

DOI: 10.25205/978-5-4437-1843-9-14

ОПТИМИЗАЦИЯ ДАННЫХ В БИОИНФОРМАТИКЕ

DATA OPTIMISATION IN BIOINFORMATICS

Р.З. Габбасов, Г.Т. Закирьянова, С.И. Хажина

Башкирский государственный медицинский университет, Уфа

R.Z. Gabbasov, G.T. Zakiryanova, S.I. Khazhina

Bashkir State Medical University, Ufa

✉vessel228@yandex.ru

Аннотация

Современная биомедицина столкнулась с беспрецедентным ростом объемов данных, требующих обработки: от полногеномного секвенирования до сложных медицинских изображений. По данным NIH, ежегодный прирост геномной информации составляет до 40 экзабайт, при этом значительная часть этих данных остается неструктурированной и неиспользованной, что обусловлено множеством факторов.

Abstract

Modern biomedicine is faced with an unprecedented increase in data volumes that require processing, from genome-wide sequencing to complex medical images. According to the NIH, the annual increase in genomic information is up to 40 exabytes, while a significant part of this data remains unstructured and unused, due to many factors.

Биоинформатика — одна из самых динамических наук в наше время. В условиях стремительного роста объемов геномной информации, развития высокопроизводительного секвенирования и появления новых экспериментальных технологий актуальность методов оптимизации становится особенно очевидной. Нелинейность, высокая структурная и морфологическая сложность моделей на фоне общего роста слабоструктурированной исходной информации и относительного роста ее нечеткости приводят к необходимости предварительного преобразования и интеграции данных. Современные исследования требуют не только обработки колоссальных массивов данных, но и обеспечения высокой точности, скорости и интерпретируемости результатов.

Стохастические методы оптимизации (SDG) являются основными для обучения крупных моделей на больших данных в совокупности с обновлением параметров на мини-батчах и возможностью параллелизации, именно поэтому данные алгоритмы в докинге и предсказании 3D-структур белков.

Активно применяются распределенные алгоритмы в оптимизации данных. В проекте 1000 Genomes оптимизированный алгоритм выравнивания позволяет анализировать 2500 геномов одновременно, при этом обрабатывая 200 ГБ данных за 3 часа вместо 24. В криминалистике пользуется успехом SPR Opt, оптимизирующий судебно-медицинские маркеры для получения максимального количества информации при минимальном количестве анализов. В качестве входных данных он принимает полную или частичную последовательность генома.

В условиях работы с неразмеченными данными крайне эффективно себя проявляет обучение без надзора (Unsupervised learning), позволяя выявлять скрытые структуры и закономерности данных без необходимости ручной разметки. Условно можно выделить два основных метода: кластеризация и метод уменьшения данных. Кластеризация — процесс объединения информации в кластеры, используемый в биоинформатике для анализа генов, белков и других биомолекул. Она нашла применение в протеомике, структурной биологии, анализе биомаркеров и др. Наиболее известные алгоритмы включают k-means, DBSCAN и иерархическую кластеризацию. Метод понижения размерности позволяет сохранить наиболее важную информацию, уменьшив количество входных данных.

Применение машинного обучения обширно. Расчет стабильности комплексов может быть оптимизирован за счет предсказания термодинамических параметров ДНК-белковых взаимодействий.

Несмотря на имеющиеся успехи, существуют проблемы, связанные с передачей данных, требующих возрастающих вычислительных мощностей. Возникают сложности с интерпретируемостью некоторых моделей и высоким уровнем шума, часто встречающимся в биологических экспериментах.

В результате проведенного анализа представлен обзор современных методов оптимизации данных в биоинформатике. Установлено, что применение усовершенствованных алгоритмов обработки геномной информации позволяет существенно повысить точность интерпретации биологических данных. Полученные результаты демонстрируют значительный потенциал для развития персонализированной медицины и оптимизации доклинических исследований за счет внедрения эффективных вычислительных решений.