

**Санкт-Петербургский Государственный Университет
Математико-Механический факультет**

кафедра системного программирования

Сервер морфинга протеинов

Курсовая работа студента 445 группы

Лушников Андрей Сергеевича

Научный руководитель:

К.В.Вяткина

Санкт-Петербург

2010

Оглавление

Введение.....	3
Терминология.....	4
Обзор технологий.....	5
Сервер.....	5
Клиент.....	5
Алгоритмы.....	6
Морфинг.....	6
Выравнивание.....	6
Результаты.....	8
Пути развития.....	11
Список литературы.....	12

Введение

В данной работе представлена реализация веб-сервера для морфинга протеинов. Несмотря на то, что на данный момент есть подобные решения, необходимость в создании аналога обусловлена наличием более современных подходов к процессу как выравнивания, так и непосредственно морфинга протеинов. Наличие подобного сервера предоставило бы отличную платформу для новых алгоритмов и подходов для морфинга протеинов.

На данный момент наиболее популярным сервером для морфинга протеинов является сервер Gershtein'a¹, запущенный в 2000 году. Целью работы была реализация сервера, не уступающего по функциональности существующему аналогу, и реализующему алгоритм, предложенный Павлом Певзнером, Natalie Castellana и их коллегами из University California, San-Diego.

Данный проект разрабатывается в сотрудничестве с Павлом Певзнером, лабораторией биоинформатики Санкт-Петербурга и UCSD.

1 <http://molmovdb.org/cgi-bin/submit.cgi>

Терминология

Протеины, они же белки – органические вещества, состоящие из остатков аминокислот, соединённых пептидной связью. В последнее время протеины широко изучаются по всему миру, что связано с чрезвычайно важными и разнообразными функциями белка в организме. Один из важных параметров белка – пространственное строение его пептидной цепи, т.е. набор пространственных координат составляющих белок атомов.

В последнее время огромное количество белков было проанализировано с помощью рентгеновского анализа. Результаты распространяются в формате pdb – формат содержит местоположение атомов белка в трёхмерном пространстве.

Процесс спонтанного сворачивания белка в уникальную третичную структуру называется фолдингом белка и на данный момент плохо изучен. Однако, зная начальную и конечную структуру белка, можно попробовать смоделировать процесс фолдинга. Моделирование изменения третичной структуры белка называется морфингом.

Морфинг, как и любое моделирование, оперирует не самими белками, которые являются исключительно сложными веществами, а их абстракциями. Третичная структура в биоинформатике принято моделировать с помощью ломанной линии в трёхмерном пространстве. Именно этот способ использовался в данной работе.

Морфинг двух протеинов зависит от их взаимного расположения в пространстве. Поэтому два протеина изначально “выравнивают” друг относительно друга. В данной курсовой работе это сделано популярным способом минимизации среднеквадратичного отклонения расстояния между аминокислотными остатками протеинов.

Обзор технологий

Сервер

При разработке проекта было проведено предварительное исследование серверных технологий. Рассматривались следующие варианты:

- java ee
- python + django
- ruby + ruby on rails

Java EE широко используется в связке с Inversion-of-control фреймворком Spring.

Системы, построенные на этой технологии, отлично масштабируются, и обладают превосходной производительностью. Этим подходом успешно пользуются такие крупные интернет-сервисы, как yandex. Однако основным их недостатком можно считать большую трудоёмкость разработки, что, в условиях достаточно небольшого ожидаемого числа клиентов, не оправдывает себя.

Языки Python и Ruby в связке с соответствующими веб-фреймворками django и ruby on rails представляются достаточно равноценными. Однако, ввиду таких факторов, как наличие высоконадёжного облачного сервиса для хостинга ruby-приложений heroku.com, а так же ввиду субъективных ощущений, выбор пал на язык ruby и веб-фреймворк ruby on rails.

Задача чтения и разбора pdb-файлов, загружаемых пользователем, была решена с помощью rubygem'a "bio" и его модуля "Pdb". Хранение всех данных пользователя организовано в реляционной базе данных². Это не является оптимальным решением, т.к. чтение pdb-файлов с диска происходит существенно быстрее, чем загрузка этой же информации из базы данных, однако heroku не позволяет загружать файлы в свой репозиторий из-вне.

Клиент

Клиентская часть ответственна за отображение морфинга двух состояний протеинов в трёхмерном пространстве. До недавних пор задача отображения трёхмерного web-контента повсеместно решалась с помощью таких технологий, как flash, java-апплеты, sylverlight, или даже с помощью написания отдельных платформо-зависимых тонких клиентов, которые необходимо устанавливать на компьютер пользователя. Все эти технологии обладают одним

² На данный момент используется SQLite, однако Rails позволяет использовать любую популярную БД, поэтому в любой момент движок БД может быть изменён на более подходящий.

существенным недостатком: они требуют от пользователя дополнительных плагинов и/или технологий, которых у него вполне может и не быть. Так, например, сервер Gershtein'a использует апплеты для решения этих целей, а потому у большинства пользователей Linux возникают традиционные проблемы, выражающиеся в надписи “Missing Plugin”.

Однако 2 марта 2011 года вышла первая версия стандарта технологии WebGL, которая позволяет аппаратно просчитывать трёхмерную сцену и отображать её на html5 элементе canvas. Для этого не требуется никаких плагинов, технологию поддерживают основные браузеры: Opera, FireFox, Chrome, Safari.

Технология является исключительно низкоуровневой. Поэтому было решено воспользоваться сторонней библиотекой, предоставляющей возможность рендеринга 3D в браузере с использованием технологии WebGL. Для этих целей есть несколько решений: GLGE, SceneJS, SpiderJS, PhiloGL, однако выбор пал на библиотеку Three.js. Она обладает очень понятным открытым исходным кодом, выложенным на github, хорошей коллекцией примеров и irc-каналом разработчиков, готовых ответить на любые вопросы. Библиотека очень молодая и находится на стадии активной разработки, поэтому документация к ней, к сожалению, отсутствует.

Одним из бонусов, полученных при использовании библиотеки three.js, стала поддержка рендеринга 3D-сцены без webgl на software уровне. Таким образом была решена проблема, возникающая на компьютерах под управлением OS Linux с видеокартой от intel: на сегодняшний день на машинах такой конфигурации webgl, к сожалению, инициализировать не удаётся.

Алгоритмы

Морфинг

Для морфинга двух протеинов был реализован алгоритм из черновика статьи Павла Певзнера и Natalie Castellana. Основная идея алгоритма заключается в построении некоторого графа переходов и использовании на нём динамического программирования³.

Первая реализация была написана непосредственно на ruby, однако морфинг небольших протеинов длился на протяжении 25 минут, в то время как теоритические оценки указывали на время в несколько секунд. Было проведено исследование скорости работы ruby, в результате которого было выяснено, что ruby – исключительно медленный и едва ли подходит для реализации алгоритмов. Так, например, $4 \cdot 10^6$ операций цикла for с пустым телом выполняются

³ Детали алгоритма, к сожалению, описанию не подлежат, т.к. сам алгоритм ещё не опубликован.

3 секунды. Поэтому алгоритм был целиком переписан на ANSI C, а для связи с ruby-on-rails была написана ruby-обёртка над этим алгоритмом. В результате удалось достигнуть времени выполнения алгоритма в 3 секунды для небольших протеинов в 80 аминокислотных остатков, и 7 секунд для достаточно больших протеинов размера 250 аминокислотных оснований.

Кроме того, реализован алгоритм, генерирующий промежуточные положения морфинга с помощью выпуклой комбинации. Этот алгоритм используется по умолчанию в текущей версии сервера.

Выравнивание

Задача выравнивания начального положения протеинов обычно трактуется как задача о минимизации среднеквадратичного отклонения расстояния между аминокислотными остатками. Для решения этой задачи есть широкоизвестный алгоритм Кабша, опубликованного в 1976 году. Предложенный им алгоритм решает матричное уравнение с учётом всех возникающих крайних случаев. Однако в процессе изучения возможных подходов выбор пал на алгоритм QCP.

QCP – наиболее быстрый из известных алгоритм для решения задачи минимизации среднеквадратичного отклонения между двумя множества точек. Алгоритм определяет матрицу поворота 3×3 , на которую надо повернуть второе множество точек, чтобы минимизировать среднеквадратичное отклонение. Основная оптимизация достигается за счёт использования свойств кватернеонов и вместо операций обращения матриц. Его реализация под лицензией BSD на языке ANSI C используется на данный момент.

Результаты

Результатом курсовой работы стал REST-сервис по морфингу протеинов, позволяющий пользователям загружать свои протеины в формате pdb на сервер, выбирать нужное число шагов морфинга, и просматривать результаты в трёхмерном пространстве без необходимости устанавливать какое-либо программное обеспечение. В режиме просмотра результатов пользователи могут переходить от текущего шага морфинга к следующему или предыдущему, включать непрерывную анимацию процесса, вращать, приближать и отдалять 3D-сцену. Для поддержки слабых компьютеров предусмотрены настройки детализации 3D-сцены. Все когда-либо проводимые запросы на морфинг протеинов доступны в архиве сайта и доступны каждому.

Альфа-версия сервиса доступна по адресу: <http://simple-waterfall-188.herokuapp.com/>



Рис. 1. Главная страница сервиса

The screenshot shows the 'morph' website interface. At the top left is the 'morph' logo. At the top right are navigation links: 'home', 'morph!', and 'archive'. The main content area is titled 'New morphing' and contains a form with the following fields and elements:

- Your name:** Input field containing 'Andrey Lushnikov'.
- e-mail:** Input field containing 'example@gmail.com'. To the right of the field is the text 'We won't publish your email anywhere'.
- First protein name:** Input field containing '1dy3'. To the right is a 'Choose File' button and the text '1DY3.pdb'.
- Second protein name:** Input field containing '1rao'. To the right is a 'Choose File' button and the text '1RAO.pdb'.
- Steps:** Input field containing '8'. To the right is the text 'Amount of interpolation steps. Should be between 2 and 20'.

Below the form is a 'Create Morph request' button. At the bottom of the page are navigation links: 'about', 'contacts', and 'help'.

Рис. 2. Создание нового морфинга

The screenshot shows the 'morph' website interface displaying the details of a morphing request. At the top left is the 'morph' logo. At the top right are navigation links: 'home', 'morph!', and 'archive'. The main content area is titled 'Morphing details' and contains the following information:

- Submitter:** Andrey Lushnikov
- First Protein:** 1dy3
- Second Protein:** 1rao
- Interpolation steps:** 8

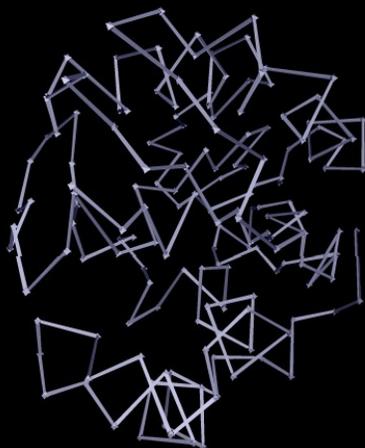
Below the details are two bullet points:

- See morphing via [webGL technology](#) [Recommended]
- If you encounter problems, try [this link](#)

At the bottom of the page are navigation links: 'about', 'contacts', and 'help'.

Рис.3. Информация о морфинге

Step: 1/8



About Settings Help

Рис.4. Просмотр морфинга в браузере

Step: 1/8

User controls

You can rotate the protein with your mouse using drag-and-drop.
Additional key bindings are provided for better user experience

h or left arrow	rotate left
j or down arrow	rotate down
k or up arrow	rotate up
l or right arrow	rotate left
+	zoom in
-	zoom out
SPACE	stop any motion
n	next morphing step
p	previous morphing step
t	start/stop morphing playback

Click anywhere to close this window.

About Settings Help

Рис.5. Окно помощи для просмотра

Пути развития

Основной упор в развитии сервера будет сделан на улучшении алгоритмов морфинга.

Возможными направлениями для развития сервера будут:

1. Использование расстояния Фреше для выравнивания протеинов
2. Использование более совершенных алгоритмов морфинга протеинов
3. Хранение загруженных пользователями pdb-файлов на серверах Amazon с помощью сервиса Amazon S3

Кроме того, на развитие сервера повлияют многочисленные отзывы специалистов, использующих сервис.

Немаловажным является избавление сервиса от некоторых ограничений, присутствующих в текущей версии:

1. Невозможность морфинга протеинов с разным числом аминокислотных остатков
2. Невозможность выбора цепей протеинов

Так же немаловажным будет экспорт результатов морфинга в формат gif или ему подобный.

Список литературы

1. <http://theobald.brandeis.edu/qcp/>
2. <https://github.com/mrdoob/three.js/>
3. <http://www.khronos.org/webgl/>
4. Dave Thomas, Andy Hunt, “Programming in ruby”, 2000
5. Scott Chacon, “Pro Git”, 2009
6. <http://ruby.railstutorial.org/ruby-on-rails-tutorial-book>
7. John McCreesh, “Four days on rails”
8. Obie Fernandez, “The rails way”
9. David Flanagan, “The ruby programming language”
10. <http://learningwebgl.com/blog>
11. Aaftab Munshi, Dan Ginsburg, Dave Shreiner, “Open GL ES 2.0 Programming Guide”
12. http://en.wikipedia.org/wiki/Kabsch_algorithm
13. <http://bioruby.open-bio.org/>