

## · 微生物组测序与分析专题 ·

王军 研究员，博士生导师，主要研究方向：生物信息学和计算生物学分析；微生物大数据的比较和挖掘；新测序方法和人工智能方法的应用。2014年获得德国马普进化生物所博士学位，然后在比利时鲁汶大学医学院/弗拉芒生物研究所进行博士后研究工作。2017年回国，同时获得德国马普学会合作伙伴计划支持。长期从事微生物组的技术和方法研究，涉及生物信息学、进化生物学、基因组学和基础医学等方向，成果以第一或共同通讯发表在 *Science*、*Nature Genetics*、*Cell Host Microbe*、*PNAS*、*Nature Communications*、*Microbiome*、*Protein Cell*、*GBP* 等期刊上，文章共计 40 余篇。回国以来开展了多项合作，获得国家自然科学基金面上、重大和新冠病毒应急专项支持，承担科技部重点研发课题、自然资源调查项目子课题、中国科学院重点部署项目课题以及先导项目子课题等，课题组已经发表/接收文章 8 篇，申请专利 2 项。此外，在新冠疫情期间作为中国科学院病原微生物与免疫学重点实验室代表赴武汉市开展了科研攻关项目。



# 病毒组研究：微生物组研究新热点

张雨青<sup>1,2\*</sup>, 曹佳宝<sup>1,2\*</sup>, 赵娜<sup>1</sup>, 王军<sup>1,2</sup>

1 中国科学院微生物研究所 病原微生物与免疫学重点实验室, 北京 100101

2 中国科学院大学, 北京 100049

张雨青, 曹佳宝, 赵娜, 等. 病毒组研究: 微生物组研究新热点. 生物工程学报, 2020, 36(12): 2566–2581.

Zhang YQ, Cao JB, Zhao N, et al. Virome: the next hotspot in microbiome research. Chin J Biotech, 2020, 36(12): 2566–2581.

**摘要:** 病毒组是指分布在各种环境中病毒的集合或病毒宏基因组的统称。病毒可以分布于水体、冰川、动植物甚至某些病毒当中，主要分为真核病毒、原核病毒和亚病毒。其在维持环境内稳态、生态系统平衡等方面起着非常重要的作用，并且与人类的健康密切相关。近年来，随着测序技术和数据分析水平的进步，人们能够采用宏基因组测序的方式研究病毒组并探究其在生态位中的潜在作用。人们在冰川、海洋、各种动植物中都得到了大量的病毒组数据，发现了众多未知病毒。人们研究病毒组主要是通过宏基因组数据挖掘和病毒样粒子 (Virus-like particles, VLPs) 分离富集测序两种方式进行分析处理。迄今为止，已存在多种不同的病毒组分离富集方法，并且针对病毒组的生物信息分析也数不胜数。然而，针对病毒组的富集和数据分析方法还缺少具体、完整的综述。文中将对病毒组的分离富集方法和数据分析进行整理与总结，并列举出部分采用病毒组分离富集方法进行的重要研究，旨在为相关人员提供参考，进一步促进病毒组研究领域的发展。

**关键词:** 病毒样粒子, 宏基因组, 富集纯化, 生物信息分析

**Received:** June 23, 2020; **Accepted:** November 10, 2020

**Supported by:** National Key Research and Development Program of China (No. 2018YFC2000500), Strategic Priority Research Program of the Chinese Academy of Sciences (No. XDB29020000), National Natural Science Foundation of China (Nos. 31771481, 91857101).

**Corresponding author:** Jun Wang.Tel: +86-10-64807502; E-mail: junwang@im.ac.cn

\*These authors contributed equally to this study.

国家重点研究发展计划 (No. 2018YFC2000500), 中国科学院战略重点研究计划 (No. XDB29020000), 国家自然科学基金 (Nos. 31771481, 91857101) 资助。

# Virome: the next hotspot in microbiome research

Yuqing Zhang<sup>1,2\*</sup>, Jiabao Cao<sup>1,2\*</sup>, Na Zhao<sup>1</sup>, and Jun Wang<sup>1,2</sup>

1 CAS Key Laboratory of Pathogenic Microbiology and Immunology, Institute of Microbiology, Chinese Academy of Sciences, Beijing 100101, China

2 University of Chinese Academy of Sciences, Beijing 100049, China

**Abstract:** Virome is the collective term for the viral collection or viral metagenomes that are distributed in various environments. Viruses can be found in bodies of water, glaciers, plants, animals, and even some viruses, which are classified as eukaryotes, prokaryotes and subviruses. Viruses play very important role in maintaining environmental homeostasis and ecosystem balance, and are especially closely related to human health. In recent years, with the advancement of sequencing technology and data analysis, we are able to gain more insights into the virome and explore its potential role in the ecological niche by metagenomic sequencing. A large amount of viral data have been obtained from glaciers, oceans, and various plants and animals, and numerous unknown viruses have been discovered. Virome has been studied mainly through metagenomic data mining, as well as virus-like particles separation and enrichment. To date, several different methods for viral isolation and enrichment exist, and numerous bioinformatic analyses of the virome have been performed. However, there is a lack of specific and complete reviews on the enrichment and data analysis methods for the virome. Thus, our review will summarize viral isolation and enrichment methods and data analysis, and present some of the landmark research conducted by the enrichment method, to provide a reference for researchers of interest and further advance the field of virome research.

**Keywords:** virus-like particles, metagenomics, enrichment and purification, bioinformatic analysis

病毒是超显微、无细胞结构、专性活细胞内寄生的生命类群，它们广泛分布在多种环境（如海洋、湖泊、土壤等自然环境，以及肠道、呼吸道等宿主环境）中<sup>[1-4]</sup>，种类丰富、数量庞大。据报道，在每毫升海水中大概具有  $10^6\text{--}10^9$  个病毒<sup>[5]</sup>，在每克土壤与沉积物中大约含有  $10^9$  个病毒颗粒，其含量至少是其他微生物的 10 倍<sup>[2]</sup>。根据其感染宿主的差异，病毒可分为动物病毒、植物病毒、噬菌体和亚病毒（类病毒、拟病毒等）。它们具有丰富的遗传多样性，在宿主的基因可塑性方面起重要作用，并能够影响其他物种的多态性。

传统的病毒研究主要是采用宿主与病毒共培养的方法，但是这种方法仅能对已知能培养的病毒进行检测。近年来，随着高通量测序技术的不断进步，人们开始运用宏基因组策略来研究病毒组<sup>[6-7]</sup>，此方法不仅能检测已知病毒，也能对未知病毒进行研究且不依赖于培养，能最大程度地还原环境中病毒的多样性。宏基因组学在病毒组学研究中最显著的影响是改变了人们对病毒多样性及种群结构的理解，并发现了大量的病毒新物

种<sup>[8-9]</sup>。2016 年，*Nature* 杂志上发表一篇极具影响力的病毒组文章，该文章的作者 David Paez-Espino 及其团队利用宏基因组测序技术分析了来自 3 042 个不同地域样本超过 5 Tb 的数据，并评估病毒的全球分布、系统发育多样性和宿主特异性<sup>[10]</sup>。通过这项工作，他们将病毒序列的数量增加了 50 倍，由此确定的病毒多样性比已知的多了 99%。Gregory 等通过整合 572 个宏基因组或病毒组研究，收集了 13 203 个病毒基因组，从而构建了人类肠道病毒基因组数据库（Human Gut Virome Database, GVD）<sup>[11]</sup>。张永振等通过宏基因组策略研究了 220 多种无脊椎动物和脊椎动物的宏转录组，发现了与无脊椎动物相关的 1 445 种 RNA 病毒，大大改变了我们对 RNA 病毒圈的认识，包括 RNA 病毒组成、进化、起源、基因组结构以及与宿主的关系，弥补了以往病毒分类中存在的大量间隙。其中一些病毒与现有已知病毒的差异性之大，以至于需要重新被定义为新的病毒科<sup>[12-13]</sup>。此外，2005 年报道的一项关于血液的病毒宏基因组学的开创性研究发现了与许多真核病

毒相关的序列，且与数据库中的序列只有很小的相似性<sup>[14]</sup>。

相比于细菌和宿主来源的基因组，病毒基因组很小，因此病毒 DNA 只占宏基因组总 DNA 量的一小部分，导致宏基因组数据挖掘研究病毒组信息存在着数据量小、效率低等缺陷。并且，许多温和噬菌体整合在宿主基因组中，常以溶原状态存在。而病毒组富集能够一定程度区分整合的噬菌体和游离噬菌体的基因组，因此许多病毒组研究都采用了对病毒样颗粒(Virus-like particles, VLPs)进行富集的方式从而对病毒进行针对性的分析。目前，针对病毒组的分离富集已存在多种方法。例如，海洋病毒密度低，除纯化方法外，还必须对 VLP 进行浓缩，即切向流过滤(Tangential-flow filtration, TFF)<sup>[15]</sup>或 FeCl<sub>3</sub>沉淀<sup>[16-17]</sup>等方法以获得足够的 VLP 密度用于测序<sup>[18]</sup>。除此之外，聚乙二醇 (Polyethylene glycol, PEG) 沉淀<sup>[19-20]</sup>、CsCl 密度梯度离心<sup>[21]</sup>、超速离心<sup>[22]</sup>等都是典型的病毒分离富集方法。近年来，VLP 富集方法被应用在各种环境的病毒组研究中。*Tara* 海洋考察项目采集了全球海洋水体样本并对其进行了病毒样粒子的分离富集和测序分析，得到的 *Tara* 海洋病毒组 (*Tara Ocean Viromes*, TOV) 数据集，涵盖了全球上层海洋病毒组信息，并发现海洋病毒分布呈现明显的局部多样性<sup>[5]</sup>。研究人员在南极冰盖下的湖泊和热带的淡水水系中都通过病毒样粒子富集的方式发现了大量的未知病毒<sup>[23-24]</sup>。并且 VLP 方法也被广泛应用到水体中致病性病毒的检测当中，如水体中诸如病毒和粪便污染指示因子胡椒轻斑驳病毒 (Pepper mild mottle virus, PMMoV) 的检测<sup>[25-26]</sup>。在许多基于超滤或过滤方式获得人类肠道病毒样粒子的研究中发现，噬菌体的含量占据肠道病毒的绝大部分，同时许多真核 RNA 病毒也能被检测到，如星状病毒、杯状病毒等<sup>[27]</sup>。肠道病毒无法完全通过母婴传递过程转移，Rabia 等发现新生儿的肠道病毒组仅有 15%

来自其母亲<sup>[28]</sup>。新生儿的肠道病毒在刚出生时几乎不存在，在出生一个月内，其病毒组种群主要为由最初在肠道内定植的某些先驱细菌诱导的噬菌体，在此后一段时间内病毒种群的变换则受到母乳喂养的调节<sup>[29]</sup>。随着年龄逐渐增长，成人的病毒组则表现出高度的个体差异性<sup>[30]</sup>。在土壤环境中，多采用 PEG 沉淀和切向流过滤 (TFF) 的方式获得病毒粒子。运用这种手段，研究人员发现了超过 24 000 种分布在全球土壤中的病毒序列及其潜在宿主<sup>[31-32]</sup>。而对中国东部沿海土壤进行的病毒组学分析则提供了一种海洋陆地过渡带病毒群落的初步轮廓<sup>[15]</sup>。此外 Adriaenssens 等对南极的土壤病毒组研究中发现病毒组的高度异质性与地理位置无关，但与土壤 pH、钙含量有极大关联<sup>[33]</sup>。

然而，迄今为止尚缺乏完整、详细的针对病毒组分离富集的标准和比较。此外，病毒组数据分析也面临如下挑战：1) 缺少类似于细菌和古菌中 16S 和真菌中 18S/ITS 等代表遗传多样性的保守基因来鉴定病毒组；2) 缺乏完整的病毒基因组数据库，无法为病毒的分类和功能性研究提供基本参考。综上，本文将系统介绍 VLP 富集方法，并针对这些方法的优缺点进行评估。此外，我们也将对病毒组数据分析的流程进行简要概述，从而帮助传统生物学家以及刚刚涉足这一领域的研究者，促进病毒组研究领域的发展和进步。

## 1 VLP 分离富集与处理

VLP 分离富集是病毒组测序的关键，样本中病毒组的真实情况取决于病毒样粒子的富集。因此，选择合适的 VLP 分离富集方法是研究者们首先要考虑的事情。

### 1.1 样品预处理

在病毒颗粒富集之前，用于分离和存储样品的方法会显著影响病毒样颗粒的稳定性，从而影

响病毒富集的质量。在准备用于病毒颗粒富集的样品时，如何破坏微生物和宿主细胞是一个需要考虑并十分棘手的问题。如果无法立即处理样品，则随后的细胞生长会污染样品。例如，收集的海水若未进行适当的处理或存储，那么在样品收集到病毒粒子处理期间发生的微生物生长会导致噬菌体暴发，最终导致数据集无法准确反映样品收集时的真实成分。通常在病毒样品中添加 2%–5% 的氯仿可以防止细胞的意外生长<sup>[34]</sup>。但是，添加溶剂会改变某些病毒颗粒的传染性和浮力密度，会给病毒粒子的收集和核酸提取产生极大影响。样品还可以在–80 °C 冷冻，以保留病毒颗粒并阻止细胞生长，这也是目前通常采用的方法。

## 1.2 基于过滤的 VLP 富集

根据粒子的大小尺寸可以对病毒粒子进行分离富集，其原理是给定范围的孔径使符合范围的病毒粒子能顺利通过，而其他如细菌、真菌等颗粒直径较大的粒子不能通过，从而达到分离富集的效果。该方法的优点是简单易操作，使用普通的针孔过滤器（通常为 0.22 μm 或 0.45 μm）就可以实现对病毒粒子的富集。Legoff 等<sup>[35]</sup>运用此方法成功在肠道中富集得到真核病毒，并证明其对造血干细胞移植后患者健康的影响。但是，孔径大小的选择会影响病毒粒子的富集效果，并且过滤器也经常会因其他杂质堵塞导致过滤变得困难。

切向流过滤（TFF）经常用于水环境中病毒粒子的分离<sup>[17]</sup>。该方法可以保留较大的颗粒并去除多余的液体（即滤液），将样品中的病毒颗粒浓缩为较小的体积。使用压力迫使样品通过中空纤维过滤器的孔，从而丢弃通过过滤器的小颗粒，样本中成分（大于过滤器孔径）则被收集到一个储水池中，然后循环通过过滤器多次，达到富集的目的。为了确保这些较大的颗粒在推向过滤器孔时不会破裂，使用油压计将系统内的压力保持在  $6.89 \times 10^4$  Pa 以下。与冲击式过滤器相比，该过滤器的表面积使大量（数十至数百升）的滤液快

速通过，并且不易堵塞。此外，TFF 可用于产生无病毒颗粒的滤液。例如，在使用 100–300 kDa TFF 滤液进行颗粒分离之前，可以从宿主组织表面冲洗掉表面病毒<sup>[36]</sup>。

## 1.3 基于离心的 VLP 富集

超速离心的方法可用于不同环境中病毒粒子的富集，包括差速离心和密度梯度离心<sup>[37]</sup>。差速离心是根据病毒粒子的大小、密度及形状对其进行沉降富集，较大的颗粒将先于较小的颗粒沉降，而密度较大的颗粒将在密度较小的颗粒之前沉降，而不对称的颗粒比相同质量和密度的球形颗粒沉降得更慢。但是，这种分离并不干净，因为从样品顶部沉淀颗粒所需的离心力也会从底部沉淀小颗粒。所以前期过滤掉非病毒粒子非常关键，同时离心力也需要足够大才能保证小的病毒粒子的沉降<sup>[22]</sup>。近期，我们应用此方法成功从健康人类粪便中富集得到了大量的噬菌体病毒<sup>[38]</sup>。但是，该方法有一个缺陷就是在离心的过程可能会破坏病毒粒子。

在密度梯度离心过程中，不同密度的同一介质可在同一个容器中旋转，导致各种密度的病毒粒子集中在与其密度相同的介质中，从而达到分离富集的目的。因此，高密度的介质，例如碱金属盐（例如 CsCl）或小的疏水性有机化合物（例如蔗糖）通常被用于密度梯度离心。根据病毒粒子的最终用途（例如宏基因组测序与病毒培养研究），选择用于密度梯度离心的介质类型至关重要，因为每种介质对粒子完整性和感染性都有不同的影响。如何选择离心的溶剂和速度以及梯度介质的类型和数量完全取决于目标病毒的密度。无论选择哪种介质，均应使用与原始样品相同的缓冲液类型进行梯度洗脱，用于产生梯度的缓冲液必须首先使用 0.02 μm 过滤器进行纯化以确保外部病毒或其他微生物不会污染所得的馏分。其中，CsCl 密度梯度离心是应用最为广泛的富集方法<sup>[39]</sup>。但是，该方法对离心机和实验操作要求高，适合收集单一病毒粒子。富集环境中多种病毒粒

子时会有较宽区带，增加实验难度。

#### 1.4 其他富集方法

大量的研究已证明，铁离子<sup>[40]</sup>、铝<sup>[41]</sup>和聚电解质<sup>[42]</sup>能有效地沉淀和去除废水中的病毒。依据以上原理，John 等<sup>[43]</sup>引入了使用  $\text{FeCl}_3$  沉淀技术从海水中浓缩病毒的方法。此方法可以回收 92%–95% 的病毒粒子，并且在冰川和深海的样品中得到了很好的应用<sup>[44-45]</sup>。与 TFF 相比，该方法的病毒回收率更高且更加经济。除此之外，PEG 也是一种重要的无需进行超速离心的病毒富集方法。PEG 能够沉淀蛋白质，而噬菌体的外壳的主要成分就是蛋白质，因此 PEG 能够将噬菌体从溶液中沉淀下来，从而达到富集的效果。PEG 沉淀法很久之前就已经应用于各种环境样本中病毒粒子的富集<sup>[46]</sup>。近期，Shkoporov 等<sup>[20]</sup>应用 PEG 沉淀病毒的原理开发了针对肠道噬菌体组的富集方法。值得注意的是，PEG 纯化病毒的过程中会形成粘性高分子化合物，通过缓冲溶液交换方法很难去除 PEG，导致病毒粒子富集失败<sup>[47]</sup>。

要成分就是蛋白质，因此 PEG 能够将噬菌体从溶液中沉淀下来，从而达到富集的效果。PEG 沉淀法很久之前就已经应用于各种环境样本中病毒粒子的富集<sup>[46]</sup>。近期，Shkoporov 等<sup>[20]</sup>应用 PEG 沉淀病毒的原理开发了针对肠道噬菌体组的富集方法。值得注意的是，PEG 纯化病毒的过程中会形成粘性高分子化合物，通过缓冲溶液交换方法很难去除 PEG，导致病毒粒子富集失败<sup>[47]</sup>。

#### 1.5 富集方式的应用

由于不同环境样本的性质和含有病毒浓度的差异，VLP 富集时也会有针对性策略（图 1）。从

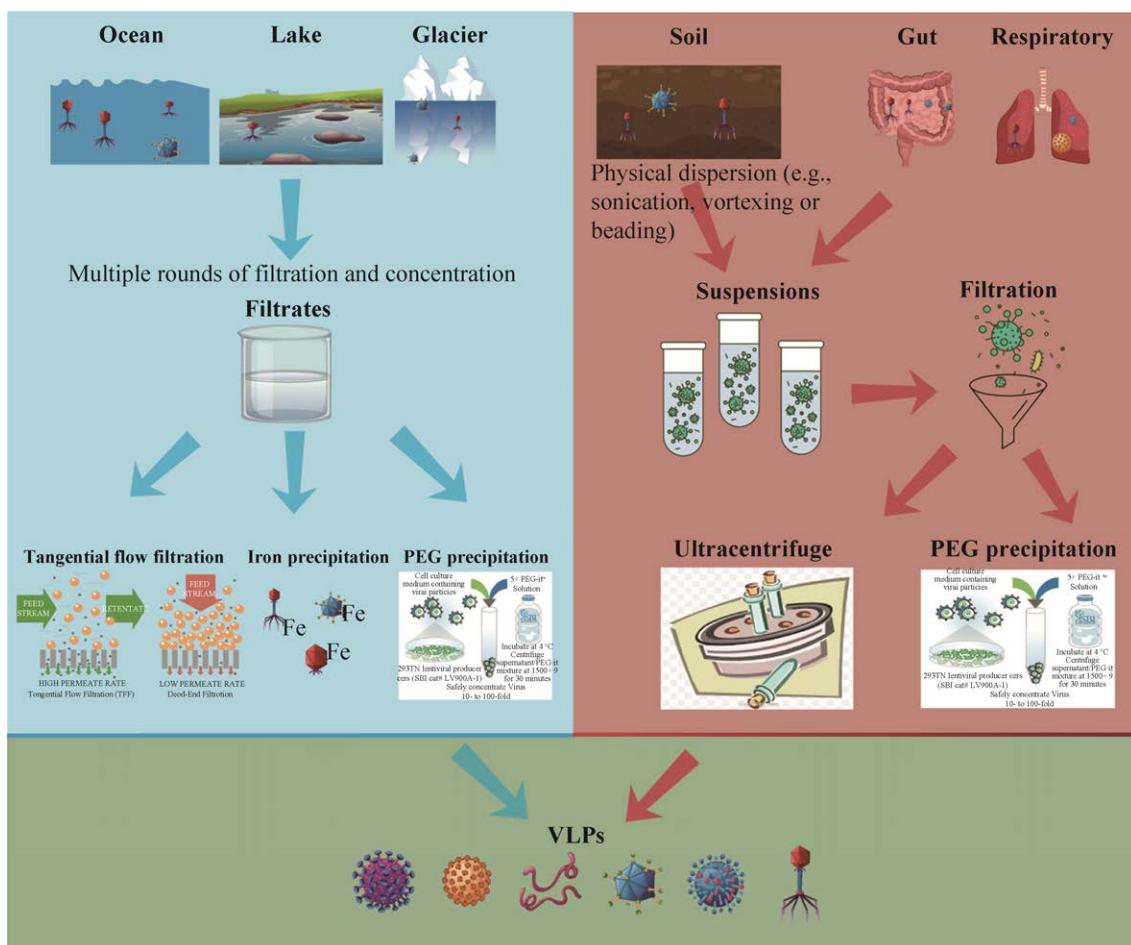


图 1 不同环境样本病毒粒子富集示意图

Fig. 1 Schematic of virus-like particles enrichment in different samples. Enrichment methods for water samples in the blue background include TFF,  $\text{FeCl}_3$  and PEG precipitation methods. Viral enrichment methods for soil and human intestinal and respiratory samples, including ultracentrifugation and PEG precipitation, are shown in the brown background. The green background part indicates enriched virus-like particles.

海洋、湖泊或冰川中获得的样本体积一般多达几升，在富集过程中通常先用大孔径过滤器进行粗过滤，过滤掉浮游生物和其他微生物并去除大量的水，然后使用 TFF/FeCl<sub>3</sub>/PEG 的方法浓缩沉淀病毒颗粒。值得注意的是，样本采集时常受到外界因素的干扰（如温度和压力），从而影响水体内噬菌体种类和数目，不能反映真实状态。因此，在获得样本后应及时处理。

土壤样本为固体状态，需要研究人员先使用病毒重悬方法进行处理。使用物理分散（如超声处理、涡旋或珠击）的方式将土壤样本中的病毒样粒子重悬，然后将洗脱液通过离心过滤的方式去除其他大颗粒后再用 PEG 沉淀或基于离心的方式进行富集，值得特别注意的是，Gareth Trubl 等发现在超滤浓缩时添加 1% 牛血清白蛋白（Bovine albumin, BSA）会提高病毒得率<sup>[48-50]</sup>。人体肠道样本与土壤样本类似，经缓冲液重悬、粗离心和过滤等步骤后可采取 PEG 沉淀或基于离心的方式进行富集。人体其他样本则可以根据样本材料采取合适的方法。

## 1.6 病毒核酸扩增与测序

病毒粒子的核酸提取可采用传统的苯酚/氯仿/异戊醇法或成熟的病毒纯化试剂盒（如 QIAamp MinElute Virus Spin Kit, Qiagen）。有时，为满足测序建库对核酸量的需求，通常需要对病毒核酸进行扩增。但是，扩增方法不同会对测序结果产生较大影响<sup>[51]</sup>。例如，随机扩增只针对双链 DNA；多重置换法倾向于扩增单链 DNA 且不均匀扩增线性基因组；衔接子扩增通常需要较高模板浓度。因此，每一种方法都有自己的局限性，研究者需要根据实验目的选取合适的扩增方法。随着测序技术的不断进步，常用的测序平台包括 Illumina、Ion torrent、Solid、454 Roche、PacBio 和 Oxford Nanopore。其中，以 Illumina 为首的二代测序技术具有通量高、价格便宜等优势被广泛应用。但是，测序产生的序列较短（200 bp 左右），对重复序列较多、高度嵌合的基因组组装带来很

大挑战。至此，相比二代，三代测序技术（PacBio 和 Oxford Nanopore）能产生更长的序列从而有利于基因组组装，但是其价格较高且序列的准确度需要进一步提升。

## 2 病毒宏基因组生物信息分析

病毒宏基因组学主要用于对环境和生物样品中的病毒进行研究。它主要利用下一代测序技术，分析病毒序列以阐明病毒对人类健康及环境的影响。与扩增子测序不同，宏基因组学是直接从环境样品中获取和研究遗传物质，使人们对微生物世界的多样性和功能有全新的认识。其中，涉及到的重要环节是对测序数据的分析，一般包括以下步骤：1) 数据质量控制和过滤，包括去除测序过程中添加的引物序列、接头序列以及低质量的序列。同时，过滤非病毒基因组序列，如人类样本中的大量宿主基因组序列；2) 病毒基因组组装；3) 病毒分类鉴定；4) 病毒多样性分析及功能注释等（图 2）。接下来，我们将对这些步骤中涉及的工具、方法及数据库进行详细介绍，同时针对不同情况给出相应的分析策略。

### 2.1 数据质量控制和过滤

获得测序数据（Raw data）后，首先应当对数据进行质量控制。在文库构建的过程中会人为添加引物和接头序列，且在测序过程中也会引入低质量或错误序列。为避免对下一步的分析造成影响，需要对这些序列进行排除。目前，常用的有 FastQC (<http://www.bioinformatics.babraham.ac.uk/projects/fastqc>)、Cutadapt<sup>[52]</sup>、Trimmomatic<sup>[53]</sup> 和 Fastp<sup>[54]</sup> 等（表 1）。FastQC 是一种基于 java 的快速测序质量评估软件，支持 Fastq、SAM、BAM 等文件格式，最终的结果以网页 HTML 格式展示。Cutadapt 具备去除引物和接头序列以及多聚腺苷酸尾等功能。Trimmomatic 是一款针对 Illumina 测序数据的质量控制软件，它提供了一系列参数用于去除接头序列和低质量序列。而 Fastp 是由 C++ 语言编

写的同时具备 FastQC、Cutadapt 和 Trimmomatic 三种软件功能的质量控制软件，支持多线程且运行速度更快。质控后的不同样本测序数据，通常需要过滤掉非病毒序列以免影响后续分析，尤其在人体样本会有一定比例的人基因组序列。该步骤通常采用基于比对的方法去除，如应用

Bowtie2<sup>[55]</sup>、BLAST<sup>[56]</sup>等软件将数据比对到宿主或细菌基因组以去除非病毒序列并得到纯净的数据 (Clean data)。另外，KneadData (<https://github.com/biobakery/biobakery/wiki/kneaddata>) 是一款常用的旨在对宏基因组测序数据进行质量控制的工具，可以用于去除环境样本中的宿主污染。

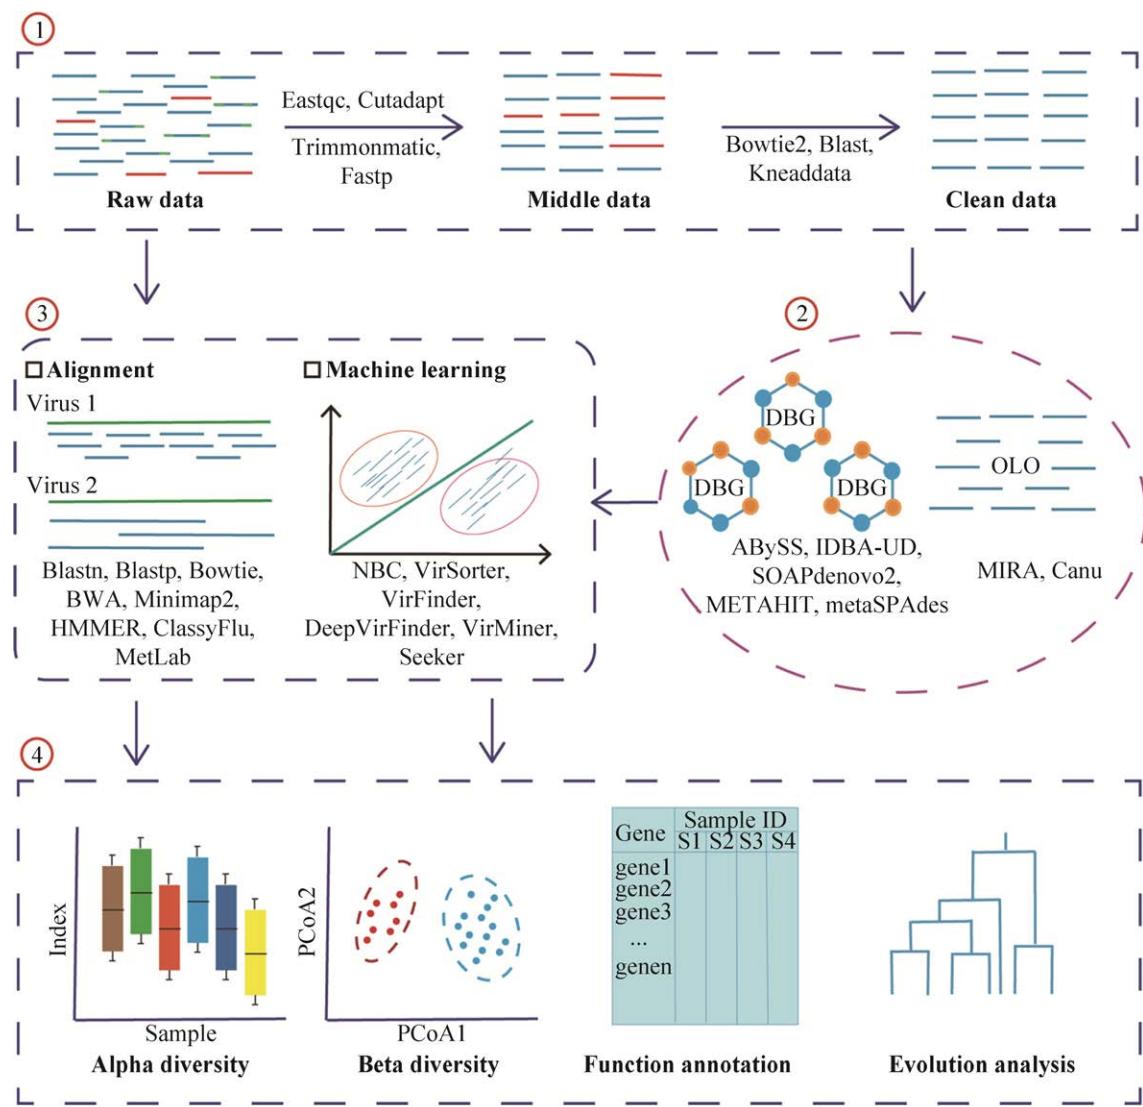


图 2 病毒组生物信息分析流程

Fig. 2 Schematic pipeline of bioinformatic analysis for virome. As shown in the figure, the analysis for virome is divided into 4 parts: Data filtering and cleaning, including filtering out adapters, primers and low quality sequences, while removing environmental contamination such as host sequences; *De novo* assembly of genome, involving a total of two algorithms (DBG and OLO); Viral classification and identification, divided into two approaches, one is a reference-based comparison method and the other is a machine learning-based method; Downstream analysis, including alpha and beta diversity analysis, gene function annotation and viral evolution. Of note, the bottom of the first three parts of the figure represents the software used in the process.

## 2.2 病毒基因组 *de novo* 组装

截至当前，仍有大量的病毒没有被注释，且在参考数据库中很难找到同源物。因此，对病毒组的研究很大程度上依赖于基因组的从头组装，以还原其组成及功能等信息。根据不同的组装策略，可将组装软件分为两大类<sup>[57]</sup>（表 1）：一类是基于 overlap-layout-consensus (OLC) 方法的组装，如 MIRA<sup>[58]</sup>、Canu<sup>[59]</sup>等适用于长读序列的拼接与组装；另一类则是基于 de-Bruijn-graph (DBG) 方法的组装，这也是宏基因组组装最常用方法，软件有 ABySS<sup>[60]</sup>、IDBA-UD<sup>[61]</sup>、SOAPdenovo2<sup>[62]</sup>、METAHIT<sup>[63]</sup>、metaSPAdes<sup>[64]</sup>等适合短读序列的组装。

MIRA 是一种支持全基因组霰弹枪测序、EST

及 RNA-Seq 测序数据的组装软件，同时支持 Sanger、454 Roche、Illumina、Ion torrent 和 PacBio 等不同测序的混合组装，不过 PacBio 仅限于 CCS (Circular Consensus Sequencing) 读取或错误校正的 CLR (Continuous Long Reads) 数据。Canu 专门应用于高噪声的单分子测序如 PacBio 和 Nanopore 数据的组装，包括 4 个主要步骤：使用 MHAP 算法<sup>[65]</sup>检测重叠序列；生成校正后共有序列；修剪校正后的序列；组装。ABySS 是一种针对双端短读序列的从头组装软件，允许进行组装算法并行计算，节省大量时间。基于 IDBA 算法，IDBA-UD 软件更适用于高度不均匀测序深度的短读序列的组装，其使用多个深度相关阈值去除了低深度和高深度区域中的错误 k-mers，并使用

**表 1 原始测序数据质量控制及基因组拼接工具**

**Table 1 A summary of raw sequencing data quality control and genome assembly tools**

Name	Description	Web address	Reference
FastQC	Quality control of fastq or fasta data	<a href="https://www.bioinformatics.babraham.ac.uk/projects/fastqc/">https://www.bioinformatics.babraham.ac.uk/projects/fastqc/</a>	
Cutadapt	Removal of primer, adapter sequences and polyA tails	<a href="https://github.com/marcelm/cutadapt/">https://github.com/marcelm/cutadapt/</a>	[52]
Trimmomatic	Filtering of low-quality sequences	<a href="http://www.usadellab.org/cms/?page=trimomatic">http://www.usadellab.org/cms/?page=trimomatic</a>	[53]
Fastp	Removal of adapter sequences and filtering of low-quality sequences	<a href="https://github.com/OpenGene/fastp">https://github.com/OpenGene/fastp</a>	[54]
KneadData	A tool designed to perform quality control on metagenomic sequencing data	<a href="https://github.com/biobakery/biobakery/wiki/kneaddata">https://github.com/biobakery/biobakery/wiki/kneaddata</a>	
MIRA	Assembly of short-read sequences based on the overlap-layout-consensus method	<a href="http://www.chevreux.org/projects_mira.html">http://www.chevreux.org/projects_mira.html</a>	[58]
Canu	A tool designed for high-noise single-molecule sequencing	<a href="https://github.com/marbl/canu">https://github.com/marbl/canu</a>	[59]
ABySS	Assembly of short-read sequences based on the de-Bruijn-graph method; faster parallel calculation support	<a href="https://www.bcgsc.ca/resources/software/abyss">https://www.bcgsc.ca/resources/software/abyss</a>	[60]
IDBA-UD	Assembly of short-read sequences based on the de-Bruijn-graph method; faster parallel calculation support	<a href="https://github.com/loneknightpy/idba">https://github.com/loneknightpy/idba</a>	[61]
SOAPdenovo2	Assembly of short-read sequences based on the de-Bruijn-graph method	<a href="https://github.com/aquaskyline/SOAPdenovo2">https://github.com/aquaskyline/SOAPdenovo2</a>	[62]
METAHIT	Assembly tools based on the de-Bruijn-graph method for single-cell and metagenomic data assembly	<a href="https://github.com/voutcn/megahit">https://github.com/voutcn/megahit</a>	[63]
metaSPAdes	Assembly tools based on the de-Bruijn-graph method for metagenomic data assembly; support for mixed assembly of short-read and long-read sequence	<a href="http://cab.spbu.ru/software/meta-spades/">http://cab.spbu.ru/software/meta-spades/</a>	[64]

具有末端信息的局部组装技术解决了低深度段重复区域的分支问题。SOAPdenovo2 是一款专门针对 Illumina GA 测序数据的组装软件, 主要用于动植物等大型基因组的组装, 也可以用于细菌或真菌基因组的组装。相比于 SOAPdenovo2 软件, MEGAHIT 是一款运行速度更快、内存消耗更小的组装软件, 其主要适用于宏基因组的组装, 同时也支持单个基因组和单细胞测序数据的组装。MetaSPAdes 是目前宏基因组组装指标最好的一款软件, 尤其是在株水平上的组装, 同时它也支持 PacBio、Nanopore 和 Sanger 测序数据的混合组装。

### 2.3 病毒分类鉴定

根据分类方法的原理不同, 病毒宏基因组的系统学分类 (Taxonomic classification) 可分为两种 (表 2)。一种是基于相似性比对的分类方法, 该方法通常是将测序原始 reads 数据或组装好的 contigs 数据与参考病毒基因组进行比对。常用的软件有 BLAST 算法中的 Blastn 和 Blastx。但是, 应用该方法大部分的从头组装的序列会被定义为未知病毒, 并且当有大量的宏基因组数据去比对核酸和蛋白数据库时, 该方法会非常耗时。因此, 近年来出现了针对测序原始数据比对方法, 如 Bowtie<sup>[66]</sup>、BWA<sup>[67]</sup>、Minimap2<sup>[68]</sup>等, 通常它们也会应用于过滤步骤且仅比对核酸序列。另外, 远源蛋白质之间的同源性比较, 可采用基于隐马尔科夫模型(Hidden Markov model, HMM)的方法去鉴定保守的蛋白结构域, 软件主要有 HMMER<sup>[69]</sup>、ClassyFlu<sup>[70]</sup>、Virsorter<sup>[71]</sup>、MetLab<sup>[72]</sup>等。另一种方法是基于基因组组成(如 GC 含量、密码子和 k-mers 使用等)应用机器学习或深度学习算法进行病毒分类的方法。应用这类方法的软件有 NBC<sup>[73]</sup>、VirFinder<sup>[74]</sup>、DeepVirFinder<sup>[75]</sup>、ViraMiner<sup>[76]</sup>、Seeker<sup>[77]</sup>等。NBC 是最早的应用朴素贝叶斯算法对病毒进行分类的网页服务器。VirFinder 基于 k-mers 的使用频率应用机器学习算法来鉴定病毒序列。另外, DeepVirFinder、ViraMiner 和 Seeker 软件都是基于深度学习的算

法进行病毒序列鉴定。这类方法的优势是不涉及同源比对, 速度更快。但是相比于基于相似性比对的方法, 该法的准确性较低且很大程度上依赖于序列的长度。

用于病毒分类鉴定的病毒基因组参考数据库有很多, 最常用的数据为 NCBI 中的病毒基因组数据库, 截至 2020 年 6 月, 该数据库中存储了 9 732 个完整的病毒基因组 (<https://www.ncbi.nlm.nih.gov/genomes/GenomesGroup.cgi?taxid=10239>)。virSITE 是一个整合的病毒基因组数据库, 截至 2020 年 2 月, 该数据库中包括了 9 255 种病毒 (11 988 个病毒基因组序列)<sup>[78]</sup>。这两个数据库包含了目前能够鉴定到的所有病毒基因组, 为研究各种环境样本中病毒的全貌提供了重要参考, 同时也为病毒的分类研究奠定了数据基础。一些真核病毒 (如流感病毒、埃博拉病毒、乙肝病毒以及 2020 年暴发的新型冠状病毒等) 常常作为病原感染人类细胞, 造成严重的人类疾病甚至死亡。针对这类病毒组的研究, 专一性病毒基因组数据库应运而生。例如, RVDB 数据库<sup>[79]</sup>提供除细菌病毒 (噬菌体) 外所有的真核病毒、类病毒和病毒相关序列, 如内源性非逆转录病毒元件、内源性逆转录病毒和逆转录病毒等。ViPR 数据库 (<https://www.viprbrc.org>)<sup>[80]</sup>是一个专门针对冠状病毒的一站式资源库和在线分析工具。它收集包括序列、基因、蛋白注释、蛋白 3D 结构、免疫表位、临床和检测等数据, 同时提供序列比对、系统进化分析、序列变异测定和引物设计等实用工具。此外, 还有一些侧重于特定病毒群体的数据库, 如流感病毒数据库 OpenFluDB<sup>[81]</sup>和 Influenza Research Database (IRD)<sup>[82]</sup>、埃博拉病毒知识库 Ebola-KB<sup>[83]</sup>、乙肝病毒数据库 HBVdb<sup>[84]</sup>等。OpenFluDB 是一个开放式的流感病毒数据库, 其包含了病毒基因组和蛋白序列数据, 以及来自 25 000 多个分离物的流行病学数据。IRD 数据库是由美国过敏症和传染病研究所 (National Institute of Allergy and Infectious

Diseases, NIAID)建立，专门研究流感病毒的综合数据库。它提供了关于流感病毒的各种数据，同时也提供用于流感数据挖掘的分析可视化工具。Ebola-KB 是一个专一收集埃博拉病毒

相关信息的整合知识库。HBVdb 为研究人员研究乙肝病的遗传变异和病毒对治疗的耐药性提供丰富的资源，截至 2020 年 7 月该数据库已包含 89 543 个条目。

**表 2 病毒分类鉴定及下游分析工具**

**Table 2 A summary of viral classification and downstream analysis tools**

Name	Description	Web address	Reference
<b>Viral classification</b>			
Bowtie	Short reads sequence alignment	<a href="http://bowtie-bio.sourceforge.net/index.shtml">http://bowtie-bio.sourceforge.net/index.shtml</a>	[55]
BWA	Short reads sequence alignment	<a href="http://bio-bwa.sourceforge.net/">http://bio-bwa.sourceforge.net/</a>	[67]
Minimap2	Long reads sequence alignment; faster speed	<a href="https://github.com/lh3/minimap2">https://github.com/lh3/minimap2</a>	[68]
HMMER	Sequence homology search based on HMM	<a href="http://hmmer.org/">http://hmmer.org/</a>	[69]
ClassFlu	Influenza virus identification	<a href="http://bioinf.uni-greifswald.de/ClassyFlu">http://bioinf.uni-greifswald.de/ClassyFlu</a>	[70]
Virsorter	Bacteriophage prediction <i>In silico</i> experimental DESIGN, SImulation	<a href="https://github.com/simroux/VirSorter">https://github.com/simroux/VirSorter</a>	[71]
MetLab	and analysis tool for viral metagenomics studies näive bayes classification tool to classify reads originating from viral and fungal organisms	<a href="https://github.com/norling/metlab">https://github.com/norling/metlab</a>	[72]
NBC	A novel k-mer based tool for identifying viral sequences from assembled metagenomic data	<a href="http://nbc.ece.drexel.edu/">http://nbc.ece.drexel.edu/</a>	[73]
VirFinder	Identifying viruses from metagenomic data by deep learning	<a href="https://github.com/jessieren/VirFinder">https://github.com/jessieren/VirFinder</a>	[74]
DeepVirFin-der	CNN based classifier for detecting viral sequences among metagenomic contigs	<a href="https://github.com/jessieren/DeepVirFinder">https://github.com/jessieren/DeepVirFinder</a>	[75]
ViraMiner	A python library for discriminating between bacterial and phage genomes	<a href="https://github.com/NeuroCSUT/ViraMiner">https://github.com/NeuroCSUT/ViraMiner</a>	[76]
Seeker		<a href="https://github.com/gussow/seeker">https://github.com/gussow/seeker</a>	[77]
<b>Viral genome annotation</b>			
VAPiD	Viral annotation and identification pipeline	<a href="https://github.com/rcc333/VAPiD">https://github.com/rcc333/VAPiD</a>	[90]
VIGOR	An annotation program for small viral genomes Viral genome annotation system combining <i>ab initio</i> method and similarity-based method	<a href="http://www.jcvi.org/vigor">http://www.jcvi.org/vigor</a>	[91]
VGAS		<a href="http://cefg.uestc.cn/vgas/">http://cefg.uestc.cn/vgas/</a>	[92]
VIGA	<i>De novo</i> viral genome annotator	<a href="https://github.com/EGTortuero/viga">https://github.com/EGTortuero/viga</a>	[93]
<b>Evolution analysis</b>			
MEGA	Phylogenetic tree construction	<a href="https://www.megasoftware.net/">https://www.megasoftware.net/</a>	[94]
FastTree	Phylogenetic tree construction	<a href="http://www.microbesonline.org/fasttree/">http://www.microbesonline.org/fasttree/</a>	[95]
IQ-TREE	Phylogenetic tree construction	<a href="http://www.iqtree.org/">http://www.iqtree.org/</a>	[96]
ggtree	Phylogenetic tree beautification; R package	<a href="https://github.com/YuLab-SMU/ggtree">https://github.com/YuLab-SMU/ggtree</a>	[97]
GraPhAn	Evolutionary branching diagram visualization	<a href="https://huttenhower.sph.harvard.edu/graphlan">https://huttenhower.sph.harvard.edu/graphlan</a>	[98]
TreeView	Phylogenetic tree visualization and editing	<a href="https://treeview.co.uk/">https://treeview.co.uk/</a>	[99]
FigTree	Phylogenetic tree visualization and editing Phylogenetic tree visualization, online editing	<a href="https://github.com/rambaut/figtree">https://github.com/rambaut/figtree</a>	
ITOL	and beautification support	<a href="https://itol.embl.de/">https://itol.embl.de/</a>	[100]

## 2.4 多样性分析

与细菌宏基因组多样性分析一致，病毒物种多样性也分为 3 类：alpha 多样性、beta 多样性、gamma 多样性。Alpha 多样性是指在一个确定的栖息环境、研究区域或者样本内存在物种的个数 (Species richness；物种丰富度) 以及每个物种的数量和分布 (Species evenness；物种均匀度)，也被称为样本内物种多样性。度量方法有 Shannon 指数<sup>[85]</sup>、Chao1<sup>[86]</sup>、ACE 指数<sup>[87]</sup>等。Beta 多样性指与环境复杂梯度和环境模式相关的群体组成变化程度或群体分化程度，也被称为样本间的多样性。多种距离方法被用于表示 beta 多样性，常用的方法有 Bray-Curtis 距离 (基于物种的数量测量样本间相异度)、Jaccard 距离 (基于物种的存在与否测量样本间相异度) 和 UniFrac 距离 (结合了进化信息来测量样本间相异度) 等<sup>[88]</sup>。Gamma 多样性是指大区域 (地理区域) 上总的多样性，其包含了 alpha 多样性和 beta 多样性。另外，一些分析技术的限制，如病毒注释不准确、缺乏系统发育标记基因以及个体差异大等，会使病毒的多样性研究复杂化，从而产生大量未被正确分类注释的序列，或者仅在几个样本中鉴定到特异的病毒，生成稀疏数据，即包含大量零的数据矩阵。因此，随后的分析应格外注意。统计分析及可视化大多使用 R 语言，常用的 R 包可参考刘永鑫等<sup>[89]</sup>的报道。

## 2.5 功能注释及进化分析

为确定病毒的功能，病毒基因组注释是常用的数据分析手段。目前针对病毒基因组注释的工具有 VAPiD<sup>[90]</sup>、VIGOR<sup>[91]</sup>、VGAS<sup>[92]</sup>、VIGA<sup>[93]</sup>等 (表 2)。VAPiD 通过与 GenBank 数据库比较来对每个输入的病毒序列进行注释，并提供元数据 (metadata)，从而简化向 GenBank 提交完整病毒基因组序列的过程。VIGOR 通过首先识别其集合中最相关的参考数据库，然后将该数据库中所有参考蛋白和成熟肽序列与输入序列进行比较，以确定其注释，

从而对输入序列进行注释。但是，这两个程序都会检测并报告某些类型的意外错误，例如过早的终止密码子。VGAS 结合 ORF 计算预测和序列相似比对这两种策略对病毒基因组进行注释。VIGA 对于大型宏基因组的注释速度更快，且能够识别不同类型 RNA 及 CRISPR 重复元件。

进化分析不仅能提供病毒之间亲缘关系，同时也能追溯病毒物种的起源。其核心步骤是构建系统发育树。而系统发育树的构建可分为两种：基于距离的方法和基于特征的方法。基于距离的方法包括具有算术平均值的非加权成对组方法 (UPGMA)、邻接法 (NJ)、最小演化法 (ME) 和 Fitch-Margoliash 方法 (FM)。基于特征的方法包括最大简约方法 (MP) 和最大似然方法 (ML)。比较计算速度，NJ 方法优于当前正在使用的其他系统发育树构建方法。该方法可以使用自展法 (bootstrap) 轻松处理大量序列，而 MP、ME 和 ML 方法会检查所有可能的拓扑结构分别搜索 MP、ME 和 ML 树，因此耗费时间较多。系统发育树的构建可以使用 MEGA<sup>[94]</sup>、FastTree<sup>[95]</sup>、IQ-TREE<sup>[96]</sup>等软件。另外，构建好的系统发育树可以应用 ggtree<sup>[97]</sup>、GraPhlAn<sup>[98]</sup>、TreeView<sup>[99]</sup>、FigTree (<https://github.com/rambaut/figtree/>) 和在线网站 ITOL<sup>[100]</sup>对其进行美化 (表 2)。

## 3 总结与展望

相比于细菌和宿主来源的基因组，病毒基因组很小且仅占微生物总量的一小部分，因此病毒颗粒的富集是非常有必要的。随着病毒组研究的快速发展，已经出现了许多富集病毒的方法。这些富集方法根据富集过程中应用的病毒物理学特性，大致分为 3 类：基于过滤的病毒颗粒富集方法；基于离心的病毒颗粒富集方法；其他富集方法。每一种富集方法都有各自的适应性和优缺点，充分了解这些富集方法的原理及优缺点，对于实验方案的设计和后续数据的分析具有重要的参考

意义。另外，根据研究目的和实验对象的不同，仅用一种方法可能不足以达到富集全部病毒的目的，所以这时候需要综合考虑选取的病毒颗粒富集方法或者配合使用多种富集方法，最终尽可能呈现各类样品中真实的病毒丰度和分布。例如，海洋病毒组研究应先过滤藻类等大颗粒物质，然后结合普通过滤和 TFF 方法进一步浓缩病毒粒子。有时为得到更加纯净且高浓度的病毒粒子，有些研究会再使用 PEG 和  $\text{FeCl}_3$  沉淀法进行富集<sup>[5, 17]</sup>。而在土壤和人体肠道病毒组研究中，实验人员可以采取过滤与超速离心或 PEG 沉淀等多种方式相结合的策略，以最大程度地获得更多的病毒颗粒。应用各类病毒粒子富集方法，研究人员大大提高了病毒组研究的分析效率和精确度，并在多种环境得到应用，如 *Tara* 海洋病毒组 (TOV)<sup>[5]</sup>、太平洋病毒组 (POV)<sup>[17]</sup>、新生儿肠道病毒组<sup>[28]</sup>、南非和中国东部沿海地区土壤病毒群落基因组<sup>[15, 32]</sup>等。然而，目前的实验方法常需要较大样本量且不能直观地观察富集得到的病毒粒子，仅能通过测序手段来检验病毒粒子的多样性。对于一些稀有或特殊的样本，常常不能满足需求。最近开发的基于流式细胞仪的方法可以通过用荧光染料标记噬菌体从背景微生物群中分离出 VLPs<sup>[101]</sup>，然后根据 VLPs 的大小和荧光水平选择 VLPs，并使用荧光激活细胞分选法从样品中去除。另外，实验的批次效应也需格外注意，研究者需严格遵守实验步骤，规避每一步由于操作造成较大误差的风险。

随着宏基因组分析技术和测序技术的发展，人们已经获得大量的病毒数据。例如，整合的人类肠道病毒数据 (Human Gut Virome Database, GVD)<sup>[11]</sup>、脊椎动物和无脊椎动物病毒组<sup>[12-13]</sup>、深海热泉泉口病毒组<sup>[102]</sup>等，极大地扩充了病毒的多样性进而加深了研究人员对病毒组学的理解。同时，高通量测序会产生大量的基因组数据，进而增大对生物信息工具和算法开发的需求。至此，我们对病毒宏基因组学数据分析的一般流程进行

综述，包括了数据预处理、病毒基因组组装、物种鉴定、多样性分析、功能注释及进化分析，并针对每一步骤所需常用生物信息分析工具进行了简要介绍。由于缺乏保守的系统发育标记基因（如细菌和古菌的 16S rRNA），且测序得到的大量序列在已知病毒基因组数据库中难以找到对应物<sup>[103]</sup>，致使病毒物种的鉴定仍然是当前最具挑战的分析步骤。虽然机器学习和人工智能领域的飞速发展，使得基于基因组组成的病毒物种鉴定工具逐渐增多，但是相比于基于比对的鉴定方法，其灵敏度和准确性还有待进一步提高。此外，相比传统的基于培养的病毒研究，病毒宏基因组学虽然能检测出更多的病毒，极大地扩展了人们对病毒丰度和多样性的认识，但是仍存在分辨率低的缺点，难以区分相似度很高的序列。基于培养的病毒研究结合透射电子显微观察的方法不仅能够识别病毒形态，还能够鉴定噬菌体的宿主。单一病毒的研究能够揭示病毒群体的遗传异质性。因此，宏病毒组学应与单病毒基因组学、分离培养与显微镜观测结合来探索病毒暗物质。

## REFERENCES

- [1] Rampelli S, Turroni S, Schnorr SL, et al. Characterization of the human DNA gut virome across populations with different subsistence strategies and geographical origin. *Environ Microbiol*, 2017, 19(11): 4728–4735.
- [2] Williamson KE, Fuhrmann JJ, Wommack KE, et al. Viruses in soil ecosystems: an unknown quantity within an unexplored territory. *Ann Rev Virol*, 2017, 4: 201–219.
- [3] Wommack KE, Nasko DJ, Chopyk J, et al. Counts and sequences, observations that continue to change our understanding of viruses in nature. *J Microbiol*, 2015, 53(3): 181–192.
- [4] Zhang YZ, Shi M, Holmes EC. Using metagenomics to characterize an expanding virosphere. *Cell*, 2018, 172(6): 1168–1172.
- [5] Brum JR, Ignacio-Espinoza JC, Roux S, et al. Patterns and ecological drivers of ocean viral

- communities. *Science*, 2015, 348(6237): 1261498.
- [6] Nooij S, Schmitz D, Vennema H, et al. Overview of virus metagenomic classification methods and their biological applications. *Front Microbiol*, 2018, 9: 749.
- [7] Rose R, Constantinides B, Tapinos A, et al. Challenges in the analysis of viral metagenomes. *Virus Evol*, 2016, 2(2): vew022.
- [8] Coutinho FH, Silveira CB, Gregoracci GB, et al. Marine viruses discovered via metagenomics shed light on viral strategies throughout the oceans. *Nat Commun*, 2017, 8: 15955.
- [9] Rascovan N, Duraisamy R, Desnues C. Metagenomics and the human virome in asymptomatic individuals. *Annu Rev Microbiol*, 2016, 70: 125–141.
- [10] Paez-Espino D, Eloe-Fadrosh EA, Pavlopoulos GA, et al. Uncovering Earth's virome. *Nature*, 2016, 536(7617): 425–430.
- [11] Gregory AC, Zablocki O, Zayed AA, et al. The gut virome database reveals age-dependent patterns of virome diversity in the human gut. *Cell Host Microbe*, 2020, 28: 1–17. doi: 10.1016/j.chom.2020.08.003.
- [12] Shi M, Lin XD, Tian JH, et al. Redefining the invertebrate RNA virosphere. *Nature*, 2016, 540(7634): 539–543.
- [13] Shi M, Lin XD, Chen X, et al. The evolutionary history of vertebrate RNA viruses. *Nature*, 2018, 556(7700): 197–202.
- [14] Breitbart M, Rohwer F. Method for discovering novel DNA viruses in blood using viral particle selection and shotgun sequencing. *Biotechniques*, 2005, 39(5): 729–736.
- [15] Yu DT, Han LL, Zhang LM, et al. Diversity and distribution characteristics of viruses in soils of a marine-terrestrial ecotone in east China. *Microb Ecol*, 2018, 75(2): 375–386.
- [16] Bahram M, Hildebrand F, Forslund SK, et al. Structure and function of the global topsoil microbiome. *Nature*, 2018, 560(7717): 233–237.
- [17] Hurwitz BL, Sullivan MB. The Pacific Ocean Virome (POV): a marine viral metagenomic dataset and associated protein clusters for quantitative viral ecology. *PLoS ONE*, 2013, 8(2): e57355.
- [18] Hurwitz BL, Deng L, Poulos BT, et al. Evaluation of methods to concentrate and purify ocean virus communities through comparative, replicated metagenomics. *Environ Microbiol*, 2013, 15(5): 1428–1440.
- [19] Castro-Mejía JL, Deng L, Vogensen FK, et al. Extraction and purification of viruses from fecal samples for metagenome and morphology analyses. *Methods Mol Biol*, 2018, 1838: 49–57.
- [20] Shkporov AN, Ryan FJ, Draper LA, et al. Reproducible protocols for metagenomic analysis of human faecal phageomes. *Microbiome*, 2018, 6: 68.
- [21] Minot S, Sinha R, Chen J, et al. The human gut virome: inter-individual variation and dynamic response to diet. *Genome Res*, 2011, 21(10): 1616–1625.
- [22] Thurber RV, Haynes M, Breitbart M, et al. Laboratory procedures to generate viral metagenomes. *Nat Protocols*, 2009, 4(4): 470–483.
- [23] López-Bueno A, Tamames J, Velázquez D, et al. High diversity of the viral community from an Antarctic lake. *Science*, 2009, 326(5954): 858–861.
- [24] Gu XQ, Tay QXM, Te SH, et al. Geospatial distribution of viromes in tropical freshwater ecosystems. *Water Res*, 2018, 137: 220–232.
- [25] Fumian TM, Fioretti JM, Lun JH, et al. Detection of norovirus epidemic genotypes in raw sewage using next generation sequencing. *Environ Int*, 2019, 123: 282–291.
- [26] Rosiles-González G, Ávila-Torres G, Moreno-Valenzuela OA, et al. Occurrence of *Pepper Mild Mottle Virus* (PMMoV) in groundwater from a karst aquifer system in the Yucatan Peninsula, Mexico. *Food Environ Virol*, 2017, 9(4): 487–497.
- [27] Lim ES, Zhou YJ, Zhao GY, et al. Early life dynamics of the human gut virome and bacterial microbiome in infants. *Nat Med*, 2015, 21(10): 1228–1234.
- [28] Maqsood R, Rodgers R, Rodriguez C, et al. Discordant transmission of bacteria and viruses from mothers to babies at birth. *Microbiome*, 2019, 7: 156.
- [29] Liang GX, Zhao CY, Zhang HJ, et al. The stepwise assembly of the neonatal virome is modulated by breastfeeding. *Nature*, 2020, 581(7809): 470–474.
- [30] Shkporov AN, Clooney AG, Sutton TDS, et al. The human gut virome is highly diverse, stable, and

- individual specific. *Cell Host Microbe*, 2019, 26(4): 527–541.e5.
- [31] Graham EB, Paez-Espino D, Brislawn C, et al. Untapped viral diversity in global soil metagenomes. *bioRxiv*, 2019, 583997.
- [32] Segobola J, Adriaenssens E, Tsekao T, et al. Exploring viral diversity in a unique south african soil habitat. *Sci Rep*, 2018, 8: 111.
- [33] Adriaenssens EM, Kramer R, Van Goethem MW, et al. Environmental drivers of viral community composition in Antarctic soils identified by viromics. *Microbiome*, 2017, 5: 83.
- [34] Thurber RLV, Barott KL, Hall D, et al. Metagenomic analysis indicates that stressors induce production of herpes-like viruses in the coral *Porites compressa*. *Proc Natl Acad Sci USA*, 2008, 105(47): 18413–18418.
- [35] Legoff J, Resche-Rigon M, Bouquet J, et al. The eukaryotic gut virome in hematopoietic stem cell transplantation: new clues in enteric graft-versus-host disease. *Nat Med*, 2017, 23(9): 1080–1085.
- [36] Wilhelm SW, Weinbauer MG, Suttle CA, et al. Filtration-based methods for the collection of viral concentrates from large water samples. Manual of Aquatic Viral Ecology. Advancing the Science for Limnology and Oceanography, 2010: 110–117.
- [37] Lawrence JE, Steward GF. Purification of viruses by centrifugation. Manual of Aquatic Viral Ecology. Advancing the Science for Limnology and Oceanography, 2010: 166–181.
- [38] Cao JB, Zhang YQ, Dai M, et al. Profiling of human gut virome with oxford nanopore technology. *Med Microecol*, 2020, 4: 100012.
- [39] Nasukawa T, Uchiyama J, Taharaguchi S, et al. Virus purification by CsCl density gradient using general centrifugation. *Arch Virol*, 2017, 162(11): 3523–3528.
- [40] Zhu BT, Clifford DA, Chellam S. Virus removal by iron coagulation-microfiltration. *Water Res*, 2005, 39(20): 5153–5161.
- [41] Chang SL, Stevenson RE, Bryant AR, et al. Removal of Coxsackie and bacterial viruses in water by flocculation. II. Removal of Coxsackie and bacterial viruses and the native bacteria in raw Ohio River water by flocculation with aluminum sulfate and ferric chloride. *Am J Public Health*, 1958, 48(2): 159–169.
- [42] Johnson JH, Fields JE, Darlington WA. Removing viruses from water by polyelectrolytes. *Nature*, 1967, 213(5077): 665–667.
- [43] John SG, Mendez CB, Deng L, et al. A simple and efficient method for concentration of ocean viruses by chemical flocculation. *Environ Microbiol Rep*, 2011, 3(2): 195–202.
- [44] Bellas CM, Anesio AM, Barker G. Analysis of virus genomes from glacial environments reveals novel virus groups with unusual host interactions. *Front Microbiol*, 2015, 6: 656.
- [45] Poulos BT, John SG, Sullivan MB. Iron chloride flocculation of bacteriophages from seawater. *Methods Mol Biol*, 2018, 1681: 49–57.
- [46] Lewis GD, Metcalf TG. Polyethylene glycol precipitation for recovery of pathogenic viruses, including hepatitis A virus and human rotavirus, from oyster, water, and sediment samples. *Appl Environ Microbiol*, 1988, 54(8): 1983–1988.
- [47] Kleiner M, Hooper LV, Duerkop BA. Evaluation of methods to purify virus-like particles for metagenomic sequencing of intestinal viromes. *BMC Genomics*, 2015, 16(1): 7.
- [48] Göller PC, Haro-Moreno JM, Rodriguez-Valera F, et al. Uncovering a hidden diversity: optimized protocols for the extraction of dsDNA bacteriophages from soil. *Microbiome*, 2020, 8: 17.
- [49] Trubl G, Jang HB, Roux S, et al. Soil viruses are underexplored players in ecosystem carbon processing. *mSystems*, 2018, 3(5): e00076–18.
- [50] Trubl G, Solonenko N, Chittick L, et al. Optimization of viral resuspension methods for carbon-rich soils along a permafrost thaw gradient. *Peer J*, 2016, 4: e1999.
- [51] Mirzaei MK, Xue JL, Costa R, et al. Challenges of studying the human virome-relevant emerging technologies. *Trends Microbiol*, 2020, doi: 10.1016/j.tim.2020.05.021.
- [52] Martin M. Cutadapt removes adapter sequences from high-throughput sequencing reads. *EMBnet J*, 2011, 17: 3.
- [53] Bolger AM, Lohse M, Usadel B. Trimmomatic: a flexible trimmer for Illumina sequence data.

- Bioinformatics, 2014, 30(15): 2114–2120.
- [54] Chen SF, Zhou YQ, Chen YR, et al. fastp: an ultra-fast all-in-one FASTQ preprocessor. Bioinformatics, 2018, 34(17): i884–i890.
- [55] Langmead B, Salzberg SL. Fast gapped-read alignment with Bowtie 2. Nat Methods, 2012, 9(4): 357–359.
- [56] Altschul SF, Gish W, Miller W, et al. Basic local alignment search tool. J Mol Biol, 1990, 215(3): 403–410.
- [57] Li ZY, Chen YX, Mu DS, et al. Comparison of the two major classes of assembly algorithms: overlap-layout-consensus and de-bruijn-graph. Brief Funct Genomics, 2012, 11(1): 25–37.
- [58] Chevreux B, Wetter T, Suhai S. Genome sequence assembly using trace signals and additional sequence information. J Computer Sci Syst Biol, 1999, 99: 45–56.
- [59] Koren S, Walenz BP, Berlin K, et al. Canu: scalable and accurate long-read assembly via adaptive  $k$ -mer weighting and repeat separation. Genome Res, 2017, 27(5): 722–736.
- [60] Simpson JT, Wong K, Jackman SD, et al. ABYSS: a parallel assembler for short read sequence data. Genome research, 2009, 19(6): 1117–1123.
- [61] Peng Y, Leung HCM, Yiu SM, et al. IDBA-UD: a *de novo* assembler for single-cell and metagenomic sequencing data with highly uneven depth. Bioinformatics, 2012, 28(11): 1420–1428.
- [62] Luo RB, Liu BH, Xie YL, et al. SOAPdenovo2: an empirically improved memory-efficient short-read *de novo* assembler. GigaScience, 2012, 1(1): 18.
- [63] Li DH, Liu CM, Luo RB, et al. MEGAHIT: an ultra-fast single-node solution for large and complex metagenomics assembly via succinct *de Bruijn* graph. Bioinformatics, 2015, 31(10): 1674–1676.
- [64] Nurk S, Meleshko D, Korobeynikov A, et al. metaSPAdes: a new versatile metagenomic assembler. Genome Res, 2017, 27(5): 824–834.
- [65] Berlin K, Koren S, Chin CS, et al. Assembling large genomes with single-molecule sequencing and locality-sensitive hashing. Nat Biotechnol, 2015, 33(6): 623–630.
- [66] Langmead B, Trapnell C, Pop M, et al. Ultrafast and memory-efficient alignment of short DNA sequences to the human genome. Genome Biol, 2009, 10(3): R25.
- [67] Li H, Durbin R. Fast and accurate short read alignment with Burrows-Wheeler transform. Bioinformatics, 2009, 25(14): 1754–1760.
- [68] Li H. Minimap2: pairwise alignment for nucleotide sequences. Bioinformatics, 2018, 34(18): 3094–3100.
- [69] Mistry J, Finn RD, Eddy SR, et al. Challenges in homology search: HMMER3 and convergent evolution of coiled-coil regions. Nucleic Acids Res, 2013, 41(12): e121.
- [70] Van Der Auwera S, Bulla I, Ziller M, et al. ClassyFlu: classification of influenza a viruses with discriminatively trained profile-HMMs. PLoS ONE, 2014, 9(1): e84558.
- [71] Roux S, Enault F, Hurwitz BL, et al. VirSorter: mining viral signal from microbial genomic data. PeerJ, 2015, 3: e985.
- [72] Norling M, Karlsson-Lindsjö OE, Gourlé H, et al. MetLab: an *in silico* experimental design, simulation and analysis tool for viral metagenomics studies. PLoS ONE, 2016, 11(8): e0160334.
- [73] Rosen GL, Reichenberger ER, Rosenfeld AM. NBC: the naive bayes classification tool webserver for taxonomic classification of metagenomic reads. Bioinformatics, 2011, 27(1): 127–129.
- [74] Ren J, Ahlgren NA, Lu YY, et al. VirFinder: a novel  $k$ -mer based tool for identifying viral sequences from assembled metagenomic data. Microbiome, 2017, 5: 69.
- [75] Ren J, Song K, Deng C, et al. Identifying viruses from metagenomic data using deep learning. Quantitat Biol, 2020, 8(1): 64–77.
- [76] Tampuu A, Bzhalava Z, Dillner J, et al. ViraMiner: deep learning on raw DNA sequences for identifying viral genomes in human samples. PLoS ONE, 2019, 14(9): e0222271.
- [77] Auslander N, Gussow AB, Benler S, et al. Seeker: Alignment-free identification of bacteriophage genomes by deep learning. bioRxiv, 2020, doi: 10.1101/2020.04.04.025783.
- [78] Stano M, Beke G, Klucar L. viruSITE-integrated database for viral genomics. Database (Oxford), 2016, 2016: baw162.
- [79] Goodacre N, Aljanahi A, Nandakumar S, et al. A

- Reference Viral Database (RVDB) to enhance bioinformatics analysis of high-throughput sequencing for novel virus detection. *mSphere*, 2018, 3(2): e00069-18.
- [80] Pickett BE, Sadat EL, Zhang Y, et al. ViPR: an open bioinformatics database and analysis resource for virology research. *Nucleic acids research*, 2012, 40(D1): D593–D598.
- [81] Liechti R, Gleizes A, Kuznetsov D, et al. OpenFluDB, a database for human and animal influenza virus. *Database (Oxford)*, 2010, 2010: baq004.
- [82] Zhang Y, Aevermann BD, Anderson TK, et al. Influenza research database: an integrated bioinformatics resource for influenza virus research. *Nucleic Acids Res*, 2017, 45(D1): D466–D474.
- [83] Kamdar MR, Dumontier M. An Ebola virus-centered knowledge base. *Database (Oxford)*, 2015, 2015: bav049.
- [84] Hayer J, Jadeau F, Deléage G, et al. HBVdb: a knowledge database for Hepatitis B Virus. *Nucleic Acids Res*, 2013, 41(D1): D566–D570.
- [85] Whittaker RH. Evolution and measurement of species diversity. *Taxon*, 1972, 21(2/3): 213–251.
- [86] Chao A. Nonparametric estimation of the number of classes in a population. *Scand J Stat*, 1984, 11(4): 265–270.
- [87] Chao A, Lee SM. Estimating the number of classes via sample coverage. *J Am Stat Assoc*, 1992, 87(417): 210–217.
- [88] Whittaker RH. Vegetation of the siskiyou mountains, oregon and California. *Ecol Monogr*, 1960, 30(3): 279–338.
- [89] Liu YX, Qin Y, Guo XX, et al. Methods and applications for microbiome data analysis. *Hereditas (Beijing)*, 2019, 41(9): 845–862 (in Chinese).  
刘永鑫, 秦媛, 郭晓璇, 等. 微生物组数据分析方法与应用. *遗传*, 2019, 41(9): 845–862.
- [90] Shean RC, Makhsoos N, Stoddard GD, et al. VAPiD: a lightweight cross-platform viral annotation pipeline and identification tool to facilitate virus genome submissions to NCBI GenBank. *BMC Bioinformatics*, 2019, 20: 48.
- [91] Wang SL, Sundaram JP, Spiro D. VIGOR, an annotation program for small viral genomes. *BMC Bioinformatics*, 2010, 11: 451.
- [92] Zhang KY, Gao YZ, Du MZ, et al. Vgas: a viral genome annotation system. *Front Microbiol*, 2019, 10: 184.
- [93] González-Tortuero E, Sutton TDS, Velayudhan V, et al. VIGA: a sensitive, precise and automatic *de novo* viral genome annotator. *bioRxiv*, 277509, 2018.
- [94] Kumar S, Stecher G, Li M, et al. MEGA X: molecular evolutionary genetics analysis across computing platforms. *Mol Biol Evol*, 2018, 35(6): 1547–1549.
- [95] Price MN, Dehal PS, Arkin AP. FastTree: computing large minimum evolution trees with profiles instead of a distance matrix. *Mol Biol Evol*, 2009, 26(7): 1641–1650.
- [96] Nguyen LT, Schmidt HA, Von Haeseler A, et al. IQ-TREE: a fast and effective stochastic algorithm for estimating maximum-likelihood phylogenies. *Mol Biol Evol*, 2015, 32(1): 268–274.
- [97] Yu GC. Using ggtree to visualize data on tree-like structures. *Curr Protoc Bioinformatics*, 2020, 69(1): e96.
- [98] Asnicar F, Weingart G, Tickle TL, et al. Compact graphical representation of phylogenetic data and metadata with GraPhAn. *PeerJ*, 2015, 3: e1029.
- [99] Page RDM. Visualizing phylogenetic trees using TreeView. *Curr Protoc Bioinformatics*, 2003, (1): 6.2.1–6.2.15.
- [100] Letunic I, Bork P. Interactive Tree Of Life (iTOL) v4: recent updates and new developments. *Nucleic Acids Res*, 2019, 47(W1): W256–W259.
- [101] Džunková M, D'Auria G, Moya A. Direct sequencing of human gut virome fractions obtained by flow cytometry. *Front Microbiol*, 2015, 6: 955.
- [102] Castelán-Sánchez HG, Lopéz-Rosas I, García-Suastegui WA, et al. Extremophile deep-sea viral communities from hydrothermal vents: Structural and functional analysis. *Mar Genomics*, 2019, 46: 16–28.
- [103] Fancello L, Raoult D, Desnues C. Computational tools for viral metagenomics and their application in clinical research. *Virology*, 2012, 434(2): 162–174.

(本文责编 郝丽芳)