arXiv:2601.02270v1 [cs.ET] 5 Jan 2026

天空航路网络中的无人机间干扰即服务建模

Gabriel Timothy, 悉尼大学计算机科学学院，澳大利亚Syeda Amna Rizvi, 悉尼大学计算机科学学院，澳大利亚Muhammad Umair, 悉尼大学计算机科学学院，澳大利亚Athman Bouguettaya,悉尼大学计算机科学学院，澳大利亚Balsam Alkouz, 悉尼大学计算机科学学院，悉尼大学，澳大利亚，以及阿卜杜拉国王

科技大学，沙特阿拉伯

我们首次研究了无人机间干扰对多无人机空中航路网络中配送效率的影响。我们通过受控实验，分析无人机在室内测试环境中的行为。本研究比较了沿预定义航线进行单机飞行与并发多无人机运行时的性能。分析涵盖飞行期间及充电站发生的干扰，从而全面评估其对整体网络性能的影响。我们在多种场景下开展了一系列全面实验，以系统地理解并建模无人机间干扰的动态特性。研究考虑了功耗和配送时间等关键指标，并由此生成了一个数据集，用于深入分析节点和路段层面的干扰。随后，我们将这些发现形式化为预测模型。结果验证了所开发模型的有效性，表明该模型有望准确预测无人机间干扰。

CCS 概念：• **计算方法** → **模型开发与分析**；**机器学习方法**；• **计算数学** → **非线性方程**。

其他关键词和短语：无人机、无人机服务、干扰、空中航路网络、无人驾驶飞行器

ACM 引用格式：
Gabriel Timothy、Syeda Amna Rizvi、Muhammad Umair、Athman Bouguettaya 和 Balsam Alkouz。2025。《天空航路网络中的无人机间干扰即服务建模》。《*ACM*杂志》37，4，文章 111（2025年1月），30 页。https://doi.org/XXXXXXX.XXXXXXX

1 引言

物流和配送服务的迅速扩张，给传统地面运输方式带来了巨大压力，导致延迟和运营成本上升 [38]。无人机（又称无人驾驶飞行器）已成为满足日益增长的需求的一种有前景的解决方案，可提供更快捷、更具成本效益的配送方式 [1]。近期研究表明，与

作者联系信息：Gabriel Timothy，gabriel.timothy@sydney.edu.au，悉尼大学计算机科学学院，澳大利亚新南威尔士州悉尼；Syeda Amna Rizvi，amna.rizvi@sydney.edu.au，悉尼大学计算机科学学院，澳大利亚新南威尔士州悉尼；Muhammad Umair，muhammad.umair@sydney.edu.au，悉尼大学计算机科学学院，澳大利亚新南威尔士州悉尼；Athman Bouguettaya，athman.bouguettaya@sydney.edu.au，悉尼大学计算机科学学院，澳大利亚新南威尔士州悉尼；Balsam Alkouz，balsam.alkouz@sydney.edu.au，悉尼大学计算机科学学院，澳大利亚新南威尔士州悉尼，以及阿卜杜拉国王科技大学，沙特阿拉伯麦加省图瓦尔。

允许免费制作本作品全部或部分内容的数字副本或纸质副本，供个人使用或课堂教学使用，但前提是不得为营利或商业目的制作或分发副本，且副本须附有本声明及首页的完整引文。对于本作品中由作者以外的其他人拥有版权的部分，必须尊重其版权。注明出处后，允许摘录。若要以其他方式复制、重新出版、发布到服务器或分发至列表，则需事先获得明确许可和/或支付费用。请通过 permissions@acm.org 申请许可。© 2025 版权归所有者/作者所有。出版权已授权给 ACM。稿件已提交至ACM

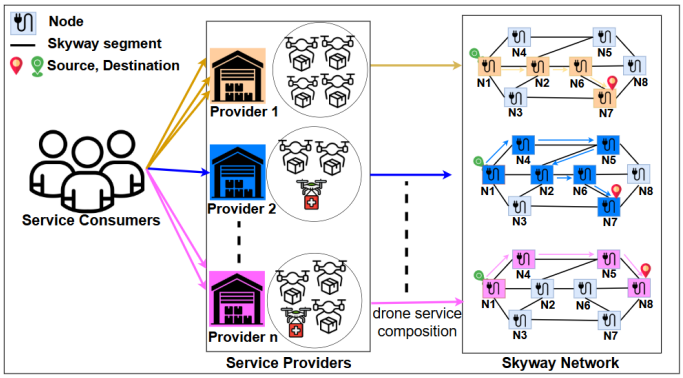


图 1. 多无人机服务提供商在空中航路网络中的路径组合

传统地面运输方式，同时显著降低运营成本 [11]。无人机能够在复杂环境中实现高效导航，使其非常适合最后一公里配送和时效性货物运输，例如医疗物资 [8]。这种高效性正推动关键行业对无人机配送的需求激增，进而导致多个无人机在空域中密集运行。在这一复杂环境中，无人机间干扰 可能对配送效率 和安全性造成重大挑战。

关于无人机配送服务的大多数讨论都强调在特定地理区域内进行点对点配送 [20]。然而，有时无人机需要飞行更远的距离，因此必须频繁充电 停靠，才能抵达目的地 [16]。这些限制使路径优化更具挑战性，尤其是在兼顾充电停靠与及时配送时。为应对这一挑战，近期研究采用面向服务的方法，在空中航路网络中对无人机即服务（DaaS）进行建模。空中航路网络由相互连接的节点 和航段构成。节点代表建筑屋顶，可作为无人机充电的战略性中途停靠点。航段则界定空域，并纳入预先设定的三维航路点（纬度、经度、高度），引导无人机在这些节点之间飞行。该面向服务的方法有助于在网络中组合长距离无人机配送路径 [34]。

在空中航路网络中近距离运行多架无人机，会因干扰因素而面临重大挑战 [25]。当这些无人机穿行于拥挤的空中航道时，信号中断、碰撞和通信冲突的风险会增加 [22]。此类干扰可能妨碍飞行平稳 运行，导致无人机移动异常，并延误配送计划 [30]。为解决这些问题，我们完善了空中航路网络内运行的服务抽象，从而能够更全面地建立无人机间干扰模型。该抽象将空中航路网络概念化为由多个无人机服务提供商 （即无人机所有者）共同使用的共享空域。这些无人机所有者负责组合由节点和航段构成的配送路径，以满足消费者对及时且经济配送的需求。此外，还设立了超级服务提供商 这一层级，负责监督共享空中航路网络中无人机交通的平稳运行，即确保其安全 且高效 运行。

现有无人机研究专注于组合无人机配送服务，以便高效地选择并整合最优服务组合，从而在空中航路网络中运输货物 [35]。这种方法需要配置一条由航段和中间节点组成的组合路线，无人机必须在规定的时间间隔内沿此路线飞行 [33]。图 1 展示了多个无人机服务提供商在共享空中航路网络中进行路径组合的概况。多个服务提供商（即无人机所有者）管理着各自的无人机机队，并以不同颜色表示。服务消费者是向不同无人机服务提供商申请包裹配送服务的稿件已提交至ACM

终端客户。每个无人机服务提供商都会策略性地规划无人机抵达和离开中间节点的时间，同时考虑无人机的充电需求，以确保配送顺畅且及时。无人机服务提供商会独立地并贪心地组合路径，目标是尽可能缩短自身的配送时间 [3]（图 1）。这种方法可能导致干扰，因为无人机需要争夺有限的充电垫和共享空域，进而可能影响整体配送效率和安全性。在此背景下，超级服务提供商发挥着关键作用：它们在帮助无人机服务提供商满足服务质量（QoS）要求的同时，优化整体网络利用率。

现有解决方案往往忽视无人机间干扰，这可能导致拥堵和延迟，最终损害满足服务质量要求的能力，尤其是在配送时间方面。据我们所知，近期大多数无人机交通管理研究都聚焦于安全性相关干扰的建模，例如碰撞 [7]。然而，据我们所知，尚无先前研究探讨各种干扰如何影响无人机服务的效率 。本研究首次全面考察无人机服务间干扰对配送时间 和能耗等关键性能指标的影响。所提出的干扰影响模型为开发无人机交通管理系统奠定了基础。这些系统将支持设计干扰消解策略，例如实时路径调整，以便为无人机生成无干扰路径。由于空中航路网络具有共享属性，实时干扰消解策略需要采用复杂的方法。这些方法必须确保多个无人机服务并发运行时的公平性和效率。例如，有利于某项无人机服务的消解策略可能会对其他服务产生负面影响。开发干扰感知路径调整框架是本研究未来的拓展方向。

我们将干扰定义为一种事件，即其会妨碍无人机服务提供商满足服务质量要求的能力，尤其是满足配送时间要求的能力。干扰可能发生在节点级和航段级。节点级干扰特指充电站发生中断而导致的延迟。例如，如果充电垫数量有限，当多架无人机排队等待使用时，某架无人机可能需要比预期等待更长时间。此外，无人机在等待充电垫时可能被迫悬停，从而消耗额外的电池电量。在此类情况下，干扰导致的能源需求增加或等待时间延长，会直接损害无人机服务满足其服务质量目标的能力。路段级干扰是指无人机在空中航路网络的特定航段中飞行时，对其预期功耗产生的影响。当多架无人机在空间上彼此距离很近、以至于它们的气动力相互干扰时，就会发生此类干扰。因此，无人机可能需要消耗更多电池电量来维持其飞行路径，从而需要在后续节点进行额外充电，以确保包裹配送成功。例如，当多架无人机被要求在同一航段内同时运行时，它们之间可能发生航段级无人机服务干扰。在这种情况下，在较高高度运行的无人机产生的下洗力，会增加其下方飞行无人机的能耗 [36]。这项额外的能量消耗可能要求无人机在后续节点进行额外充电，从而扰乱服务提供商的服务计划，并削弱其满足配送时间服务质量目标的能力。

我们提出了一种新颖的方法，用于对无人机的节点级和路段级干扰进行建模。该模型考虑了关键的效率因素，包括节点处充电垫的利用率，以及路段 traversing 过程中的无人机间交互。为此，我们收集并分析了一个数据集，以研究节点级和路段级干扰对自主无人机机群配送时间的影响。每次无人机飞行都会因其所经过的特定中间节点而有所不同，这取决于指定的源节点和目标节点。此外，每次无人机飞行的载荷也各不相同，因而在各节点的充电需求也有所差异。我们在一套室内测试台中，围绕这些无人机飞行开展了一系列全面实验。该测试台旨在模拟空中航路网络，

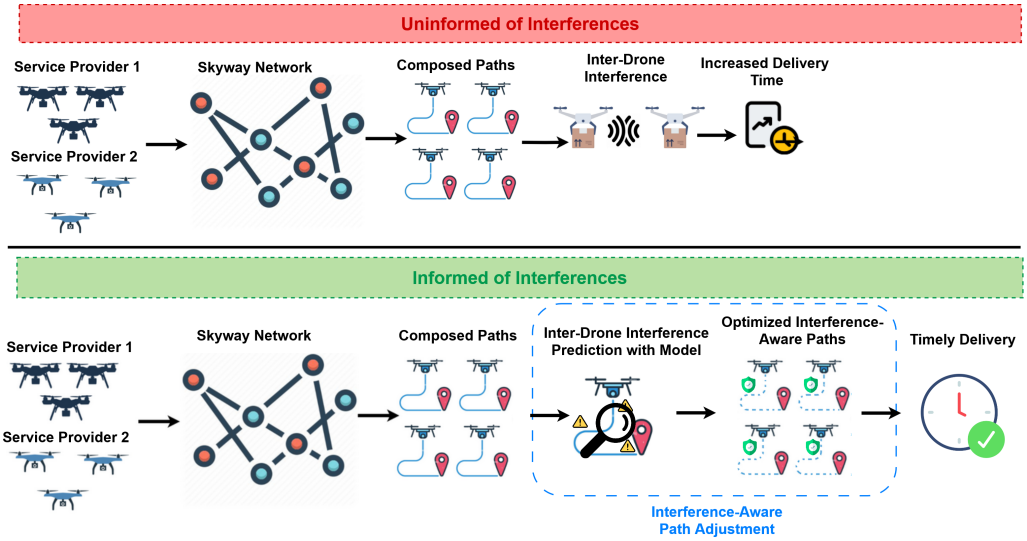


图2。动机示例

并复现城市条件。我们进一步扩展实验，纳入不同的风况，并考虑可能影响配送时间和能耗的环境因素。为了量化这些干扰的影响，我们采用先进的经验建模技术，以捕捉外部条件与无人机服务效率之间的细微关系。具体而言，我们使用多项式回归模型对无人机间干扰进行建模。结果验证了所开发经验模型的有效性。本研究的主要贡献如下：

- 我们全面分析了空中航路网络中发生的无人机间干扰，重点阐述共享空中航路网络中并发运行所带来的复杂性。
- 我们提出了一种模型，用于量化无人机间干扰的影响，评估其对航段和节点级运营效率的影响。

- 我们开发了一个图形用户界面，以便在空中航路网络中跟踪多条无人机轨迹。该界面允许用户将实时无人机运动可视化，从而提升运营态势感知以及无人机之间的协调能力。

需要注意的是，其他因素也可能影响无人机间干扰，例如载荷的体积和形状、无人机的尺寸以及速度。尽管这些变量未纳入我们当前的模型，但它们可能会显著影响无人机稳定性、功耗和整体性能。未来的模型迭代可以通过纳入这些参数加以完善，从而更深入地理解现实条件下的干扰动态。这种改进将提高在更广泛环境和运行场景下预测多无人机系统性能的准确性。

2 动机场景

随着无人机配送服务在电子商务、医疗保健和应急响应等领域不断发展，在共享空域协调多架无人机所面临的挑战也日益凸显。高效协调至关重要，可避免运行效率低下，尤其是在高密度人口地区。稿件已提交至ACM

无人机间干扰是指近距离运行的无人机相互作用所造成的干扰，它给配送效率和安全性带来了重大挑战。为说明无人机间干扰的复杂性，若干值得关注的事件凸显了在共享空域运行无人机所面临的挑战。一个典型案例是西塔科在2023年美国独立日庆祝活动期间发生的安格尔湖无人机表演事故：200架无人机中有55架意外坠入湖中，造成的设备损失估计达143,000美元。这起事件凸显了无人机易受外部干扰影响，例如偏离频率的蜂窝基站或未经授权的干扰设备可能造成的干扰。另一起重大事件发生在布里斯班，一架配送无人机缠绕在电力线上，导致当地居民停电。这起事件反映了无人机面临的导航挑战以及无人机间干扰带来的风险，尤其是在多架无人机近距离运行时。这些挑战表明，随着无人机在各领域的应用不断扩大，必须制定稳健的干扰管理策略，以确保无人机运行的可靠性和安全性。

这些事件凸显了实施高效无人机交通管理解决方案、以缓解此类干扰的迫切必要性。我们在图2中展示了这一动机，其中给出了共享空中航路网络中无人机路径规划的对比示例。如图2所示，在未考虑潜在无人机间干扰的情况下进行路径规划，会导致航线重叠，进而造成配送延迟。相比之下，具备干扰感知能力的无人机交通管理可使服务提供商主动调整航线，从而确保及时配送。本研究旨在应对上述挑战，通过建模无人机间干扰的影响，尤其关注气动扰动及其对能耗和配送时间的影响。

3 相关工作

我们确定了与本研究密切相关的三个关键研究领域：(1) 基于服务的无人机配送，(2)近距离飞行中的无人机气动扰动，以及(3)无人机充电资源利用与队列动态。

3.1 基于服务的无人机配送

服务计算框架采用按需模型，允许用户访问服务，而无需管理底层资源 [9]。近期研究利用服务范式，根据无人机的功能属性和非功能属性将无人机建模为服务 [2]。无人机的功能主要涉及其在指定空中航路网络中运送包裹的能力 [2]。一项关键的功能能力是无人机能够在这些网络中导航，从而确保配送精准及时。非功能能力，即服务质量（QoS）属性，包括有效载荷能力、电池寿命、飞行航程和充电需求等因素。这些属性决定了无人机的整体性能，以及特定配送路线的可行性 [2]。

由于这些限制，单架无人机往往无法胜任远距离配送。近期的无人机即服务（DaaS）研究将多项无人机服务组合起来，以满足超出单架无人机能力范围的配送需求 [34]。无人机根据自身能力负责配送路线中的不同航段。组合无人机服务需要挑选最佳的无人机组合来满足配送需求，每架无人机都具有独特的服务质量属性。目标是在考虑充电点和天气状况等运行限制的同时，按时并以最低成本完成配送 [34]。近期的算法，包括启发式算法和基于迪杰斯特拉算法的方法，通过选取最佳无人机服务组合来优化这一过程。这些算法会考虑时空因素、有效载荷能力和电池寿命，以确保配送兼具成本效益与时效性 [34]。然而，据我们所知，现有框架均未考虑无人机间交互（例如干扰）对功耗和

配送时间。我们的框架通过揭示无人机间干扰带来的意外影响，弥补了这一空白，帮助服务提供商做出更明智的运营决策。

3.2 近距离无人机飞行中的气动干扰

无人机近距离运行时，会产生复杂的空气动力学相互作用，显著影响飞行稳定性和效率。这种不稳定性源于下洗效应：较高高度的无人机产生的气流会影响较低高度的无人机 [27, 32]。在编队飞行期间，这些扰动尤为明显。例如，无人机以纵队编队飞行时，领航无人机产生的下洗流会影响后方无人机的性能。当无人机以较高速度飞行或处于湍流条件下时，这种影响会更加显著 [13]。这些力会增大阻力并降低升力，导致受影响的无人机为补偿受扰气流而消耗更多功率 [42]。另一项研究通过分析无人机周围的空气扰动，检测附近无人机是否存在以及其距离远近 [42]。所提出的方法使用陀螺仪和加速度计等机载传感器，以低成本实现近距检测，不过检测精度可能因无人机设计和飞行条件而异 [42]。近期的数据采集工作利用无人驾驶飞行器从地面无线传感器网络（WSN）中收集信息。然而，一个关键挑战在于如何高效收集这些数据，同时尽量缩短无人驾驶飞行器的飞行时间并降低能耗。一项研究将此问题表述为无人机轨迹优化问题，以高效收集分布式地面传感器的数据，同时兼顾行程时间、数据传输时延和无人驾驶飞行器的能量约束 [24]。该研究将相关轨迹规划问题形式化，并证明其属于NP完全问题，同时提出了适用于实际应用的近似算法。基于不同场景的评估结果表明，在兼顾时间和能量约束的情况下，这些算法能够有效提高数据收集效率。

近期研究提出了用于提前预测这些交互的模型。一项研究开发了一种模型，用于估算两架多旋翼无人机近距离编队飞行时产生的力和扭矩 [17]。该模型可预测气动力（包括阻力）以及影响无人机朝向的扭矩，预测结果会随无人机之间的垂直间距和水平间距而变化。当垂直间距大于无人机尺寸的七倍时，该模型的准确度最高 [17]。尽管所提出的方法有效解决了微观层面上的气动干扰（无人机间交互），但当多架无人机同时在较大的编队中运行时，这些扰动会变得复杂得多。鉴于无人机交通预计将不断增长，无人机编队的管理和跟踪也愈发具有挑战性。研究提出了加权分量拼接（WCS）方法和基于加权分量的卡尔曼滤波算法（两者的复杂度均为 $O(n^3)$），以便在稀疏且含噪的网络条件下可靠地跟踪无人机编队 [40]。大量实验表明，与先进方法相比，这些方法可将编队跟踪准确度提高 21%–48%。

据我们所知，现有模型均未能捕捉整个运行计划中气动扰动的累积影响，而非仅关注孤立实验。我们的研究填补了这一空白，考察这些扰动如何影响无人机的功耗和配送时间。这种方法全面呈现了无人机间干扰，有助于在多无人机 网络中制定更明智的运营决策。

3.3 优化无人机充电与队列管理

无人机的电池寿命有限，因此需要频繁充电才能维持持续运行。通常，无人机电池可支持约 25 至 30 分钟的飞行，之后便需要充电或更换 [10, 39]。随着无人机应用扩展至电子商务和医疗配送等领域，完善的充电基础设施变得愈发重要。无人驾驶飞行器需要更频繁地进行短时充电，这会给 Manuscript submitted to ACM 带来

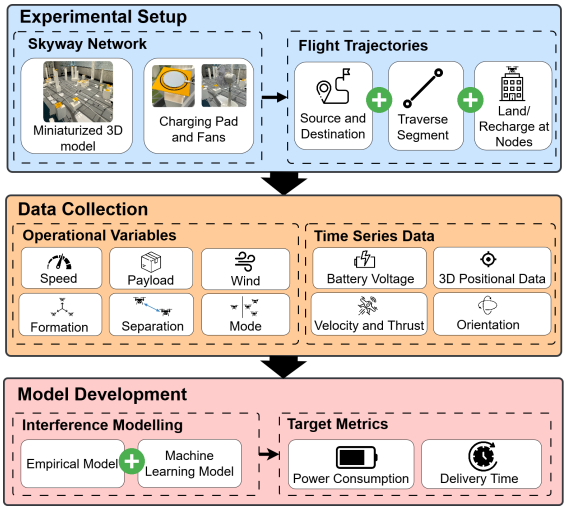


图 3. 系统设计主要框图

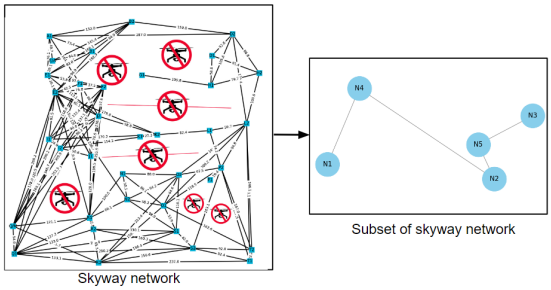


图 4. 空中航路网络 [21]

前所未有的压力 [23]。近期一项研究探讨了为无人驾驶飞行器和电动汽车（EV）部署共享充电基础设施。研究结果表明，共享使用会导致资源争用，进而延误无人驾驶飞行器充电 [29]。这些发现意味着，随着无人驾驶飞行器资源需求的增加，现有充电基础设施可能会变得拥堵，因此需要进行升级，以有效应对增加的负载 [29]。近期研究提出了负载均衡和路径优化技术，以将无人驾驶飞行器流量分配至各个充电站，从而减少拥堵 [5]。据我们所知，尚无研究探讨共享充电站中无人机间干扰的累积影响。本文首次尝试对这类相互作用如何影响配送效率和安全性进行建模。

4 系统设计与实现

我们构建了该系统，以深入分析多无人机空中航路网络中的无人机间干扰。图 3 展示了我们方法的整体工作流程，包括实验设置、数据收集和模型开发阶段。我们在室内无人机测试平台中全面收集了自主无人机配送飞行的数据。该室内无人机测试平台由一个基于悉尼中央商务区 3D 模型构建的空中航路网络组成 [13]。如图 4 所示，我们选取了该空中航路网络的一个子集，其中包含由视距（LoS）航段互连的节点（即建筑屋顶）。在数据收集阶段，我们收集了每次无人机飞行单独运行以及与同伴无人机同时运行时的时间序列数据。在开发阶段，我们使用收集到的数据，针对节点和航段层级发生的干扰开发经验模型和机器学习模型，并重点关注功耗和配送时间这两项关键性能指标。最后，我们评估模型的性能，以确保其适用于更大规模的网络和不同条件。

4.1 数据收集协议

为确保模型的可靠性和准确性，我们采用受控的数据收集协议，生成适用于建模的高质量数据集。我们排除了无人机固有的混杂因素，这些因素可能会

影响邻近诱发干扰对无人机能耗的影响。这些因素包括无人机速度、载荷体积和无人机型号 [6]。例如，无人机速度和无人机间距的变化都可能导致无人机能耗发生变化。因此，要区分观察到的能耗变化究竟是由无人机间干扰还是速度变化造成的，以及各因素的影响程度，就会变得很困难。因此，我们在所有无人机飞行中固定速度、统一载荷，并选用 Crazyflie 2.1 作为无人机型号。

我们搭建了一个室内无人机测试平台，因为根据政府法规，在室外开展涉及商用无人机型号同时飞行的实验受到限制 [18]。我们使用 Crazyflie 2.1 无人机型号，因为它适合室内实验。这些无人机与一些公司（如亚马逊和 DHL）使用的不同商用无人机型号（例如 DJI Flycart 30、Amazon MK30）采用相同的多旋翼架构 [4]。因此，由于螺旋桨持续旋转，它们表现出相似的空气动力学特性。不过，干扰影响的严重程度会随螺旋桨尺寸增大而加剧，因为更大型的无人机会产生更强的湍流力 [15]。我们模拟了动态无人机飞行，并考虑了多种贴近实际场景的参数，包括不同的无人机位置、编队、风速、风向和载荷重量。这些因素使我们能够系统地评估无人机间干扰对无人机配送效率和安全性的影响。需要注意的是，载荷体积、无人机速度和型号等因素不在当前模型的研究范围内。未来一项重要的研究方向是将模型扩展到异构无人机机队，并纳入这些因素。

4.2 数据收集策略

我们收集了多个无人机飞行的真实数据集，以分析节点级和路段级干扰对无人机配送效率的影响。该数据集包含两类数据：单机飞行，即无人机独立运行；以及同时无人机飞行，即多架无人机在多无人机空中航路网络中同时运行。该数据集记录了多无人机空中航路网络中同伴无人机引发的延迟对配送时间和能耗的影响。收集的数据集包含无人机在单独 运行以及与同伴无人机同时 运行时的各种参数。这些参数的详细信息列于表1中。

表1. 数据收集过程中采集的参数

参数	描述及取值范围
电池电压	无人机电池电压（V）
三维位置数据	无人机的 x、y、z 坐标，每 0.1 秒采样一次
姿态数据	滚转、俯仰、偏航角（度）
Wind	风向和风力（无、轻载/强逆风、轻载/强顺风）
载荷	无人机携带的重量（范围为 0 至 4.5 克，增量为 1.5 克）
无人机编队	无人机的空间排列（前后、并排、上下）
无人机间距	无人机间距离从 30 厘米到 150 厘米不等，增量为 10 厘米。
飞行时间	完成飞行所需的总时间（秒）
充电时间	在节点充电所花费的时间（秒）
配送时间	从出发到完成配送的总时间（秒）

4.2.1 单机无人机飞行。我们自主控制一架 Crazyflie 无人机，沿预定义轨迹将不同重量的载荷从源节点运送至目标节点。这些自主单机飞行数据作为基准，用于衡量不受同伴无人机干扰影响时的标准配送表现。每条无人机轨迹均根据从源节点到目标节点的最短路径确定（图 5）。然而，由于飞行时间仅为七分钟，无人机通常需要在中间节点充电才能成功抵达目标节点。稿件已提交至ACM

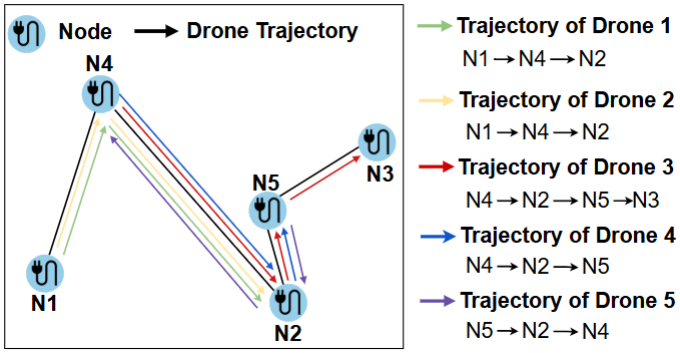


图 5. 自主无人机配送飞行的轨迹

我们计算无人机在后续节点的充电时间如下:

$$t_{node} = -\tau \cdot \ln\left(\frac{1-S_f}{1-S_i}\right) = -(T_{full} \cdot \beta) \cdot \ln\left(\frac{1-S_f}{1-S_i}\right) \tag{1}$$

其中， S_i 是无人机抵达后续节点时的电池电量初始状态， S_f 是无人机从中间节点起飞后的电池电量最终状态（$i.e.,\ \approx 100\%$）。 τ 是根据 T_{full} 和 β 定义的函数，其中 T_{full} 是无人机完全充电所需的总时间，通常以电池容量从 0% 充至 99% 来衡量； β 是一个缩放因子，用于考虑充电速率的变化，因为电池充电通常遵循非线性曲线。无人机抵达后续节点时的电池电量初始状态（S_i）会因载荷以及无人机在一个航段内飞行的距离而异。我们在不同风速（从 6.1 km/h 到 7.6 km/h，增量为 1.5 km/h）和不同风向（即逆风和顺风）条件下重复进行了这组自主无人机飞行。我们使用以 0.1 秒为间隔采集的每次无人机飞行时间序列数据，计算从源节点到目标节点的总功耗（%）和配送时间。我们根据无人机在时间 t_{segment_i} 内经过每个 i^{th} 航段时消耗的累计功率，使用公式（2）计算每次无人机飞行的总功耗 P_{total}。

$$P_{\text{total}} = \sum_{i=1}^{n} P_i(t_{\text{segment}_i}) \tag{2}$$

总功耗 P_{total} 是无人机从源节点到目标节点的轨迹上所有 n 航段的功耗之和。总飞行时长是 n 个航段的路段通行时间总和，加上无人机在 m 个节点停留以完成配送请求所花费的时间。我们使用公式 (3) 计算总配送时长（DT_{total}），如下所示:

$$DT_{\text{total}} = \sum_{i=1}^{n} t_{\text{segment}_i} + \sum_{j=1}^{m} t_{\text{node}_j} \tag{3}$$

4.2.2 同时无人机飞行。在这组实验中，我们收集了共享空中航路网络中同时运行的无人机数据集。我们让同一组无人机从各自的源节点飞往目标节点（图 5）。我们评估了无人机间距在 30 厘米至 150 厘米之间、以 10 厘米为增量变化时，路段级干扰的影响。我们为抵达的无人机分配充电垫、等待垫和悬停区

采用先到先服务（FCFS）方法的节点。假设一个节点有 N 个充电位和m 个等待垫，则无人机 D_i 的分配过程 A 定义如下。

$$A(D_i) = \begin{cases} \text{Recharging Pad}, & \text{if } i \leq n, \\ \text{Waiting Pad}, & \text{if } n < i \leq (n+m), \\ \text{Hovering Zone}, & \text{if } (n+m) < i \leq (n+m+n_{hover}), \end{cases} \tag{4}$$

我们使用收集到的数据集，根据公式 (3) 计算从源节点到目标节点的配送时长。总功耗取决于无人机在节点悬停时以及飞行航段期间消耗的功率。假设一架无人机经过 n 个航段和 m 个节点，其中 $P_j(t_{\text{hover}_j})$ 是无人机在节点 j 悬停t_{hover_j} 时间所消耗的功率，则该无人机的总功耗计算如下：

$$P_{\text{total}} = \sum_{i=1}^{n} P_i(t_{\text{segment}_i}) + \sum_{j=1}^{m} P_j(t_{\text{hover}_j}) \tag{5}$$

4.3 干扰检测与建模

检测并建模节点和路段级干扰，对于分析其对无人机配送效率的影响至关重要。我们的框架处理从单独和同时无人机飞行中收集的时间序列数据，以检测并量化无人机间干扰对无人机配送时间的影响。我们利用这些数据构建数学模型，以便在多无人机空中航路网络中给定一次无人机配送飞行时，估算额外功耗和延迟。

4.3.1 路段级干扰对功耗的影响建模。我们对路段级无人机间干扰对无人机功耗的影响进行建模。这种影响有助于了解其对无人机配送时间的作用。我们确定了若干会影响无人机在航段内预期功耗的因素，包括有效载荷重量、无人机间距、无人机编队、风况和无人机位置。我们对上述因素正式定义如下：

无人机载荷： 载荷因素表示每架无人机所携带的重量。载荷会直接影响无人机的功耗。较重的载荷会增加抵消重力并抵抗潜在空气动力学干扰、维持稳定性所需的功率。根据无人机的载重能力，我们将载荷重量分为以下三个离散类别：无、轻载和重载：

$$P_{\text{payload}} = \begin{cases} \text{None} & \text{if payload} = 0\,\text{g} \\ \text{Light} & \text{if payload} = 3\,\text{g} \\ \text{Heavy} & \text{if payload} = 4.5\,\text{g} \end{cases} \tag{6}$$

无人机间距： 该因素指三维区段中无人机之间的空间间距。设 (x_1, y_1, z_1) 和 (x_2, y_2, z_2) 是时间 t时两架无人机的坐标，则任意时间 t的间距 $d_{sept}(t)$ 计算如下：

$$d_{\text{sep}}(t) = \sqrt{(x_1(t) - x_2(t))^2 + (y_1(t) - y_2(t))^2 + (z_1(t) - z_2(t))^2}$$

这一因素对于建立路段级干扰模型至关重要，因为无人机之间的近距离可能会显著影响无人机的电池功耗。我们收集了无人机间不同间距的数据集，间距范围为30厘米至150厘米，间隔为10厘米，如图6所示。稿件已提交至ACM

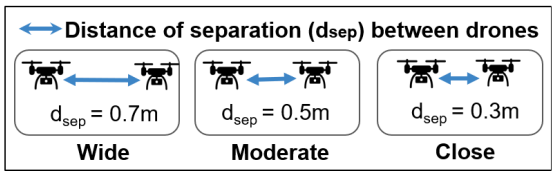


图6. 研究中使用的无人机间距

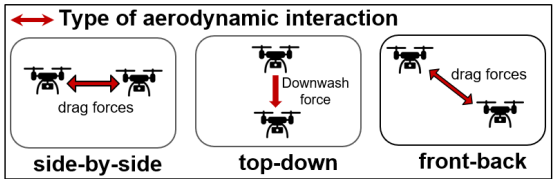


图7. 研究中使用的不同无人机编队

我们将这些间距划分为宽、中、近三类，具体如下：

$$\text{Category}(d_{\text{sep}}) = \begin{cases} \text{Close} & \text{if } 0.3\,\text{m} \le d_{\text{sep}} < 0.5\,\text{m} \\ \text{Moderate} & \text{if } 0.5\,\text{m} \le d_{\text{sep}} < 0.7\,\text{m} \\ \text{Wide} & \text{if } d_{\text{sep}} \ge 0.7\,\text{m} \end{cases} \tag{7}$$

无人机编队：此因素指无人机相对于同伴无人机的空间排列方式。我们根据无人机沿三维坐标轴的间距，确定无人机相对于同伴无人机的编队。无人机相对于同伴无人机的编队定义如下：

$$f_{formation} = \begin{cases} \text{Side-by-Side} & \text{if } |z_1 - z_2| < \delta_z \text{ and } |y_1 - y_2| < \delta_y \text{ and } |x_1 - x_2| > \delta_x \\ \text{Top-Down} & \text{if } |x_1 - x_2| < \delta_x \text{ and } |y_1 - y_2| < \delta_y \text{ and } |z_1 - z_2| > \delta_z \\ \text{Front-Back} & \text{if } |z_1 - z_2| < \delta_z \text{ and } |y_1 - y_2| < \delta_y \text{ and } |x_1 - x_2| > \delta_x \\ \text{None} & \text{otherwise} \end{cases} \tag{8}$$

其中， δ_x、 δ_y 和 δ_z 是用于确定间距的阈值。此外，无人机相对于同伴无人机的编队决定了无人机之间气动相互作用的类型（图7）。例如，在上下编队中，高空无人机产生的下洗力可能会干扰其下方区域内运行的无人机。同样，在前后编队中，后方无人机可能会因前导无人机螺旋桨产生的尾随涡流而遭遇湍流 [37]。

无人机位置：另一个因素是，在三维区段中给定无人机的空间排列时，该无人机相对于同伴无人机的位置。无人机相对于同伴无人机的位置决定了干扰对无人机电池消耗的点对点影响。我们将三维区段中根据无人机编队确定的无人机相对位置定义为：

$$P_{\text{pos}} = \begin{cases} \text{Top} & \text{if } f_{\text{formation}} = \text{Top-Down and } z_1 > z_2 \\ \text{Down} & \text{if } f_{\text{formation}} = \text{Top-Down and } z_1 < z_2 \\ \text{Left} & \text{if } f_{\text{formation}} = \text{Side-by-Side and } x_1 < x_2 \\ \text{Right} & \text{if } f_{\text{formation}} = \text{Side-by-Side and } x_1 > x_2 \\ \text{Front} & \text{if } f_{\text{formation}} = \text{Front-Back and } x_1 > x_2 \\ \text{Back} & \text{if } f_{\text{formation}} = \text{Front-Back and } x_1 < x_2 \end{cases} \tag{9}$$

风况：我们还考虑了风况和速度这一因素，它们可能会影响在共享航段中运行的无人机之间空气动力干扰的强度。我们收集了不同风速下的数据集（风速范围为 6.1 km/h 至 7.6 km/h，增量为 1.5 km/h），以及不同风向（即逆风和顺风）。风况 C_{wind} 定义为：

$$C_{\text{wind}} = \begin{cases} C_{\text{none}} & \text{if no wind} \\ C_{\text{light-headwind}} & \text{if light headwind} \\ C_{\text{light-tailwind}} & \text{if light tailwind} \\ C_{\text{intense-headwind}} & \text{if intense headwind} \\ C_{\text{intense-tailwind}} & \text{if intense tailwind} \end{cases} \tag{10}$$

ˆ 我们根据这些因素量化路段级干扰总效应(I_{segment})：

$$\hat{I}_{\text{segment}} = \beta_1 \cdot W_{\text{payload}} + \beta_2 \cdot f_{\text{formation}} + \beta_3 \cdot C_{\text{wind}} + \beta_4 \cdot d_{\text{sep}} + \beta_5 \cdot P_{\text{pos}}$$

其中，系数 β_1、β_2、β_3、β_4 和 β_5 表示各因素对整体干扰的影响程度。该干扰效应表示同一路段上运行的同伴无人机所造成的功耗增加。我们在式（11）中定义无人机间干扰和不同风况对无人机功耗的影响。

$$P_{\text{interference}} = P_{\text{expected}} \times \hat{I}_{\text{segment}} \tag{11}$$

其中，P_{expected} 是不受干扰时的功耗（即基准功耗），I_{total} 表示干扰导致的功耗增幅比例。

4.3.2 节点级干扰对延迟和功耗的影响建模。我们根据因充电垫不可用而产生的额外等待时间和功耗，对节点级干扰对无人机配送时间的影响进行建模。额外等待时间 W_d 取决于在等待垫 W_p 上花费的时间、在悬停区 H_d 内花费的时间，以及补回悬停期间所消耗功率所需的额外时间 T_{hover}。

$$W_d = H_d + W_{p,d} + T_{hover} \tag{12}$$

其中，H_d 表示没有可用等待垫时在悬停区内停留的时间，$W_{p,\ d}$ 表示在等待垫上等待、直至可以使用充电垫的时间。$T_{hover,\ d}$ 表示无人机 d 为补回悬停 H_d 时长所消耗的电池电量而需额外充电的时间。假设某节点共有 m 个充电垫和 n 个等待垫，且等待垫上排在无人机 d 前面的无人机数量为 p，则悬停时间和等待垫等待时间分别通过公式（13）和公式（14）计算。

$$H_d = \max\left(0, \sum_{i=1}^{n} T_{w,i} - \sum_{j=1}^{m} T_{f,j}\right) \tag{13}$$

其中，$T_{w,\ i}$ 表示当前每架位于等待垫上的无人机占用充电垫所需的等待时间。$T_{f,\ j}$ 表示每架位于充电垫上的无人机的剩余充电时间。等待垫等待时间通过以下公式计算：

$$W_{p,d} = \max\left(0, \sum_{k=1}^{p} T_{r,k} - \sum_{l=1}^{m} T_{f,l}\right) \tag{14}$$

其中，$T_{r,\ k}$ 表示充电队列中排在无人机 d 前面的 k^{th} 无人机的充电时间，而 $T_{f,\ l}$ 表示当前正在使用充电垫的无人机所需的剩余时间。充电速率为 $P_{recharge}$ 的无人机 d 因悬停而产生的额外充电时间按如下方式计算：

$$T_{hover} = \frac{P_{hover} * H_d}{P_{recharge}} \tag{15}$$

4.3.3 干扰对配送时间的影响建模。 我们对路段级和节点级干扰对无人机预计配送时间的影响进行建模。配送时间受到的影响取决于节点和航段上发生的干扰的累积效应。节点处的干扰通常是由于无法使用充电设施或等待垫而产生的。这种不可用情况会导致无人机等待，或在悬停时额外消耗电池电量。相比之下，由于存在同伴无人机，路段级干扰会影响无人机在节点间飞行时的功耗。因此，我们根据两个因素在式（16）中描述其对配送时间的影响：（1）无人机所访问的节点处发生节点级干扰所导致的累计等待时间 n；（2）飞越 m 个航段时，路段级干扰导致的额外充电时间。我们根据整个飞行路径上干扰的累积效应，对配送时间受到的影响进行如下建模：

$$DT_{interference} = DT_{expected} + \sum_{i=1}^{n}(W_d) + \sum_{j=1}^{m} T(P_{\text{interference},j}) \tag{16}$$

其中 $DT_{expected}$ 是无人机不受干扰影响时的配送时间。

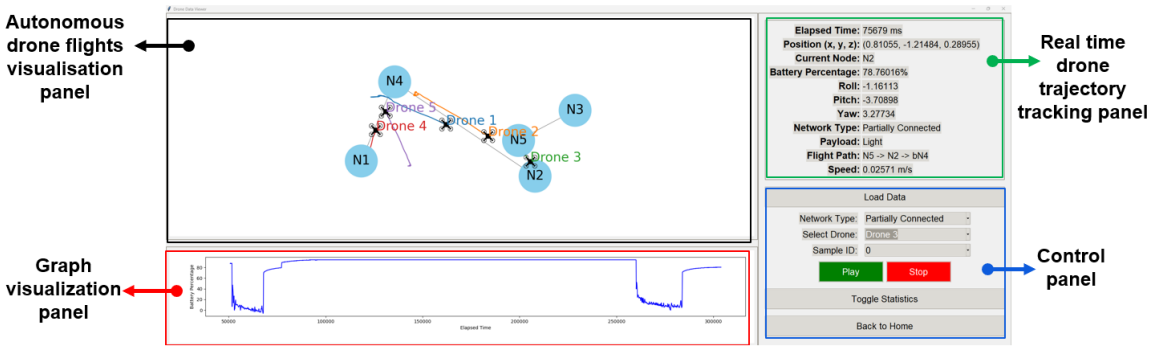


图8. 图形用户界面

4.4 图形用户界面

为便于分析实验数据，我们使用 Tkinter[1] 开发了一个图形用户界面（GUI）（图 8）。该界面支持通过回放飞行记录来回顾无人机轨迹，并利用记录的时间序列数据查看各项指标随时间的变化。每次实验飞行结束后，可以在界面中可视化时间序列数据，包括位置坐标（x、y、z）、速度及其他飞行参数。该图形用户界面提供回放功能，用户可以观察无人机在空中航路网络中不同时间点的移动情况。我们分析第 4.3.1 节所讨论的各种因素对共享空中航路网络中无人机配送时间和功耗的影响。

[1]https://docs.python.org/3/library/tkinter.html

4.5 模型开发

本节旨在建立航段级和节点级干扰模型，以准确估算各种条件下对配送时间和功耗的影响。这些模型针对两种主要干扰源：飞行航段中的气动扰动 以及节点处的资源争用。针对路段级干扰，我们采用机器学习对无人机间距、载荷和风况等特征变量之间的非线性关系进行建模。针对节点级干扰，第 4.3.2 节提出了一种经验模型，用于估算充电垫拥堵导致的等待时间和悬停时间。接下来，我们将介绍路段级干扰模型的建立过程。

4.5.1 分段干扰模型。 分段干扰模型的数据集由受控无人机飞行实验生成，记录了单机飞行和同时飞行期间的功耗。这些飞行是在第 4.2 节所述的不同条件下进行的。主要目标是量化同时飞行期间气动扰动对功耗的影响，并与单机飞行进行比较。图 9 展示了单机飞行和同时飞行时功耗值的分布。我们观察到，同时飞行通常会产生更高的功耗。这是由于同伴无人机之间的气动干扰，导致无人机需要消耗额外的电池电量来维持飞行稳定性。

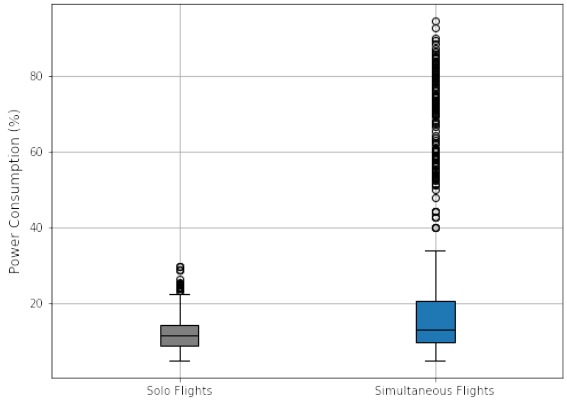


图 9. 比较单机飞行与同时飞行功耗的箱线图。

我们将式（17）中定义的干扰比（*IR*）用作分段干扰模型的目标变量。该比值量化了同时飞行期间的功耗相对于单机飞行的比例增幅 $P_{simultaneous}$ P_{solo}。这反映了同伴无人机产生的气动扰动所导致的额外能源需求。干扰比是利用机器学习技术构建预测模型的基础。

$$IR = \frac{P_{\text{simultaneous}}}{P_{\text{solo}}} \tag{17}$$

下一步，我们分析特征变量（即配置、位置、间距、载荷和风）与目标变量（即干扰比）之间的关系。图 10 显示，随着无人机之间的间距、载荷和无人机配置发生变化，功耗也会增加。然而，部分特征变量与目标变量之间呈现非线性关系。因此，我们选择多项式回归模型稿件已提交至ACM

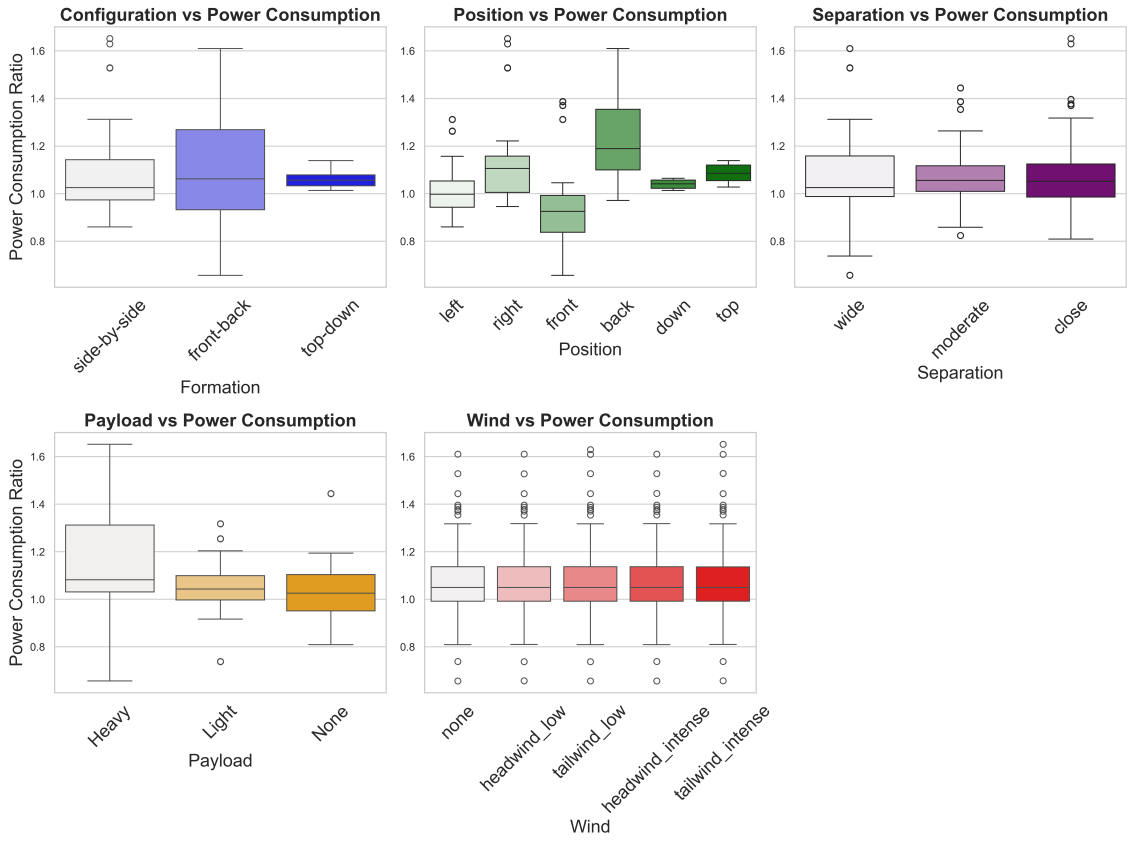


图 10. 箱线图展示了不同变量的功耗分布。

以准确建模特征变量与目标变量之间的线性和非线性关系。随后，我们系统地测试了从 1 到 4 的多项式次数，以确保为每个变量选取合适的多项式次数。我们采用三种评估指标：交叉验证平均绝对误差（平均绝对误差，MAE）、赤池信息准则（赤池信息准则，AIC）和贝叶斯信息准则（贝叶斯信息准则，BIC），以评估模型在不同多项式次数下的表现。先前的研究已证明，使用上述指标有助于选出最佳模型，同时避免过拟合问题 [41]。这是因为 AIC 和 BIC 指标同时考虑模型复杂度和拟合精度，数值越低表示模型拟合效果越好。同样，MAE 根据平均预测误差反映模型对真实值的逼近程度。

算法 1 展示了我们选择多项式次数的详细过程。对于每个变量，我们系统地测试了从 1 到 4 的多项式次数，同时将所有其他变量的次数保持为 1（第 1–8 行）。我们在数据集上训练模型，并针对每个次数计算评估指标（即平均绝对误差、贝叶斯信息准则和赤池信息准则）（第 9–11 行）。由于各指标的量纲不同，我们先对每个指标进行归一化，再计算每个次数的综合得分（第 11–12 行）。我们为每个变量选择综合得分最低的多项式次数（第 13–14 行）。选择结果见表2。

算法 1 分段干扰模型的多项式次数选择

输入： 数据集 D $=\{X, y\}$，变量 $V=\{v_1, v_2、\ldots\ldots、v_n\}$
输出： 每个变量的最优次数 $\{d_{v_1}, d_{v_2}、\ldots\ldots、d_{v_n}\}$
初始化多项式次数集合 $D=\{1、2、3、4\}$
为所有 $v \in V$ 设置初始次数 $d_v = 1$
对于每个 $v \in V$ **执行**
  对于每个 $d \in D$ **执行**
    对 v 应用次数为 d 的多项式变换
    将所有其他 $v \in V \setminus v$ 保持为 1 次
    在 D 上训练模型
    评估： 计算平均绝对误差、赤池信息准则和贝叶斯信息准则
    标准化平均绝对误差, AIC, BIC: $\hat{MAE}, \hat{AIC}, \hat{BIC}$
    计算综合得分： $S(d) = \frac{\hat{MAE}+\hat{AIC}+\hat{BIC}}{3}$
    如果 $S(d) <$ 最佳综合得分 **则**
      更新 $d_v = d$
    结束如果
  结束循环
结束循环
使用 $\{d_{v_1}, d_{v_2}, \ldots, d_{v_n}\}$ 训练最终模型
返回： $\{d_{v_1}, d_{v_2}, d_{v_3}, \ldots, d_{v\ n}\}$

表2. 基于平均绝对误差、赤池信息准则、贝叶斯信息准则和归一化均值分数的各变量最佳多项式次数。

变量	最佳度数	MAE	AIC	BIC	归一化平均分
编队	1	0.096	-700.857	-640.775	0.143
载荷	1	0.092	-700.857	-640.775	0.001
位置	3	0.096	-700.857	-640.775	0.127
间距	4	0.096	-700.857	-640.775	0.126
Wind	1	0.093	-700.857	-640.775	0.038

随后，我们在收集到的数据集上训练多项式回归模型，以推导出用于估算干扰对功耗影响的路段级干扰模型。四阶多项式的路段级干扰影响表达式如下：

$$\hat{I}_{\text{segment}} = \beta_1 \cdot P_{\text{pos}}^3 + \beta_2 \cdot d_{\text{sep}}^4 + \beta_3 \cdot f_{\text{formation}} + \beta_4 \cdot C_{\text{wind}} + \beta_5 \cdot W_{\text{payload}}$$

其中，β_1、β_2、β_3、β_4 和 β_5 是系数，表示各变量对干扰影响的贡献。我们根据各变量在预测干扰时的相对重要性确定这些系数的值。各变量的相对重要性通过对其在所有阶数下多项式项的绝对值求和来确定。随后，将这些总和表示为所有变量总贡献的百分比，从而得到相对重要性的度量。如表3所示，无人机彼此之间的相对位置及其空间邻近性是影响干扰影响的关键因素。路段级干扰的多项式回归模型表示如下：

$$\hat{I}_{\text{segment}} = 0.4085 \cdot P_{\text{pos}}^3 + 0.3272 \cdot d_{\text{sep}}^4 + 0.1262 \cdot f_{\text{formation}} + 0.0780 \cdot C_{\text{wind}} + 0.0601 \cdot W_{\text{payload}}$$

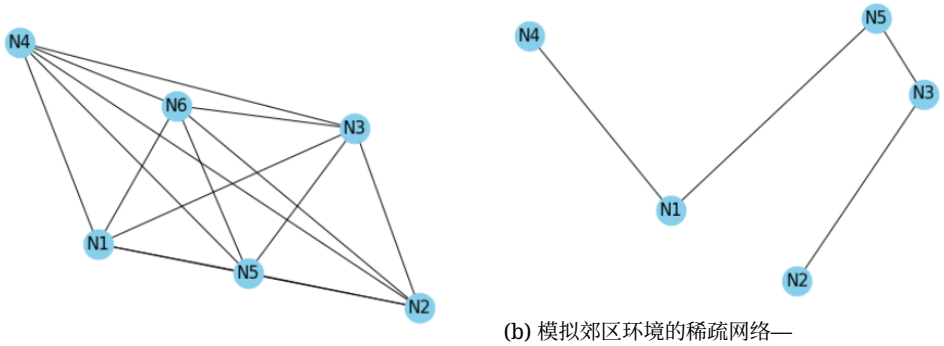
ˆ其中 I_{segment} 表示预测的干扰比，而位置和间距的高阶项则捕捉了数据中观察到的非线性效应。

表3. 变量对干扰R的相对影响 atio.

指标	位置	间距	编队	Wind	载荷
相对影响（%）	40.85%	32.72%	12.62%	7.80%	6.01%

4.5.2 模型选择的理由。 本研究采用的多项式回归模型旨在捕捉共享空中航路网络中运行的无人机之间复杂的空气动力学相互作用。先前的实证研究表明，最高三次的多项式模型能够有效捕捉单独运行的无人机的空气动力学特性，同时保持可解释性 [14, 19]。相比之下，我们采用四次多项式模型，以捕捉共享空中航路网络中复杂的多无人机交互所产生的高阶非线性。此外，多项式回归模型能够清晰揭示特定因素如何影响无人机间干扰，使超级服务提供商（即无人机交通管理机构）和利益相关者能够根据模型的预测结果轻松解读并论证运营决策 [26]。例如，我们的模型通过三次多项式项确定了无人机的位置 是影响配送效率的重要因素。由于黑箱模型的可解释性有限，这类洞见通常难以从中提取 [26]。未来的研究可以探索复杂模型，但我们的结果表明，四次多项式回归能够捕捉多无人机空中航路网络中的复杂空气动力学相互作用，并支持在这一背景下进行透明的决策。

4.6 模型验证



(a) 模拟城市环境的密集网络

(b) 模拟郊区环境的稀疏网络—ment

图 11. 用于验证轨迹的网络。

我们使用包含 50 次无人机飞行的数据集，对路段级和节点级干扰模型进行了验证。这些飞行是在两种空中航路网络设置中进行的，旨在测试不同的节点密度和路段连通性。这些轨迹未纳入训练数据集。第一种网络代表节点密度较高的密集城市空域（图 11a）。第二种网络模拟节点较少、连通性较低的郊区环境（图 11b）。在这两种设置中，我们规划了 50 条轨迹，分别进行单独飞行和同时飞行。第 4.3.1 节中的路段级模型预测同时飞行期间的功耗。使用第 4.3.2 节中的经验模型估算节点处的等待时间。根据式 (16) 计算配送时间，并计入节点级和路段级干扰。使用平均绝对误差、平均绝对百分比误差、均方误差以及 R^2 以下公式评估模型性能：

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \quad \text{MAPE} = \frac{100}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \quad \text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2} \tag{18}$$

其中， $\bar{y}$ 表示观测到的干扰值的均值 y_i。

5 实验与结果

我们实现并评估了所提出的方法，用于分析空中航路网络中的无人机间干扰。评估重点关注功耗和交付延迟等关键性能指标。首先，我们按照预定义轨迹进行一系列单机飞行，并记录其初始功耗和配送时间。随后，我们考察同时飞行如何引发干扰效应，导致功耗和交付延迟增加。实验旨在捕捉不同干扰场景的影响。我们详细分析了这些干扰因素的影响，随后评估模型的准确性。

5.1 数据集与实验设置

我们在一个室内测试台中采集了无人机轨迹数据集，该测试台包含悉尼中央商务区的3D打印模型 [13]。每栋建筑都配备了无线充电和等待垫，作为主要的着陆与充电基础设施。实验使用了配备 Qi充电功能和 Lighthouse定位甲板的 Crazyflie 2.1[2] 无人机。无人机沿各航段飞行，并在中间节点充电，以完成源节点屋顶与目的地屋顶之间的配送请求。两个 HTC Vive 基站实现了精准导航，两个 FANCO DC 台式风扇则以不同速度和方向产生风。我们使用 CFLib Python库采集时间序列数据。表1列出了记录的属性，包括无人机间干扰下的电池消耗和配送时间。该数据集包含1485次飞行，其中包括由无人机独立完成的单机飞行，以及在共享网络中的同时飞行。

表 4. 无人机型号规格

规格	Crazyflie 2.1
重量 (g)	27
最大载荷 (g)	15
无人机速度 (m/s)	0.15
最长飞行时间（分钟）	7
充电时间（分钟）	40
起飞尺寸（毫米）（宽×高×深）	92×92×29

5.2 跨场景变量的无人机间干扰效应分析

在本节中，我们分析了影响无人机间干扰对无人机配送时间和功耗影响的各种因素。我们使用图形用户界面，比较无人机独立运行与在同伴无人机存在时同时运行所受到的干扰影响。表4概述了我们实验中使用的无人机模型规格。接下来，我们将讨论各种因素对无人机配送服务效率的影响。

[2]https://www.bitcraze.io/products/old-products/crazyflie-2-1/ 稿件已提交至ACM

每次仅研究一个实验变量，并将其他所有因素保持不变。具体而言，数据集针对关键场景变量包含均衡的样本量：无人机配置（前后：495，并排：495，上下：495）、间距（近：495，中等：495，远：495）和风况（无：297，弱逆风：297，弱顺风：297，强逆风：297，强顺风：297）。载荷实验的数据集主要包含三种标准化载荷条件（无、轻载、重载），每种条件各有429次飞行。统计分析基于这些一致的样本量得出，从而确保所有结果具有可比性和可靠性。各变量的均值和置信区间汇总于表5。

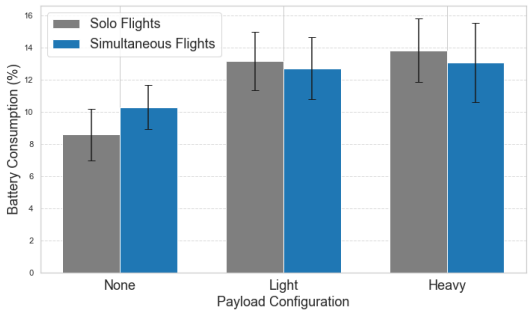
表5. 按场景变量划分的功率（%）均值和95%置信区间。

配置			间距		
等级	**Mean**	**95%置信区间**	**等级**	**Mean**	**95%置信区间**
前后	16.98	[15.50，18.47]	关闭	17.33	[15.82, 18.85]
并排	15.52	[14.09, 16.94]	中等	17.74	[16.18、19。29]
上下	20.26	[18.59, 21.93]	wide	17.55	[16.01，19.09]
载荷			**Wind**		
等级	**Mean**	**95%置信区间**	**等级**	**Mean**	**95%置信区间**
重载	20.60	[18.85，22.34]	强逆风	19.65	[17.52, 21.77]
轻载	16.97	[15.54, 18.40]	弱逆风	16.72	[14.82, 18.62]
none	14.67	[13.39，15.94]	none	15.75	[13.69, 17.81]
			强顺风	16.14	[14.32, 17.96]
			弱顺风	19.04	[17.09, 21.00]

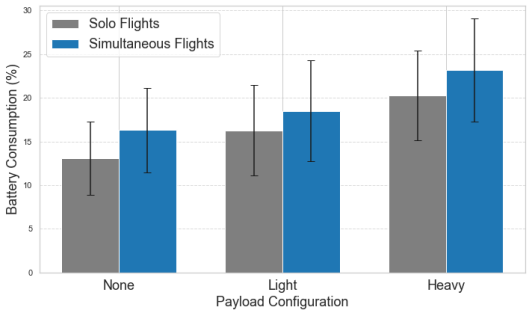
5.2.1 载荷效应。在无人机配送服务中，载荷尺寸会因无人机服务提供商的要求而有显著差异。载荷的这种变化是影响气动干扰的关键因素。我们考察不同载荷配置如何影响全部五架无人机飞行的功耗。预计较重的载荷会加剧航段级和节点级干扰效应，导致功耗增加，进而延长充电时间。我们比较单机飞行与同时飞行作业之间的增幅。

五架无人机均呈现预期趋势：载荷越重，平均功耗越高；如图 12 所示，每个重量类别的消耗约增加 17 %。然而，逐架比较单机飞行与同时飞行时的功耗，会发现一些特定规律。无人机 2 和无人机3因干扰而功耗显著上升。相比之下，无人机 5 在单机飞行与同时飞行时的功耗没有差异，因为其轨迹上未受到干扰。无人机 1 和无人机 4 在单机飞行时的功耗高于同时飞行时。这一结果受到所测试的前后编队的影响：无人机 1 领先无人机 2，无人机 4 领先无人机3。在这些编队中，前导无人机受到后方无人机产生的顺风效应影响，因此同时飞行时的功耗降低。

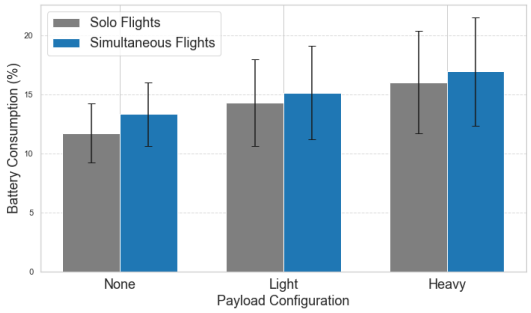
表6显示，在同时飞行时，路段级干扰会使所有载荷下的功耗增加约30%至35%。由于Crazyflie无人机的电池容量有限，这种增长对它们的影响尤为显著。功耗增加会使轻载的充电时间延长26%，重载则最多延长34%。更重的载荷会进一步加剧这些干扰效应。除了路段级干扰外，载荷重量也会直接影响节点级干扰。较重的载荷需要更多功率才能完成每次



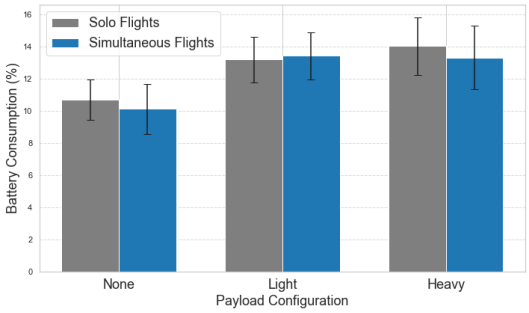
(a) 无人机 1



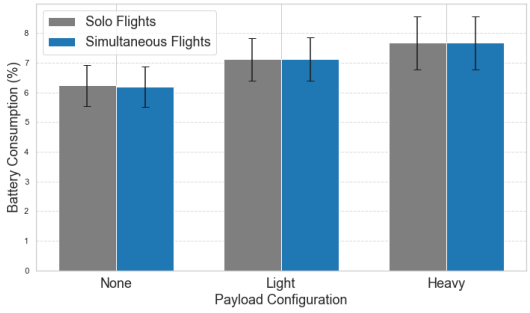
(b) 无人机 2



(c) 无人机3



(d) 无人机 4



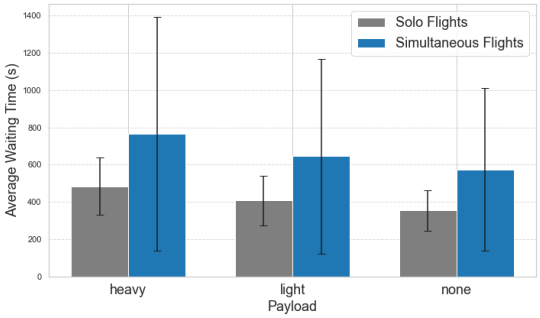
(e) 无人机 5

图 12。 所有无人机在各载荷（无、轻载、重载）下的平均电池消耗，并按所有飞行场景汇总 s.

飞行，从而延长节点处的充电时长。如图 13所示，充电时长的延长会进一步导致节点处等待时间增加。较重的载荷会加剧节点处的资源争用，因为无人机占用充电垫的时间更长；携带最重载荷类别时，占用时长会从30%增加至40%。等待时间延长也会对悬停无人机造成影响。长时间悬停会显著增加功耗。在我们的无人机飞行集合中，当所有等待垫都被无人机 5和4占用时，无人机3必须在节点 N2悬停。图 14表明，载荷越重，在这些情况下的电量消耗越显著。稿件已提交至ACM

表6. 不同载荷配置下 Drone2 飞行样本的功耗、充电时间和配送延迟比较。

载荷	功率消耗（单独）%	功率消耗（同时）%	充电时间（单独）(s)	充电时间（同时）(s)	配送配送延迟（秒）
None	9.80	12.88	352	445	93
轻载	10.81	14.23	383	486	103
重载	13.78	17.79	592	472	120



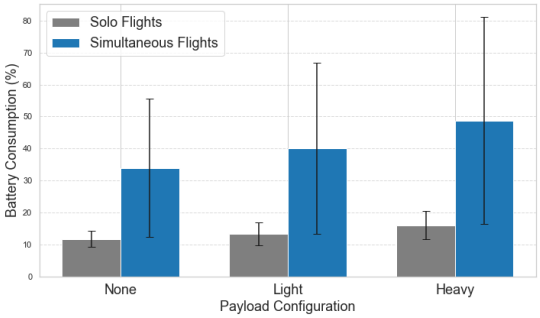


图 13. 按载荷统计的无人机平均等待时间（汇总所有无人机）。 图 14. 不同载荷下无人机3的悬停功耗。

悬停载荷从轻载时的30%增加到重载时的40%。因此，无人机需要额外的时间来补回这部分损失的电量，从而导致进一步的延迟。

表7. 不同载荷配置下无人机3的配送延迟。

载荷	悬停时间（秒）	悬停功耗（%）	充电时间（秒）
None	352	32.7	964
轻载	383	45.2	1264
重载	472	55.3	1506

表7展示了载荷对充电和悬停的叠加影响，其中两者都会导致额外延迟。较重的载荷会延长充电时间，并需要更多悬停，从而增加总配送延迟。这些延迟会影响服务提供商满足时效性需求的能力。我们的结果强调了服务提供商在运营计划中管理载荷分布的重要性。有效的规划能够帮助服务提供商显著减少延迟和运营成本。

5.2.2 无人机编队、位置和间距效应。在多无人机配送服务中，通常需要根据空中航路网络的飞行路径和空间限制采用不同的编队。无人机可能需要并排、上下或前后飞行，具体取决于空域可用性、配送优先级或充电计划等因素。这些编队以及无人机在其中所处的位置，会产生不同的空气动力学相互作用。我们研究了不同无人机编队及其内部位置对功耗的影响。

每种编队都会产生独特的空气动力学相互作用，这可能会影响同时飞行作业期间观察到的干扰效应。这些效应会影响无人机在所采用编队下最终的配送性能。

并排编队。 如图 15 所示，平均而言，与单机飞行相比，左侧和右侧位置的功耗均有所增加。两个位置之间没有显著差异。此外，如图 16 所示，缩短无人机之间的间距会加剧这种干扰，从而导致功耗进一步增加。

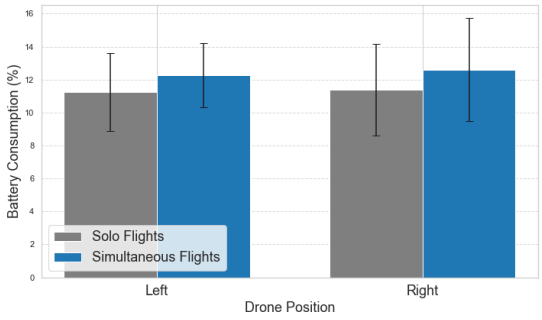


图 15. 并排编队中单机飞行与同时飞行时不同位置的平均电池消耗。

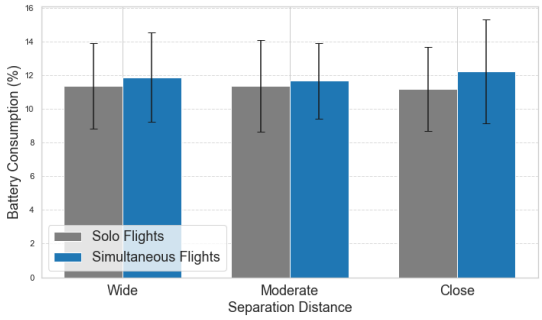


图 16. 并排编队中单机飞行与同时飞行时不同间距下的平均电池消耗。

前后编队。 对所有飞行场景取平均后的结果表明，无人机位置会导致功耗出现明显差异（见图 17）。同时飞行时，前导无人机的功耗始终较低。这是因为后方无人机产生的顺风为领航无人机提供助力，降低了其能源需求。相比之下，后方无人机的功耗较高。这是因为它在领航无人机的尾流中飞行时会受到空气动力阻力，因此必须消耗更多能量来维持稳定性和速度。图 18 进一步表明，缩短无人机之间的间距会放大这些影响。需要指出的是，由于我们的无人机体积较小，这种影响并不明显。尽管如此，这一趋势表明，合理规划间距或可提升前导无人机的效率优势。

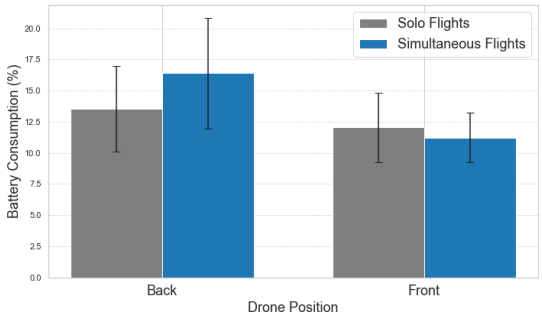


图 17. 前后编队中单独飞行与同时飞行时各位置的平均电池消耗。

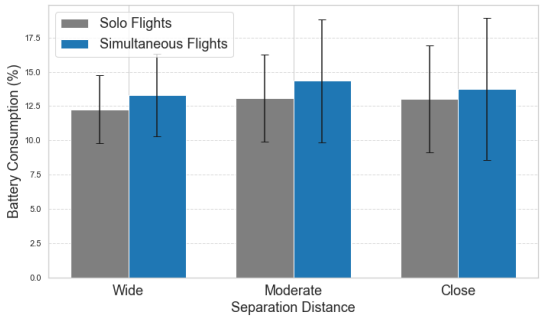


图 18. 前后编队中单独飞行与同时飞行时不同间距下的平均电池消耗。

上下编队。 由于上方无人机产生的下洗流，该编队会导致下方无人机的功耗增加。如图19所示，与单机飞行相比，下方无人机在同时飞行期间始终消耗更多功率。相比之下，上方无人机受到的干扰较小。此外，如图20所示，增大两架无人机之间的间距可以减弱空气动力学影响，从而降低下方无人机的功耗。

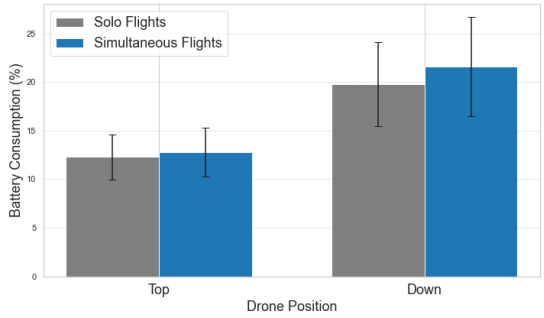


图19。上下编队中单独飞行与同时飞行按位置划分的平均电池消耗。

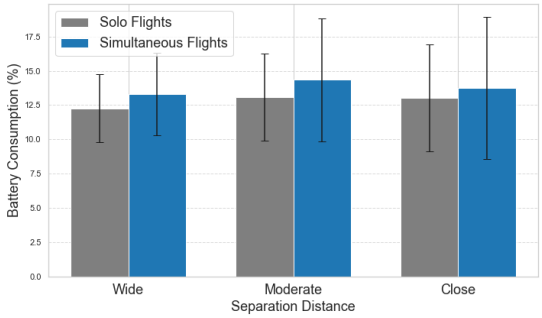


图20。上下编队中单独飞行与同时飞行按间距划分的平均电池消耗。

表8。按无人机编队和位置划分的功耗、充电时间和配送延迟。

编队 Type	无人机位置	功率消耗（单独）%	功率消耗（同时）%	充电 Time（单独）（秒）	充电时间（同时）（秒）	配送时间 净差值 (s)
并排	Left	11.66	11.99	409	418	9
	右侧	10.43	11.16	364	372	8
前后	前方	12.40	10.04	431	360	-71
	Back	10.71	11.78	380	412	32
上下	Top	18.22	18.36	605	610	5
	下方	12.25	13.04	426	450	24

表8展示了评估的三种不同编队对配送及时性的不同影响。在前后配置中，领航无人机的功耗比单机飞行时低19%，充电时间因此缩短16%，配送时间减少71秒。与此同时，后方无人机的功耗增加10%，配送时间延长32秒。这种编队有利于时间要求严格的配送任务。在并排编队中，左侧和右侧位置的功耗及配送时间差异很小，两个指标均仅略有增加。这种一致性使并排编队非常适合要求无人机间效率均衡的场景。在上下配置中，上方无人机产生的气动下洗流使下方无人机的功耗增加6%，导致配送延迟24秒，因此在我们的结果中，这种编队最不理想。

这些发现凸显了根据空域和运营需求进行编队选择的战略价值。前后编队有利于紧急配送，而并排编队则能提供均衡、稳定的性能。选择符合特定目标的编队，有助于服务提供商减少延迟。

5.2.3 风况影响。外部环境条件，尤其是风况，对无人机运行的效率有着重要影响。逆风和顺风等风况会显著影响功耗。逆风通常会增加功耗，而顺风则可能通过降低能量需求带来空气动力学优势。在无人机间干扰的情境下，风况可能加剧或减轻干扰效应，尤其是在无人机近距离飞行时。

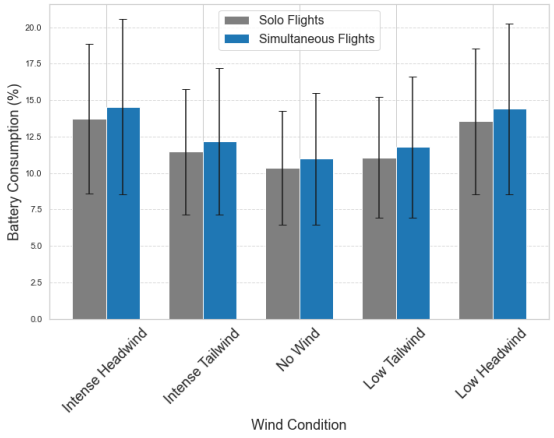


图2 21. 平均 了所有风况下的电池消耗量的数据。

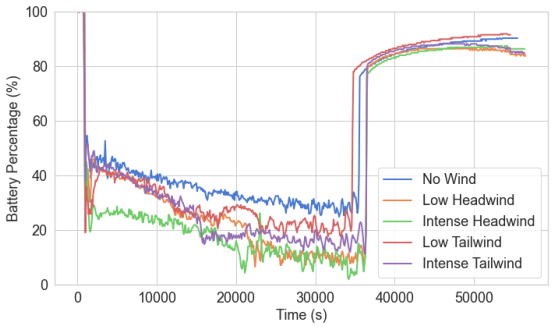


图2 22. 电池消耗的时间序列比较，适用于不同风况。

r
况，汇总

如图2所示，逆风会持续导致更高的功耗，而顺风则会降低能耗。风的强度会放大这些影响，风力越强，影响越明显。单独飞行和同时飞行都会受到风况的影响，但由于气动干扰与风力效应的共同作用，同时飞行的消耗略高。此外，我们分析了五种风况下的飞行样本：无风、低强度逆风、强逆风、低强度顺风和强顺风。图22对这些风况下的电池消耗进行了时间序列比较。由于无人机需要补偿不稳定飞行，风的存在会导致功耗模式出现不规则波动。在顺风条件下，电池电量下降得更加缓慢，因为风力会助推无人机向前移动，从而减轻电机的负荷。这些结果证实，无论风向或速度如何，风都会持续增加功耗（见表9）。逆风对功耗的影响最大。强逆风会使功耗增加32%，将充电时间延长近30%，并使配送延迟93秒。顺风同样会增加功耗，但影响程度较轻。强顺风会使功耗增加7%，并导致配送延迟22秒。这一差异表明存在战略机遇。服务提供商应将风力预报纳入运营规划，以减少干扰。正如我们的结果所示，使飞行路径与顺风方向一致，有助于抵消功耗方面的负面影响。稿件已提交至ACM

表 9. 同时飞行时不同风况下的功耗、充电时间和配送延迟。

风况	功耗（%）	充电时间（s）	配送时间增加量（s）
无风	8.81	316	0
低强度逆风	9.75	350	34
强逆风	11.67	409	93
低强度顺风	9.31	334	18
强顺风	9.42	338	22

5.3 模型验证结果

以下结果展示了所提出的干扰模型在验证数据集上的性能。我们在各种干扰场景下对该模型进行了评估，以衡量其预测功耗和配送时间的准确性。我们使用第4.6节中讨论的评估指标（即 MAPE、MAE、MSE 和 R^2）来评估模型的准确性。

表10。所提出的干扰模型在验证集上的性能。

		测试			
模型	**指标**	**MAE**	**MSE**	**MAPE**	R^2
所提出的干扰模型	功率	1.62	4.25	4.63%	0.98
	Time	198.86	91370.06	10.79%	0.76

如表10所示，在预测干扰导致的功耗时，模型的平均绝对误差、均方误差和平均绝对百分比误差分别为 1.62、4.25 和 4.63。这些较低的误差得分表明，与观测值相比，该模型能够以最小的误差范围做出准确预测。较高的 R^2 值 0.99 进一步印证了这一点，表明模型能够有效捕捉功耗数据中几乎所有的方差，具有较强的预测可靠性。对于受无人机间干扰影响的配送时间估计，模型的平均绝对误差和均方误差分别为 198.86 和 91370.06。这些较高的数值反映出，准确预测受累积充电需求影响的配送时间较为复杂。不过， R^2 值 0.76 表明，尽管存在这些复杂因素，模型仍能捕捉配送时间中相当大一部分方差，尤其能够反映数据中的整体趋势。

在图23中，45度参考线表示理想精度，即预测值与实际值完全一致。对于功耗，数据点紧密分布在这条线上，展现了模型的准确性和较低的预测偏差。数据点在线周围分布范围较窄，反映出模型在各种场景下的表现稳定。85%的功耗预测值与实际值的偏差在 ±5%以内。相比之下，飞行时间预测的离散程度略高。偏差主要出现在节点级干扰较强的场景中，尤其是涉及长时间悬停的情况。在干扰更严重的场景中，较高的功率需求会影响充电时间估计的准确性。

图 24 中，预测残差点均匀分布在零线周围。这种分布表明，在整个预测范围内，模型并未持续高估或低估功率。缺乏明显的模式表明功率预测具有较高的准确性，方向性偏差很小。相比之下，飞行时间残差显示出

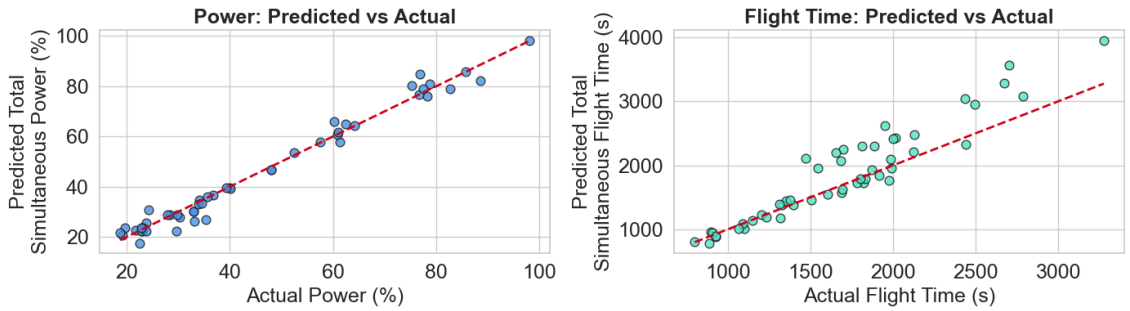


图23. 验证轨迹的功耗和飞行时间模型预测值与实际测量值。

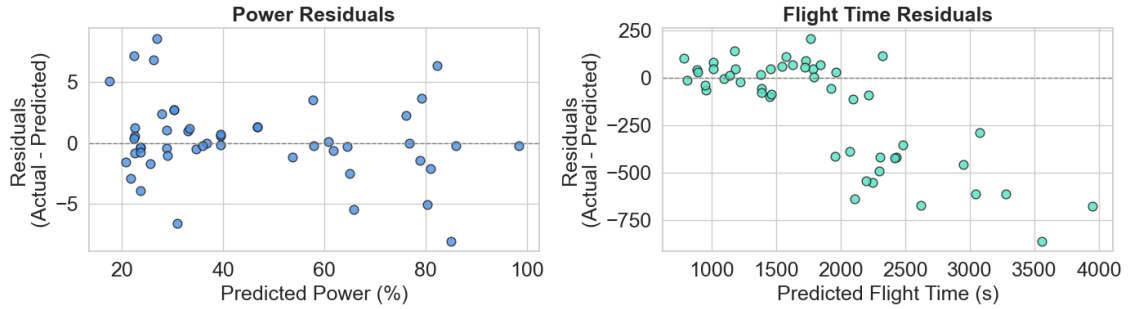


图24. 功耗和飞行时间预测残差的散点图。

在预测值较高时存在更大的偏差。这一趋势主要出现在节点级干扰较强的干扰场景中，尤其是那些悬停时间较长的场景。在这些情况下，由于功率需求增加，模型低估了充电时间。这种低估意味着实际充电时间长于模型的预测值。

总之，尽管所提出的模型对功耗表现出较强的预测性能，但在节点级干扰加剧的情况下，配送时间估计起初会面临较高的误差率。由于充电节点处的排队行为存在不确定性，任务早期的预测误差最为明显。然而，随着无人机接近目的地，节点级干扰会显著减弱。在后期阶段，直接的航段 traversing 占据主导地位。回顾验证集的结果，我们的模型能够高精度地预测这些航段（表12（$R^2 = 0.98$））。因此，随着任务推进，预测准确度会有所提高。相应地，随着任务推进，配送时间预测也会显著改善。通过更先进的排队模型和基于仿真的模型来解决这些初期的不确定性，是未来研究的一个重要方向。

5.4 性能评估

我们分两部分进行实验评估：（a）我们开展了一系列实验，将所提出的模型与文献中的四种先进方法进行比较，以评估其性能。（b）我们开展了消融实验，定量评估各项特征对所提出模型预测性能的贡献。稿件已提交至ACM

表11. 比较模型的超参数。

弹性网络 $\alpha \in [0, 1]$ $L1$ 比率 $\in \{10^{-3},\ 10^{-2},\ 10^{-1}\}$	**XGBoost** 树的数量 $[100, 1000]$ 最大深度 $[2, 7]$ 学习率 $\{0.1, 0.3, 0.5\}$ 按树列采样 $\{0.5, 0.8, 1\}$
随机森林 树的数量 $[100, 1000]$ 最大深度 $[2, 7]$	**SVR** $C \in \{0.1, 1, 10\}$ 核函数 $\in$ {径向基函数, 线性} $\epsilon \in$ {0。01，0。1}

5.4.1 性能效果。我们将所提出的干扰模型与先进的机器学习方法进行比较：弹性网络、XGBoost、随机森林回归和支持向量回归（SVR）。所有模型均采用先前研究中确定的、用于预测交付延迟的最优超参数进行实现 [12, 28, 31]。表 11 总结了各模型所用的超参数配置。为确保比较公平，所有模型均在相同的实验条件下进行评估，即使用同一数据集进行训练和测试（第4.6节）。我们通过平均绝对误差、均方误差、平均绝对百分比误差、 R^2和预测时间来报告模型的效果。

表12. 验证集上的模型性能比较

模型	指标	MAE	MSE	MAPE	R^2	预测时间（毫秒）
所提出的干扰模型	功率 Time	1.62 **199.00**	4.25 **91370.00**	4.63% **10.79%**	0.993 **0.760**	0.32
XGBoost	功率 Time	**0.29** 516.72	**0.43** 489577.86	**0.88%** 27.04%	**0.999** -0.289	1.6
弹性网络	功率 Time	1.47 527.75	3.38 494407.17	4.22% 28.01%	0.993 -0.301	0.22
随机森林	功率 Time	1.02 521.53	2.21 488578.13	3.01% 27.58%	0.995 -0.286	91.5
支持向量回归	功率 Time	1.17 520.85	2.01 487408.20	3.43% 27.53%	0.996 -0.283	13.3

如表12所示，与其他功耗预测方法相比，我们提出的模型取得了相当的性能。虽然性能相近，但需要注意的是，与其他机器学习模型相比，所提出的模型具有可解释性。多项式回归模型通过直接系数表示每个变量的影响，从而能够评估有效载荷重量或飞行编队等因素对干扰的影响 [26]。相比之下，其他方法基于集成方法、正则化或核变换来构建预测，因此难以看清各个变量的单独影响。尽管这些方法在准确性上略有提升，但所提出的模型在预测性能与可解释性之间取得了更好的平衡，因此整体可用性更优。此外，与其他基线方法相比，所提出的模型平均可将预测时间缩短约 ≈98%。在大规模部署中，高预测速度尤为关键，

表 13. 消融实验结果

排除的变量	功率				飞行时间			
	MAE	MSE	MAPE	R^2	MAE	MSE	MAPE	R^2
无（所有特征）	1.53	3.40	4.35%	0.99	196.94	90047.81	10.57%	0.76
编队	1.53	3.40	4.35%	0.99	196.94	90047.81	10.57%	0.76
位置	2.28	8.82	6.45%	0.98	213.44	95966.74	12.20%	0.75
间距	1.54	3.43	4.36%	0.99	197.01	90155.21	10.58%	0.76
载荷	1.35	3.84	4.04%	0.99	201.07	102912.60	10.72%	0.73
wind	1.53	3.39	4.34%	0.99	196.86	89964.88	10.57%	0.76

因为必须监控数千次无人机飞行，以避免级联延误和服务中断。此外，在配送时间预测方面，所提出的模型优于其他基线模型。如表12所示，该模型的平均绝对误差（MAE）最低（199.00），均方误差（MSE）也最低（91370.00），同时 R^2 得分最高（0.760），表明其对配送时间的拟合效果显著更好。这是因为所提出的模型能够捕捉节点级干扰的影响，这些干扰是由无人机在节点处被迫悬停或等待所导致的。所提出的模型利用第4.3.2节提出的经验模型来处理这些影响。这些发现表明，与其他最先进的模型相比，我们提出的模型效果出色。

5.4.2 消融研究。 我们进行了消融研究，以评估模型对各个特征变量的敏感性。为此，我们每次移除一个特征来重新训练模型，并使用与包含全部特征的模型相同的评估指标，评估性能下降情况。随后，我们将这些影响与第 5.2 节实验分析中观察到的趋势进行验证。

消融实验的结果如表 13 所示。从特征集中移除位置 会导致所有指标的预测误差显著增加（功率平均绝对误差从 1.53 增至 2.28，飞行时间平均绝对误差从 196.94 增至 213.44）。这些发现与第 5.2.2 节中的实证分析一致。我们的分析表明，无人机相对于近距离同伴无人机的位置会直接影响功耗和飞行时间。此外，如表 13 所示，排除载荷 会使飞行时间平均绝对误差从 196.94 增至 201.07。这一结果反映了第 5.2.1 节中的实验观察：载荷会直接影响干扰的作用，进而影响配送时间。例如，与载荷较轻的无人机相比，载荷较重的无人机会因附近无人机引起的湍流而消耗更多电池电量。这会导致更长的充电时长和更长的配送时间。相比之下，排除编队（平均绝对误差没有变化）、间距（功率平均绝对误差仅从 1.53 增至 1.54）或风（没有显著变化）时观察到的有限影响，与实证证据高度吻合；这些证据表明，它们的影响要么较小，要么已通过位置和载荷被隐式捕获。消融结果与第 5.2 节实验分析之间的一致性支持了所选特征的有效性以及所提出模型的泛化能力。

6 结论

我们提出了一种新颖模型，用于阐明无人机间干扰对多无人机空中航路网络中无人机服务的服务质量（QoS）的影响。我们在室内无人机测试平台上收集了多条无人机轨迹的数据集。随后，我们深入分析了无人机穿越空域前往目的地并在中间节点充电时产生的无人机间干扰。接着，我们开发了一种模型，用于阐明干扰对稿件已提交至ACM

无人机与同伴无人机同时运行时，干扰对功耗和配送时间的影响。结果表明，无人机相对于同伴无人机的位置会显著影响干扰对无人机服务质量的影响。随后，我们将所提出的模型与先进方法进行比较，评估其预测干扰效应的能力。结果表明，所提出的模型能够准确预测干扰对无人机效率的影响，同时保持较低的计算成本。需要注意的是，载荷体积、无人机速度和形状等因素不在当前模型的研究范围内。未来，我们将纳入这些额外因素，以提升模型在不同场景下的准确性和适用性。此外，我们还计划利用这些见解制定无人机间干扰消解策略，从而实现多无人机网络的高效运行。

致谢

本研究部分得益于澳大利亚研究理事会提供的 LE220100078 和 DP220101823 资助。本声明中的观点完全由作者负责。

参考文献

[1] Junaid Akram、Muhammad Umair、Rutvij H Jhaveri、Muhammad Naveed Riaz、Haoran Chi 和 Sharaf Malebary。2023 年。链式无人机：用于无人机物联网中安全且智能服务提供的基于区块链的隐私保护框架。《计算机与电气工程》110（2023），108772。[2] Balsam Alkouz、Babar Shahzaad 和 Athman Bouguettaya。2022 年。基于服务的无人机配送。*arXiv*（康奈尔大学）（2022 年第 1 期）。https: //doi.org/10.48550/arxiv.2201.00277[3] Giulio Attenni、Viviana Arrigoni、Novella Bartolini 和 Gaia Maselli。2023 年。基于无人机的配送系统：路径规划综述。《*IEEE Access*》11（2023），123476–123504。[4] 澳大利亚空中服务公司。2024 年。澳大利亚无人机产业的未来规模。https://www.airservicesaustralia.com/wp-content/uploads/2024/02/Sizing-the-Future-Drone-Industry-in-Australia_February.pdf[5] Salih Safa Bacanli、Enas Elgeldawi、Begümhan Turgut 和 Damla Turgut。2022 年。机会网络中的无人机充电站选址。《*Drones*》6，10（2022 年 10 月），293。https://doi.org/10.3390/drones6100293[6] P Beigi、MS Rajabi 和 S Aghakhani。2022 年。无人机能耗因素与模型概述。arXiv，2022 年。*arXiv* 预印本 *arXiv:2206.10775*（2022 年）。[7] Juan A Besada、David Carramiñana、Luca Bergesio、Ivan Campaña 和 Ana M Bernardos。2022 年。面向无人交通管理的协同监视建模与仿真。《*Sensors*》22，4（2022），1498。[8] Francesco Betti Sorbelli。2024 年。基于无人机的配送系统：系统综述、当前趋势与研究挑战。《自主交通系统期刊》1，3（2024），1–40。[9] Athman Bouguettaya、Munindar P. Singh、Michael N. Huhns、Quan Z. Sheng、Hai Dong、Qi Yu、Azadeh Ghari Neiat、Sajib Mistry、Boualem Benatallah、Brahim Medjahed、Mourad Ouzzani、Fabio Casati、Xumin Liu、Hongbing Wang、Dimitrios Georgakopoulos、Chen Liang、Surya Nepal、Zaki Malik、Abdelkarim Erradi、Yan Wang、M. Brian Blake、Schahram Dustdar、Frank Leymann 和 Michael P. Papazoglou。2017 年。服务计算宣言。《*Commun. ACM*》60，4（2017 年 3 月），64–72。https://doi.org/10.1145/2983528[10] Sarah Bradley、Albertus Alvin Janitra、Babar Shahzaad、Balsam Alkouz、Athman Bouguettaya 和 Abdallah Lakhdari。2023 年。多无人机空中航路网络中的基于服务的轨迹规划。*arXiv*（康奈尔大学）（2023 年第 1 期）。https://doi.org/10.48550/arxiv.2303.11514[11] A. Cornell、B. Kloss、DJ Presser 和 R. Riedel。2023 年。无人机飞上天空，可能扰乱最后一公里配送。麦肯锡公司。可访问：
h
t
t
p
s://
www.mckinsey.com/industries/aerospace-and-defense/our-insights/future-air-mobility-blog/drones-take-to-the-sky-potentially-disrupting-last-mile-delivery。[12] Wei Dai、Mingcheng Zhang 和 Kin Huat Low。2024 年。利用集成学习对四旋翼无人机作业功耗进行估计的数据高效建模。《航空航天科学与技术》144（2024 年第 1 期），108791。https://doi.org/10.1016/j.ast.2023.108791[13] S. Guo、B. Alkouz、B. Shahzaad、A. Lakhdari 和 A. Bouguettaya。2023 年。用于高效群体能耗的无人机编队。arXiv:2303.09694v1[cs.RO]。arXiv:2303.09694 [cs.RO][14] R. Gupta、A. Sinha 和 S. Banerjee。2023 年。用于估计小型无人机螺旋桨空气动力系数的新型经验模型。《国际航空航天科学杂志》（2023 年）。https://link.springer.com/article/10.1007/s42401-023-00203-y[15] Charbel Hage、Tonino Sophy 和 El-Hassane Aglzim。2023 年。研究移动障碍物附近无人机螺旋桨的性能：计算流体力学研究、推力控制与电池能量管理。《*IEEE*车辆技术开放期刊》4（2023），590–609。[16] Insu Hong、Michael Kuby 和 Alan T Murray。2018 年。用于无人机配送服务规划的距离受限充电站覆盖模型。《交通研究*C*辑：新兴技术》90（2018），198–212。

[17] Karan P. Jain、Trey Fortmuller、Jaeseung Byun、Simo A. Mäkiharju 和 Mark W. Mueller。2019。多旋翼飞行器近距离飞行的气动扰动建模。载于《2019年国际无人机系统会议（ICUAS）》。1261–1269。https://doi.org/10.1109/ICUAS.2019.8798116[18] Therese Jones。2017。国际商用无人机监管与无人机配送服务。技术报告。RAND，美国加利福尼亚州圣莫尼卡。[19] Kwang Min Koo、Kyung Rak Lee、Sung Ryung Cho 和 Inwhee Joe。2018。采用多项式回归的远程传感器数据采集无人机路径规划方法。载于《国际普适信息技术与应用会议》。施普林格，428–433。[20] Woojin Lee、Balsam Alkouz、Babar Shahzaad 和 Athman Bouguettaya。2021。利用自主无人机在空中航路中配送包裹。载于《2021年ACM国际普适与泛在计算联合会议暨2021年ACM国际可穿戴计算研讨会附属论文集》。48–50。[21] Woojin Lee、Balsam Alkouz、Babar Shahzaad 和 Athman Bouguettaya。2021。利用自主无人机在空中航路中配送包裹。arXiv（康奈尔大学）（2021年1月）。https://doi.org/10.48550/arxiv.2108.06056[22] Xiaohui Li。2021。民用空中无人机部署与导航中的若干问题。arXiv预印本 arXiv:2106.13162（2021）。[23] Michael C. Lucic、Omar Bouhamed、Hakim Ghazzai、Abdullah Khanfor 和 Yehia Massoud。2023。利用无人驾驶飞行器为智能交通系统和智慧城市打造动态智能空中基础设施：综述。《Drones》7卷2期（2023年1月），79。https://doi.org/10.3390/drones7020079[24] Chuanwen Luo、Wenping Chen、Deying Li、Yongcai Wang、Hongwei Du、Lidong Wu 和 Weili Wu。2020。优化无人机飞行轨迹，以高效采集无线传感器网络中的数据。《理论计算机科学》853卷（2020年5月），25–42。https://doi.org/10.1016/j.tcs.2020.05.019[25] Franco Minucci、Evgenii Vinogradov 和 Sofie Pollin。2020。以任何（低）代价避免碰撞：面向无人驾驶飞行器的类广播式自动相关监视位置广播。《IEEE Access》8卷（2020），121843–121857。[26] Christoph Molnar。2020。可解释机器学习。Lulu.com。[27] Sara Montagner。2024。自由来流湍流对小型无人机螺旋桨空气动力学和气动声学的影响。博士学位论文。都灵理工大学。[28] Alex S. Prasetia、Rong-Jong Wai、Yi-Lun Wen 和 Yu-Kai Wang。2019。基于任务的多旋翼无人机能耗预测。《IEEE Access》7卷（2019年1月），33055–33063。https://doi.org/10.1109/access.2019.2903644[29] Yujie Qin、Mustafa A. Kishk 和 Mohamed-Slim Alouini。2022。无人机与涉及电动汽车的网络中充电基础设施共享的性能分析。《IEEE车辆技术汇刊》72卷3期（2022年11月），3973–3988。https://doi.org/10.1109/tvt.2022.3219764[30] Mohammad Reza Rezaee、Nor Asilah Wati Abdul Hamid、Masnida Hussin 和 Zuriati Ahmad Zukarnain。2024。无人机碰撞规避方案综述：挑战与待解决问题。《IEEE智能交通系统汇刊》（2024）。[31] Arupa Sarkar、Fendy Santoso、Jun Shen、Bo Du、Akbar Telikani 和 Jun Yan。2024。四旋翼无人驾驶飞行器能耗预测模型评估。2021年IEEE第94届车辆技术会议（VTC2021-Fall）（2024年10月），1–7。https://doi.org/10.1109/vtc2024- fall63153.2024.10757699[32] David K Schmidt。2016。柔性飞翼无人机的稳定性增强与主动颤振抑制。《制导、控制与动力学杂志》39卷3期（2016），409–422。[33] Babar Shahzaad。2022。智慧城市中的无人机配送服务。博士学位论文。[34] Babar Shahzaad、Athman Bouguettaya、Sajib Mistry 和 Azadeh Ghari Neiat。2019。用于配送的无人机即服务（DaaS）组合。2019年IEEE国际Web服务会议（ICWS）（2019年7月）。https://doi.org/10.1109/icws.2019.00017[35] Babar Shahzaad、Athman Bouguettaya、Sajib Mistry 和 Azadeh Ghari Neiat。2019。约束感知的无人机即服务组合。载于《面向服务的计算：第17届国际会议，ICSOC 2019，法国图卢兹，2019年10月28日至31日，论文集17》。施普林格，369–382。[36] Cheng Shouji、Reza Alidoost Dafsari、Seung-Hwa Yu、Yong Choi 和 Jeekeun Lee。2021。农业无人机单个旋翼桨叶产生的下洗气流的均值流动与湍流特性。《农业中的计算机与电子学》190卷（2021），106471。[37] Vejaykarthy Srithar、Syeda Amna Rizvi、Amani Abusafia、Athman Bouguettaya 和 Balsam Alkouz。2024。空间邻近性对无人机服务的影响。载于《2024年ACM国际普适与泛在计算联合会议伴随会议》。235–238。https: //doi.org/10.1145/3675094.3677555[38] Muhammad Umair、Muhammad Aamir Cheema、Omer Cheema、Huan Li 和 Hua Lu。2021。2019冠状病毒病对医疗保健、智能家居、智能建筑、智慧城市、交通运输和工业物联网中物联网应用的影响。《Sensors》21卷11期（2021），3838。[39] Changfu Wang、Yaohui Wang、Bin Zhang、Mengyi Wang 和 Xudong Wang。2022。无人机集群无线充电队列优化方法研究。第758–765页。https://doi.org/10.1007/978-981-19-0390-8_94[40] Yongcai Wang、Tianyuan Sun、Guoyao Rao 和 Deying Li。2018。稀疏空中网络中的编队跟踪。《IEEE通信领域精选期刊》36卷9期（2018），2000–2014。https://doi.org/10.1109/JSAC.2018.2864374[41] Zhiming Wang、Xuan Wang 和 Weimin Liu。2023。风功率曲线建模与风功率预测的遗传最小二乘估计方法。《科学报告》13卷1期（2023），9188。[42] Q. Zhao、J. Hughes 和 D. Lyons。2020。通过空气扰动分析进行无人机近距检测。11425（2020），114250L–114250L–9。https: //doi.org/10.1117/12.2556385