基于深度学习的农业计数方法、数据集与应用

Guy Farjon[1] 刘慧君[2] Yael Edan[1]

摘要 物体的数量被认为是农业领域众多任务中的重要因素。自动计数可以帮助农民改进产量估算、胁迫检测、病害防治等方面的决策。近年来，深度学习日益应用于许多农业相关应用中，并为传统计算机视觉算法在农业对象计数方面提供了补充。本文综述了过去十年农业计数方法的进展与最新技术水平，重点关注深度学习方法。文章概述了计数算法、指标、平台和传感器，列出了所有公开数据集，并深入讨论了用于计数的各种深度学习方法。最后，本文讨论了利用深度学习进行目标计数所面临的开放性挑战，并展望计数研究的新方向与未来前景。综述显示，在过去十年中，随着深度学习方法逐渐应用于计数平台，农业目标计数取得了重大飞跃。

Key词语： 精准农业、视觉计数、卷积神经网络、深度学习 g

✉ guyfar@post.bgu.ac.il

[1] 以色列贝尔谢巴内盖夫本-古里安大学工业工程与管理系[2] 中国杭州中国计量大学计量技术与工程学院

引言

全球人口快速增长，因此必须大幅提高粮食产量，同时合理利用现有资源，以保持较高的营养质量和生产效率（Kamilaris，2018年）。未来的发展方向在于精准农业，即运用先进技术，包括传感器（如 RGB-Depth（RGB-D）相机、多光谱和高光谱传感器）、平台（如机器人和无人机（UAV））、先进信息系统（如物联网（IOT）和地理信息系统（GIS））、算法，以及工作方法（如数据驱动型管理软件、大数据分析和多种信息源的融合）。精准农业还包括优化现有资源，以提高生产力、盈利能力、质量和可持续性，减少农业活动造成的负面影响，并保障营养供给（Gebbers，2010）。在精准农业中，计数能够提供宝贵信息，包括时间、空间和个体数据。例如，统计植物叶片、水果和花朵的数量，甚至统计植物或树木本身的数量，都有助于农户系统地监测生长情况、预测产量和植物健康状况，从而更好地依据数据制定针对局部区域的农业处理措施。这有助于通过改进种植和管理实践来提升产品质量和产量，并支持优化收获时机的决策，以及快速、精准地进行疾病和胁迫检测。在植物育种中，对叶片、水果或花朵等目标进行计数，可为自动评估特定杂交组合或栽培品种提供有价值的工具。在精准畜牧管理中，计数使农户能够准确掌握动物的生活条件，并据此改善动物健康和福利，进而提升质量、产量和盈利能力（Ruiz-Garcia，2009年）。

传统上，计数通常通过人工完成，有时还需要农业专家参与。这一过程容易出错，而且速度较慢、十分繁琐，需要耗费大量时间才能获得足够的数据，所有这些因素共同导致结果精确率较低且人工成本较高（Maheswari，2021）。此外，当某项应用要求专家在田间作业时，专家可能难以在较短时间内满足对准确信息的需求。例如，苹果园化学疏果的过程需要专家参与，而专家只有几天时间（即花期）来估计开花强度（Farjon，2019）。因此，人工计数可能成为阻碍农民作出知情、数据驱动决策的障碍。

通过使用基于人工智能（AI）的系统，可以减少对人工计数的依赖。这类系统包括使用配备传感器和先进机器学习（ML）算法的自主平台来自动收集数据。机器学习（ML）是人工智能（AI）的一个子领域，其中使用经过良好标注的数据集来训练一组用于特定任务的算法。机器学习算法经过训练，可以在训练数据集中发现模式。为解决某项任务，算法需要一个标注数据集、一个成本函数（算法据此获得关于其成功或失败的反馈）以及一个测量指标。获得训练好的模型后，便可将其应用于真实世界数据，从而减少对人工计数的需求。

为特定应用开发计数模块时，常见的数据输入是通过不同传感器采集的图像数据，例如 RGB 或 RGB-D 相机、红外传感器，或多光谱、 高光谱传感器。由于这些传感器提供的数据类型各不相同，因此需要针对不同数据开发不同的专用算法。处理这项任务主要有两种方法。第一种方法是从图像中提取特征。这些特征需要预先定义，可包括目标对象的纹理、形状、颜色和尺寸，以及图像处理统计量，例如基于颜色的特征或形态学特征（Harel, 2020b）。随后根据这些特征检测物体，再进行计数。通常会采用传统机器学习算法，例如 K均值聚类、随机森林（RF）和支持向量机（SVM）算法；大量论文介绍了如何使用这些方法实现农业应用中的自动计数（Albuquerque, 2019; Alharbi, 2018; Bao, 2022; Gutiérrez, 2019; Kim, 2018; Syazwani, 2022; Zhang, 2020）。例如，研究人员采用计算机视觉流程实现了鱼苗的自动计数，该流程包括使用高斯混合模型（MoG）算法对图像进行二值化（Zivkovic, 2006），以及利用斑点检测算法根据预先调优的参数（如照明和鱼的形状）识别几何特征（Albuquerque, 2019）。另一个例子是，利用配备 RGB

相机的无人机拍摄的俯视图像，基于包含 RGB 信息特征提取阶段的算法，并结合形状和纹理等几何特征，识别并计数菠萝冠（Syazwani, 2022）。提取的特征通过采用单因素方差分析（ANOVA）的特征选择滤波器进行筛选；选定特征后，使用不同的机器学习算法 [例如人工神经网络（ANN）、随机森林（RF）、支持向量机（SVM）、XGBoost、LightGBM、广义混合模型（GMM）等]，将每个物体分类为菠萝或假阳性样本。最终的计数估计值是处理流程分类阶段确定的检测到的物体数量。另一个例子是，研究人员根据颜色信息对图像进行二值化，并将生成的二值特征图像输入基于 AlexNet（Krizhevsky, 2012）的分类模型，将苹果簇分为 7 类；该方法假设每个簇含有 0 至 6 个苹果（Häni, 2018）。最后，研究人员采用形态学方法和聚类算法，对石榴树三维图像中的石榴果实进行计数（Zhang, 2021）。

在上述所有研究中，与机器学习算法相关的主要问题是泛化能力较差（Yamamoto, 2014; Farjon, 2019; Linker, 2017），即无法在其他数据集上使用所提出算法的相同设置。数据集变异性是农业领域固有的现象（Kurster, 2018），可能由多种因素造成，尤其包括：完全不同的对象类型（水果和牲畜）、同一对象的不同版本（青苹果和红苹果；形状、颜色和尺寸各不相同的辣椒品种）、光照变化、不同的传感器、果园与受控环境之间的差异，甚至是在特定年份中生长条件相同的情况下也会发生变化。本综述将详细讨论这些挑战及其应对方案。

第二种方法是将算法直接应用于图像。这种方法基于深度学习（DL）算法，而深度学习是机器学习的子领域。深度学习是一种学习方法，利用分层结构的多层提取有用的表征。深度学习领域的绝大多数研究都将神经网络用作计算组件；涉及图像数据时，通常使用卷积神经网络（CNN）。过去五年中，机器学习算法取得了巨大进展，推动精准农业领域涌现出大量研究，而该领域也因此实现了跨越式发展，这主要得益于不断改进并得到广泛应用的深度学习算法和计算机视觉技术。广泛应用深度学习进行计数的农业应用包括作物监测与生长分析、作物病害检测、牲畜监测（Tian, 2019; Xu, 2020）、昆虫检测（Zhong, 2018）、用于化学疏花疏果的花朵密度估计（Farjon, 2019）、产量估算（Linker, 2017; Xiong, 2019）等。

本文对过去十年开展的计数研究进行了批判性综述，重点关注不同的物体、应用、传感器、平台、算法和环境，以及这些场景的变化。我们探讨了农业应用中目标计数的不同方法，并介绍了最先进的方法，展示了深度学习计数器在不同应用中的部署情况，同时展望了基于深度学习的农业计数方法的未来发展。

文献综述：方法与结果

方法

本综述针对农业计数方法、数据集和应用领域的科学出版物，采用基于（Brereton，2007年）的五步文献计量分析方法开展。五个步骤包括：（a）选择要检索的数据库；（b）确定检索标准（关键词、时间范围等）；（c）对论文进行初步筛选；（d）选出最终论文进行深入阅读；以及（e）分析并讨论结果。下文将进一步详细介绍这一过程。

数据库选择 —— 本综述使用两个数据库开展检索——**科学网（WoS）**（包括 IEEE Xplore、ACM数字图书馆、MDPI、Springer、Elsevier、SAGE、John Wiley、Taylor and Francis、ScienceDirect 和谷歌学术）以及 **Scopus**。

检索标准 - 检索范围涵盖农业领域的任何论文，但特别关注包含计数模块的论文。所使用的检索词为“计数”和“agri*”，其中星号用于检索“农业”一词的所有可能派生词，例如“农业的”，

“农业从业者”等。检索范围限定为2022年1月1日至6月30日期间的同行评审论文，[1]且仅限以英语撰写的论文

粗略筛选 - 初步检索共找到2290篇论文，其中Scopus收录162篇，Web of Science收录2128篇，包括期刊文章、会议论文和综述。初步筛选时，我们仔细阅读了论文的标题和摘要，以确保其相关性。此过程将论文数量缩减至282篇。

最终筛选 - 为确保每篇论文都与主题相关，即论文确实使用机器学习算法解决农业中的计数问题，我们仔细阅读了全文。最终选出243篇同行评审论文，其中包括22篇综述和221篇期刊文章。

分析与讨论 - 为追踪农业计数任务自动化方法的发展，我们展示了历年来发表的论文数量，并按物体类型、传感器、算法方法、应用领域、平台、环境和场景变化进行分类。

文献综述结果

结果分为综述论文和应用论文。结果表明，多年来，农业领域中使用计数模块的论文数量不断增加（图 1）。

综述论文的结果 – 文献检索共发现 22 篇综述论文，涉及以下主题：水果产量估算、害虫监测、动物与作物监测以及表型分析。其中只有五篇综述采用了系统性文献研究方法。过去一年，综述论文的数量翻了一番（其中 8 篇于 2021年开展），主要聚焦于农业领域的一般机器学习、计算机视觉和图像处理算法在农业中的应用，以及深度学习在各种任务中的应用。这 22 篇综述均未针对农业领域的目标计数问题，但涵盖了以下主题：

- 使用无人机系统进行牛群监测的进展与局限（Barbedo，2018年）；
- 基于机器学习的方法：利用遥感图像检测和计数动物（Hollings，2018年）；
- 水果计数的应用（Mavridou，2019），但未对计数方法进行任何泛化；
- 使用机器学习算法预测作物产量，尤其关注棕榈油产量预测，并设有一节介绍油棕树计数（Rashid, 2021）；
- 用于水果计数的水果检测与定位深度学习模型（Koirala, 2019）；
- 深度学习在农业密集场景分析中的应用（Zhang, 2020）；
- 基于深度学习语义分割的水果产量估算（Maheswari, 2021）；
- 果园中水果产量预测与估算的直接和间接方法（He, 2022）。

上述论文以及其他论文（Anderson, 2021；Chen, 2019；Darwin, 2021；Dhaka, 2021；Hassler, 2019；Jayasinghe, 2021；Oghaz, 2019；Palacios, 2020；Saleem, 2021；Santos, 2019）都提到了在农业中使用机器学习和/或深度学习进行目标计数的重要性。然而，这些论文均未对计数方法进行概述或分析。从这些论文中可以得出的主要见解是，机器学习目前是应用最广泛的方法，而且应特别重视解决计数误差。通过综述这些论文还可以得出另一项重要结论：仅靠深度学习

[1] 结果涵盖过去十年；由于分析基于截至2022年6月已发表论文的数量，因此2022年的数据为外推值，后续将随着更多论文获准出版而更新。

无法在杂乱环境中准确获得计数结果，因为目标不可见且存在遮挡，因此应将深度学习与其他方法相结合。

应用论文的结果—— 对选出的 221 篇 论文进行了以下分析：主要应用领域、论文数量的年度增长、目标对象、数据采集技术、平台和传感器，以及所采用的方法和算法，具体讨论如下，并见图2。

- **目标对象 -** 过去 5–6 年中，包含计数模块的论文数量急剧增加。早期论文研究的计数方法主要针对五种不同类型的对象：水果、花朵、树木、昆虫和谷物。研究对象的类别和类型也在不断增加；迄今为止，我们已发现 9 个主要目标对象类别，即牲畜、叶片、蔬菜、农作物，以及上述五类对象（图2A）。

- **传感器** - 在精准农业中，人们使用不同的传感器采集图像信息，以对物体进行计数（图2B）。这些传感器包括激光探测与测距（LiDAR）传感器，以及不同类型的相机：单色相机、彩色相机、RGB相机（包括手机相机）、RGB-D相机、多光谱/高光谱相机和热成像相机。在若干研究中，研究人员结合使用多种传感器，以更好地分析目标对象的性状。十多年来，大多数论文使用 RGB相机（82.93%），这可能主要是由于其价格低廉，以及手机相机应用的增加。尽管如此，人们对这一领域的关注有所增加，使用其他类型传感器的论文数量虽少，但正在增长。这种日益浓厚的兴趣表明，该方向的未来研究已有坚实基础。

- **算法方法 -** 在机器学习和深度学习应用于农业领域之前，目标计数主要通过形态学操作从图像中提取基本特征来完成，例如尺寸、形状、颜色、纹理等。目前，图像中目标计数主要有三种算法方法：i）基于形态学操作的传统图像处理方法；ii）使用从图像中提取的特征的机器学习算法；以及 iii）直接应用于输入图像的深度学习方法。如图2C所示，过去几年中，基于深度学习的方法已占据主导地位，这可能是因为其实现相对简单且性能表现出色。

- **应用领域 -** 论文中与数量相关的应用领域可分为五类（图2D）：产量估算（51%）、表型分析（28%）、牲畜监测（11%）、昆虫监测（7%）和其他（3%）。“其他”类别包括与果园田间管理相关的应用，例如修剪（Santoro，2013年；Westling，2021年）、路径规划（Mokrane，2019）、植物水分状况（Bruscolini，2021）、监测果实成熟度（Tenorio，2021）以及监测资源（Vermote，2020；AlMaazmi，2018年）。

- **平台 -** 我们还考察了这些论文多年来使用不同平台的情况（图 2E）。数据采集的主要方式是手动采集（即使用三脚架或手动拍摄图像），但近年来，自动数据采集（使用机器人或无人机）的应用有所增加，从而实现了大规模数据采集。自动数据采集带来了额外的挑战，正如我们将在下文的挑战部分中讨论的那样。

- **环境条件变化 -** 研究逐渐从单一品种、单一时间和单一地点，发展到多品种、多年份和多个生产区域，并涵盖处于不同生长阶段的作物（图 2F）。这一重要演变使该领域近期的方法在不同条件下更加稳健且具有更好的泛化能力。在挑战部分中，我们将进一步讨论开发能够应对环境条件变化的方法和算法的重要性。

- **环境 -** 水果计数、谷物产量估算和动物监测等应用主要在室外环境中开展，基本上是在田间或野外完全开放的环境中，也就是自然条件下。只有少数研究在室内环境或实验室中开展，且全部聚焦于作物表型分析。

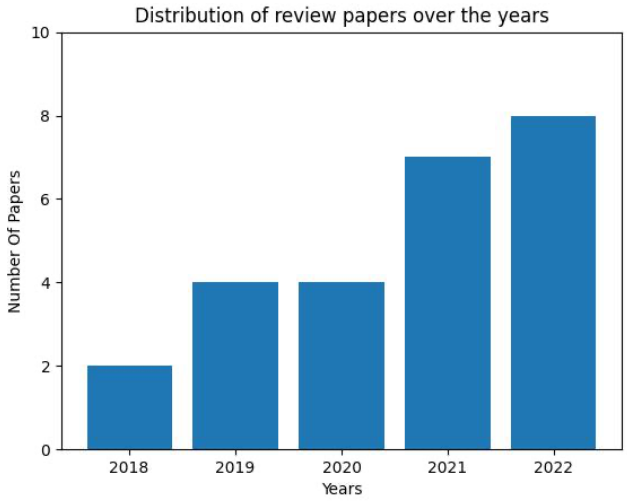

图. 1 基于深度学习的农业计数相关综述论文分布。2022年的数据根据前六个月的数据外推得出。2012年到2017年间没有综述论文。

文献综述结果总结

文献检索结果显示，人们对农业环境中的目标计数日益关注，包含计数模块的论文数量也在急剧增加。这一增长可能归因于数据采集技术（传感器和平台）的“成熟”，以及机器学习架构和框架带来的优势。从总体上看，数据采集越容易（例如使用无人机或机器人），包含深度学习模块的论文数量也越多。从传感器的角度来看，文献检索显示，使用先进传感器（如高光谱／深度相机）进行目标计数的论文寥寥无几。因此，我们认为研究人员和从业者在利用先进传感器开发深度学习架构方面拥有很大的机会。

深度学习计数方法

本节介绍了不同的深度学习计数方法，并详细说明各方法，同时介绍数据采集和标注负担。我们还综述了与每种方法相关的若干论文。

直接计数

使用卷积神经网络直接统计图像中物体数量有两种方法。使用分类器时，需要一定的领域知识来确定分类类别的数量上限。例如，Häni 等人（2020）使用 Resnet50 分类器，对包含苹果簇的图像块中的苹果进行计数。由于苹果簇最多包含六个苹果，作者将该问题定义为 7 类分类问题，其中包括图像块中没有苹果的情况。该论文首先应用分割器提取感兴趣区域（ROIs），然后使用 7 类分类器预测感兴趣区域中的苹果数量。

一种更稳健的方法是使用深度回归器，其类别数量不受限制。深度回归器是一种深度卷积神经网络（通常最初是为分类问题设计的），配有回归头（而非常规的分类头）。在这种方法中，输入一组图像及每张图像中的物体数量，$[I_j, y_j]_{j=1}^{N}$。深度回归器仅以物体数量作为监督信号，这简化了已标注数据集的收集。不过，模型究竟学会了识别什么尚不明确，这可能是这种深度网络方法较少被采用的原因。

ResNet50主干网络（He，2016）也被用于对叶片计数挑战赛（LCC）公开数据集（Dobrescu，2017）中的叶片进行计数。2017年LCC的最终成果是一种当时最先进的叶片计数器，其开发过程如下。该挑战赛表明，使用数量有限的图像训练的简单直接回归器能够学会计数。该直接回归器在所报告的指标——计数绝对差（$|DiC|$）——上取得了0.91的结果，该指标与平均绝对误差（MAE）相似。基于这一策略，研究人员开发了一种更复杂的处理流程，采用直接回归器（Farjon，2021）。此前，研究人员已基于RetinaNet（Lin，2017）架构构建了多尺度回归（MSR）处理流程，并对损失函数作了重要改进。研究人员应用了Kendall与Gal（2017）提出的不确定性损失函数，以学习如何基于特征金字塔网络（FPN）的输出，在多尺度上对叶片进行计数[）]。结果通过最大似然估计（MLE）函数进行融合。在同一LCC数据集上的结果得分为0.83（$|DiC|$），由此提出了一种当时最先进的叶片计数方法。

由于难以全面理解上述模型的结果，Dobrescu（2019）开始分析这些深度回归器所得的结果。为完成这项任务，他们使用 VGG-16 网络（Simonyan，2014）作为回归器，并通过逐层相关性传播（LRP）（Bach，2015）和引导式反向传播（GBP）（Springenberg，2014），将图像中与最终数量相关的区域可视化。他们的方法是在网络中输入训练集中的图像，并在这些图像上放置不同尺寸的“黑色方块”，以模拟叶片遮挡。分析结果表明，回归器的中间层关注植物的边缘，而顶层（全连接层）中最活跃的神经元则关注图像中的不同区域。因此，结果显示，训练后的模型并未存储图像中的叶片数量信息，而是在计数叶片时关注叶片边缘。

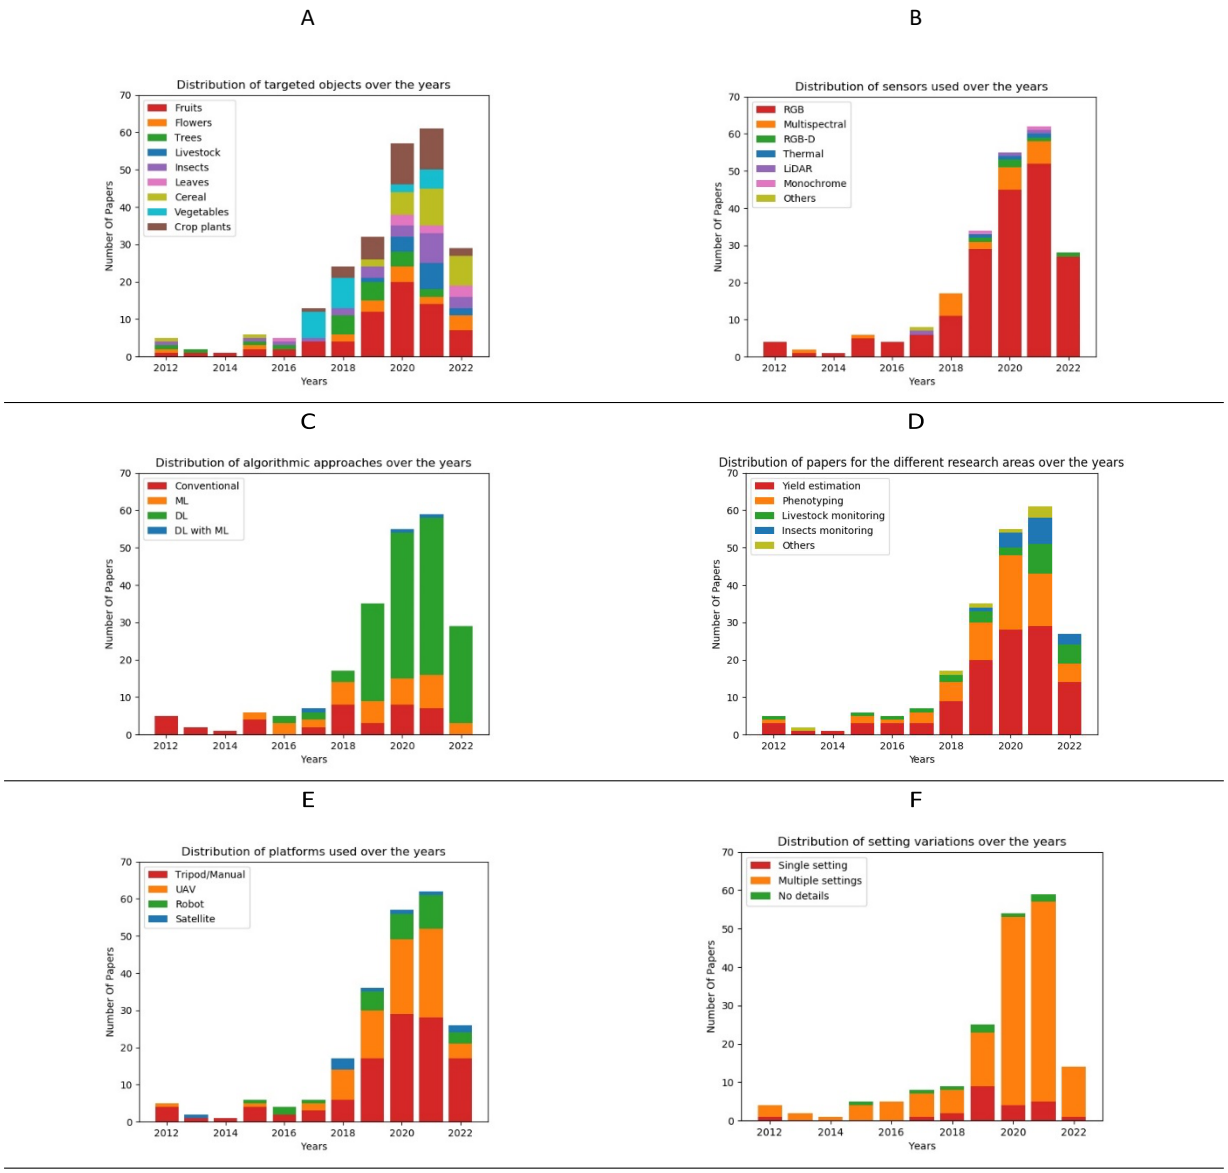

图2. 文献综述结果。2022年数据仅涵盖前六个月。A - 各年份目标对象的分布，其中两大对象类别为水果和蔬菜。B - 各年份所用传感器的分布。C - 各年份算法方法的分布。D - 各年份不同研究领域论文的分布。E - 各年份所用平台的分布。F - 各年份场景变化的分布，比较单一变体与多重变体。

近期有研究展示了一种弱监督方法，仅使用图像级计数标注来计数苹果果实和花朵（Bhattarai, 2022）。该研究提出了一种名为 *CountNet* 的基于回归的网络，用于室外环境中的花朵和水果计数。该网络无需显式检测和定位，仅凭感兴趣对象的少量特征信息进行学习。研究人员对图像激活区域和特征进行可视化，旨在展示其可解释性工具。

基于检测和基于分割的计数器

基于目标检测器的计数器将目标检测器用作计数模块。这种方法很自然，因为该算法旨在检测图像中的目标对象。随后对这些检测到的物体进行计数，其数量即为最终的估计计数。目标检测任务包括

确定图像中存在特定物体的位置，并将其分类为特定的目标类别。在训练阶段，目标检测器接收集合$[I_j, B_j]_{j=1}^{N}$，其中I表示图像集合，而B_j表示每张图像中包围各个物体的边界框集合i。B的尺寸可能因图像而异。每个$[b_k \in B_j]_{k=1}^{|B_j|}$包含四个描述边界框尺寸的参数，以及一个表示物体类别的附加数值。在测试时，模型会输出一组检测假设D，其中每个候选边界框都包含目标对象，并附有一个置信度分数，表示该边界框中包含物体的置信程度（对于多类别检测，网络还会预测具体类别）；更多说明请参见指标部分。在基于目标检测的方法中，标注负担相对较重，因为标注本身较为困难（相较于基于回归的计数器所需的物体数量标注而言），而且应对农业领域带来的挑战时，标注负担会更加沉重。如图3所示，图像中的物体在尺寸和颜色上存在差异，且许多物体被遮挡或模糊不清。挑战部分将详细讨论这些差异。

基于分割的计数器将目标分割模块作为计数模块。在这种方法中，物体不仅会在计数前被检测出来，还会被分割。为了减少误报并改善计数器的结果，可以在计数前对分割出的物体进行进一步处理。目标分割任务包括确定图像中存在特定物体的位置，将其分类到相应的目标类别，并分割每个物体的特定区域。近年来，基于深度学习的目标检测器在多个公共数据集上取得了出色的结果，这些数据集并非专门针对农业，例如 Pascal-VOC (Everingham, 2010)、MS-COCO (Lin, 2014) 等。由于表现出色且可在开源代码库中获取，目标检测器已成为农业目标计数中最常用的计数模块。如下文示例所示，该模块大多直接使用，不作任何改进或更改。

研究人员针对检测和计数诱捕器中捕获的松干蚧 昆虫这一任务，对 Faster-RCNN (Ren 2015)、SSD (Liu, 2016)、MobileNet (Howard, 2017)、RetinaNet (Lin, 2017) 和 Efficient-Det (Tan, 2020) (D_0 和 D_4) 目标检测器进行了比较研究 (Hong, 2021)。与图像分辨率 (6000×4000) 相比，这些昆虫的尺寸相对较小（60×60 边界框），而小物体很难检测，因为目标检测器通常会将图像缩小到更低的分辨率（在上述网络中最高可缩小至 1024×1024 ）。通常通过将图像裁剪成 K 子图像来解决这一难题，Hong 等人 (2021) 就采用了这种做法。Farjon (2019) 也采用了这一解决方案：作者首先使用 Faster-RCNN (Ren, 2015) 检测苹果花，然后对其计数，以估算花期内的开花强度，最后估算盛花日。Mosley 等人 (2020) 对无人机拍摄的 RGB 图像中的高粱穗进行了计数，并通过为 Yolov3 (Redmon, 2018) 架构调整锚框，取得了良好的结果。由于 COCO数据集与高粱穗数据集中的物体尺寸不同，因此必须对锚框进行调整；具体而言，新增了一个 10×10 锚框，用于捕捉较小的高粱穗。

训练了一个 Mask-RCNN 模型，用于分割簇中的蓝莓，以预测产量（Ni，2020）。该模型检测了四种不同的蓝莓品种（'Emerald'、'Farthing'、'Meadowlark' 和 'Star'），并将其分类为成熟或未成熟。如"挑战部分"所示，使用多个栽培品种对于提升泛化能力十分重要。为了衡量模型正确检测蓝莓的能力，研究人员拟合了一个线性回归模型，分析人工计数结果与簇中预测的浆果数量之间的关系。

研究采用两步处理流程来检测和计数小麦穗（Sadeghi-Tehran，2019）。首先，使用简单线性迭代聚类（SLIC）提取小麦穗候选区域，以降低输入卷积神经网络（CNN）的复杂度，即减少像素数量。第二步使用卷积神经网络架构区分不同的簇，也就是对小麦穗进行计数。Palacios（2020）采用两步算法量化葡萄花的数量，并探究估算的花朵数量与每株葡萄藤实际产量之间的相关性。研究使用移动传感平台，在田间条件下采集数据。首先，使用两个 SegNet 语义分割框架提取葡萄花掩膜。然后，根据分割掩膜，使用线性回归模型估算花朵数量。

为更准确地界定高粱穗边界，Malambo 等人（2019）开发了一种基于田间的方法，利用 SegNet 进行监督式语义分割，以根据无人机系统图像统计穗的数量。

在后处理中，使用形态学操作去除小物体，并将粘连的穗分开，以便逐个计数。由于 SegNet 编码器中的下采样，边缘效果较差（U-Net 网络中也存在这一问题）。图像分辨率以及无人机图像的镶嵌也会影响分割，但对计数问题的影响不那么显著。

为实现更高程度的自动化，一些研究人员会从田间采集视频数据。其思路是，不再由人员使用相机，而是通过无人机采集数据。例如，研究人员曾使用葡萄园视频来检测、分割和跟踪葡萄簇（Santos, 2020）。研究中采用 Mask R-CNN 检测单个葡萄簇，并使用运动恢复结构（SfM）进行实例匹配和跟踪。在另一项研究中，研究人员使用 RetinaNet（Lin, 2017）对视频中的开心果进行计数（Rahimzadeh, 2022）。该研究中，相机固定不动，物体则在传送带上移动，因此可以分析多张图像。新物体进入帧时，算法会在连续图像中匹配“旧”的开心果，同时识别新出现的开心果。主要任务是统计开口和闭口开心果的数量，因此还使用了一个额外的分类器函数。由于开心果在传送带上翻转和旋转，导致检测算法在不同帧中将同一物体分类到不同类别，因此需要这一额外步骤。该方法能够跟踪检测到的物体，进而统计开口和闭口开心果的总数。另一项研究（Anderson, 2021）估算了2019-2020年从37个果园以及2020-2021年从19个果园采收的水果的果实负载。研究人员采集了不同树龄、不同栽培品种以及不同果园布局的树木数据，并使用 MangoYolo 检测器（Koirala, 2019）检测所采集视频每一帧中的水果。为跟踪不同帧中的水果，研究采用了卡尔曼滤波法。

上述方法均使用 RGB 图像作为输入数据。然而，它们并不总能有效应对特定挑战；在这种情况下，研究人员尝试向目标检测器/分割器引入额外信息，以改善结果。例如，使用 RGB-D 相机或多光谱传感器，将信息加入学习过程，或从图像中提取额外特征。由于多光谱相机能够捕获额外信息，因此可用于作物成熟度评估和精细分割、疾病检测以及生长状况估计。例如，有研究开发了一种用于对不同成熟度的樱桃番茄进行计数的方法：先使用 Fast R-CNN 检测由 RGB 相机采集的图像中的目标，再应用 DeepSort 算法进行多目标跟踪，以避免重复计数（Chen，2020）。通过对齐 RGB 图像与近红外反射率图像（由多光谱相机采集），并使用支持向量机分类器为每个番茄计算作为成熟度指标的归一化差异植被指数（NDVI），从而能够按成熟度对番茄进行计数。另一个例子是使用深度学习，根据无人机多光谱图像估算高密度果园中的柑橘树数量（Osco，2020）。在这类高密度种植园中，单株植物的边界不够清晰，难以将树木彼此分开；随着植物尺寸减小，检测性能也会下降。研究人员开发了密集置信度图，用于表示每个像素存在植物的概率，以此估算柑橘树的数量及其地理位置，而非采用以矩形表示树木的目标检测方法。Afonso 等（2020）使用 Mask R-CNN，在夜间对温室中的番茄进行深度学习实例检测与分割。他们利用深度通道对结果进行后处理，剔除背景中的假阳性。这一过程提高了精确率，但降低了召回率；这可能是由于深度图像中的深度值精度较低，导致部分前景果实被排除。

研究人员开发了一种端到端流程，用于检测和计数 RGB-D 图像中的百香果（Tu，2020）。这些图像是在自然户外环境中采集的，这对于泛化能力至关重要。由于百香果相对较小，因此提出了一种多尺度快速区域卷积神经网络（MS-FRCNN）方法，将低层的特征图与 ROI 池化后的特征图相结合。该方法以 ResNet 替换 Faster R-CNN 的特征提取网络，并结合自顶向下连接。此过程生成了三个尺度的多尺度特征图（分别对应 conv3、conv4 和 conv5 卷积块），并使用 RGB-D 相机采集的 RGB 图像和深度图像进行训练。与用于 RGB-D 图像的 Faster R-CNN 检测器相比，MS-FRCNN 方法的召回率、精确率和 F1 分数[2]分别从 0.922 提高到 0.962、从 0.850 提高到 0.931，以及从 0.885 提高到 0.946；对于此类体积较小且被遮挡的水果而言，这是显著的提升。这

[2] 召回率、精确率和F1分数的定义见指标部分。

融合通道网络的 F1分数为 0.946，比仅使用 RGB 和仅使用深度的检测器高出最多 10%。

A



B



图3 农业领域目标检测面临的挑战。(A) 温室中的黄瓜果实；物体尺寸各异，且存在大量遮挡。(B) 温室中的番茄果实；物体的尺寸和颜色各异，第二、三排的物体尺寸较小且模糊。

基于密度估计的计数

使用密度估计组件进行目标计数被视为一项回归任务，网络通过预测图像的热力图表示来估算物体数量，再据此回归出物体数量。训练期间，向网络输入一组 $[I_j,P_j]_{j=1}^{N}$，其中 I 表示一组图像，P 表示一组人工标注的点，用于标记目标对象的中心，也就是说，每个 $[p_k \in P_j]\ ]_{k=1}^{P_j}$ 包含两个参数，用于表示图像中的一个像素。网络通过预定义热力图进行引导，该热力图由 P 中的点生成（例如，Farjon 等（2019）在每个中心点上放置一个二维高斯函数，并训练网络预测这些高斯热力图）。基于密度估计的计数所需的标注负担相对较低，因为标注人员只需在物体中心放置一个点即可。不过，必须将中心点标注放在物体的质心处，而质心并非总是容易估算，尤其是在物体部分被遮挡或形状不规则时。

根据我们综述的论文，上述方法不像基于检测或分割的计数器那样常见，但直观且易于使用。由于目标计数任务不要求模型区分不同实例，因此基于密度估计回归物体数量能够取得最先进的结果，以下示例便是证明。

Tian 等（2019）认为，由于透视畸变程度不同、姿态各异且存在遮挡，直接根据检测结果回归物体（此处为猪）的数量不够准确，而密度图包含更丰富的空间分布信息。因此，他们使用改进的计数卷积神经网络模型，学习从图像特征到密度图的映射，再对密度图进行积分，从而获得真实养猪场中整幅图像内的猪的总数。

另一个例子是使用一种基于定位的计数算法（即点监督方法）LC-DenseFCN 对鸡进行计数（Cao, 2021）。由于家禽养殖场中的鸡密度很高，目标检测和分割并不适用于图像中的鸡计数。与其他基于目标检测的计数方法不同，LC-DenseFCN 方法在鸡计数方面效率更高，因为它无需定义完整目标特征，尤其是在多只鸡相互重叠时。与基于语义分割或实例分割的计数方法相比，该方法的架构更简单，也降低了标注成本。

Farjon 等（2021）提出了检测回归网络（DRN）架构；该架构同样基于 RetinaNet（Lin, 2017）架构构建（与上文直接回归部分提到的 MSR 类似），

但有三点不同：i）不使用所有金字塔层级，而只使用最大分辨率（C_3输出）；ii）将回归子网络替换为基于检测的子网络（用于检测中心点标注）；iii）将损失函数替换为双项损失函数，其中一项用于密度估计，另一项用于回归最终估计值。作者在 LCC数据集上取得了当前最先进的结果，表现优于其他图像级监督网络。

Dijkstra等人（2018年）提出了一种基于U-Net架构的全卷积神经网络（FCNN），称为CentroidNet，用于从无人机图像中进行作物定位和计数。该网络生成的输出与输入具有相同的高度和宽度，并包含$C+2$ 个输出通道（其中C是类别数量）。另外两个输出图分别表示可能包含质心的像素坐标。将这些坐标汇总后，即可生成投票图。该图中的数值越高，表示该像素包含质心的可能性越大。其余通道则保存logit图，类似于语义分割的输出，即每个像素表示其属于$c_i \in C$类的概率。随后生成分割图像作为输出，其中包含植物的中心。结果表明，使用训练得到的分割掩膜能够抑制误检，尤其是在无人机拍摄的低质量图像中。

Wu等人（2019）提出了一种利用两个FCNN对RGB无人机影像中的水稻幼苗进行原位计数的方法。第一个网络用于训练，以分割每幅图像中的水稻幼苗区域和非水稻幼苗区域；第二个网络则用于估计水稻幼苗的分布并生成密度图，与“基于密度估计的计数”一节介绍的其他方法类似。此外，也有研究提出了应用不同密度估计网络变体的其他实例（Gomez，2021；Hobbs，2020；Rahnemoonfar，2019；Xiong，2019）。

特定应用方法

本节介绍采用多个组件或使用定制网络来解决计数任务的研究。这些研究通常尝试创建一种基于数据采集平台、架构和分析的端到端解决方案。这些方法通常针对特定场景，未必能够充分泛化。例如，Bellocchio等人（2019）提出了WS-COUNT网络，该网络仅通过二元监督（即物体存在或不存在）来统计图像中的物体数量。该网络通过学习“目标性”这一概念来统计一般物体，并根据物体是否存在来预测物体数量。WS-COUNT网络采用了多个组件：i）监督回归器（S-COUNT）；ii）存在缺失分类器（PAC）；以及iii）多分支计数卷积神经网络（MBC-CNN）。S-COUNT单独训练，后续步骤中不会对其进行微调。PAC网络是一个简单的分类器，使用上述二元监督进行训练。MBC-CNN利用图像的多个尺度，在不同分辨率下统计物体。最终数量通过融合所有组件的信息进行估计。WS-COUNT是一种新颖的弱监督策略，无需任务特定监督标签即可学会计数。其对橄榄、杏仁和苹果的计数结果与全监督基线方法相当。尽管该方法无法很好地区分被遮挡的果实，尤其是在果实密集成簇时，但它为新的水果计数方法提供了新思路。

继 Bellocchio, 2019 的研究之后，鉴于针对每种物体学习一个新的专用模型成本高昂且不切实际（遵循监督范式），研究者提出了一种弱监督迁移学习模型，用于计数训练集中未包含的水果（Bellocchio, 2020）。与上述方法（Beelocchio, 2019）类似，该模型采用存在-缺失分类器（PAC），并使用循环生成对抗网络（C-GAN）将源果园（即一个标注数据集）的图像转换为目标果园的图像，而目标果园没有可用标签。C-GAN 模型经过训练，可将物体在源果园中的外观转换为其在目标果园中的外观，从而使模型能够计数未见类别中的物体。训练后的 PAC 为计数模块生成弱监督信号，随后即可将该模块直接用于目标果园。

在 Nellithimaru 等人（2019 年）的研究中，安装在机器人上的双目相机被用于对葡萄园中的葡萄进行计数。该架构包含三个步骤：首先，将图像输入 MASK-RCNN 网络，为每幅图像生成分割掩膜（以及初步的计数估计）；其次，利用生成的掩膜构建场景的三维重建

，随后使用奇异值分解（SVD）算法生成第二次计数估计；第三，为检测到的每个图形拟合圆形，随后使用 同步定位与建图（SLAM）算法生成最终的计数估计。这些步骤提高了计数结果的准确率，并提升了推理速度。

数据集和评估指标

公共数据集

农业领域面临的主要挑战之一是缺乏经过充分标注的数据集。在表格1 中，列出了根据上述对 243 篇论文进行的深入文献综述汇编而成的公开数据集；表格展示了数据类型和所采用的方法（检测/分割），并附有数据集链接。

评估指标

下文将讨论用于评估计数器性能或计数流程中其他相关组件性能的相关指标。如上所述，物体计数可用于各种应用，但每种应用都需要特定的指标，以最大限度地提升整个处理流程的效果。

计数指标 - 为评估计数器的性能，将对每个样本 i, $e_i = y_i - \hat{y_i}$ 中预测值（$\hat{y}$）与真实数量（y）之间的偏差进行测量。 利用这一误差，通过汇总所有样本的误差来评估整体性能。

用于评估整体性能的标准且广泛使用的指标是平均绝对误差（MAE）和均方误差（MSE）：

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|e_i| \tag{1}$$

$$MSE = \frac{1}{N}\sum_{i=1}^{N} e_i^2 \tag{2}$$

在某些情况下，研究人员会使用均方根平均绝对误差（RMAE）或均方根误差（RMSE），它们分别等同于 MAE 或 MSE。另外两个常用指标是相对均方根误差（rRMSE）和决定系数（R^2）。rRMSE 衡量每个样本相对于物体数量的偏差，而R^2衡量模型预测值与真实值之间关系的强度：

$$rMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\frac{e_i}{y_i}\right)^2} \tag{3}$$

$$R^2 = 1 - \frac{\sum_{i=1}^{N} e_i^2}{\sum_{i=1}^{N}(y_i - \bar{y})^2} \tag{4}$$

表1

从243篇综述论文中收集的公开数据集。文中列出了每个数据集可用的标注，以及数据下载链接。

目标对象	数据类型	数量	中心点	检测	分割
鱼类 [1] (Albuquerque, 2019)	视频	✓	-	-	-
葡萄串 [2] (Santos, 2020)	RGB图像	-	-	✓	✓
苹果花 [3] (Bhattarai, 2022)	RGB图像	✓	-	-	-
苹果 [3] (Bhattarai，2022)	RGB图像	✓	-	-	-
苹果 [4] (Gao, 2020)	RGB图像	-	-	✓	-
苹果 [5] (Häni, 2020)	RGB图像	-	-	✓	✓
芒果 [5] (Häni, 2020)	RGB图像	-	-	✓	-
杏仁 [5] (Häni, 2020)	RGB图像	-	-	✓	-
葡萄串 [6] (Liu, 2020)	RGB图像	✓	-	-	-
猪 [7] (Tian, 2019)	RGB图像	✓	✓	-	-
牛 [8] (Soares, 2021)	RGB图像	-	-	✓	-
油棕 [9] (Tong, 2021)	RGB图像	-	✓	-	-
金合欢 [9] (Tong, 2021)	RGB图像	-	✓	-	-
小麦 [10] (David, 2021)	RGB图像	-	-	✓	-
油萝卜 [11] (Krogh, 2019)	RGB图像	-	-	-	✓
植物幼苗 [12] (Jiang, 2019)	视频 + RGB图像	-	-	✓	-
苹果 [13] (Gené-Mola, 2019)	RGB-DS	-	-	✓	-
芒果 [14] (Kestur, 2019)	RGB图像	-	-	-	✓
苹果 [15] (Gené-Mola, 2020)	RGB图像 + 运动恢复结构	-	-	✓	✓
蔬菜（各种） [16]（Lac, 2022）	RGB图像	-	-	✓	-

[1-16] 数据集的链接见附录 A.

目标检测和分割指标 - 使用检测器和分割器进行计数时，分别评估检测或分割任务的性能以及计数任务的性能非常重要。评估这些组件性能的主要指标有两个，即 1）平均精度均值（mAP）和 2）F1分数。准确率／误差指标并不适用于目标检测任务，因为“负”类（非目标边界框）的数量远多于“正”类。mAP 指标（即召回率-精确率曲线下的面积）是更好的替代方案，因为它考虑了这种类别不平衡：

1. **平均精度均值** – 该指标对于检测和分割任务而言相似。使用目标检测器时，评估以对象为单位；而在分割任务中，评估则按像素进行。本节仅介绍目标检测器的评估。

mAP 指标用于衡量不同预测置信度阈值 t_p下的精确率和召回率。在测试时，检测器会为每幅图像 $i \in I$输出一组检测假设 D。如果检测假设 $d \in D$ 与真实值 GT 之间的交并比（IoU）大于某个阈值 t_{IoU}，则通常将其视为真正例（TP），其中 t_{IoU} =为 0.5 $\left(\frac{d \cap g}{\cup g} t \; dt > t_{IoU}\right)$。

在检测任务中，mAP 用于评估检测器的性能。mAP 是每个对象类别的平均精度（AP）得分的均值。AP 得分是召回率-精确率曲线下的面积，其中召回率是正确预测数量占正样本数量的百分比 [6]，精确率是正确的正预测数量所占的百分比 [5]。

$$Precision = \frac{TP}{TP+FP} \tag{5}$$

$$Recall = \frac{TP}{TP+FN} \tag{6}$$

其中，FN 是假阴性样本，即检测器未能检测到已标注目标时产生的样本；FP 是假阳性样本，即检测器错误地检测到图像中的其他物体，并将其分类为目标时产生的样本。检测假设可能因各种原因产生虚警：d 不包含目标是最简单的情况，但也可能因为边界框中的目标分类错误，或同一目标被多个边界框重复计数而产生虚警。

通过改变置信度阈值（t_p）来评估平均精度均值（mAP）。如“基于检测和基于分割的方法”一节所述，每个检测假设（d）也会获得一个置信度分数。当该分数高于置信度阈值时，d便被判定为一个目标。要输出特定的计数测量结果，必须选择一个能够优化计数结果的阈值。自然应选择不会引入计数偏差的阈值。通常，选择该阈值是为了平衡FP（误检物体）和FN（漏检物体）的数量。然而，这一阈值适用于只需要物体数量、无需后处理的目标应用（如 Vitzrabin 等人（2016b）所述）。在某些情况下，还应考虑其他阈值（例如，在机器人采收中，为了尽量减少虚警、缩短采收时间）。

2. **F1-s核心 –** 该指标概括了检测器在特定置信度阈 d.

$$F_1 = \frac{2 \cdot (Recall \times Precision)}{Recall+Precision} \tag{7}$$

这种方法也自然适用于计数应用，因为计数时选择的置信度阈值将是能获得最高 F1分数的阈值。

密度估计 – 在此，我们介绍用于计数密度估计的指标。我们根据监督方式定义基于密度估计的计数器，即在目标对象中心放置单个点标注（Farjon，2021；Rahnemoonfar，2019）。此方法主要使用两种指标：1）结构相似性度量指数（SSIM）和 2）关键点正确率（PCK）。SSIM 指标用于评估预测输出热图与真实值热图（根据提供的点标注生成，详见“基于密度估计的计数”部分）之间的质量。PCK 用于根据检测到的目标尺寸，评估预测点相对于所提供点标注的定位：

1) SSIM 表示为：

$$\text{SSIM}\,(\hat{y}, y) = \frac{\left(2\mu_y\mu_{\hat{y}}+c_1\right)\left(2\sigma_{y\hat{y}}+c_2\right)}{\left(\mu_y^2+\mu_{\hat{y}}^2+c_1\right)\left(\sigma_y^2+\sigma_{\hat{y}}^2+c_2\right)} \tag{8}$$

其中，y 是真实掩码，$\hat{y}$ 是预测掩码，μ 是掩码的平均值，σ^2 是掩码的方差，而 c_1 和 c_2 是用于稳定除法的两个变量（以防分母变为 0）。

2) 对于 PCK，如果预测点与真实中心标注之间的距离小于 $\alpha*max(w, h)$，则该预测点被视为命中； 其中，(w, h)分别是包围整个目标对象的边界框的宽度和高度，α 是一个超参数，用于控制预测点与真实标注之间的允许距离，以判定是否命中（$0 < \alpha < 1$）。当 α 趋近于 0 时，对预测点位置误差的容忍度较低（Yang，2012年）。

虽然 SSIM 提供图像级分析，但不考虑目标对象的定位，而 PCK 指标还会考虑预测对象中心的定位。请注意，当预测输出图不是密集图时，仍可计算 PCK，这意味着该点是被明确预测出来的（Farjon，2021）。

挑战

通过对本文所综述文献的分析，我们了解了开发新方法时必须应对的挑战。在此，我们提出了推进相关研究、获得更优深度学习解决方案的方法。具体而言，在农业领域使用基于深度学习的计数器时，存在两类挑战。第一类是领域挑战，涉及户外农业环境无结构且动态变化的特性。第二类挑战与硬件方面有关，例如计算设备、多模态约束以及传感器的准确率。

领域挑战

许多与使用基于深度学习的计数器相关的挑战，都与农业和环境条件有关。在真实世界的户外条件（田间或温室）下使用深度计数器，由于环境无结构且高度变化、无法加以控制或建模，因此会产生重大挑战。此外，产品的生物学特性进一步增加了这种变化性。其中一些挑战属于一般性的计算机视觉挑战，只是在农业领域中更加严重；另一些则是由该领域的独特特征直接导致的。下文将对这些不同的挑战进行更详细的讨论。

目标对象变异性- 在农业领域，目标对象具有较高的类内差异。同一对象在生长阶段发生变化时（Harel, 2020a）、从不同视角观察时（同一水果、植物或树木会因视角不同而呈现不同外观）（Hemming, 2014），甚至其单个特征发生变化时（例如颜色）（Ringdahl, 2017; Kurtser, 2018），本身就会表现出很大的差异。例如，杏在生长季初期呈绿色，随着生长，其颜色会变为黄橙色。同样，有些苹果品种（例如 Pink Lady）同时具有红色和黄色的部分；甜椒也可能一侧为红色、另一侧为绿色，因为它们的成熟过程并不同步（Harel, 2020a）。为应对这一变异性挑战，重要的是收集涵盖所有可能变异的数据，并确保训练集、验证集和测试集中都包含来自不同对象群体的数据。农业对象（尤其是水果和花朵）的另一个特点是，相对于环境中的其他物体，它们通常较小（例如，大树上的小水果）。在大多数应用场景中，应结合其所属的植物或树木来计数目标对象。此外，大多数数据集都包含高分辨率图像（例如，3648×5472 见 (Farjon, 2019)），图像会完整捕捉树木及其周围环境，因此目标对象显得十分微小（70×100 见 (Farjon, 2019)）。通常，卷积神经网络的输入尺寸比高分辨率图像小一个数量级。因此，算法的第一步是调整图像尺寸。由此，标注边界框也会随之缩小，变得过小而难以检测。一种简单直接的解决方案是将图像切分成 K 个子图像，并在相邻图块之间设置较小的重叠区域。然而，这种方法可能会导致同一物体在不同图块中被重复计数。因此，重要的是根据图块重建图像，并在原始图像上应用非极大值抑制。Wosner 等人 (2021) 对这一问题进行了深入讨论。

光照变化-许多研究所应对的另一项挑战是光照变化。由于图像是在户外条件下采集的，太阳的位置以及环境天气条件（云、雨）会对所采集的帧产生显著影响。此外，图像中很可能包含会造成阴影的叶片和树枝，而阴影会随着一天中的时间推移而变化，并且会

取决于视角。所有这些因素都会导致不同图像之间，甚至同一图像内部的光照条件存在显著差异（Vermote，2020）。一些物体可能处于阴影中，一些可能受到直射阳光照射，另一些可能较暗，还有一些可能受到眩光影响。为避免漏检，在处理所有农业相关任务，尤其是目标计数时，必须考虑这些问题。一种可行的方法是尝试在不同光照条件下（一天中的不同时间、不同天气条件，即多云与晴朗）采集同一目标对象的样本，并将这些不同样本纳入训练集。这种方法存在两个缺点：i）数据集的采集可能需要很长时间；ii）采集不同条件下的图像并不能保证测试时光照不会发生剧烈变化（即不会以影响推理结果的方式发生变化）。为获得更好的泛化能力，研究人员应在训练阶段利用数据增强和正则化方法，人为引入可选的光照条件。然而，由于光照条件可能变化过于多样，因此有必要制定一套数据收集方案，尽可能将这些条件纳入考虑。光照增强并非易事，因此应谨慎使用，并且只能作为模型训练的辅助过程。

物体遮挡 - 这一挑战存在于许多计算机视觉任务中，在农业场景下尤为突出，特别是在与计数相关的应用中。农业目标物体常被叶片、树枝或其他非目标物体（例如温室中的基础设施线缆）遮挡。此外，由于某些水果（例如苹果、葡萄和番茄）呈簇状生长，目标物体也可能被其他目标物体严重遮挡，导致难以区分单个水果。因此，必须谨慎设计数据采集和标注流程。选择计数方法时，应考虑物体的遮挡程度（这是环境和特定栽培品种的特征）。为避免漏检（即遗漏被遮挡的物体），应将被遮挡的物体也标注为物体；如果目标物体呈簇状分布，研究人员应考虑在预处理阶段确定每簇中的物体数量，以限定可能的物体数量（并防止重复计数）。

重复计数 - 重复计数是许多计数应用中常见的挑战，在农业领域尤其突出；在高分辨率图像处理中，图像切片被视为一种常见解决方案（如计数方法一节所述）。对图像进行切片会导致某些物体被分割成两部分或更多部分。因此，分别统计每个切片中的物体时，同一物体可能会被重复计数。因此，完成计数分析后，必须重新拼合图像，并进一步执行非极大值抑制（NMS）处理。由于难以收集高质量数据集，近期许多研究探讨了自动化数据收集方法的应用。然而，逐帧跟踪物体并非易事，而且在很大程度上取决于目标检测器的性能（Villacres，2023）。由于存在遮挡问题，在真实环境中进行目标跟踪更具挑战性：物体可能被其他物体完全遮挡或部分遮挡。这可能导致物体混淆，使跟踪器难以区分它们。为克服这些挑战，必须慎重选择并调整跟踪器，以达到所需的性能。尽管近期研究改进了真实环境中的目标跟踪（Villacres，2023；Gao，2022），但跟踪仍是一项具有挑战性的任务，在农业领域尤其如此。这是因为农业环境复杂多变，物体可能受到严重遮挡，并呈现非刚性运动模式。因此，仍需进一步研究，以开发更稳健可靠的农业应用目标跟踪方法。

背景与前景 - 在自然环境中分析植物和树木会带来两种截然不同的挑战。第一种源于场景非常密集（例如枝叶繁茂的树木），导致目标对象受到严重遮挡；第二种则源于树木或植物分布稀疏，背景因此可见，进而使计数算法将无关物体也计算在内。图4。 清楚地展示了这一问题。对于密集场景，一个不错的方向是重新思考计数应用。例如，如果应用需要统计树木数量，从俯视图采集图像（使用无人机）可以更好地区分树木。对于彼此紧挨着生长或呈簇状分布的水果或花朵，将簇检测与簇内物体计数相结合，可以取得良好结果。对于稀疏场景，一种简单的解决方案是使用背景屏幕，确保无关物体不会出现在画面中。更好的解决方案是屏蔽距离相机超过一定范围的物体（将深度相机传感器的数据与RGB数据结合），这样

只有位于相机特定距离范围内的物体才会被计数。正如下文将进一步讨论的那样，这种方法也带来了额外的挑战。



图4 密集与稀疏场景的区别。图4A 展示了真实户外环境中密集生长的苹果花。由于树木茂密，遮挡很多，树木之间难以区分。 花朵被树木茂盛的枝叶严重遮挡。图4B 展示了温室中稀疏生长的黄瓜植株。由于植株较为稀疏，背景中的一行植株清晰可见，这可能导致模型将背景中的果实也计入数量，背景中的黄瓜清晰可见，因为植株相对稀疏。

硬件挑战

计算负担重 - 无人机、物联网设备或地面机器人等终端设备无法搭载强大的计算单元，但基于深度学习的计数器计算量大，需要先进的计算硬件，例如图形处理器（GPU）、张量处理器（TPU）及其他类似设备。这个问题主要与推理处理时间有关。整个推理流程（包括输入的预处理、前向传播和后处理）都依赖这类硬件。解决这些相互冲突需求的一种可行方法，是将数据传输到配备此类硬件的云端（或任何远程）服务器，并在那里分析数据。然而，这种方法也带来了额外挑战，涉及田间的通信基础设施以及边缘设备上的通信硬件。例如，远程地面机器人可以装载SIM卡，将数据传输到远程服务器，但仍必须具备稳定且高速的互联网或蜂窝网络连接。如果所考察的田地位于有人居住的区域，这可能是一个不错的解决方案。

传感器配准 - 大多数深度学习网络仅依赖 RGB 数据。然而，加入其他传感器能够补充来自这些先进传感器（如多光谱/高光谱、红外、热成像等）的额外信息。使用多个传感器分析单株植物时，必须对它们进行配准。图像配准是指对不同图像进行对齐，使每幅图像中呈现相同的信息。由于这些传感器并未物理连接，因此必须使用软件方案来确定图像 i 中的每个像素在图像 j 中的位置。否则，不同算法的结果就无法正确聚合（如果数据分别进行分析并在后处理阶段进行聚合），或者根本无法使用（如果算法同时将多幅图像作为一幅具有多个通道的图像来处理）。这是一项颇具挑战性的任务，因为每个传感器的图像分辨率各不相同（通常，热成像传感器和深度传感器的分辨率低于 RGB 传感器）。在复杂的农业环境中，这一问题并非易于解决。由于极端天气条件（例如风）、崎岖地形以及植物的移动，必须开发稳健的传感器配准方法，因为哪怕轻微的移动也会导致传感器错位，进而需要重新校准传感器。

高精度传感器的高成本 – 高精度传感器和先进传感器的高成本（Osco，2021年）意味着农业部门中的大多数数据仍在使用标准RGB相机采集（如表 1所示）。这给先进传感器的使用带来了额外挑战，因为常用方法都是针对RGB相机定制的，不适用于其他数据类型。此外，先进传感器数据还缺乏基准数据集。

总结

本文系统综述了过去十年中与农业目标计数相关的研究。我们收集并分析了2012年1月至2022年6月期间发表的243篇论文，以概述农业自动化尝试从传统计算机视觉算法转向深度学习方法、从单独使用RGB数据转向将RGB数据与先进传感器信息相结合的发展趋势。本文综述了农业中目标计数的不同方法，以及标注流程及其负担、数据采集流程、各种任务和子任务的相关性能指标，以及将基于深度学习的计数器应用于不同应用场景所面临的挑战。

将深度学习模型应用于实际计数应用仍面临诸多挑战。大多数综述研究给出的结果表明，从传统计算机视觉算法转向基于深度学习的计数器具有诸多优势。本综述还指出，部分挑战之间存在关联。例如，先进且精确的设备稀缺，促使人们开发仅使用 RGB 图像的算法，因此这些算法只能在日光条件下使用。下一代研究应着力于推广这些方法，并通过开展研发工作应对数据的多样性，涵盖不同田间的各种作物、各类生长条件以及不同季节。

另一项亟待解决的重要挑战是方法缺乏标准化，这意味着研究人员和从业者目前必须投入时间和资源来建立稳定的系统，之后才能着手解决其他挑战。因此，我们建议创建标准基准和数据集。收集的数据集应公开，以便比较新开发方法的结果，并构建通用模型。研究人员还可以通过共享代码、超参数和网络权重，以及完整的文档和教程而受益。这种做法将提供可靠的基准和平台，推动开发快速、稳定的系统，使其能够部署于田间供农民使用。

最后，随着更先进的传感器成为标准配置并得到广泛应用，受益于大数据的基于深度学习的计数器将变得更加准确，从而为解决实时产量估计、作物生长和植物病害监测、胁迫建模以及选择性农药处理设计等复杂任务铺平道路。这些复杂任务需要跨季节、生长条件和地理位置收集的大规模、高质量标注数据集。

致谢

本研究部分获得了Phenomics Consortium、科学部研究创新管理局资助（资助编号2018年7号）的支持，并获得内盖夫本-古里安大学通过农业、生物与认知机器人计划、Marcus捐赠基金以及W. Gunther Plaut制造工程教席提供的支持。

伦理标准合规性

作者声明不存在任何利益冲突。作者声明，本研究未涉及任何人类参与者和/或动物。本研究的资

参考文献

Afonso, M., Fonteijn, H., Fiorentin, F.S., Lensink, D., Mooij, M., Faber, N., Polder, G., Wehrens, R., 2020. 使用深度学习在温室中进行番茄果实检测与计数。植物科学前沿 11, 571299。

Albuquerque, P.L.F., Garcia, V., Junior, A.d.S.O., Lewandowski, T., Detweiler, C., Gonçalves, A.B., Costa, C.S., Naka, M.H., Pistori, H., 2019. 使用计算机视觉自动计数活鱼苗。《农业中的计算机与电子学》167, 105015。

Alharbi, N., 周, J., Wang, W., 2018年。基于小麦生长图像的小麦穗自动计数。科学与技术出版物。

AlMaazmi, A., 2018年。阿拉伯联合酋长国高分辨率WorldView-3卫星图像中的棕榈树检测与计数，载于：农业、生态系统与水文学遥感 XX，国际光学与光子学学会。第 107831M 页。

Anderson, N.T., Walsh, K.B., Koirala, A., Wang, Z., Amaral, M.H., Dickinson, G.R., Sinha, P., Robson, A.J., 2021。利用机器视觉估算澳大利亚芒果园的果实负载。《农学》11，1711。

Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K.R., Samek, W., 2015。关于通过逐层相关性传播对非线性分类器决策进行逐像素解释。《公共科学图书馆·综合》10，e0130140。

Bao, W., Lin, Z., Hu, G., Liang, D., Huang, L., Zhang, X., 2022年。基于 MSVF-ISCT 频域分解的小麦穗计数方法。《农业信息处理》。

Barbedo, J.G.A., Koenigkan, L.V., 2018年。关于利用无人机系统监测牛群的展望。《农业展望》47，214–222。

Bellocchio, E., Ciarfuglia, T.A., Costante, G., Valigi, P., 2019。利用空间一致性进行产量估算的弱监督水果计数。《IEEE机器人与自动化快报》4，2348–2355。

Bellocchio, E., Costante, G., Cascianelli, S., Fravolini, M.L., Valigi, P., 2020。结合领域自适应与空间一致性进行未见果实计数：一种准无监督方法。《IEEE机器人与自动化快报》5，1079–1086。

Bhattarai, U., Karkee, M., 2022年。《苹果园中花朵/果实计数的弱监督方法》。《工业中的计算机》138, 103635。

Brereton, P., Kitchenham, B.A., Budgen, D., Turner, M., Khalil, M., 2007年。《在软件工程领域应用系统性文献综述流程的经验教训》。《系统与软件杂志》80, 571–583。

Bruscolini, M., Suttor, B., Giustarini, L., Zare, M., Gaffinet, B., Schumann, G., 2021.《用于植物水分状态制图的无人机服务》，载于：2021年IEEE国际地球科学与遥感研讨会（IGARSS），IEEE。第8527–8530页。

Cao, L., Xiao, Z., Liao, X., Yao, Y., Wu, K., Mu, J., Li, J., Pu, H., 2021.《基于点监督算法的监控摄像环境下自动鸡只计数：Lc-densefcn》。《农业》11, 493。

Chen、C.H.、Kung、H.Y.、Hwang、F.J.，2019。用于农学应用的深度学习技术。《农学》，9(3)，142。

Chen, I.T., Lin, H.Y., 2020. 使用多光谱图像和机器学习技术对樱桃番茄进行检测、计数和成熟度评估，载于：VISIGRAPP（5：VISAPP），第759–766页。

Darwin, B., Dharmaraj, P., Prince, S., Popescu, D.E., Hemanth, D.J., 2021. 使用深度学习模型识别作物图像中的开花/产量以实现智慧农业：综述。《农学》11，646。

David, E., Serouart, M., Smith, D., Madec, S., Velumani, K., Liu, S., Wang, X., Pinto, F., Shafiee, S., Tahir, I.S. 等，2021年。2021年全球小麦穗检测：用于基准评测小麦穗检测方法的改进数据集。《植物表型组学》2021。

Dhaka, V.S., Meena, S.V., Rani, G., Sinwar, D., Ijaz, M.F., Woźniak, M. 等，2021。一项关于应用于植物叶片病害预测的深度卷积神经网络的综述。《传感器》21，4749。

Dijkstra, K., Loosdrecht, J., Schomaker, L.R., Wiering, M.A.，2018。CentroidNet：一种用于联合目标定位与数量计数的深度神经网络，载于：欧洲机器学习与数据库知识发现联合会议，Springer。第585–601页。

Dobrescu, A., Valerio Giuffrida, M., Tsaftaris, S.A., 2017年。利用多个数据集进行深度叶片计数，载于：IEEE国际计算机视觉会议研讨会论文集，第2072–2079页。

Dobrescu, A., Valerio Giuffrida, M., Tsaftaris, S.A., 2019。理解用于叶片计数回归的深度神经网络，载于：IEEE/CVF计算机视觉与模式识别会议研讨会论文集。

Everingham, M., Van Gool, L., Williams, C.K., Winn, J., Zisserman, A., 2010。Pascal视觉对象类别（VOC）挑战赛。《国际计算机视觉杂志》88，303–338。

Farjon, G., Itzhaky, Y., Khoroshevsky, F., Bar-Hillel, A., 2021。叶片计数：融合网络组件以提高准确率。《植物科学前沿》12，1063。

Farjon, G., Krikeb, O., Hillel, A.B., Alchanatis, V., 2019。用于改进化学疏花疏果决策的苹果树花朵检测与计数。《精准农业》，1–19。

Gao, F., Fu, L., Zhang, X., Majeed, Y., Li, R., Karkee, M., Zhang, Q., 2020。使用 Faster R-CNN 在SNAP系统中进行苹果多类别果实—植物检测。《农业中的计算机与电子学》176，105634。

Gao, F., Fang, W., Sun, X., Wu, Z., Zhao, G., Li, G., ... & Zhang, Q. (2022)。一种基于深度学习和树干跟踪的现代果园苹果果实检测与计数新方法。《农业中的计算机与电子学》，197，107000。

Gebbers, R., Adamchuk, V.I., 2010。精准农业与粮食安全。《科学》327，828–831 .

Gené-Mola, J., Sanz-Cortiella, R., Rosell-Polo, J.R., Morros, J.R., Ruiz-Hidalgo, J., Vilaplana, V., Gregorio, E., 2020。Fuji-SfM 数据集：利用运动恢复结构摄影测量进行富士苹果检测和定位的标注图像及点云集合。《数据简报》30，105591。

Gené-Mola, J., Vilaplana, V., Rosell-Polo, J.R., Morros, J.R., Ruiz-Hidalgo, J., Gregorio, E., 2019。Kfuji RGB-ds 数据库：用于水果检测的富士苹果多模态图像，包含颜色、深度和距离校正红外数据。《数据简报》25，104289。

Gomez, A.S.、Aptoula, E.、Parsons, S.、Bosilj, P.，2021年。机器人表型分析中的深度回归与检测计数方法比较。《IEEE机器人与自动化快报》6，2902–2907。

Gutiérrez, S.、Wendel, A.、Underwood, J.，2019。用于大规模芒果产量估算的地面高光谱成像。《农业中的计算机与电子学》157，126–135。Häni, N.、Roy, P.、Isler, V.，2018年。使用卷积神经网络进行苹果计数，载于：2018年IEEE/RSJ智能机器人与系统国际会议（IROS），IEEE。第2559–2565页。Häni, N.、Roy, P.、Isler, V.，2020。一项关于苹果园中水果检测与计数方法的比较研究。《现场机器人学期刊》37，263–282。

Harel, B., van Essen, R., Parmet, Y., Edan, Y., 2020a. 甜椒成熟度分类的视角分析。《传感器》20, 3783。

Harel, B., Parmet, Y., Edan, Y., 2020b. 使用图像进行甜椒成熟度分类 e 在不同时间采集的数据集。《工业中的计算机》121, 103274。

Hassler, S.C., Baysal-Gurel, F., 2019. 无人机系统（UAS）技术及其在农业中的应用。《农学》9, 618。

He, K., Zhang, X., Ren, S., Sun, J., 2016. 用于图像识别的深度残差学习，载于：IEEE计算机视觉与模式识别会议论文集，第770–778页。

He, L., Fang, W., Zhao, G., Wu, Z., Fu, L., Li, R., Majeed, Y., Dhupia, J., 2022. 果园水果产量预测与估算：全面综述直接方法和间接方法的最新进展。《农业中的计算机与电子学》195, 106812。

Hemming, J., Ruizendaal, J., Hofstee, J.W., Van Henten, E.J., 2014. 甜椒不同相机位置下的水果可检测性分析。《传感器》14，6032–6044。

Hobbs, J., Paull, R., Markowicz, B., Rose, G., 2020. 基于航拍图像的开花密度估算，用于自动化菠萝花计数，载于：人工智能促进社会公益研讨会。

Hollings, T., Burgman, M., van Andel, M., Gilbert, M., Robinson, T., Robinson, A., 2018年。如何找到那只绿色绵羊？利用遥感影像检测和计数动物的批判性综述。《生态学与进化方法》9，881–892。

Hong, S.J., Nam, I., Kim, S.Y., Kim, E., Lee, C.H., Ahn, S., Park, I.K., Kim, G., 2021. 使用深度学习目标检测器从信息素诱捕器图像中自动计数害虫，以监测松干蚧 。《昆虫》12，342。

Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H., 2017年。MobileNets：适用于移动视觉应用的高效卷积神经网络。arXiv 预印本 arXiv:1704.04861。

Jayasinghe, C., Badenhorst, P., Jacobs, J., Spangenberg, G., Smith, K., 2021。基于图像的高通量表型分析，用于估算多年生黑麦草（*Lolium perenne* L.）的持久性——综述。《草与饲草科学》76，321–339。

Jiang, Y., Li, C., Paterson, A.H., Robertson, J.S., 2019。DeepSeedling：用于田间植物幼苗检测和计数的深度卷积网络与卡尔曼滤波器。《植物方法》15，1–19。

Kamilaris, A., Prenafeta-Boldú, F. X.（2018）。农业中的深度学习：综述。《农业中的计算机与电子学》147，70-90

Kendall, A., Gal, Y., 2017年。贝叶斯深度学习的计算机视觉需要哪些不确定性？载于：《神经信息处理系统进展》，第5574–5584页。

Kestur, R., Meduri, A., Narasipura, O., 2019。Mangonet：一种深度语义分割架构，用于检测和统计露天果园中芒果数量的方法。《人工智能工程应用》77，59–69。

Kim, D.W., Yun, H.S., Jeong, S.J., Kwon, Y.S., Kim, S.G., Lee, W.S., Kim, H.J., 2018年。利用基于无人机的 RGB 影像对白菜和白萝卜生长状况进行建模与测试。《遥感》10，563。

Koirala, A., Walsh, K.B., Wang, Z., McCarthy, C., 2019。深度学习方法概述及其在水果检测和产量估算中的应用综述。《农业中的计算机与电子学》162，219–234。

Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012年。使用深度卷积神经网络进行 ImageNet 分类。《神经信息处理系统进展》第25卷。

Krogh Mortensen, A., Skovsen, S., Karstoft, H., Gislum, R., 2019。用于语义分割和产量估算的油萝卜生长数据集，载于：IEEE/CVF计算机视觉与模式识别会议（CVPR）研讨会论文集。

Kurtser, P., Edan, Y., 2018年。水果可检测性的统计模型：甜椒的空间与时间分析。《生物系统工程》171, 272–289。

Lac, L., Keresztes, B., Louargant, M., Donias, M., Da Costa, J.P., 2022。一种用于近距离传感应用的蔬菜作物早期生长阶段标注图像数据集。《数据简报》42, 108035。

Lin, T.Y., Goyal, P., Girshick, R., He, K., Dollár, P., 2017年。用于密集目标检测的焦点损失，载于：IEEE国际计算机视觉会议论文集，第2980–2988页。

Lin, T.Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., Zitnick, C.L., 2014。Microsoft coco：情境中的常见物体，载于：欧洲计算机视觉会议，Springer。第740–755页。

Linker, R., 2017年。利用光照分布估算夜间果园图像中绿色成熟苹果数量的方法及其在产量估算中的应用。《精准农业》18，59–75。

Liu, S., Zeng, X., Whitty, M., 2020。3dbunch：一款新颖的 iOS 智能手机应用，可运用图像分析技术评估每串葡萄果粒的数量。IEEE Access 8，114663–114674。

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y., Berg, A.C., 2016。SSD：单次拍摄多框检测器，载于《欧洲计算机视觉会议》，Springer。第21–37页。

Maheswari, P., Raja, P., Apolo-Apolo, O.E., Pérez-Ruiz, M., 2021。基于深度学习语义分割技术的果园智能水果产量估算——综述。《植物科学前沿》12，1247。

Malambo, L., Popescu, S., Ku, N.W., Rooney, W., 周, T., Moore, S., 2019. 一种基于深度学习语义分割的田块级高粱穗计数方法。《遥感》11, 2939。

Mavridou, E., Vrochidou, E., Papakostas, G.A., Pachidis, T., Kaburlasos, V.G., 2019. 用于作物种植精准农业的机器视觉系统。成像杂志 5, 89。

Mokrane, A., Braham, A.C., Cherki, B., 2019. 支持自主水果计数系统的无人机覆盖路径规划，载于：2019年应用自动化与工业诊断国际会议（ICAAID），IEEE。第 1–5 页。

Mosley, L., Pham, H., Bansal, Y., Hare, E., 2020年。基于图像的高粱穗计数：只需看一次。arXiv预印本 arXiv:2009.11929。

Nellithimaru, A.K., Kantor, G.A., 2019。Rols：用于葡萄计数的鲁棒对象级同步定位与地图构建，载于：IEEE/CVF计算机视觉与模式识别会议研讨会论文集，第0–0页。

Ni，X., Li, C., Jiang, H., Takeda, F., 2020。利用深度学习进行图像分割并提取blu蓝莓水果性状，这些性状与可采收性和产量相关。《园艺研究》7。

Oghaz, M.M.D., Razaak, M., Kerdegari, H., Argyriou, V., Remagnino, P., 2019。利用航拍图像和深度学习进行场景与环境监测，载于：2019年 第15届传感器系统分布式计算国际会议（DCOSS），IEEE。第362–369页。

Osco, L.P., de Arruda, M.d.S., Gonçalves, D.N., Dias, A., Batistoti, J., de Souza, M., Gomes, F.D.G., Ramos, A.P.M., de Castro Jorge, L.A., Liesenberg, V. 等，2021 年。一种利用卷积神经网络同时对植物进行计数并从无人机图像中检测种植行的方法。《ISPRS摄影测量与遥感杂志》174，1–17。

Osco, L.P., De Arruda, M.d.S., Junior, J.M., Da Silva, N.B., Ramos, A.P.M., Moryia, É.A.S., Imai, N.N., Pereira, D.R., Creste, J.E., Matsubara, E.T. 等，2020 年。一种利用卷积神经网络对无人机多光谱图像中的柑橘树进行计数和地理定位的方法。《ISPRS摄影测量与遥感杂志》160，97–106。

Palacios, F., Bueno, G., Salido, J., Diago, M.P., Hernández, I., Tardaguila, J., 2020. 基于计算机视觉和深度学习，利用移动传感平台在田间条件下进行移动成像，实现葡萄藤花朵自动检测与定量的方法。《农业中的计算机与电子学》178, 105796.

Preti, M., Verheggen, F., Angeli, S., 2021. 使用配备摄像机的诱捕器监测害虫：优势与局限。《害虫科学杂志》94, 203–217.

Rahimzadeh, M., Attar, A., 2022. 基于深度学习检测并计数开心果。伊朗计算机科学期刊5, 69–81.

Rahnemoonfar, M., Dobbs, D., Yari, M., Starek, M.J., 2019. Discountnet：用于实时计数和定位高分辨率无人机影像中稀疏目标的判别与计数网络。《遥感》11, 1128.

Rashid, M., Bari, B.S., Yusup, Y., Kamaruddin, M.A., Khan, N., 2021. 使用机器学习方法进行作物产量预测的综合综述，特别强调棕榈油产量预测。IEEE Access 9, 63406–63439。

Redmon, J., Farhadi, A., 2018年。Yolov3：渐进式改进。arXiv 预印本 arXiv:1804.02767。

Ren, S., He, K., Girshick, R., Sun, J., 2015. Faster r-CNN：利用区域提议网络实现实时目标检测。《神经信息处理系统进展》第28卷。

Ringdahl, O., Kurtser, P., Edan, Y., 2017年。甜椒采摘机器人的最佳接近方向选择策略，载于：自主机器人系统年会，Springer。第516–525页。

Ruiz-Garcia, L.、Lunadei, L.、Barreiro, P.、Robla, I.，2009年。农业和食品工业中的无线传感器技术及其应用综述：技术现状与当前趋势。《传感器》9，4728–4750。

Sadeghi-Tehran, P.、Virlet, N.、Ampe, E.M.、Reyns, P.、Hawkesford, M.J.，2019。Deepcount：利用简单线性迭代聚类和深度卷积神经网络对田间小麦穗进行自动定量。《植物科学前沿》，1176。

Saleem, M.H.、Potgieter, J.、Arif, K.M.，2021年。通过机器和深度 ep 学习技术实现农业自动化：近期发展的综述。《精准农业》22，2053–2091 .

Santoro, F.、Tarantino, E.、Figorito, B.、Gualano, S.、D'Onghia, A.M.，2013年。一种用于精准农业任务的树木计数算法。International Journal of Digital Earth 6，94–102。

Santos, L., Santos, F.N., Oliveira, P.M., Shinde, P., 2019。农业中的深度学习应用：简短综述，载于：伊比利亚机器人会议，Springer。第139–151页。

Santos, T.T., de Souza, L.L., dos Santos, A.A., Avila, S., 2020。使用深度神经网络和三维关联进行葡萄检测、分割与跟踪。《农业中的计算机与电子学》170，105247。

Simonyan, K., Zisserman, A., 2014。用于大规模图像识别的超深卷积网络。arXiv预印本 arXiv:1409.1556。

Soares, V.H.A., Ponti, M.A., Gonçalves, R.A., Campello, R.J., 2021。在大面积牧场中利用带地理定位的航空图像进行野外牛只计数。《农业中的计算机与电子学》189，106354。

Springenberg, J.T., Dosovitskiy, A., Brox, T., Riedmiller, M., 2014. 追求简洁：全卷积网络。arXiv 预印本 arXiv:1412.6806。

Syazwani, R.W.N., Asraf, H.M., Amin, M.M.S., Dalila, K.N., 2022. 使用机器学习对俯视菠萝冠部进行自动图像识别、检测和水果计数。《亚历山大工程学报》61, 1265–1276。

Tan, M., Pang, R., Le, Q.V., 2020. Efficientdet：可扩展且高效的目标检测，载于：IEEE/CVF计算机视觉与模式识别会议论文集，第10781–10790页。

Tenorio, G.L., Caarls, W., 2021. 植物行中番茄簇成熟度的自动视觉估计。《机器视觉与应用》32, 1–18。Tian, M., Guo, H., Chen, H., Wang, Q., Long, C., Ma, Y., 2019. 使用深度学习自动统计猪只数量。《农业中的计算机与电子学》163, 104840。

Tong, P., Han, P., Li, S., Li, N., Bu, S., Li, Q., Li, K., 2021. 使用逐点监督分割网络进行树木计数。《人工智能工程应用》100, 104172。

Tu, S., Pang, J., Liu, H., Zhuang, N., Chen, Y., Zheng, C., Wan, H., Xue, Y., 2020. 基于RGB-D图像的多尺度Faster R-CNN百香果检测与计数。Precision Agriculture 21, 1072–1091. doi:10.1007/s11119-020-09709-3。

Vermote, E.F., Skakun, S., Becker-Reshef, I., Saito, K., 2020. 利用超高空间分辨率WorldView-3数据遥感监测汤加的椰子树。Remote Sensing 12, 3113。

Villacrés, J., Viscaino, M., Delpiano, J., Vougioukas, S., & Cheein, F. A. (2023). 基于深度学习策略的苹果园产量估算：跟踪检测算法的比较。《农业中的计算机与电子学》，204，107513。

Vitzrabin, E., Edan, Y., 2016a. 使用RGBD传感器进行融合的自适应阈值处理，用于红甜椒检测。《生物系统工程》146，45–56。

Vitzrabin, E., Edan, Y., 2016b. 调整任务目标以改进用于机器人采收的甜椒检测。《IEEE机器人与自动化快报》1，578–584。

Westling, F., Underwood, J., Bryson, M., 2021. 使用果树激光雷达扫描数据生成自动化树木修剪建议的流程。《农业中的计算机与电子学》187，106274。

Wosner, O., Farjon, G., Bar-Hillel, A., 2021. 农业场景中的目标检测：多分辨率基准及与人类的比较。《农业中的计算机与电子学》189，106404。

Wu, J., Yang, G., Yang, X., Xu, B., Han, L., Zhu, Y., 2019。基于深度全卷积神经网络的无人机图像原位水稻幼苗自动计数。《遥感》11，691。

Xiong, H., Cao, Z., Lu, H., Madec, S., Liu, L., Shen, C., 2019。Tasselnetv2：利用上下文增强局部回归网络进行田间小麦穗计数。《植物方法》15，150。

Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., Tait, A., Schneider, D., 2020。利用 Mask R-CNN 在四旋翼无人机视觉系统中进行自动牛只计数。《农业中的计算机与电子学》171，105300。

Yamamoto, K., Guo, W., Yoshioka, Y., Ninomiya, S., 2014。利用图像分析和机器学习方法检测完整番茄果实中的植物。《传感器》14，12191–12206。

Yang, Y., & Ramanan, D.（2012年）。基于灵活部件混合模型的人体姿态检测。《IEEE模式分析与机器智能汇刊》，35(12)，2878–2890。

Zhang, C., Zhang, K., Ge, L., Zou, K., Wang, S., Zhang, J., Li, W., 2021。一种基于三维点云、多特征融合和支持向量机的石榴树器官分类与水果计数方法。《园艺科学》278，109791。

Zhang, L., Li, W., Liu, C., 周, X., Duan, Q., 2020。利用图像密度分级和局部回归的自动鱼类计数方法。《农业中的计算机与电子学》179，105844。

Zhang, Q., Liu, Y., Gong, C., Chen, Y., Yu, H., 2020。深度学习在 den 中的应用 se 农业场景分析：综述。《传感器》20，1520。

Zhong, Y., Gao, J., Lei, Q., Zhou, Y., 2018年。《智能农业中飞行昆虫的基于视觉的计数与识别系统》。《传感器》18，1489。

Zivkovic, Z., Van Der Heijden, F., 2006. 用于背景减除任务的高效逐图像像素自适应密度估计。《模式识别快报》27，773–780。

附录

A – 公共数据集链接

1. goo.gl/6aS64p
2. https://zenodo.org/record/3361736#.Yny17vNBxhE
3. https://rex.libraries.wsu.edu/esploro/outputs/99905026194018424
4. https://github.com/fu3lab/Scifresh-apple-RGB-images-with-multi-class-label
5. http://data.acfr.usyd.edu.au/ag/treecrops/2016-multifruit/
6. http://www.robotics.unsw.edu.au/srv/dataset/liu2015lightweight.html
7. https://github.com/xixiareone/counting-pigs/tree/master/counting/datasets
8. https://vhasoares.github.io/downloads.html
9. https://onedrive.live.com/?authkey=%21AMtRaqnBYG25eeE&id=5EE9D2EA82EE73C1%212 304&cid=
10. https://zenodo.org/record/5092309#.YrBqcBNBxh5EE9D2EA82EE73C1E
11. https://vision.eng.au.dk/oil-radish/
12. https://figshare.com/s/616956f8633c17ceae9b
13. https://zenodo.org/record/3715991#.Yrbc3hNBw1I
14. https://github.com/avadesh02/MangoNet-Semantic-Dataset
15. https://zenodo.org/record/3712808#.YrcDpRNBw1I
16. https://data.mendeley.com/datasets/d7kbzjr83k/1