AIR-VIEW:用于天气能见度估计的航空图像库,一个数据集和基准测试

Chad Mourning, Member, IEEE, Zhewei Wang, Member, IEEE, Justin Murray, Student Member, IEEE

摘要—航空气象领域的机器学习是一个正在发展的研究领域,旨在提供低成本的替代方案来代替传统且昂贵的天气传感器;然而,在大气能见度估计这一领域中,不存在适用于航空相关距离、来自多样化地点、规模足够大以便于监督式学习使用的公共数据集。本文介绍了一个新数据集,该数据集代表了从联邦航空局(FAA)气象摄像头网络收集的一年图像数据的成果,这些图像是为此目的而采集的。我们还展示了在三个公开可用的数据集以及我们的数据集上训练和测试时应用三种常用方法及一个通用基准的表现情况,并将结果与最近批准的一项 ASTM 标准进行比较。

Index Terms—数据集,机器学习,大气能见度

I. 介绍

POOR 能见度是飞机事故的主要原因,特别是所谓的 "VFR-into-IMC"情况,即飞行员从满足目视飞行规则条件的情况转到仪表气象条件 [1] 的情况。决定这一状况的主要大气属性是大气能见度,这是一个水平测量值,以及它的垂直对应物,天花板高度。

有几个与大气能见度相关的定义,包括世界气象组织(WMO)、联邦航空管理局(FAA)和国际民航组织(ICAO)。WMO的定义侧重于物理特性,将其称为"使平行光束亮度降至原值5%所需的大气路径长度"[2]。相比之下,FAA和ICAO的定义则更注重航空应用。FAA将能见度定义为"在观察点处大气水平浑浊程度的度量,并以一个人能够看到并识别特定物体的水平距离来表示"[3]。而ICAO则更为精确地将其定义为"能看到并辨认出近地面适当尺寸黑色物体的最大距离,这些物体背景明亮",或者,"在黑暗背景下能看见并识别周围1,000坎德拉灯光的最大距离"[4]。

现有的估计这些能见度值的方法需要具有小地理 覆盖范围的昂贵硬件,而创建低成本机器学习估算器的

Chad Mourning, Zhewei Wang, and Justin Murray are with the School of Electrical Engineering and Computer Science, Ohio University, Athens, OH $45701\,$

研究开始获得动力。然而, 航空领域至今尚未形成真正 的通用解决方案, 部分原因是缺乏多样且高质量的真实 标记图像。

本文的主要贡献是:

- 1) 新数据集的介绍,以协助训练试图估计大气能见度的机器学习算法。
- 2) 表示当前方法在本数据集及其他公开可用数据集 上训练时估计能见度有效性的基准。

第 II 节将详细阐述能见度估计问题,并介绍一些已尝试解决该问题的相关工作。第 III 节涵盖了研究人员可能用于训练模型的公开可用数据集及其与本文中提出的数据集的不同之处。第 IV 节介绍了有关数据集的一些描述性统计信息,而第 V 节展示了使用各种方法对我们的数据集进行基准测试的结果。最后,我们将讨论这些方法的局限性和可能的未来研究方向。

II. 可见性问题

估算大气能见度不仅在航空领域引起关注。一些最早的尝试估算大气能见度的努力发生在 18th 世纪的天文学家试图校正减弱的星光时,这导致了诸如比尔定律和比尔-朗伯定律 [5] 等数学模型的形成。最近,它也引起了自动驾驶汽车开发者的极大兴趣;然而,飞行员所需的距离通常为 10 英里或更多,因此需要比地面车辆更强大的方法。

此外, 航空领域对能见度估计的关注主要集中在机场。目前能见度估计的"黄金标准"是自动气象观测系统 (AWOS)[6], 该系统使用透射仪或散射计来推断光的消光系数, 从而得出能见度估计值。这可以从美国联邦航空管理局在机场附近大量投资天气摄像机以及与麻省理工学院林肯实验室合作开发 VEIA[7] 算法中看出。这突显了能见度估算研究中的一个二分法:全参考与无参考估算。

VEIA 需要一个晴朗天气的参考图像,它将此视为部署后几天内最清晰的图像,在此期间它使用经典计算机视觉技术找到平均边缘权重;然后在当前图像中找到平均边缘权重并得出能见度。

我们的工作旨在支持无参考模型,其中从手机拍摄的照片与价值一百万美元的 FAA 天气摄像头安装一样有可能获得良好的能见度估计。

李等人集成模型 [8] 是最早解决这个问题的方法之一;然而,它们的准确率仅达到 61%。RMEP[9] 是一种基于回归的方法,其 RSME 约为 1 公里,这符合 FAA 指南;然而,他们训练和测试的是接近上午 11 点的图像。虽然这种方法在一定程度上控制了图像中的辐照度,但它也引发了对其方法普遍适用性的疑问。

VisNet[10] 是可见性估计的领先候选者,原论文将距离分类到了20公里(超过12英里)。VisNet 的关键见解是在预处理步骤中使用傅里叶变换来隔离高频噪声作为图像中能见度损失的替代指标。不幸的是,VisNet 的作者没有公开发布他们的数据集,所以我们无法验证他们的结果。我们还担心FFT 频谱缺乏适应性,这可能不适用于不同分辨率的相机。

值得考虑的是,流行的、现成的模型在可见性估计任务中是否有效; Kevin Kipfer[11] 比较了各种著名的架构,其中 VGCC-16[12] 实现了 52% 的最高准确率。类似地,我们使用 ResNet50[13] 模型对新数据集进行测试。

III. 相关数据集

本节描述了一些研究人员目前常用的流行数据集 以及我们的新数据集如何进行比较。有几个问题使得各 种数据集在航空相关的能见度估算方面不太理想,大致 按重要性顺序排列:

- 可见性值 如果数据集没有标注可见性估计值, 则监督学习模型的价值会大大降低。
- 2) 图像数量 没有足够的数据机器学习模型将无法 泛化。
- 3) 开放获取——控制实现对于科学研究至关重要, 而没有先前论文数据集的访问权限则难以量化 进步。
- 4) 场景多样性——为了实现鲁棒的泛化,优选多样 化的地点,否则可能会过度拟合到地点中的地形 或其他特征。

5) 真实图像-虽然足够逼真的合成图像可以训练出能够泛化到现实的模型,但在这一问题中,从仿真到真实的迁移验证很少,仍然是一个研究领域。

FRIDA¹ (雾天道路图像数据库)和 FRIDA2²数据集是合成数据集,分别包含 90 张和 330 张来自 2010年的 18 个场景的图像,但没有标注可视距离。Foggy Cityscapes和 Foggy Driving数据集³来自 [14],包含近 25,000 张合成图像,带有高达 600 米的可见性标签和 500 张没有可视距离估计的真实图像。FRIDA和 Foggy Cityscapes数据集还提供了逐像素深度图信息,这可能对训练自动驾驶汽车有用,但不适合大气能见度估算。SynFog[15]是合成数据集的最新进展,但仍然专注于自动驾驶车辆的距离,并且尚未发布他们的数据集(声明为"即将推出")。

"雾中道路标志"数据集(FORSI)[16]包含大约3500张合成图像,是公开可用的,但仅具有高达250米的能见度。Schaupp等人[17]正在进行高保真合成图像的研究,用于使用各种雾模型估算在航空相关距离上的能见度,但尚未发布任何数据集。

FVEI (雾视估计图像) 数据集在 [18] 中引入,包含 15,000 张带能见度标签的图像,略好一些,但所有距离 都在 500 米或以内,并且似乎需要在中国云存储服务百 度网盘上注册才能访问。DENSE 数据集 ⁴ [19] 特别有趣,因为它基于穿过雾气的激光雷达,是另一个汽车应用案例,可以公开获取,但在注册后仅提供与汽车行业相关的距离。

FOVI (雾天户外能见度图像),是由 VisNet[10]的作者使用的数据集,该数据集包含来自韩国 26 个地点的 3,000,000 张图像。这是一个数量庞大的图像集合,并且包括了相当多样化的地理位置;它还包含了与航空应用相关的距离信息。遗憾的是,这一数据集并未公开发布。海量户外场景存档 (AMOS) ⁵ [20] 数据集包含了大量的图像和多样的地理位置,共计来自 538 个地点的1700 万张图片,但这些数据集中缺乏能见度的真实值。

RMEP 使用 SSF (Sub-SkyFinder)[9] 数据集,从 30 个地点精选出 24,000 张图像,并在其位置和时间上回溯性地标记能见度记录,这是本文评估的一个公开可

¹http://perso.lcpc.fr/tarel.jean-philippe/bdd/frida.zip

 $^{^2} http://perso.lcpc.fr/tarel.jean-philippe/bdd/frida2.zip$

 $^{^3}$ https://people.ee.ethz.ch/~csakarid/SFSU_synthetic/

 $^{^4} https://www.uni-ulm.de/en/in/institute-of-measurement-control-and-microtechnoresearch/data-sets/dense-datasets/$

 $^{^5 \}rm https://mvrl.cse.wustl.edu/datasets/amos/$

用数据集。这可能是我们发布数据集之前最适合大气能 见度估计任务的数据集。

IV. 数据集

2024年1月,在介绍我们关于可见性估计问题 [21] 的初步工作时,有人建议我们考虑利用 FAA Weather Camera 网络作为其模型的训练数据来源。在联系管理员请求批量数据后,我们被告知 FAA 不会保存提供给用户的摄像头图像,并且他们不提供 API 来程序化地收集这些图像。

在此讨论之后,我们开始了数据收集活动,从与能见度传感器共址的各种 FAA 气象摄像头网站上抓取图像,以创建用于能见度估计问题的真实数据集。下一节描述了我们的数据集。

A. 描述性统计分析

版本 1 的 AIR-VIEW 包含 147,182 张图像,这些图像是在 2024 年 4 月 9th 至 2025 年 5 月 17th 期间从 444 个不同的 FAA 气象摄像机站点收集的;仅包括有能见度估计值的站点。首先,我们在图 1 中展示了数据集的关键特征,即能见度真实值。自动报告的有效能见度可以在 [6] 找到;然而,为了清晰起见,在直方图中将部分英里的能见度合并在一起。大多数日子的天气都很晴朗,9 英里和 10+英里的样本占数据集的 80%,因此用户应注意重新平衡数据。

一个方案被设计出来,以随机间隔收集 FAA 气象摄像头图像,以便在数据集中提供有意义的时间变化多样性;然而,在美国东海岸早期采集的图像可能仍然早于阿拉斯加的日出时间,特别是在冬季月份。图 2 显示了每月的采集次数;可以注意到夏季由于额外的日照,有效采集次数有所增加。采集方案中的一个错误导致十一月只有一次采集,但我们认为数据集包含足够的有意义的冬季图像以供使用。

最初,图像来源于所有 FAA 天气相机站点,但只有部分 FAA 天气相机在网站上提供能见度估算,因此仅收集了这些图像,并且这些图像是 AIR-VIEWv1 数据集的一部分。图 3显示了数据集中包含的摄像机位置。尽管通过 FAA 网站访问天气相机,但仍有许多合作摄像头在加拿大提供数据。

另一个考虑因素是时间。RMEP[9] 模型故意选择 大约上午11点左右的图像,试图控制图像中的辐照度;

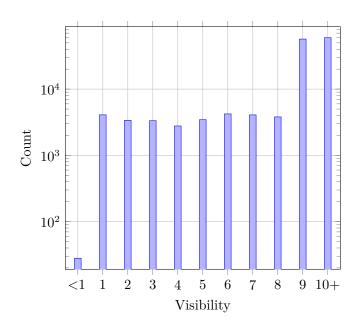


图 1. 数据集中发现的能见度的直方图。小于一的值合并为一个区间,但整个数据集中的总数仍然只有 28 个实例。这是一个对数图,所以 9 英里和 10+英里的能见度实例主导了数据。

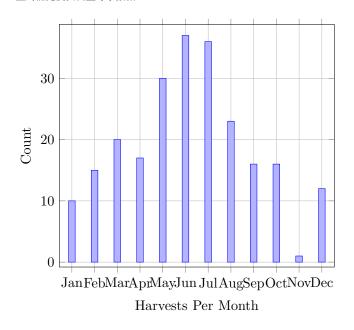


图 2. 每月收获次数的直方图。一般来说,在日照时间较长的月份,收获次数较多。一次意外的系统停机导致 2024 年 11 月仅有一次收获。

然而,这引发了关于一般性的担忧。图 4 显示了图像捕捉小时的直方图。数据集可以在这里找到 ⁶。

V. 基准测试

a) 方法论: 为了评估我们的数据集相对于其他公开可用模型的有效性, 我们将评估三个流行的能见度估计架构: VisNet[10]、RMEP[9] 和 Li 的集成模

 $^{^610.5281/}zenodo.15742555$

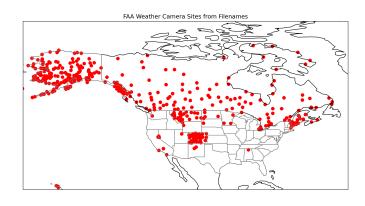


图 3. 包含在我们数据集中协同位置能见度估计值的 444 个 FAA 气象摄像头子集的位置。

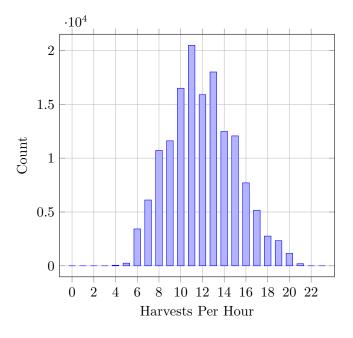


图 4. 每小时收割次数的直方图。每个区间包含在调整时区后,给定小时内的时间对应的收割次数。例如,第 8 个区间包含了在当地时间早上 8:00 到 8:59 之间收集的所有图像实例数。每隔一小时进行标记以便清晰区分。

型 [8]。此外,作为基线,我们还将评估一个流行的通用 架构 ResNet50[13]。

对于 AIR-VIEW 测试,我们整理数据集以平衡类别表示,并训练回归风格的网络以便更好地与天气信息提供商的 ASTM 标准进行比较 [22]。这些结果应作为任何试图改进大气能见度估算领域的研究人员的起点。

b) 结果: 表 I 展示了四个模型在三个公开可用的数据集上训练和测试的结果,以及它们单独训练后与 AIR-VIEW 对比测试的结果。现有数据集的每个单元格包含典型的回归指标,包括: MAE、MAPE、MSE,以及 MRSE,在该列的数据集上训练并针对该数据集进行测试(左侧)和在 AIR-VIEWv1 上进行测试(右侧)。AIR-VIEW 列仅显示在 AIR-VIEW 上训练和测试的结

果,并包含根据 ASTM WIP 标准 [22] 得出的额外指标, 这对应于图像距离其正确值 1.5 英里内的百分比。

c) 讨论: 鉴于与其它公开数据集相比,图像数量较多而距离较少,训练在FROSI、FCS和SSF上的模型无法泛化并不令人惊讶。令人惊讶的是, ResNet的表现与专门针对任务设计的模型相当。

尽管是最古老的, Li 综合模型 [8] 在这个新数据集上整体表现似乎最好。ResNet 也表现出色,在该数据集上的表现超过了两个专门为此任务设计的模型。在一项未发布的研究中, FAA 舱内气象技术计划将 20%的 MAPE 作为 AWOS 与专家对能见度图像综合估计一致性的基准;这些示例均未达到这一阈值——需要进一步的研究。

d) 限制条件: 光学能见度估计的主要缺点是在没有光源的情况下难以进行,例如在夜间。由于图像采集过程的性质,数据集中可能存在一些低光图像;东海岸清晨的采集可能发生在阿拉斯加日出之前,而阿拉斯加傍晚的采集可能发生在东海岸日落之后。这些应从训练中排除。

e) 结论:每个模型在使用相同数据训练和测试时通常表现良好,但在对使用 FROSI 和 FCS 训练的模型进行真实数据测试时,其表现普遍非常差,RMSEs约为5英里,表明行为大致相当于随机猜测。基于 SSF数据集训练的模型开始接近实际情况,但仍难以处理网络摄像头数据集,这也可以归因于相机参数差异,如视场、焦点等。

作者恳请 Palvanov 等人发布他们的数据集,以便 测试解决此问题的新方法,因为我们无法在我们的数据 集上重现他们的出色表现。在此期间,我们认为我们的 数据集是最优质的公开可用的真实标记数据集,并配备 了同位认证的能见度测量设备。

VI. 未来工作

收集活动将继续进行。非常低能见度的图像在数据集中仍然代表性不足,我们不认为大多数模型已经达到饱和。美国联邦航空管理局继续部署新摄像头,这些摄像头将被常规添加到数据集之中。我们计划每年发布更新版的 AIR-VIEW 数据集。

作者在可见性估计中的下一个研究兴趣是分布偏移,这一问题也可能通过该数据集进行研究。季节模型、月度模型或使用滑动窗口的模型可能会提高性能。另一个研究方向是对天花板高度的光学估算。作者认为

方法\ 数据集	FROSI	前向纠错	SSF	AIR-视图 v1
视网 [10]	MAE: 4.20 m / 4.34 mi	MAE: $71.8 \text{ m} / 5.02 \text{ mi}$	MAE: 1.42 mi / 4.54 mi	MAE: 1.83 mi
	MAPE: 2.06% / 158%	MAPE: 24.5% / 98.8%	MAPE: 87.1% / 196%	MAPE: 56.5%
	MSE: $347 \text{ m}^2 / 27.2 \text{ mi}^2$	MSE: 9,950 $\mathrm{m^2}$ / 32.6 $\mathrm{mi^2}$	MSE: $7.02~\mathrm{mi^2}$ / $28.2~\mathrm{mi^2}$	MSE: 5.56 mi^2
	RMSE: 18.6 m / 5.22 mi	RMSE: 99.8 m / 5.71 mi	RMSE: $2.65~\mathrm{mi}$ / $5.31~\mathrm{mi}$	RMSE: 2.38 mi
				ASTM: 75%
RMEP[9]	MAE: 5.12 m / 11.4 mi	MAE: 38.3 m / 4.86 mi	MAE: 1.35 mi / 4.66 mi	MAE: 1.79 mi
	MAPE: 0.0331% / 95.4%	MAPE: 13.4% / 97%	MAPE: 60.1% / 140%	MAPE: 54.3%
	MSE: $0.004 \text{ m}^2 / 31.6 \text{ mi}^2$	MSE: 1 $\times 10^4~\text{m}^2$ / 32.3	$\mathrm{MSE}\mathrm{:}~7.76~\mathrm{mi}^2~/~19.0~\mathrm{mi}^2$	MSE: 5.48 mi^2
	RMSE: 0.066 m / 5.62 mi	mi^2	RMSE: $2.78~\mathrm{mi}$ / $4.36~\mathrm{mi}$	RMSE: $2.34~\mathrm{mi}$
		RMSE: 102 m / 5.68 mi		ASTM: 75%
李集成 [8]	MAE: 3.31 m / 3.62 mi	MAE: 50.8 m / 4.86 mi	MAE: 1.25 mi / 4.15 mi	MAE: 1.77 英里
	MAPE: 2.22% / 60.12%	MAPE: 16.1% / 97.2%	MAPE: 72.4% / 180%	MAPE: 56.2%
	MSE: $26.8 \text{ m}^2 / 21.3 \text{ mi}^2$	MSE: $5,930 \text{ m}^2 / 32.2 \text{ mi}^2$	MSE: $6.37 \text{ mi}^2 / 25.0 \text{ mi}^2$	MSE: 5.25 英里 ²
	RMSE: 5.18 m / 4.62 mi	RMSE: 77.0 m / 5.67 mi	RMSE: 2.52 mi / 5.0 mi	RMSE: 2.29 英里
	·			ASTM: 77%
ResNet50[13]	MAE: 1.58 m / 4.75 mi	MAE: 36.2 m / 4.81 mi	MAE: 1.22 mi / 3.72 mi	MAE: 1.77 英里
	MAPE: 0.789% / 93.9%	MAPE: 12.6% / 95.8%	MAPE: 66.1% / 158%	MAPE: 52.1 %
	MSE: $4.63 \text{ m}^2 / 31.2 \text{ mi}^2$	MSE: $5,960 \text{ m}^2 / 31.8 \text{ mi}^2$	MSE: $6.68 \text{ mi}^2 / 20.4 \text{ mi}^2$	$MSE: 5.46 \text{ mi}^2$
	RMSE: 2.15 m / 5.58 mi	RMSE: 77.2 m / 5.64 mi	RMSE: 2.59 mi / 5.52 mi	RMSE: 2.34 mi

表I

每个方法在各个数据集上的评估指标。四个被评估的数据集代表列,而四个被评估的技术代表行。每个单元格有5个指标,前三列中的每个指标有两个值:当训练和测试使用该列数据集的结果,以及在其自身数据集上训练并在AIR-VIEW上测试的结果。最后一列展示了技术在AIR-VIEW上训练和测试的结果。最后一列中最好的数值被加粗显示。最后一列有一个额外的指标"ASTM",表示达到ASTMWIP标准中的第一级数据的能力 [22]

这可能无法仅凭单一视角解决。全天空成像仪存在并且 可以部署以收集用于训练的有用数据集。

致谢

这项工作部分受到了俄亥俄联邦研究网络项目 502 的启发: 低空天气网络。此外,没有联邦航空管理局 (FAA) 的天气相机网络,这项工作是不可能实现的。

参考文献

- Federal Aviation Administration, "14 CFR § 91.155 Basic VFR Weather Minimums," Code of Federal Regulations, Title 14, Part 91, Section 155, 2021, Accessed on April 29, 2023.
- [2] World Meteorological Organization, Guide to Instruments and Methods of Observation, 8th ed., ser. WMO-No. 8. Geneva, Switzerland: World Meteorological Organization, 2018, accessed: 2024-11-24. [Online]. Available: https://library.wmo.int/doc_num. php?explnum_id=4147
- [3] Federal Aviation Administration, FAA Order JO 7900.5E: Surface Weather Observing—METAR and SPECI, U.S. Department of Transportation, Washington, DC, 2023, available at: https://www.faa.gov.

- [4] International Civil Aviation Organization, Annex 3 to the Convention on International Civil Aviation: Meteorological Service for International Air Navigation, 20th ed., International Civil Aviation Organization, Montreal, Canada, 2018, iCAO Doc 7300.
- [5] Beer, "Bestimmung der absorption des rothen lichts in farbigen flüssigkeiten," Annalen der Physik, vol. 162, no. 5, pp. 78–88, 1852.
- [6] F. A. Circular, "Automated weather observing systems (awos) for non-federal applications," 3 2017.
- [7] M. P. Matthews, "Visibility estimation through image analytics," MIT Lincoln Laboratory, Tech. Rep. ATC-453, 2023.
- [8] S. Li, H. Fu, and W.-L. Lo, "Meteorological visibility evaluation on webcam weather image using deep learning features," Int. J. Comput. Theory Eng, vol. 9, no. 6, pp. 455–461, 2017.
- [9] P. Su, Y. Liu, S. Tarkoma, A. Rebeiro-Hargrave, T. Petäjä, M. Kulmala, and P. Pellikka, "Retrieval of multiple atmospheric environmental parameters from images with deep learning," *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1–5, 2022.
- [10] A. Palvanov and Y. I. Cho, "Visnet: Deep convolutional neural networks for forecasting atmospheric visibility," *Sensors*, vol. 19, no. 6, p. 1343, 2019.
- [11] K. Kipfer, "Fog prediction with deep neural networks," Master's thesis, ETH Zurich, 2017.
- [12] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.

- [13] B. Koonce, "Resnet 34," Convolutional neural networks with swift for tensorflow: image recognition and dataset categorization, pp. 51–61, 2021.
- [14] C. Sakaridis, D. Dai, and L. Van Gool, "Semantic foggy scene understanding with synthetic data," *International Journal of Computer Vision*, vol. 126, no. 9, pp. 973–992, Sep 2018. [Online]. Available: https://doi.org/10.1007/s11263-018-1072-8
- [15] Y. Xie, H. Wei, Z. Liu, X. Wang, and X. Ji, "Synfog: A photorealistic synthetic fog dataset based on end-to-end imaging simulation for advancing real-world defogging in autonomous driving," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024, pp. 21763–21772.
- [16] R. Belaroussi and D. Gruyer, "Impact of reduced visibility from fog on traffic sign detection," in 2014 IEEE intelligent vehicles symposium proceedings. IEEE, 2014, pp. 1302–1306.
- [17] J. Schaupp, C. Mourning, and J. Murray, "Synthetic imagery in the use of training visibility estimators," in AIAA SCITECH 2025 Forum, 2025, p. 2325.
- [18] W. Yang, Y. Zhao, Q. Li, F. Zhu, and Y. Su, "Multi visual feature fusion based fog visibility estimation for expressway surveillance using deep learning network," *Expert Systems with Applications*, vol. 234, p. 121151, 2023.
- [19] T. Gruber, F. Julca-Aguilar, M. Bijelic, and F. Heide, "Gated2depth: Real-time dense lidar from gated images," in The IEEE International Conference on Computer Vision (ICCV), 2019.
- [20] N. Jacobs, N. Roman, and R. Pless, "Consistent temporal variations in many outdoor scenes," in *IEEE Conference on Computer Vision* and Pattern Recognition (CVPR), Jun. 2007, pp. 1–6, acceptance rate: 23.4%.
- [21] C. Mourning, D. Wright, and J. Murray, "Towards a low cost distributed awos: Machine learning for cost effective visibility estimation," in AIAA SCITECH 2024 Forum, 2024, p. 2355.
- [22] ASTM International, "Standard specification for performance for weather information reports, data interfaces, and weather information providers (wips)," ASTM Standard F3673-23, ASTM International, West Conshohocken, PA, 2024, available from: https://www.astm.org/Standards/F3673.htm.



Zhewei Wang Zhewei Wang is a Visiting Assistant Professor of Artificial Intelligence in the School of Electrical Engineering and Computer Science at Ohio University. He completed his Ph.D. in Computer Science and M.S. in Biomedical Engineering at Ohio University in 2020 and 2019, respectively. From 2021 to 2023, he conducted research at Massachusetts General Hos-

pital of Harvard Medical School. His research interests include Deep Learning, Machine Learning, Computer Vision, Medical Image Analysis, Natural Language Processing, Graph Neural Networks, and Reinforcement Learning.

Justin Murray Justin received a Bachelor of Science in Computer Science from Ohio University in 2023 and is currently pursuing a Master of Science in Computer Science from Ohio University. Justin is a 2023 recipient of the Ohio Space Grant Consortium Research Fellowship. Current research interests include machine learning, and computer graphics.



Chad Mourning Chad Mourning is Principal Investigator of the VizSim Lab at Ohio University. Chad Mourning is an Assistant Professor of Computer Science at Ohio University. Chad is a native of Middleport, Ohio and received his Ph.D. from Ohio University in 2015. Chad's main research areas include Computer Graphics & Data Visualization, Modeling & Simulation,

Augmented & Virtual Reality, and Machine Learning with applications in Meteorology. Chad is currently serving as Principal Investigator on the Low Altitude Weather Network project and has other ongoing funded projects by NASA, the Ohio Space Grant Consortium, and the FAA.