简化系统分析，我们在数字孪生同步 [10] 中仅考虑上传和数字孪生处理。

其中，上传延迟可表示为$\frac{\Delta g}{C^{DT}}$，其中 C^{DT}是为数字孪生同步预留的带宽。此外，数字孪生同步延迟由边缘服务器的处理能力 $\upsilon_{DT^{edge}}$和运行偏差的值Δg决定。其可表示为$\frac{\chi\Delta g}{\upsilon_{DT^{edge}}}$，其中 χ是用于衡量数字孪生计算复杂度的指标。假设最大箭头数字孪生同步延迟为 t^{DT}，则其必须满足 $t^{DT} \geq \frac{\Delta g}{C^{DT}} + \frac{\chi\Delta g}{\upsilon_{DT^{edge}}}$。因此，我们可以得到为数字孪生同步预留的带宽，即

$$C^{DT} = \frac{\Delta g \upsilon_{DT^{edge}}}{t^{DT}\upsilon_{DT^{edge}} - \chi\Delta g}. \tag{13}$$

此后，根据网络演算，我们在模型共享收敛条件下，得到一个包含预留带宽 C^{DT}、学生模型k、共享频率 q和最大节点度 d_{max}(*G*) 的函数。

在网络演算理论中，到达过程 $A(s,\ t) = A(t) - A(s)$ 定义了无人机在时间区间 (0，t] [14] 内输入网络流量的累积量。无人机 i 有 $|N_i|$ 个邻居。 $\delta(k)$ 表示共享的第k个学生模型参数的总量。传输速率 $\mathcal{E}$ 用于维持与邻居的基本连接。由于 (ϵ，σ)-上界约束，我们有 $A(t) - A(s) \leq \mathcal{E}(t-s) + q\delta(k)^{t-s}_{t}$ [15]。因此，无人机 i 向邻居共享模型的到达曲线为

$$A_{k,q}(t) = \mathcal{E}t + q\delta(k). \tag{14}$$

此外，用于模型共享的信道服务曲线 S 可表示为

$$S(s,t) = (C - C^{DT}) \cdot (t-s), \tag{15}$$

其中， C 是总带宽消耗。 $C - C^{DT}$ 表示扣除 DT 带宽消耗后可用于模型共享的可用带宽。我们假设无人机 i 的所有邻居 N_i 都具有相同的到达曲线。参与

模型共享的邻居数量为 $|N_i|$。根据剩余服务定理 [15], , 单个 UAVis 的信道服务曲线为

$$S'(t) = (C - C^{DT}) \cdot t - (|N_i| - 1)\left[\mathcal{E} \cdot t + q\delta(k)\right]. \tag{16}$$

基于时延上界分析, [15], 端到端最大时延为 $\min\left\{\omega \geq 0 : \max_{\epsilon \in [0,t]}\{A_{k,q}(\epsilon,\ t) - S'(\epsilon,\ t+\omega)\} \leq 0\right\}$。经过若干代数运算，可得车间通信时延的上界为:

$$D(k,q) = \frac{|N_i| q\delta(k)}{C - (|N_i| - 1)\mathcal{E} - C^{DT}}. \tag{17}$$

因此，上界时延 $D(k,\ q)$ 可视为模型共享收敛的时延要求 ϵ，如式 (11) 所示。将 $D(k,\ q) = \epsilon \leq \frac{\pi}{4d_{\max}(G)}$ 代入式 (17)，模型共享收敛的带宽要求为:

$$C(k,q) \geq \frac{4d_{\max}(G)}{\pi}|N_i| q\delta(k) + (|N_i| - 1)\mathcal{E} + C^{DT}. \tag{18}$$

因此，为了尽量减少带宽消耗，$C(k,\ q)$ 应满足式 (18) 中的等号。由此，我们可以将优化问题**P1** 改写为:

$$\begin{aligned} \textbf{P2:}\quad & \min_{\{k,q,d_{\max}(G)\}} \frac{4d_{\max}(G)}{\pi}|N_i| q\delta(k) + (|N_i| - 1)\mathcal{E} + \varphi(k) \\ & \text{s.t.} \quad \textbf{C2},\ \textbf{C3},\ \textbf{C4}. \end{aligned} \tag{19}$$

由于 C^{DT}与 $\{k, q, d_{\max}(G)\}$无关，因此在优化中可将其视为常数。C^{DT}的具体取值不会影响最终的最优损失。因此，我们从 $P2$的目标函数中移除 C^{DT}。此外，传输数据量 $\delta(k)$ 和计算成本 $\varphi(k)$ 均随 k单调递增。这意味着，在约束条件下最小化 k、q 和 $d_{\max}(G)$，即可实现**P2**的目标。

算法2: 基于DT的最优配置搜索

1 初始化 $k_0 = 1$; k_1 **是具有** $\varphi(k_1) \leq F$**的** k **最大数量;** $q_0 = 1$; q_1 **是** q**的最大数量;** $d_{max}(G) = 2$**2 当** $\omega(k_0, q_0) \leq \Theta$ **时执行 3 当** $k_0 \neq k_1$ **时执行 4 设置** $k_m = \lfloor \frac{k_1 - k_0}{2} \rfloor + k_0$**; 5 如果** $\omega(k_m, q_1) > \omega(k_0, q_1)$ **且** $\omega(k_m, q_1) > \omega(k_0, q_1)$ **则6** $k_0 = \lfloor \frac{k_m - k_0}{2} \rfloor$; $k_1 = \lfloor \frac{k_1 - k_m}{2} \rfloor$**; 7 否则如果** $\omega(k_1, q_1) \geq \omega(k_m, q_1) \geq \omega(k_0, q_1)$ **则8** $k_0 = k_m$; $k_m = \lfloor \frac{k_1 - k_m}{2} \rfloor$**; 9 否则如果** $\omega(k_0, q_1) \geq \omega(k_m, q_1) \geq \omega(k_1, q_1)$ **则 10** $k_1 = k_m$; $k_m = \lfloor \frac{k_m - k_0}{2} \rfloor$**; 11 当** $q_0 \leq q_1$ **时执行 12 如果** $\omega(k_0, q_0) \geq \Theta$ **则 13 返回** $(k_0, q_0, d_{max}(G))$**14** $q_0 = q_0 + 1$**; 15** $d_{max}(G) = d_{max}(G) + 1$**; 16 返回** $(k_0, q_0, d_{max}(G))$

然而，学习模型的识别准确率 $\omega(k,\ q)$ 是关于 k 和 q的非解析且不可微函数。当 k-q 对的搜索空间较小时，边缘数字孪生可以通过枚举并利用查找表方法获取 $\omega(k,\ q)$。表 I 展示了不同 $(k,\ q)$ 下的识别准确率 ω。实验配置参照“仿真”部分的设置。PSN 的识别准确率不会随着共享频率 q的增加而提高，因为 PSN 的模型结构简单，不具备提取数据特征的学习能力。因此，采用 PSN 的无人机共享的是不准确的模型，这会引发模型污染并降低共享性能。粗略而言，MSN 和 CSN 的识别准确率会随着 q的增加而提高，且其识别准确率优于 PSN。与此同时，CSN 的性能逊于 MSN，因为 CSN 可能会出现过拟合。当准确率要求为 $\Theta = 0.9$时，只有 $(k = 2,\ q = 3,\ 4,\ 5)$ 和 $(k = 3,\ q = 4)$ 符合要求。此外，在 $(k = 2,\ q = 3)$ 时，带宽和计算成本最低。

表 I：不同 q-k 对的识别准确率。

$\omega\ (k,\ q)$	**PSN** $k=1$	**MSN** $k=2$	**CSN** $k=3$
频率 $q=1$	0.780	0.821	0.769
频率 $q=2$	0.734	0.804	0.787
频率 $q=3$	0.817	0.923	0.872
频率 $q=4$	0.890	0.935	0.902
频率 $q=5$	0.739	0.930	0.895

通过对式（18）进行代数变换，模型共享频率 q 受到如下约束：

$$q \leq \frac{[C-(|N_i|-1)\mathcal{E}-C^{DT}]\pi}{4d_{max}(G)|N_i|\delta(k)}. \tag{20}$$

在我们的仿真配置中，最大节点度 $d_{max}(G)=3$ 以及邻居数量 $|N_i|=6$。根据上述公式 (20)，我们可以推导出最优的 $q=3$。

参见表 I，我们发现 $\omega(k,\ q)$ 随着 k 先增大后减小。原因在于，$\omega(k,\ q)$ 随 k 增加，直到第 k 个学生模型出现过拟合。因此，我们提出一种二分搜索方法，以探索最优的 k，从而最大化 $\omega(k,\ q)$。当 k-q 对的搜索空间变大时，我们可以利用 q、k 和 $d_{max}(G)$ 的性质快速求解 **P2**。由于带宽有限，最优的 q 通常较小，因此我们研究了表 I 中从 $q=1$ 开始的 q 取值。此外，在包含 3 个以上节点的全连接拓扑中，$d_{max}(G)$ 至少为 2。进一步地，我们的分析表明，较小的 $d_{max}(G)$ 带宽开销更低，如公式 (18) 所示。总之，我们提出了一种模型共享配置搜索方案，如算法 2 所示。所提方法的时间复杂度为 $O(n\log(n))$，因为在大多数情况下，最优共享频率 q 小于 5。

算法 2 在边缘服务器上实现，用于搜索最优的模型共享配置。边缘数字孪生可以操控克隆网络的最大节点度，在不产生实际网络改造和部署成本的情况下优化**P2**。最终，边缘数字孪生会在下一个时隙提供最合适的学生模型、通信拓扑和共享频率，以引导物理模型共享方案。

IV. 性能评估

为了评估和比较所提出的应用于模型共享的数字孪生赋能的 KD-DMS 算法，我们在流行的点云数据集 ShapeNet 上研究了不同的学生模型、拓扑和共享频率。该数据集包含 16681 个样本，属于 16 个常见类别 [16], [17]。每架无人机均匀采样 2500 个带坐标的点云作为输入。为促进学习多样性，我们将数据集分为四个等份，每架无人机随机选取其中三份作为其数据库。每架无人机的训练数据集均从其数据库中独立采样，采样概率为 0.5，以模拟无人机数据采集的差异。此外，测试集采用 ShapeNet 原始划分中的测试集。我们提出的 KD-DMS 算法在一台配备 NVIDIA GeForce RTX 2060 GPU 的计算机上运行，并使用 PyTorch 编写。模型训练采用 Adam 优化器，学习率设为 0.001。批量大小为 32，总训练轮次为 60。部分重要的仿真参数列于表 II。

表 II：仿真参数

学习率	0.001	共享频率	5
批量大小	32	采样概率	0.5
类别数量	16	每架无人机的数据量	2500
知识蒸馏温度 τ	20	知识蒸馏权重 α	0.5

图5为不同模型对应时间消耗的箱线图，其中，y轴表示训练时间。教师模型 Pointnet 的训练时间最长。PSN 的时间消耗仅为 Pointnet 的 66%。此外，MSN 和 CSN 的时间消耗分别为 Pointnet 的 81% 和 91%。因此，替代 Pointnet 的三种知识蒸馏模型均可加速无人机的机载训练过程。

图6展示了用于模型共享的相应通信拓扑。图7比较了采用模型共享的三种知识蒸馏模型与未采用模型共享的 Pointnet 的识别准确率。如图7所示，经过十个训练轮次后，MSN 和 CSN 中采用 $q=5$ 的所提出 KD-DMS 在识别准确率方面优于未采用模型共享的 Pointnet。通过公式（10）中的模型共享，学生模型可以整合邻居在不同数据集上训练得到的学习参数。在不同数据集上进行模型共享可带来多样性训练增益。此外，采用 MSN 模型的 KD-DMS 的识别准确率完全超过了采用 CSN 模型的 KD-DMS。可能的原因是，CSN 包含的学习参数多于 MSN，因此更容易引发不一致/错误传输问题。

图8展示了不同共享频率下 MSN 的性能 q。我们可以观察到，采用 $q \geq 3$ 进行共享的 MSN 在识别准确率方面优于原始 Pointnet 模型。这表明，所提出的 KD-DMS

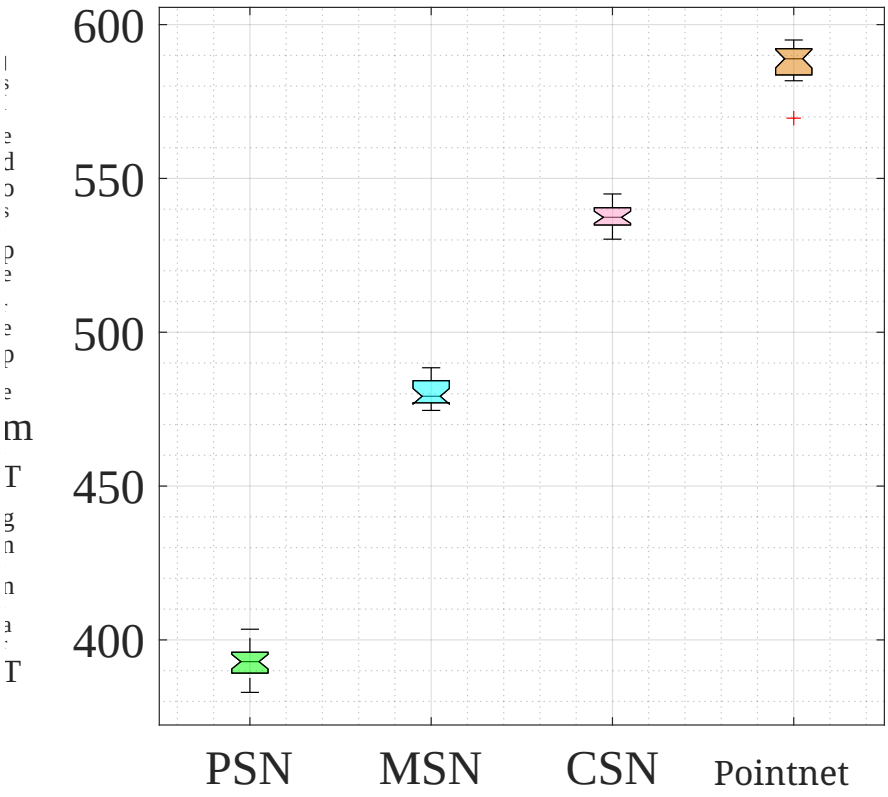

图 5： 不同模型每个训练轮次的耗时。

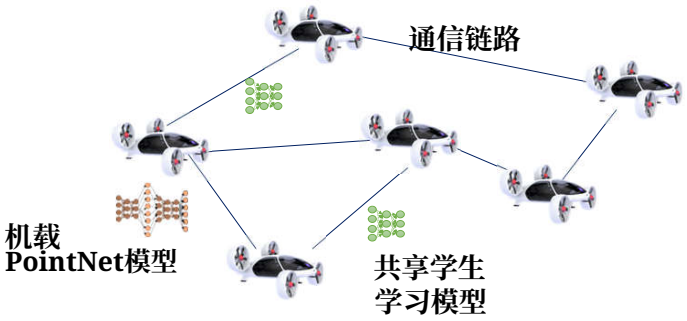

图 6： 最大节点度为 $d_{max}(G) = 3$ 时的模型共享拓扑，其中，飞行汽车搭载的 *Pointnet* 通过知识蒸馏生成轻量级学生模型，随后飞行汽车根据该拓扑与邻居传输学生模型。

能够通过频繁共享，有效吸收其他已训练模型的知识。当 q 大于 3 时，不同 q 的最终收敛精度相同。更大的 q 可以加快收敛速度。然而，参见公式 (20)，较大的 q 也会消耗大量通信带宽 C。因此，必须谨慎配置共享频率 q，同时考虑通信带宽、拓扑特征和应用性能要求。

图 9 展示了不同模型、无人机和共享频率下的识别准确率。图 6 显示，节点 5 和节点 3 的节点度分别为 3 和 2。图 9.(a) 展示了节点 5 和节点 3 的 PSN 性能。节点 5 的性能优于节点 3，因为节点 5 的节点度更大。拥有更多邻居的无人机可以获得更多训练良好的模型，从而显著提高识别准确率。然而，识别准确率不会随着 q 的增加而提高。原因在于，PSN 需要更复杂的学习模型来从点云数据中提取特征，这阻碍了通过模型共享提升性能。此外，交换多个性能较差的模型可能会导致性能下降。

图 9 中，采用 MSN 的模型共享方案在点云识别方面优于采用 PSN 的方案。这表明，相比 PSN，MSN 能更有效地捕获局部点云的属性。随着共享频率q 增加，识别准确率也随之提高。然而，识别性能并不会随着 q 逐步增长，而是呈现跃升式提升。在曲线末端，存在两个稳定区域，分别对应 $q \geq 3$ 和 $q < 3$。如果 q 小于 3，模型共享不足会使无人机难以

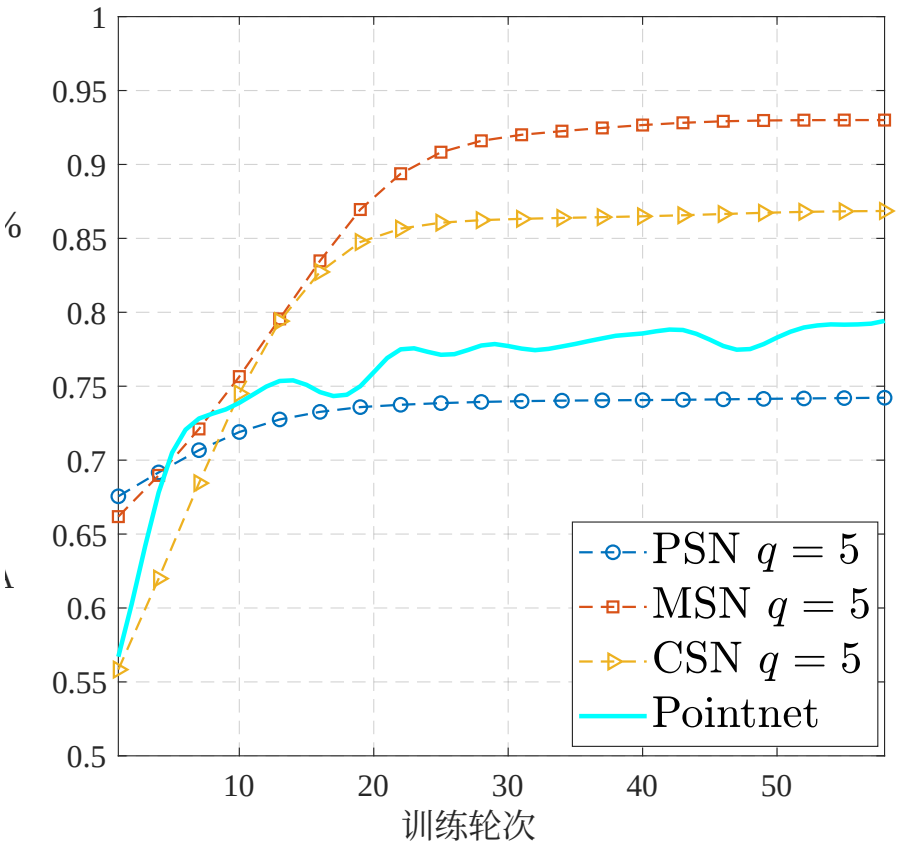

图7： *KD-DMS* 使用不同学习模型时的性能。

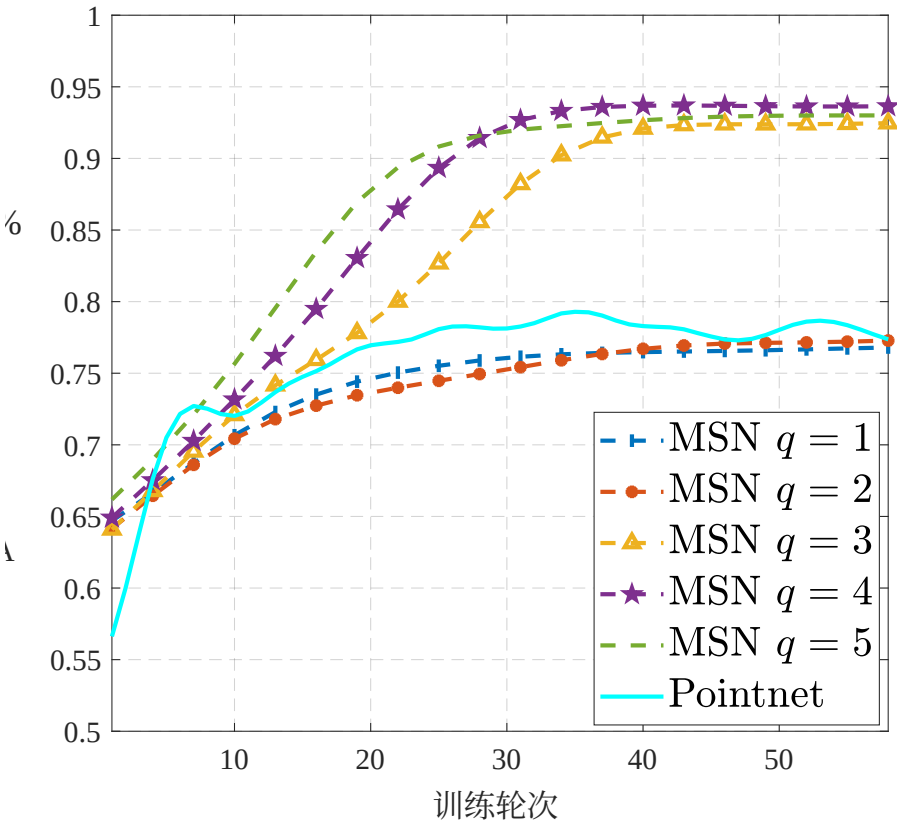

图8： 不同 q下 *MSN* 的性能。

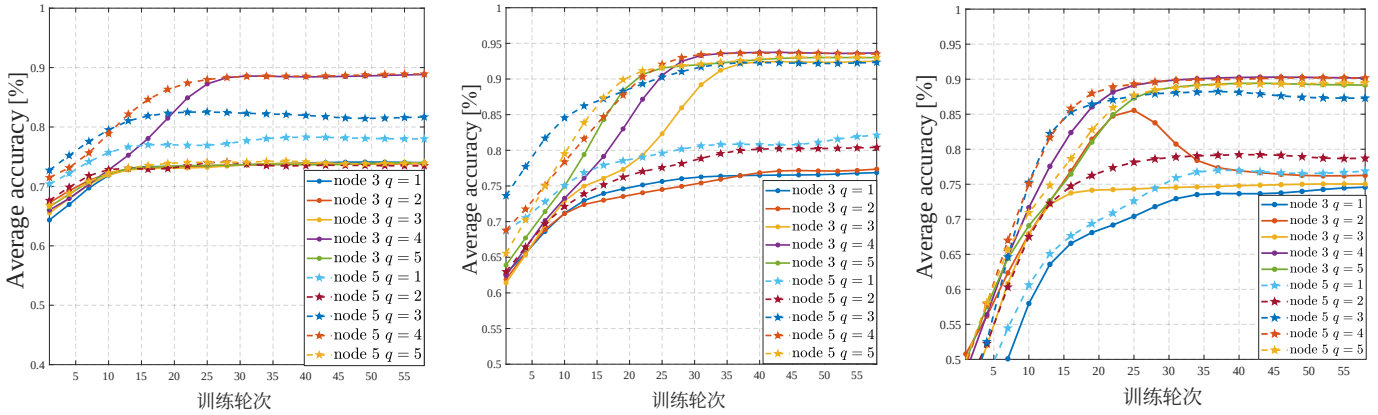

(a) *PSN*。 **(b)** *MSN*。 **(c)** *CSN*。

图 9： 不同学生模型中具有共享频率 q 的不同节点（无人机）的性能 .

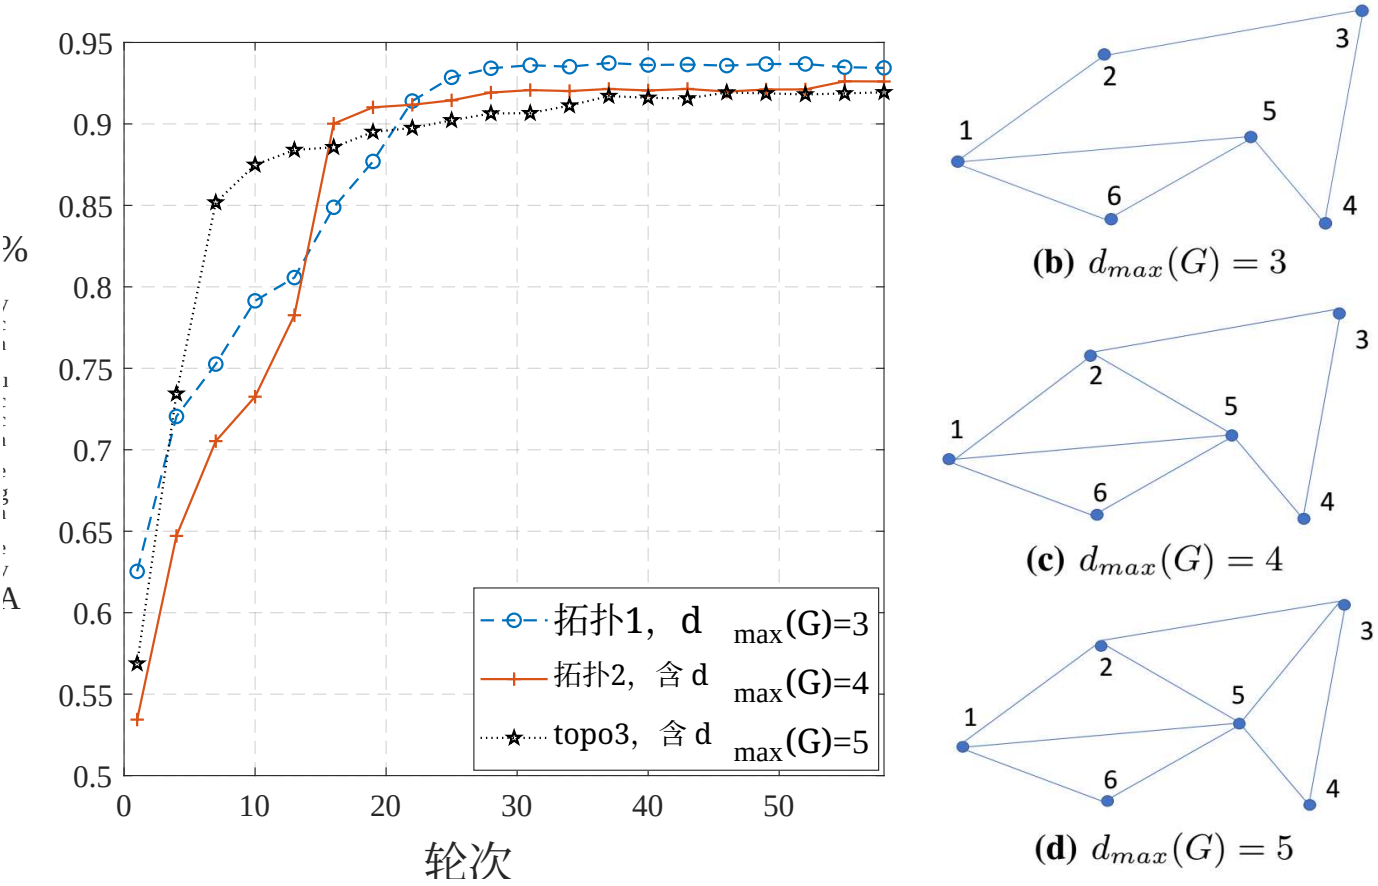

(a) *MSN* 识别性能。 **(b)** $d_{max}(G)=3$ **(c)** $d_{max}(G)=4$ **(d)** $d_{max}(G)=5$

图 10： *(a)* 描绘了采用不同拓扑结构的 *MSN* 的识别准确率。*(b)-(d)* 分别为 $d_{max}(G) = 3$、$d_{max}\ G = 4$ $d_{max}\ G = 5$ () 和 () 的实际拓扑结构。

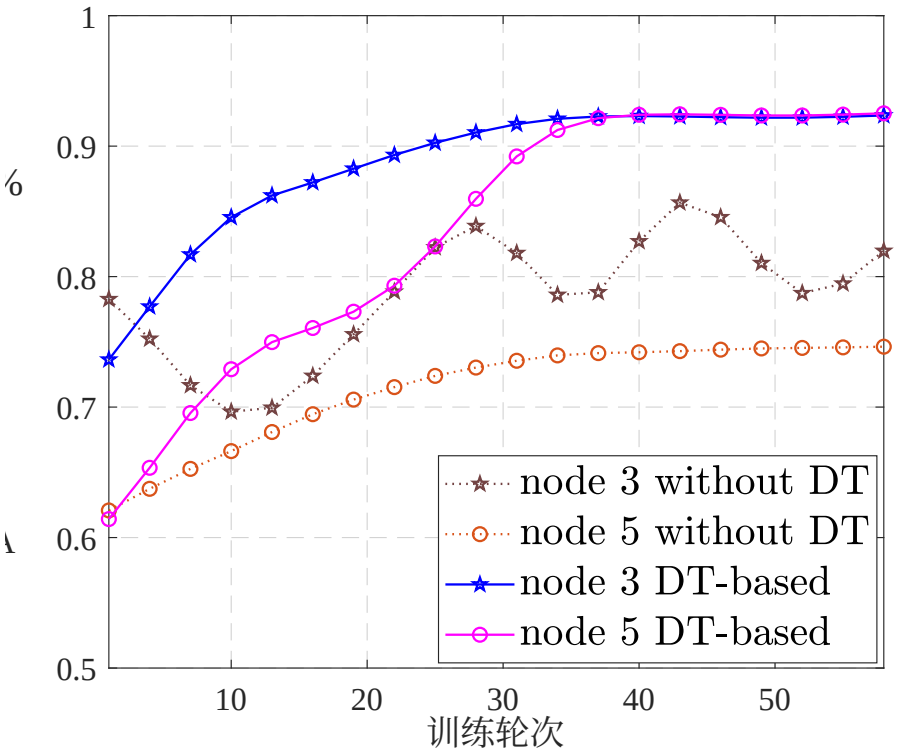

图 11： 基于数字孪生的模型共享与不使用数字孪生的模型共享性能对比。

为了获得模型共享的益处。此外，无人机可以像 $q \geq 3$ 一样充分掌握邻居的知识。无论如何，当 $q > 3$ 时，识别准确率不会随着 q 而提高。因此，只有当 $q < 3$ 时，节点度才会影响模型共享性能。在所提供的图中，经过三次以上模型共享后，图 6 中节点 5 和节点 3 的准确率可以收敛到相同值。

我们还可以观察到，采用 CSN 模型的模型共享方案在 $q \geq 3$ 和 $q < 3$ 条件下具有两种稳定的准确率。然而，CSN 的性能不如 MSN，因为 CSN 的深层模型结构容易导致过拟合。总体而言，高共享频率和较大的节点度能够有效提升在不同数据集上的学习能力。

为评估通信拓扑对模型共享的影响，图 10 展示了最大节点度不同的 MSN 模型共享情况，其中共享频率为 5。三种拓扑的最终稳定准确率大致相似。此外，具有较大 $d_{max}(G)$ 的拓扑能够快速收敛至稳定准确率。因此，通过增大通信拓扑的最大节点度 $d_{max}(G)$，模型共享可以获得更快的收敛速度，从而适用于对时延敏感的应用。然而，根据公式（18），较大的 $d_{max}(G)$ 会消耗更多通信带宽。因此，需要在收敛速度和带宽消耗之间进行权衡。

我们在图 11 中展示了有 DT 和无 DT 时模型共享的识别准确率，以评估 DT 带来的性能提升。共享拓扑与图 6 一致。无 DT 的模型共享需要交换共享模型，但无线传输可能导致丢包。为简化起见，本次仿真假设节点 3 的丢包率为 30%，节点 5 的丢包率为 50%，因为度较大的节点面临更严重的带宽竞争。然而，DT 资产中不存在传输错误，因此能够模拟数字通信。图 11 显示，基于 DT 的模型共享比无 DT 的模型共享具有更好的识别性能。这是因为丢包会导致模型共享不一致或出错。此外，节点 3 的丢包率低于节点 5。但节点 3 仅整合两个邻居模型。与节点 5 相比，节点 3 中任何一个邻居发生丢包对其性能的影响都更难以承受，因此节点 3 的曲线出现了明显波动。

图 12 描绘了带宽消耗下界 C、无人机数量 N 与共享频率 q 之间的关系，其中 q 和 N 仅取整数值。频率 q 与带宽 C 成正比，但与 N 成反比。随着无人机数量 N 增加，可用带宽 C 将根据公式 (18) 减少。根据公式 (20)，较大的 N 也会导致较小的 q。因此，当 $N > 5$ 时，q 通常是一个相对较小的数，在大多数情况下不太可能超过 3。结合图 9，我们可以预先确定实际模型共享场景中的合适轻量级模型、无人机共享频率以及带宽资源配置。

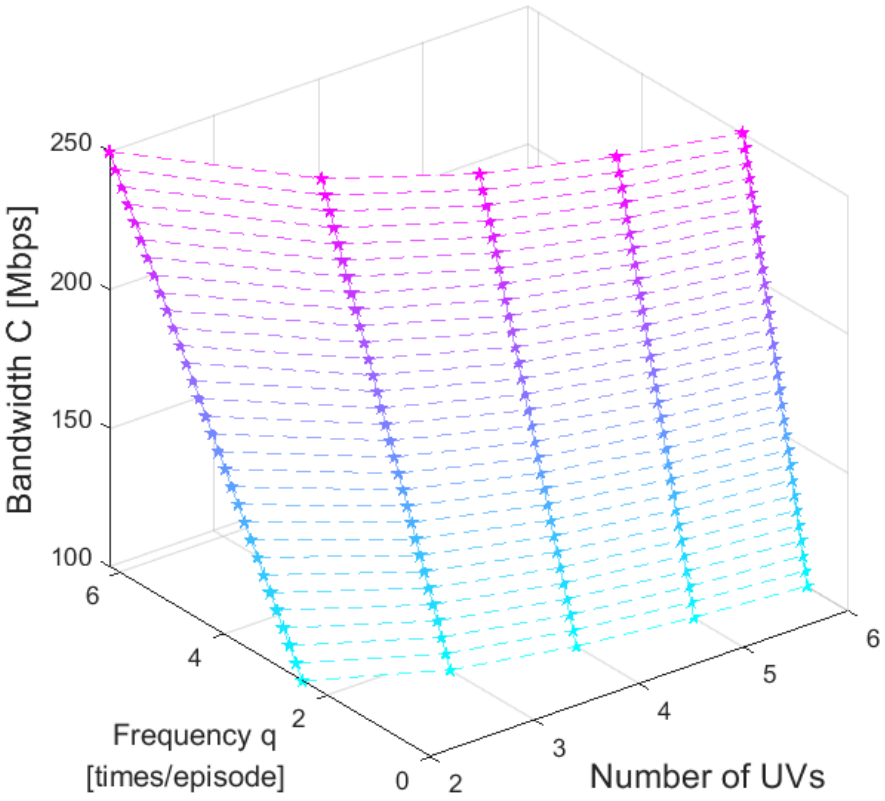

图 12：带宽、无人机数量与共享频率之间的关系。

V. 结论

本文提出了一种用于三维点云识别的数字孪生赋能的分布式模型共享方案。该方案可应用于资源受限无人机，以感知生产环境。在设备-边缘数字孪生系统的支持下，设备数字孪生可及时监测无人机的状态，边缘数字孪生则可通过可靠的群体模仿对其进行优化。具体而言，边缘数字孪生首先在边缘服务器上通过知识蒸馏压缩同时生成三个轻量级模型。基于知识蒸馏轻量级模型，本文提出了一种模型共享方案，以确保无人机共享的模型收敛至同一模型。该模型共享方案利用网络演算，为多架无人机协作确定合适的共享模型、网络拓扑和资源分配。此外，边缘数字孪生中的网络演算分析依赖于设备数字孪生提供的汇总信息。实验结果表明，所提出的模型共享方案切实可行，且在识别准确率方面优于未进行模型共享的 Pointnet。这项工作展示了利用多个资源受限设备协作来提升嵌入式学习性能的可能性，并在工业物联网场景的大规模群体智能应用中展现出巨大潜力。

参考文献

[1] F. Tian、R. Zhou 等，“考虑地形约束的自动驾驶矿用卡车轨迹规划”，*IEEE Transactions on Intelligent Vehicles*，第6卷第4期，第772–786页，2021年。[2] X. Ding、W. Zhou 等，“露天矿爆破冲击载荷作用下碎片尺寸分布特征及爆破参数优化”，*IEEE Access*，第7卷，第137 501–137 516页，2019年。[3] L. Zhou、S. Leng、Q. Wang和Q. Liu，“无人机群协同多目标跟踪中的感知与通信一体化”，*IEEE Transactions on Mobile Computing*，第1–17页，2022年。[4] H. Gao、B. Cheng 等，“自动驾驶车辆环境中基于卷积神经网络的视觉与激光雷达融合目标分类”，*IEEE Transactions on Industrial Informatics*，第14卷第9期，第4224–4231页，2018年。[5] X. Zou、K. Li 等，“面向自动驾驶点云学习的多任务Y形图神经网络”，*IEEE Transactions on Intelligent Transportation Systems*，第1–12页，2022年。[6] R. Q. Charles 等，“Pointnet：面向点集的深度学习及三维分类与分割”，*2017 IEEE*计算机视觉与模式识别会议（*CVPR*），第77–85页，2017年。[7] G. Hinton、O. Vinyals 等，“神经网络中的知识蒸馏”，2015年。[8] S. Kim，“一种基于条件生成对抗网络的虚拟知识蒸馏方法”，*IEEE Access*，第10卷，第34 766–34 778页，2022年。[9] K. Xie、Q. Cai 等，“具有快速收敛特性的输入数据平均一致性分布式算法”，*IEEE Transactions on Systems, Man, and Cybernetics: Systems*，第51卷第5期，第2653–2664页，2021年。[10] Y. Lu、S. Maharjan和Y. Zhang，“面向6G无线数字孪生网络的自适应边缘关联”，*IEEE Internet of Things Journal*，第8卷第22期，第16 219–16 230页，2021年。[11] C. Qian、W. Yu 等，“面向工业物联网的生成对抗网络”，*IEEE Internet of Things Journal*，第1–1页，2022年。

[12] A. Bhardwaj、S. Pimpale 等，“通过开放集识别增强知识蒸馏，实现稳健的三维点云分类”，《模式识别快报》，第151卷，第172–179页，2020年。[13] R. Olfati-Saber和R. Murray，“具有切换拓扑及时延的智能体网络中的一致性问题”，《*IEEE*自动控制汇刊》，第49卷第9期，第1520–1533页，2004年。[14] M. Fidler、A. Rizk 等，“随机网络演算指南”，《*IEEE*通信调查与教程》，第92–105页，2015年。[15] Y. Jiang、Y. Liu 等，“随机网络演算”，2008年。[16] Y. Wang、Y. Sun 等，“用于点云学习的动态图卷积神经网络”，《*ACM*图形学汇刊》，第38卷第5期，2019年10月。[17] X. Zou、K. Li和C. Chen，“面向点云学习的基于多层注意力的U形图神经网络”，*IEEE Transactions on Industrial Informatics*，第18卷第1期，第448–456页，2022年。