

9. McMackin E. A. W., Marsden A. E., Yahr T. L. H-NS Family Members MvaT and MvaU Regulate the *Pseudomonas Aeruginosa* Type III Secretion System // J. Bacteriol. 2019. Vol. 201. № 14. P. 1–15.
10. Chambonnier G., Roux L., Redelberger D. et al. The Hybrid Histidine Kinase LadS Forms a Multicomponent Signal Transduction System with the GacS/GacA Two-Component System in *Pseudomonas Aeruginosa* // PLoS Genet. 2016. Vol. 12. № 5. P. 1–30.
11. Cooper C. E., Nicholls P., Freedman J. A. Cytochrome c oxidase: structure, function, and membrane topology of the polypeptide subunits // Biochem. Cell Biol. 1991. Vol. 69. № 9. P. 586–607.
12. Cabeen M. T., Leiman S. A., Losick R. Colony-morphology screening uncovers a role for the *Pseudomonas aeruginosa* nitrogen-related phosphotransferase system in bio-film formation // Mol. Microbiol. 2016. Vol. 99. № 3. P. 557–570.

НЕОБХОДИМОСТЬ РУЧНОЙ ВАЛИДАЦИИ ДАННЫХ АВТОМАТИЧЕСКОЙ СБОРКИ И АННОТАЦИИ ГЕНОМОВ НА ПРИМЕРЕ МИТОХОНДРИАЛЬНЫХ ГЕНОМОВ НАСЕКОМЫХ

С. С. Левыкина, Н. В. Воронова

Белорусский государственный университет, Минск, Беларусь

E-mail: s.lewykina@yandex.by

Рассмотрена необходимость ручной валидации полученных данных автоматической сборки и аннотации геномов. Ручная валидация применима при анализе небольших геномов, таких, как митохондриальные геномы. Необходимо совершенствовать методы биоинформатики, чтобы необходимость ручной валидации отсутствовала.

Ключевые слова: методы биоинформатики; митохондриальный геном; тли.

На сегодняшний день для реализации таких процессов, как сборка и аннотация геномов, разработано множество доступных программных пакетов, позволивших автоматизировать выполнение такого рода задач [1–2]. Однако, при всём многообразии информационных технологий для обработки данных секвенирования, а также анализа нуклеотидных последовательностей, полученные результаты часто нуждаются в ручном пересмотре со стороны эксперта в данной конкретной области исследования.

В данной работе необходимость ручной валидации данных рассматривается на примере митогеномов насекомых, в частности тлей (Aphidoidea) [3].

Митохондриальный геном тлей представляет собой двуцепочечную ДНК-молекулу, размером обычно не превышающую 15–20 Кб. Структура генома обычно включает в себя 37 генов, среди которых 22 – гены

транспортных РНК, 2 – гены, кодирующие рибосомальные РНК, 13 – белок-кодирующие участки, а также 2 протяженных некодирующих участка, обозначенных как регион формирования D-петли и участок, богатый tandemными повторами [4]. Установлено, что митохондриальный геном тлей является высококонсервативной структурой, богатой аденин-тиминовыми основаниями (83–86%) [5]. В большинстве митогеномов тлей реализуется предковый для насекомых порядок генов [6]. Наличие любых генных транслокаций или делеций рассматривается как важный эволюционный и филогенетический признак.

База данных GenBank NCBI к моменту написания данной работы содержала 40 аннотированных митогеномов тлей, 5 из которых были собраны, аннотированы и депонированы сотрудниками СНИЛ биоинформатики и молекулярной эволюции животных [7]. Одной из пяти депонированных последовательностей был митохондриальный геном *Aphis craccivora*, сборка и аннотация которого была проведена по аналогии с уже представленным в генетическом банке геномом того же вида, депонированным китайскими исследователями в 2016 году (см. рис. 1.).

Митохондриальный геном данного вида тли представлял интерес для исследования в связи с присутствующей в нем транслокацией гена, кодирующего транспортную РНК аминокислоты тирозина (Y), место локализации которого обычно следует за геном тРНК-цистеина (C), а в работе китайских исследователей ген данной транспортной РНК был обнаружен в составе некодирующего участка, обозначенного как область формирования D-петли (d-loop) [8]. Заинтересовавшись данной перестройкой и её наличием в митохондриальном геноме представителя белорусской популяции *A. craccivora*, мы провели аналогичную работу по сборке и аннотации митогенома данного вида.



Рис. 1. Два варианта аннотации митохондриального генома *Aphis craccivora*: результаты, полученные авторами статьи [MT095075] и китайскими исследователями [NC031387.1]

В результате более детального исследования, проведенного авторами ранее [7], было установлено, что транслокации как таковой в геноме данного вида нет, и обнаруженная в составе области D-петли последовательность является изоформой соответствующей тРНК. Принятая за транспортную РНК китайскими исследователями изоформа, при выравнивании с другими тРНК-тирозина, извлеченными из остальных митогеномов в GenBank, демонстрировала визуально фиксируемые различия в нуклеотидном составе между ней и другими генами тРНК-тирозина. Также было установлено, что область, обозначенная китайскими исследователями как ген тРНК-тирозина, на самом деле является одним из важных консервативных участков D-петли, который не перекрывается с последующим геном в остальных митогеномах [9].

Причиной данной ошибки было то, что автоматическая аннотация не прошла ручную валидацию. Китайские исследователи обозначили стартовый кодон белок-кодирующего гена COI примерно на 27 нуклеотидов раньше, чем это было сделано во всех остальных геномах. При переносе рамки считывания гена COI в типичную для нее локализацию, искомая тРНК обнаружилась между генами тРНК-цистеина и COI геном, а также сформировала типичную для нее вторичную структуру с характерным антикодоном.

Данная ситуация послужила поводом к пересмотру всех аннотаций митогеномов, депонированных в GenBank. В результате ручной валидации 35 аннотаций, депонированных сторонними исследователями, были обнаружены ошибки в 7 геномах, среди которых 4 содержало запись об отсутствующей перестройке, и в 4 не были обозначены границы региона повторов. Отсутствие в аннотациях данных о наличии данной области, при проведении сравнительного анализа с использованием депонированных в GenBank митогеномов, впоследствии привело бы к ошибкам.

Программы, обеспечивающие автоматическую аннотацию геномов, без сомнений, значительно сокращают затрачиваемое на исследование время и ресурсы, однако на практике оказывается недостаточным использование исключительно программных пакетов без проверки полученных данных компетентным в данной области исследователем. Ручная валидация данных, полученных в ходе автоматической аннотации, не представляет труда в случае анализа небольших геномов, таких как митохондриальные геномы, однако коррекция результатов аннотации полногеномных данных весьма затруднительна. В связи с этим, не оставляет сомнений необходимость совершенствования существующих методов биоинформатики, чтобы необходимость ручной валидации данных отпала как таковая, что само по себе открывает множество возможностей и задач для исследователей, специализирующихся в данной области.

БИБЛИОГРАФИЧЕСКИЕ ССЫЛКИ

1. Hahn C., Bachmann L., Chevreux B. Reconstructing mitochondrial genomes directly from genomic next-generation sequencing reads – a baiting and iterative mapping approach // *Nucleic Acids Res.* 2013. Vol. 41. № 13. P. 1–9.
2. Seemann T. Prokka: rapid procaryotic genome annotation // *Bioinformatics.* 2014. Vol. 30. № 14. P. 2068–2069.
3. Воронова Н. В., Бондаренко Ю. В., Левыкина С. С., Шулинский Р. С. Митохондриальный геном *Aphis Fabae Mordvilko* Borner & Janisch, 1992 // *Молекулярная и прикладная генетика: сб. науч. трудов.* 2018. Т. 25. С. 73–83.
4. Lee J., Park J., Lee H. et al. The complete mitochondrial genome of *Paracolopha morisoni* (Baker, 1919) (Hemiptera: Aphididae) // *Mitochondrial DNA Part B.* 2019. Vol. 4. № 2. P. 3037–3039.
5. Voronova N. V., Warner D., Shulinski R. S. et al. The largest aphid mitochondrial genome found in invasive species *Therioaphis tenera* (Aizerberg, 1956) // *Mitochondrial DNA Part B.* 2019. Vol. 4. № 1. P. 730–731.
6. Cameron S. L. Insect mitochondrial genomics: implications for evolution and phylogeny // *Annu. Rev. Entomol.* 2014. Vol. 59. P. 95–117.
7. Voronova N. V., Levykina S. S., Warner D. et al. Characteristic and variability of five complete aphid mitochondrial genomes: *Aphis fabae mordvilko*, *Aphis craccivora*, *Myzus persicae*, *Therioaphis tenera* and *Appendiseta robiniae* (Hemiptera; Sternorrhyncha; Aphididae) // *International Journal of Biological Macromolecules.* 2020. V. 149. P. 187–206.
8. Sun W., Huynh B. L., Ojo J. A. et al. Comparison of complete mitochondrial DNA sequences between old and new world strains of the cowpea aphid, *Aphis craccivora* (Hemiptera: Aphididae) // *Agri Gene.* 2017. Vol. 4. P. 23–29.
9. Chen L., Chen P.-Y., Xue X.-F. et al. Extensive gene rearrangements in the mitochondrial genomes of two egg parasitoids, *Trichogramma japonicum* and *Trichogramma ostrinae* (Hymenoptera: Chalcidoidea: Trichogrammatidae) // *Scientific Reports.* 2018. Vol. 8. № 1. P. 1–11.

АВТОЭНКODЕРНАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ГЕНЕРАЦИИ ПОТЕНЦИАЛЬНЫХ ИНГИБИТОРОВ ВИЧ-1 МЕТОДАМИ ГЛУБОКОГО ОБУЧЕНИЯ

Г. И. Николаев¹, Н. А. Шульдов², А. И. Анищенко²,
А. В. Тузиков¹, А. М. Андрианов³

¹Объединенный институт проблем информатики

Национальной академии наук Беларуси, Минск, Беларусь

²Белорусский государственный университет, Минск, Беларусь

³Институт биоорганической химии Национальной

академии наук Беларуси, Минск, Беларусь

E-mail: reshaemvsem@gmail.com

Методами глубокого обучения разработан генеративный состязательный автоэнкодер для рационального дизайна потенциальных ингибиторов проникновения ВИЧ-1, способных блокировать участок белка gp120 оболочки вируса, критический для