

Hammock: nástroj pro shlukování velkého množství krátkých peptidových sekvencí

Adam Krejčí

RECAMO, Brno, Czech Republic



EUROPEAN UNION
EUROPEAN REGIONAL DEVELOPMENT FUND
INVESTING IN YOUR FUTURE



**OP Research and
Development for Innovation**

Obsah

- 1 Motivace: peptidové knihovny
- 2 Shlukování sekvencí
- 3 Hammock - software pro shlukování sekvencí
- 4 Experiment - Doména SH3
- 5 Experiment - Monoklonální protilátky
- 6 Experiment - Pouze selekce
- 7 Závěr



Peptidové knihovny

- Laboratorní metody
- Využívají rozsáhlé knihovny obsahující až 10^9 různých náhodných peptidů
- Cíl: selektovat peptidy interagující s *cílem* (protein, DNA, povrch buněk...)
- Phage display, ribosome display, mRNA display...
- Typické využití: mapování epitopů

Phage display

- Modifikované fágy nesou krátkou (12 AA) sekvenci na povrchu (= *mimotop*)
- Fág spojuje selektovatelný peptid s čitelnou (DNA) informací
- Protein upevněný na povrchu - *cíl*
- Postup:
 - 1 Vystavení proteinu fágové knihovně.
 - 2 Vymytí fágů, které neinteragovaly (nejsou přichyceny na povrchu proteinu).
 - 3 Uvolnění interagujících fágů a jejich amplifikace v bakteriích.
- Opakování všech kroků. Nakonec sekvenace interagujících fágů.

Phage display




Problémy

Problémy


Problémy

- Fágy interagují nespecificky (s povrchem, s jinými fágy...)



Problémy

- Rozdíly v úspěšnosti amplifikace fágů ("*parazitní fágů*")



Využití NGS

- Výrazně větší množství dat
 - Méně kol selekce/amplifikace
 - Sekvenování po každém kole selekce/amplifikace
- Více různých interagujících sekvencí → určení vazebného motivu
- Možnost zkoumat více interakcí naráz
 - vícenásobně specifické proteiny, proteinové komplexy, celé buňky, krevní sérum...
 - Možnost získat řádově miliony unikátních sekvencí

Jak identifikovat významné sekvenční motivy reprezentující jednotlivé interakce v tak rozsáhlých datech?

Shlukování sekvencí

GPILGHYNNTAQGT
 MPITTYWLSRYR
 ALWPPNLHAWV
 SHIOTYSSRIFT
 VMSRGNNVEWLN
 SGAFQTIPLVTL
 TPLTVHGLPOLT
 LLWPPNLHAWEP
 ALYTLPPDSLNL
 SQPDCYMSPHCG
 APTTQRVFWDQR
 FLPWTTYTNLMOL
 ALYTLPPDSLNL
 ANYHPWSLMSDM
 NEYLRQYSQPL



HLTHSPIPVRAM
 QLTHSPIPVRAM
 HLTHSPIPVRAT


ALWPPNFHAWLP
 SALWPPSLDAWV -
 ALWSPNLHAWAP
 ALC -PNLHACVP

Shluky sekvencí


```

---AIMPEVPQRNWV--
----APALPLRNDGRY
----APVLPARIWYDV
---DLGPLLPSRNVS--
----ERPLLVRNLGI-
----FGPALPARWGGV-
----GIPEIPAGNWAV-
----GIPEIPARNWAV-
----GPALPARTVGIL
QRMWFLPAVPGL-----
---RAGPMLPDKNLY--
---RAGPMLPDRSLY--
----RGPALPLRVLLH-
----RGPALPLRVLLR-
----RGPVLPLRVLLH-

```



Hammock - software pro shlukování sekvencí



KREJCI, A. et al. Hammock: a hidden Markov model-based peptide clustering algorithm to identify protein-interaction consensus motifs in large datasets.


Bioinformatics. sep 2015, s. btv522, doi: 10.1093/bioinformatics/btv522

Postup algoritmu

- ❶ Vytvoření iniciálních shluků ("jader") hladovým algoritmem
- ❷ Vybrána největší jádra, zbytek sekvencí chápán jako neshlukované
- ❸ Shluky (jádra) reprezentovány pomocí HMM
- ❹ Několik iterací:
 - ❶ Rozšiřování shluků - prohledání zbylých sekvencí pomocí HMM
 - ❷ Slučování shluků - s využitím porovnání HMM-HMM
- ❺ Výsledek: Finální shluky + zbylé (neshlukované) sekvence

HMM - Skrytý Markovův Model

- Účel: zarovnání + skóre MSA vs. sekvence
- Stochastický konečný automat s výstupem
- Původní využití: rozpoznání signálu
- varianta pHMM (profile HMM) určena pro reprezentaci MSA
- 3 druhy stavů - match, insertion, deletion
- Rozdíl oproti PSSM - lze reprezentovat vnitřní mezery



Hladový (greedy) shlukovací algoritmus

- 1 Seřazení sekvencí
 - 2 1. sekvence je reprezentantem 1. shluku
 - 3 2. až n. sekvence: porovnání se všemi reprezentanty shluků, následně:
 - Dostatečné skóre → vložena do nejpodobnějšího shluku
 - Nedostatečné skóre → označena jako reprezentant nového shluku
- $O(n^2)$
 - Využití substituční matice
 - Omezené zarovnání bez vnitřních mezer

Rlozšřřvání shluků

- Hmmer
- Iterativní přidávání nalezených sekvencí do MSA
- Omezení délky zarovnání, počtu *match* stavů HMM, entropie pozic MSA, počtu vnitřních mezer

FINN, R. D. – CLEMENTS, J. – EDDY, S. R. *HMMER web server: interactive sequence similarity searching. Nucleic Acids Research.* 2011, 39, 2, s. 29–37.

ISSN 0305-1048

Slučování shluků

- Založeno na HMM-HMM porovnání (HH-suite)
- Kompletní aglomerativní hierarchické shlukování (shluků)
- Výpočetně náročné ($O(n^3)$)
 - Heuristika
 - Využití informací z minulého kroku
 - Nalezené sekvence vypovídají o podobnosti shluků
- Omezení délky zarovnání, počtu *match* stavů HMM, entropie pozic MSA, počtu vnitřních mezer

SÖDING, J. Protein homology detection by HMM-HMM comparison.

Bioinformatics. 2005, 21, 9, s. 2144.


ISSN 1367-4803

Implementace

- Java + externí procesy
- Všechny kroky paralelizovány
- Modul pro Galaxy

Rychlost

- 10^6 sekvencí za ~ 3 h (Desktop, 8 jader)




Obsah

- 1 Motivace: peptidové knihovny
- 2 Shlukování sekvencí
- 3 Hammock - software pro shlukování sekvencí
- 4 Experiment - Doména SH3**
- 5 Experiment - Monoklonální protilátky
- 6 Experiment - Pouze selekce
- 7 Závěr

Experiment - Doména SH3

- Malý soubor dat (2457 sekvencí)
- Dříve použito pro testování obdobných nástrojů
- Phage Display, Src SH3 doména
- Doména váže 2 motivy



Porovnání výsledků

Nástroj	Čas	Počet shluků	Počet sekvencí	KLD match	KLD all
Hammock	17 s	2	2153	28.165	24.858
Gibbs	39 min	2	2450	25.151	22.369
MUSI	17 s	2	2456	20.96	19.89

KIM, T. et al. **MUSI: an integrated system for identifying multiple specificity from very large peptide or nucleic acid data sets.**

Nucleic Acids Research. 2012, 40, 6

ANDREATTA, M. – LUND, O. – NIELSEN, M. **Simultaneous alignment and clustering of peptide data using a Gibbs sampling approach.**

Bioinformatics. 2013, s. 8 – 14.

ISSN 1367-4803

Obsah

- 1 Motivace: peptidové knihovny
- 2 Shlukování sekvencí
- 3 Hammock - software pro shlukování sekvencí
- 4 Experiment - Doména SH3
- 5 Experiment - Monoklonální protilátky**
- 6 Experiment - Pouze selekce
- 7 Závěr


Experiment - Monoklonální protilátky

- Phage display, selekce pomocí 3 monoklonálních protilátek
- 3 kola selekce, 2 kola amplifikace
- Sekvenováno po každém S/A kole
- 74 041 unikátních sekvencí, 316 119 sekvencí celkem





Teoreticky...

- Shluky sekvencí specificky rozpoznaných protilátkou
→ Obohaceny pouze v selekčních krocích této protilátky
- Shluky sekvencí s nespecifickou vazbou:
→ Obohaceny ve všech selekčních krocích
- Shluky fágů, které se lépe amplifikují
→ Obohaceny ve všech amplifikačních krocích


Největší shluky



Největší shluky




Největší shluky




CHIP - FDPVTR

Největší shluky



p53 - FSDLWKLL

Největší shluky



HSP90-alpha - LKEFEGKT

Porovnání výsledků

Nástroj	Čas	Počet shluků	Počet sekvencí	KLD match	KLD all
Hammock	2 m 35 s	74	14421	17.897	17.635
Gibbs	>72 h	-	-	-	-
Gibbs -g 100	14 h 13 m	100	74040	12.622	11.335
MUSI	8 h 20 m	1	74041	0.0	3.22

- Shluky obsahují:
 - 14 421 (19.5 %) unikátních skvencí
 - 316 119 (81.1 %) sekvencí celkem


Obsah

- 1 Motivace: peptidové knihovny
- 2 Shlukování sekvencí
- 3 Hammock - software pro shlukování sekvencí
- 4 Experiment - Doména SH3
- 5 Experiment - Monoklonální protilátky
- 6 Experiment - Pouze selekce**
- 7 Závěr


Experiment - Pouze selekce

- Phage display, selekce pomocí protilátky DO-1
- pouze 1 kolo selekce, žádná amplifikace
- Duplikát, sekvenování knihovny + čistého G-proteinu
- 690 491 unikátních sekvencí


Největší shluky



Největší shluky



Cluster 4



Cluster 17

Obsah

- 1 Motivace: peptidové knihovny
- 2 Shlukování sekvencí
- 3 Hammock - software pro shlukování sekvencí
- 4 Experiment - Doména SH3
- 5 Experiment - Monoklonální protilátky
- 6 Experiment - Pouze selekce
- 7 Závěr**

Shrnutí

- Hammock shlukuje krátké peptidové sekvence
- Až 10^6 sekvencí na desktopu
- Umožňuje provádět Phage display experimenty bez amplifikace
- **Aplikace**
 - Phage display - charakterizace protilátek
 - Phage display - polyklonální sérum po vakcinaci
 - Shlukování CDR3 sekvencí
 - ...

Poděkování



- Petr Müller
- Borivoj Vojtesek



- Ted R. Hupp
- Anne-Sophie Huart



- Matej Lexa