

Ю. Ю. ВАСЬКИН, Ю. Э. ДАНИЛОВА

СВОБОДНЫЙ ДУХ БИОИНФОРМАТИКИ

Темп развития, набранный молекулярной биологией, не может не поражать. Рутинным делом стала расшифровка ДНК: современное оборудование для высокопроизводительного секвенирования позволяет полностью определить нуклеотидные последовательности генома человека всего за один день и 1 тыс. долларов! И сейчас внимание ученых сконцентрировано на исследовании функциональной роли тех или иных участков генома и последствий, к которым приводят изменения в них. В распоряжении исследователей уже находятся большие базы данных, и каждый день генерируются все новые и новые гигабайты биологической информации. Адекватно оперировать столь гигантскими объемами данных невозможно без автоматизированных средств анализа. Именно биоинформатика становится в наши дни связующим звеном между компьютерными и молекулярно-генетическими технологиями, обеспечивая прогресс в новых динамично развивающихся фундаментальных и прикладных областях биологии



ВАСЬКИН Юрий Юрьевич – инженер-программист НЦИТ УНИПРО (Новосибирск), магистрант факультета Новосибирского национального исследовательского государственного университета. Победитель конкурса УМНИК Фонда содействия развитию малых форм предприятий в научно-технической сфере (2012 г.). Автор и соавтор 5 научных работ





ДАНИЛОВА Юлия Эдуардовна – кандидат физико-математических наук, заместитель директора НЦИТ УНИПРО (Новосибирск). Автор и соавтор 10 научных работ

В биоинформатике можно выделить три основных направления: анализ и статистическая обработка биологических данных, разработка алгоритмов анализа и создание специализированных программных средств. Первые два направления по большей части относятся к исследовательской деятельности и получению значимых научных результатов. Последнее же очень близко по духу к традиционной разработке программного обеспечения, с которой имеют дело IT-компании.

В зарубежной практике принято, что научные лаборатории нанимают специалистов или даже содержат целые отделы по обработке биологических данных и созданию программно-аппаратного обеспечения,

Ключевые слова: биоинформатика, молекулярно-генетическая информация, высокопроизводительное секвенирование, вычислительные конвейеры, свободное ПО
Key words: bioinformatics, molecular-genetic information, high throughput sequencing, computational chains, open source

© Ю. Ю. Васькин, Ю. Э. Данилова, 2013



Молодежная биоинформационная команда, работающая над проектом UGENE

однако в нашей стране ученые часто самостоятельно осваивают или даже разрабатывают нужные им программные средства. И такой переход от традиционных «пробирок» к высокопроизводительным вычислениям не дается легко. У исследователей могут возникать сложности при использовании разнородных комплектов программного обеспечения, которые могут работать с несовместимыми форматами данных и только на непривычных операционных системах. Возникают проблемы и с редактированием огромных файлов, с поиском и установкой программ, часто представляющих собой файлы с исходным кодом, который нужно сначала скомпилировать и настроить, а также с решением других компьютерных задач, которыми не должен заниматься биолог.

В этой связи в 2003 г. Новосибирский центр информационных технологий «Унипро» решил приложить свой опыт программных разработок в бурно развивающейся области оцифрованной биологии. Тогда же были налажены первые научные контакты, результатом которых стало первое биоинформационное приложение, разработанное новичком компании, выпускником физфака НГУ М. Фурсовым.

В течение последующего десятилетия компания разрабатывала специализированные биоинформационные приложения и расширяла круг потребителей и разработчиков своих программных продуктов.

Основным наукоемким проектом «Унипро» стал UGENE, появившийся в июне 2008 г. И хотя на старте этого проекта участвовало всего три инженера-программиста, задачу сразу поставили амбициозную – перегнать коммерческие аналоги.

Что умеет UGENE

UGENE объединяет «под одной крышей» множество популярных инструментов для работы с молекулярно-генетической информацией. В то же время изрядную долю пакета составляют результаты реализации оригинальных идей самих разработчиков, а также предложений, которые постоянно вносят пользователи. Немаловажным фактором привлекательности UGENE является и удобный графический интерфейс: пользователь может запускать интересующие его алгоритмы и сразу отслеживать результат в одном из окон визуализации.

Программные инструменты, с помощью которых реализован UGENE, позволяют использовать его на большинстве операционных систем. К тому же пакет распространяется бесплатно и с открытым исходным кодом, т.е. любой пользователь может видеть, как устроена программа изнутри, и при желании адаптировать ее под собственные нужды – лицензионное соглашение GPL позволяет встраивать в пакет другие програм-



«УНИПРО» – 20 ЛЕТ!


НЦИТ «Унипро» был создан в 1993 г. в новосибирском Академгородке командой профессионалов системного программирования, работавших в российском суперкомпьютерном проекте «Эльбрус». В течение 12 лет центр в сотрудничестве с американской компанией Sun Microsystems, известным производителем программного и аппаратного обеспечения, тестировал и улучшал язык Java – ныне самый востребованный язык программирования. Сейчас в компании работают свыше 70 человек, в большинстве своем выпускники НГУ и НГТУ.

Программисты Унипро много лет успешно разрабатывают сложные тестовые и моделирующие системы, встроенное программное обеспечение для электроэнергетики, оптимизирующие компиляторы, корпоративные системы управления. Большинство проектов компании – долгосрочные, а среди заказчиков есть такие громкие имена, как Google.

Биоинформатикой в Унипро стали заниматься с начала 2000-х гг. Почему же компания, столь успешно работающая в традиционных компьютерных областях, вступила в такую сложную, рискованную и «чуждую» научную область? Наверное, не последнюю роль сыграло обычное человеческое любопытство, ведь речь идет о близкой всем науке о жизни, только рассмотренной под другим углом.

Кроме того, находясь в научном центре, трудно удержаться от сотрудничества с учеными: у компании к этому времени уже имелся успешный опыт сотрудничества с геофизиками и математиками.

Биоинформатику в Унипро сегодня можно назвать научной отдушиной среди заказных коммерческих проектов, которая предполагает полную свободу творчества. К тому же она служит и хорошим полигоном для тренировки начинающих программистов: большинство биоинформационной команды составляют студенты, магистранты и вчерашние выпускники университетов, работающие под руководством опытных инженеров-программистов




Режим подсветки одинаковых нуклеотидов позволяет быстро отследить различия между последовательностями ДНК при их выравнивании (выявлении одинаковых участков). Использование функции выравнивания UGENE: *слева* – при поиске некодирующей митохондриальной ДНК, пригодной для видовой идентификации восьми видов байкальских губок, *справа* – для сравнения последовательностей одного из ферментов грибов, обратной транскриптазы Tsp1. По данным ЛИИ СО РАН (Иркутск) и ИЦиГ СО РАН (Новосибирск)


мные разработки с совместимыми лицензиями.

Как известно, высокое сходство макромолекул обычно указывает на их значительное структурное, функциональное и эволюционное родство. Поэтому одной из главных задач биоинформатики является *выравнивание* – поиск сходных участков молекулярных последовательностей.

Сегодня имеются сотни различных видов и инструментов выравнивания. В зависимости от задачи ученый может работать с одной или с миллионами последовательностей, искать похожие участки в удаленной базе данных или проводить выравнивание нескольких десятков

Так выглядит построенная в программе UGENE 3D-структура антифризного белка, который, встраиваясь в кристаллическую решетку льда, препятствует росту ледяных кристаллов в клетках арктических животных. Реконструкция по данным: (Howard et al., 2011)





Программа UGENE была использована для оценки степени флексибельности ДНК и обнаружения в ней потенциальных мест цепочечных разрывов ДНК, которые связаны с образованием рака молочной железы.

Анализ выполнен на участке нуклеотидной последовательности 18-й хромосомы человека, включающей семь генов (база данных GenBank). Данные Н.Ю. Маценко (НИИМББ СО РАН, Новосибирск)

последовательностей, полученных в эксперименте. Соответственно и подходы к обработке и визуализации данных должны быть совершенно разными. К тому же нужно помнить об удобстве пользователя и предоставить ему возможность выполнять рутинные операции самым простым способом.

Поэтому в рамках UGENE предусмотрены различные специализированные рабочие среды. Например, если требуется анализировать только одну нуклеотидную последовательность, то открывается соответствующее окно с ее изображением, где предлагаются инструменты поиска схожих участков, конструирования молекулярных векторов и т.д. Для белковых аминокислотных последовательностей доступны визуальные трехмерные модели или алгоритмы предсказания вторичных структур.

Для манипулирования множественными последовательностями выделено отдельное рабочее пространство, где под рукой у биолога имеется свыше десятка известных алгоритмов выравнивания и сравнения последовательностей, а также построения филогенетических деревьев.

Довольно часто ученым приходится выполнять многостадийную обработку большого количества данных. Обычно в таких вычислительных «конвейерах» одни алгоритмы или программы используют результаты предварительной работы других, поэтому ученым часто приходится вручную осуществлять взаимодействие между ними. Встроенный в UGENE оригинальный дизайнер вычислительных схем позволяет быстро собирать конвейерные схемы обработки из вычислительных элементов, в которых данные передаются автоматически



Пример работы встроенного в UGENE дизайнера вычислительных схем: схема, позволяющая фильтровать любое количество нуклеотидных или аминокислотных последовательностей по заданной длине (отобранные последовательности записываются в разные файлы). Схему можно использовать многократно

Заместитель директора Института цитологии и генетики СО РАН (Новосибирск) С. В. Лаврушев:
 «Команду разработчиков Унипро знаем давно, регулярно и конструктивно общаемся. Мы видим их неуклонный прогресс в освоении новых технологий и областей биоинформатики. Наши ученые уверенно пользуются их софтом наряду с разработками Института и зарубежными пакетами. Надеемся, что наше сотрудничество в будущем будет только укрепляться»



по соединениям, заданным пользователем. Такие схемы хороши тем, что в дальнейшем их можно использовать многократно для обработки различных наборов входных данных.

Под флагом UGENE

В Унипро не числится ни одного биолога, но поддерживать высокий научный уровень проекта позволяют постоянные контакты с учеными, среди которых не только пользователи UGENE, но и активные участники разработки алгоритмов.


Например, в UGENE был встроен алгоритм поиска сайтов связывания транскрипционных факторов SITECON, разработанный к.б.н. Д. Ощепковым и его коллегами из Института цитологии и генетики СО РАН (Новосибирск). А по мнению д.ф.-м. н. Е.Е.Витяева из Института математики СО РАН, от интеграции с UGENE, несомненно, выиграла разработанная им система ExpertDiscovery для поиска комплексных сигналов в регуляторных районах генов. Благодаря такому «слиянию» этой программой могут пользоваться исследователи из разных стран.

Многие алгоритмы аннотирования и анализа геномов разрабатываются непосредственно под конкретные задачи биологов. Так, с 2004 г. Унипро сотрудничает с лабораторией молекулярно-генетических систем ИЦиГ СО РАН, где занимаются поиском мобильных элементов в геномах различных грибов. Алгоритмы поиска, разработанные в Унипро, позволили ускорить эти вычисления в десятки и сотни раз.

В 2011 г. Унипро совместно с НГУ и Intel-lab проводили школу-семинар «Вычислительные задачи молекулярной биологии и платформа UGENE», в ходе которого молодым ученым был задан вопрос: каким образом UGENE

Презентация биоинформационных разработок Унипро на выставке «Живая инновация». Новосибирск, Технопарк, 2010

С 2010 г. для ученых-биологов время от времени проводятся ознакомительные и обучающие семинары по работе с пакетом UGENE. И хотя аудитория этих семинаров в сотни и даже тысячи раз меньше той, которую можно собрать в результате интернет-маркетинга, такая форма продвижения программного продукта достаточно эффективна. Ведь если хотя бы один человек из научного подразделения после посещения семинара начнет активно и успешно пользоваться программой, это неизбежно привлечет внимание и многих его коллег. Такой пиар очень значим для команды разработчиков, ведь именно «сарафанное радио» в научной среде является самым быстрым и надежным рекламным инструментом



Unipro
UGENE

Пользователи UGENE сегодня имеются во всех частях света, кроме Антарктиды. Его разработчики регулярно получают благодарные отклики: «Very good software for using... Many thanks!». Некоторые иностранные пользователи инициируют выпуск локализованных версий на своем родном языке: уже появились версии на чешском и китайском языках, а скоро, вероятно, к ним добавится испанская. На карте – география пользователей UGENE по данным Google Analytics. Согласно этой информации, наибольшее число пользователей к настоящему времени приходится на Россию, страны СНГ и США

может быть полезен для Вашей научной работы? Среди ответов упоминались моделирование экспериментов по клонированию генов, построение филогенетических деревьев и другие задачи, уже успешно решаемые в среде UGENE. Однако под специфические запросы некоторых участников имеющийся функционал пришлось дорабатывать. Например, по просьбе к.б.н. Н.Ю. Маценко из Института молекулярной биологии и биофизики СО РАН (Новосибирск) был разработан специальный модуль по поиску в ДНК сайтов флексибельности, т.е. участков нуклеотидной цепочки с критическими параметрами гибкости и ломкости.

Активные пользователи UGENE есть не только в Сибири, но и в европейской части России. Среди них – специалисты из Санкт-Петербургского Всероссийского научно-исследовательского института сельскохозяйственной микробиологии РАСХН, занимающиеся анализом почвенных микробиомов*, и московского Центрального НИИ эпидемиологии, интересующиеся обработкой результатов высокопроизводительного секвенирования ДНК микроорганизмов. А недавно сотрудники Унипро стали желанными гостями на Всероссийском семинаре по современным методам

индикации возбудителей инфекционных болезней для сотрудников институтов системы Роспотребнадзора, где провели практическое обучение за компьютерами. Это свидетельствует о том, что сегодня UGENE используется уже не только в фундаментальной науке, но и в прикладных исследованиях, направленных на улучшение здоровья людей и окружающей среды.

В 2012 г. был заключен контракт с американским Национальным институтом аллергических и инфекционных болезней (NIAID), согласно которому на базе дизайнера вычислительных схем UGENE предстоит построить особую инфраструктуру по анализу данных высокопроизводительного секвенирования.

Дело в том, что обычно такие вычисления производят на мощных компьютерных кластерах, однако в некоторых случаях (например, когда пользователь находится в экспедиции в удаленных районах) возникает необходимость использовать только локальный компьютер. Все результаты этой работы также должны войти в открытую бесплатную версию UGENE, т.е. станут доступны для всего мирового сообщества.

* Подробнее на с. 68–75

Обучение молодых ученых на школе-семинаре в лаборатории НГУ-Intel, Новосибирск, май 2011 г.



Биоинформатика сразу стала в Унипро самым молодежным направлением. Костяк фирмы в последние годы остается стабильным, однако приток начинающих программистов постоянен. Поэтому над проектом UGENE успели потрудиться не менее двадцати человек – студенты, магистранты и недавние выпускники вузов, для которых проект стал настоящей профессиональной школой. Открытый код проекта, с одной стороны, предъявляет к его участникам повышенные требования, но с другой – служит им отличной рекомендацией.

Сейчас биоинформационный отдел компании, насчитывающий 13 человек, превратился в настоящую научно-исследовательскую лабораторию. Здесь ведется постоянная работа по исследованию и разработке новых вычислительных алгоритмов, оптимизации уже существующих методов, использованию новых программных технологий. Сюда ежегодно на преддипломную практику приходят студенты НГУ и НГТУ, постепенно становясь профессиональными программистами, а сотрудники регулярно выступают с докладами на конференциях и семинарах.

Два года назад UGENE был удостоен звания «Лучший свободный проект России – 2011», а биоинформационная команда Унипро стала единственным российским участником международного конкурса «Illumina IDEA Challenge 2011», объявленного мировым производителем секвенаторов. В 2012 г. разработчики UGENE опубликовали результаты своей работы в «Bioinformatics» – одном из самых уважаемых международных журналов в этой области, что упрочило позиции пакета в научной среде.

За девять лет работы в области биоинформатики в компании Унипро только укрепилась в мысли, что хорошие программисты нужны биологам, и что биоинформатика – нетривиальный и интересный путь, ведущий к пониманию окружающего нас сложного органического мира.

Заместитель директора НЦИТ «Унипро» М. Ю. Фурсов: «Нам часто задают вопрос: открытый и такой серьезный проект – это здорово, но за чей счет вы его делаете, неужели он окупается?»

Особенность нашего проекта в том, что он не начался с нуля, а родился и развивался внутри стабильной компании, имеющей долгосрочные проекты в других технологических областях программирования. Именно поэтому мы пошли на риск, сделав UGENE бесплатным, и долгое время развивали его без какой-либо финансовой отдачи. Лишь в 2011 г., через три года после выпуска первой версии, стали поступать первые заказы на биоинформационные разработки. Это дает основания надеяться, что уже в ближайшем будущем проект станет окупаемым»

Литература

Lesk A. *Introduction to Bioinformatics. Third Edition. 2008.*
Vaskin Y. Y., Khomicheva I. V., Ignatyeva E. V. Vityaev E. E. *Expert Discovery and UGENE integrated system for intelligent analysis of regulatory regions of genes // Silico Biol. 2011–2012;11(3–4):97–108. doi: 10.3233/ISB-2012-0448. PMID: 22935964.*

Okonechnikov K., Golosova O., Fursov M. *Unipro UGENE: a unified bioinformatics toolkit // Bioinformatics. 2012; doi:10.1093/bioinformatics/bts091.*

Авторы выражают благодарность команде UGENE за помощь в подготовке статьи