

Echo + баесовская кластеризация

Дмитрий Грошев, Ирина Горбунова



СПБАУ

04.06.2012

Краткое содержание предыдущих серий

- ▶ <http://uc-echo.sourceforge.net/>
- ▶ эффективно исправляет ошибки

- ▶ улучшенная версия утилиты hammer
- ▶ кластеризует k-меры перед исправлением ошибок
- ▶ эффективнее начальной версии

- ▶ попытка улучшить ECHO
- ▶ кластеризация похожих ридов

Как работает ECHO

- ▶ поиск пересекающихся ридов (соседей)
- ▶ исправление ошибок



Поиск соседей

- ▶ поиск точно совпадающего k-мера hashmap'ом

$$K = \max\left(\frac{L}{5}, \log(\sqrt[4]{N * L})\right)$$

- ▶ подбор ω и ϵ (покрытие конкретного нуклеотида должно иметь распределение Пуассона)
- ▶ поиск неточных соседей по ω и ϵ

- ▶ В группе соседей делается MAP по каждому нуклеотиду и confusion matrix
- ▶ На основе исправленных ридов пересчитывается confusion matrix
- ▶ Повторять до сходжения

Это EM-алгоритм

Maximum A Posteriori

$$P(A_i) = \prod_{j=1}^N \Phi_{READS_{j,i}, A}$$

$$\arg \max_{X=A, T, G, C} P(X)$$


Что сделали мы




- ▶ выбираются произвольные центры
- ▶ для каждой точки ищется ближайший центр (диаграмма Вороного)
- ▶ пересчитываются центры

Это тоже EM


K-Means




K-Means



K-Means



K-Means



Модификация K-Means с более сложной инициализацией

- ▶ центроидом выбирается случайная точка
- ▶ подсчитывается расстояние от каждой точки до ближайшего центроида
- ▶ новый центроид выбирается из оставшихся точек с вероятностью, пропорциональной квадрату расстояния от остальных центроидов

Проблема

Риды не полностью совпадают (в отличие от k-меров):

```
ATGCATGCA
  TCATGTACGG
  TGCATGCAC
```

Добавим спецсимвол:

ATGCATGCA
 TCATGTACGG
 TGCATGCAC

Расстояние от _ до любого символа = 0.

Если выбран неполный центроид, дополнить из ближайших
(случайный нуклеотид пропорционально расстоянию)

Инициализация

 ATGC
GCGCTGC
GCGCTAC
GCGCT <---
TATATAT
TCTAT
TATGTAT

Инициализация

 ATGC
GCGCTGC *
GCGCTAC *
GCGCT <---
TATATAT
TCTAT
TATGTAT

Инициализация

 ATGC
GCGCTGC
GCGCTAC
[GCGCTGC] <---
TATATAT
TCTAT
TATGTAT

Поиск ближайшего центроида

Расстояние = $1 - \text{likelihood}$

Поиск новых центроидов

Снова MAP:

group1	group2
ATGC	TATATAT
GCGCTGC	TCTAT
GCGCTAC	TATGTAT
GCGCT	
-----	-----
GCGCTGC	TATATAT

Результаты

- ▶ кластеризация кластеризует
- ▶ запускается
- ▶ на больших наборах данных ещё не запускали

Вопросы?