

GSA 和 BIGD — 填补我国生物信息资源服务的空白

北京大学生命科学学院、北京大学国家蛋白质和植物研究重点实验室、北京大学生物信息中心, 北京 100871, luojc@pku.edu.cn

Genomics Proteomics and Bioinformatics 期刊 (GPB) 2017 年第一期发表了一篇数据库专题论文“基因组序列归档库”(Genome Sequence Archive, 简称 GSA)^[1]。作者来自中国科学院北京基因组研究所大数据中心 (Big Data Center, Beijing Institute of Genomics, 简称 BIGD), 文中对他们开发的 GSA 平台作了简要介绍。该平台旨在收集、整合和发布国内外用户递交的原始序列数据。GSA 项目是基因组所大数据中心正在进行的几个主要研究开发项目之一, 该中心由近 50 位年轻的生物信息学研究开发人员组成。除 GSA 项目外, 还开展了多项面向生物信息资源服务的课题^[2]。应 GPB 编辑部邀请, 笔者写了一篇短文, 简单回顾国际生物信息数据库创建历史, 并向读者推荐 GSA 平台和 BIGD 团队的工作。文章以 Preview 形式发表在同一期的 GPB 上, 原文为英文^[3]; 特撰写此中文稿, 以飨国内读者。

最近半个多世纪以来, 分子生物学取得了长足的进展。DNA 双螺旋的发现、遗传密码的破解、中心法则的提出, 为分子生物学研究奠定了坚实的理论基础。与此同时, 费雷德里克·桑格 (Frederick Sanger) 等先后建立了蛋白质、tRNA 和 DNA 序列测定方法, 约翰·肯德鲁 (John Kendrew) 和马克斯·佩鲁茨 (Max Perutz) 解决了 X-射线晶体衍射解析蛋白质三维空间结构的难题。这些开拓性的研究, 为日后分子生物学数据积累提供了必不可少的技术储备。

蛋白质序列数据库

最早从事蛋白质序列收集的是美国国家生物医学研究基金会 (National Biomedical Research Foundation, 简称 NBRF) 的生物信息学先驱玛格蕾特·戴霍芙 (Margaret Dayhoff) 博士 (https://en.wikipedia.org/wiki/Margaret_Oakley_Dayhoff)。1965 年, 她把当时能收集到的 65 个蛋白质信息编纂成册, 并以《蛋白质序列和结构图册》(Atlas of protein sequence and structure) 为名公开发表, 并在以后的几年中不断更新再版。这就是国际上第一个蛋白质序列数据库“蛋白质信息资源”(Protein Information Resource, 简称 PIR) 的雏形。基于收集到的蛋白质家族序列, 戴霍芙构建了氨基酸替换计分矩阵 PAM, 至今仍广泛用于序列比对和数据库相似性搜索。PIR 于 1984 年正式上线, 用户可通过电话网络进行查询。两年后, 瑞士日内瓦大学在读研究生埃姆斯·贝洛克 (Amos Bairoch) 开始对蛋白质序列进行人工注释 (https://en.wikipedia.org/wiki/Amos_Bairoch), 为每个序列条目添加功能和相关文献等信息, 并在此基础上创建了著名的“瑞士蛋白质序列数据库”(Swiss-Prot)。

蛋白质结构数据库

第一个蛋白质结构数据库（Protein Data Bank, 简称 PDB）创建于 1971 年。与蛋白质序列数据库分别诞生于美国和欧洲不同，PDB 的建立是欧美两国合作者共同努力的结果。1971 年，英国剑桥晶体学数据中心（Crystallographic Data Center）和美国布鲁克海文国家实验室（Brookhaven National Laboratory）在《自然：新生物学》（Nature: New Biology）发布短讯，宣告该数据库系统开始运行^[4]。双方各自保存相同的数据文件，并免费向用户发布。1998 年，美国结构生物信息学研究协作组（Research Collaboratory for Structural Bioinformatics, 简称 RSCB）成立，负责蛋白质结构数据库运行，称 RSCB PDB。

核酸序列数据库

70 年代末，由桑格等建立的 DNA 测序方法日趋成熟，核酸序列开始积累。欧美各国知识分子敏锐地意识到，大规模测序很快就会到来，建立核酸序列数据库的任务已经提上议事日程。1979 年，美国能源部下属洛斯阿拉莫斯国家实验室（Los Alamos National Laboratory）沃特·高德（Walter Goad）领导的计算生物学研究组开始利用计算机收集核酸序列，并开发序列分析计算机软件，著名的序列局部比对 Smith-Waterman 算法也因此应运而生。获美国国立健康研究院（National Institute of Health, 简称 NIH）以及科学基金会（National Science Foundation, 简称 NSF）、能源部（Department of Energy, 简称 DOE）和国防部（Department of Defense, 简称 DOD）等部门资助，核酸序列数据库 GenBank 开始运行。就在同一年，位于德国海德堡的欧洲分子生物学实验室（European Molecular Biology Laboratory, 简称 EMBL）发布了欧洲版的核酸序列数据库 EMBL-Bank，有时也简称 EMBL。

美国国家生物技术信息中心 NCBI

八十年代中后期，核酸、蛋白质序列和蛋白质结构数据库已经积累了相当可观的数据，而基于中小型和微型计算机的序列和结构分析软件也不断涌现。与此同时，由美国科学基金会资助的为科研教育服务的计算机网络 NSFNet 也开始投入使用。1988 年 11 月，由已故参议员克劳德·裴帕尔（Claude Pepper）提议，位于美国首都华盛顿北郊的美国国家生物技术信息中心（National Center for Biotechnology Information, 简称 NCBI）成立。NCBI 隶属美国国家医学图书馆（National Library of Medicine, 简称 NLM），而 NLM 则是美国国家健康研究院（National Institutes of Health, 简称 NIH）的一个下属机构。NCBI 成立初期，仅 8 名人员，经过近 30 年的建设，NCBI 已发展成国际上最大的生物信息中心，著名的数据库搜索软件 BLAST 主要开发者之一大卫·李普曼（David Lipman）担任主任至今。NCBI 拥有上百个数据库和软件工具，包括著名的生物医学文献摘要数据库 PubMed、参考序列数据库 RefSeq、数据库相似性搜索软件 BLAST 等。1989 年，核酸序列数据库 GenBank 也由 NCBI 接管。

欧洲生物信息学研究所 EBI

欧洲生物信息学研究所成立于 1994 年，坐落在英国剑桥南部 12 英里维康基金会 (Wellcome Trust) 基因组园区内。EBI 是欧洲分子生物学实验室 EMBL 的一个下属单位，主要经费来自欧盟，研究人员主要来自西欧各国。经过 20 多年的建设，EBI 已经成为仅次于 NCBI 的国际生物信息中心，为欧洲各国和世界各地用户提供生物信息资源服务，并从事生物信息研究开发。除核酸序列数据库 EMBL 外，EBI 还有许多特色数据库，如基因组数据库 ENSEMBL、蛋白质家族和结构域数据库 InterPro、基因本体数据库 Gene Ontology 等。

三大国际数据库联盟

由美国政府部门资助的国家级生物信息中心 NCBI 和由欧盟资助的生物信息机构 EBI 的成立，为生物信息资源服务提供了人员和经费保障，促成了国际数据库联盟的建立。2003 年，EBI 的蛋白质结构数据库 PDBe，日本蛋白质结构数据库 PDBj 和美国蛋白质结构数据库 RSCB PDB 共同组成国际蛋白质结构数据库联盟 wwPDB (<http://www.wwpdb.org/>)。2005 年，NCBI、EBI 和 1987 年成立的日本核酸序列数据库 DDBJ 达成协议，建立国际核酸序列数据库联盟 (International Nucleotide Sequence Database Collaboration, 简称 INSDC, <http://www.insdc.org/>)。同年，EBI 的 TrEMBL 与 Swiss-Prot 和 PIR 一起，组成了国际上统一的蛋白质序列数据库 UniProt (<http://www.uniprot.org/>)。TrEMBL 是核酸序列数据库 EMBL 中的编码区翻译所得的蛋白质序列。

互联网诞生和大数据时代到来

20世纪90年代诞生的国际互连网，标志着信息时代的到来。正如诺贝尔奖获得者沃特·吉尔伯特 (Walter Gilbert) 于1991年1月发表在Nature上的卓有远见的文章中指出的那样，“我们必须把各自的个人电脑接入全球互联网，以便充分利用日新月异的数据库资源，并通过网络进行直接交流”。他明确指出，生命科学研究面临着一个模式的改变^[5]。十年后的2001年2月，由政府资助的人类基因组计划协作组和美国Celera公司分别发布了人类基因组草图^[6,7]，标志着基因组学研究进入了一个新阶段。得益于高通量、低成本的新一代测序技术的快速发展，数以万计的基因组和宏基因组已经测定。根据基因组在线数据库的统计数据^[8]，265,734个不同个体的基因组测序已经完成或正在进行 (GOLD, <https://gold.jgi.doe.gov/>)。毋庸置疑，大数据革命将在未来几年中极大影响分子生物学研究，而数据收集和发布是必不可少的重要步骤^[9]。

GSA 项目和基因组所大数据中心 BIGD

近三十年来，尽管我国生物信息学研究开发取得了一定成绩^[10]，但在生物信息资源建设方面，却几乎还是空白。历史是最好的镜子，上述历史回顾告诉我们，在提供生物信息资源服务方面，我国已远远落后于欧美各国；三大国际数据库联盟中，根本就没有中国的踪影。

为应对即将到来的大数据浪潮，建立国家级的生物信息资源和服务体系势在必行。遗憾的是，过去十多年来，尽管郝柏林院士等国内许多有识之士大声疾呼，我国的国家级生物信息中心依然渺无音讯（<http://blog.sciencenet.cn/blog-1248-237322.html>）。

值得庆幸的是，由中国科学院北京基因组研究所大数据中心 BIGD 开发的“基因组序列归档系统” GSA 项目已经启动。自 2015 年 12 月上线以来，国内 39 个研究机构近 200 个研究课题已经把他们的数据汇交到 GSA 平台。更加令人欣喜的是，该系统也得到了国际上的认可，美国科学院院报 PNAS 等多个期刊已经发表了汇交到 GSA 的学术论文。GSA 系统只是该大数据中心 BIGD 的主要项目之一，数据库构建、基因组变异图谱等其它多个项目也已经开始，其特色数据库涵盖了基因组、转录组、甲基化组等各个方面，而若干重要动植物的基因组变异数据库也已经上线。此外，国际生物信息数据库目录（Database Common）、水稻信息资源维基（Rice Wiki）等也是该中心开发的特色平台。

在国际合作方面，BIGD 也已经迈出了重要的一步。2016 年年底，BIGD 举办生物信息大数据讨论会，NCBI 和欧洲分子生物学网络组织（European Molecular Biology Network, 简称 EMBNet, <http://www.embnet.org/>）等机构的学者应邀参加，与中心成员交流生物信息研究、开发、服务的经验。此外，中心聘请了 NCBI、EBI、DDBJ 等国际著名生物信息中心的资深人士担任科学顾问，并于 2017 年春节前召开了第一届国际科学顾问委员会会议。

当然，BIGD 还刚刚建立，需要得到政府部门的资助和用户群体的支持，才能不断发展壮大，为建立我国国家级的生物信息中心奠定基础。值得深思的是，BIGD 从事的公益性、服务性的工作，在目前国内“以学术论文论英雄、以影响因子排座次”的评价体系下，很难得到足够重视，希望 BIGD 近 50 位年轻的生物信息研究开发人员要有“板凳坐得十年冷”的思想准备。在此，借用英国学者安澜·布里斯比（Alan Bleasby）的话，聊以共勉：“*I don't think we can get a Nobel prize by what we are doing so, but the Nobel prize winners know what we are doing for*”。

参考文献

1. Wang YQ, Song FH, Zhu JW, Zhang SS, Yang YD, Chen TT, et al. GSA: Genome Sequence Archive. *Genomics Proteomics Bioinformatics*. 2017;**15**:14-18.
2. BIG Data Center Members. The BIG Data Center: from deposition to integration to translation. *Nucleic Acids Res*. 2017;**45**:D18-D24.
3. Luo JC, GSA and BIGD: Filling the gap of bioinformatics resource and service in China. *Genomics Proteomics Bioinformatics*. 2017; **15**:11-13.
4. Berman HM, Kleywegt GJ, Nakamura H, Markley JL. The Protein Data Bank at 40: reflecting on the past to prepare for the future. *Structure*. 2012;**20**:391–396.
5. Gilbert W. Towards a paradigm shift in biology. *Nature*. 1991;**349**:99.

6. Lander ES, Linton LM, Birren B, Nusbaum C, Zody MC, Baldwin J, et al. Initial sequencing and analysis of the human genome. *Nature*. 2001; **409**:860-921.
7. Venter JC, Adams MD, Myers EW, Li PW, Mural RJ, Sutton GG, et al. The sequence of the human genome. *Science*. 2001;**291**:1304-1351.
8. Mukherjee S, Stamatis D, Bertsch J, Ovchinnikova G, Verezemska O, Isbandi M, et al. Genomes OnLine Database (GOLD) v.6: data updates and feature enhancements. *Nucleic Acids Res*. 2017;**45**:D446-D456.
9. Toronto International Data Release Workshop Authors. Prepublication data sharing. *Nature*. 2009;**461**:168-170.
10. Wei L, Yu J. Bioinformatics in China: a personal perspective. *PLoS Comp Biol*. 2008;**4**:e1000020.