

IV107 Bioinformatika I

Přednáška 1

Katedra informačních technologií
Masarykova Univerzita Brno

Jaro 2011



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



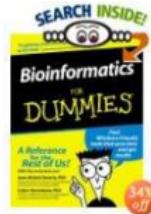
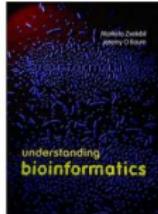
Kontaktní údaje

- ▶ Dr. Matej Lexa, C506 (lexa@fi.muni.cz)
- ▶ Přednáška Po 08:00-09:50 (B410)
- ▶ Konzultace Čt 13:00-15:00
- ▶ <http://www.fi.muni.cz/~lexa/teaching.html>



Studijní literatura

1. Zvelebil and Baum (2007).
Understanding bioinformatics, Garland Science, Oxford, 772 s. (ISBN: 0-8153-4024-9)
2. Krane and Raymer (2005).
Fundamental concepts in bioinformatics, Benjamin Cummings, London, 320 s. (ISBN 0-8053-4633-3)
3. Claverie (2005).
Bioinformatics for dummies, Wiley Publishing, Hoboken, 452 s. (ISBN: 0-7645-1696-5)



Vědecké časopisy

- ▶ Bioinformatics
- ▶ BMC Bioinformatics
- ▶ J. of Bioinformatics and Computational Biology
- ▶ Briefings in Bioinformatics
- ▶ Genome Informatics
- ▶ Theoretical Biology and Medical Modelling
- ▶ InSilico Biology
- ▶ Biosemiotics



Obor bioinformatika na FI

- ▶ Bakalářská a magisterská úroveň
- ▶ Lze zvolit i v průběhu studia
- ▶ Základní sada předmětů Aplikované informatiky na FI a čtyři předměty na LF a PřF.
- ▶ Povinnost vypracovat bioinformatickou závěrečnou práci
- ▶ <http://www.fi.muni.cz/~lexa/teaching.html.cz>
- ▶ https://is.muni.cz/auth/setkavani/kruh.pl?kruh_id=7161
Bioinformatika@FI Muni



Navazující předměty FI

- ▶ IV108 - Bioinformatika II (podzim)
- ▶ IV105/IV106 - Seminář z bioinformatiky P/G (Út 8:00 B411)
- ▶ IV110/IV114 - Projekt z bioinformatiky (podzim)
- ▶ IV116 - Evolutionary Bioinformatics (podzim?)
- ▶ PB051 - Výpočetní metody v bioinformatice a systémové biologii



Příbuzné předměty FI

- ▶ IV109 - Modelování a simulace
- ▶ IV117/8 - Systémová biologie



Harmonogram kurzu

- ▶ Rychlý úvod do molekulární biologie (do poloviny března)
- ▶ Semestrální test (březen/duben)



Klasifikace

- ▶ Hodnotí se
 - ▶ Semestrální test 20 bodů
 - ▶ Zkouška 80 bodů
- ▶ Klasifikační stupnice
 - ▶ A 90 - 100
 - ▶ B 80 - 89
 - ▶ C 70 - 79
 - ▶ D 60 - 69
 - ▶ E 50 - 59
 - ▶ F méně než 50



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



Definice bioinformatiky

Bioinformatika

Studuje metody shromážďování, spřístupňování a analýzy rozsáhlých souborů biologických dat, zejména molekulárně – biologických.

Další disciplíny

- ▶ Výpočetní nebo matematická biologie
matematické přístupy k reprezentaci a zkoumání
biologických procesů, často simulace
- ▶ Lékařská informatika
práce s medicínskými daty, převážně záznamy pacientů



Předmětem zájmu nebo používanými metodami se bioinformatika prolíná s

1. molekulární biologií
2. genomikou a proteomikou
3. genetikou
4. výpočetní biologií
5. matematickou či teoretickou biologií
6. systémovou biologií
7. biomedicínskou informatikou
8. biomedicínským inženýrstvím
9. výpočetní chemií
10. informatikou
11. počítačovou lingvistikou



Typické okruhy problémů

- ▶ Analýza sekvencí
- ▶ Anotace genomů
- ▶ Evoluční bioinformatika
- ▶ Studium biodiverzity
- ▶ Analýza exprese genů
- ▶ Analýza genové regulace
- ▶ Analýza proteomu
- ▶ Odhad struktury proteinů
- ▶ Srovnávací genomika
- ▶ Modelování biologických systémů
- ▶ Analýza obrazu
- ▶ Studium strukturních interakcí proteinů

Převzato z <http://en.wikipedia.org/wiki/Bioinformatics> 16.2.2008



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

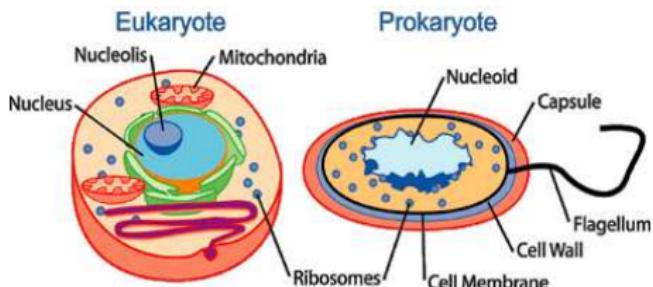
Struktura DNA

Transkripce a translace

Struktura proteinů



Buňka – základní forma organizace živé hmoty



- ▶ Molekuly (DNA, proteiny, sacharidy, lipidy)
Geny (abstraktní pojem)
- ▶ Proteinové komplexy/membrány
- ▶ Organely a jiné substruktury
- ▶ Buňka
- ▶ Tkáň/pletivo
- ▶ Organizmus



Složitost biologických systémů na molekulární úrovni

Člověk: cca 10^{14} buněk.

Buňka: 3×10^9 párů nukleotidů DNA (A:T a C:G).

Nukleotidy: vytváří sřetězenými kombinacemi cca 20000 genů
(a statisíce funkčních míst)

Geny: kódují (a aktivitou vytváří) staticíce molekul
(proteinů a RNA)

Buňka: aktivuje v daném momentu určitou podmnožinu
této sady

Výsledek: obrovské množství možných stavů buněk (2^{20000}
je velmi podceňující odhad)

Geny: evolucí vybrané sady z cca 4^{1000} možných
sekvencí DNA (1000 nukl./gen)



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů

Bioinformatická data

- ▶ Sekvence DNA a RNA
- ▶ Sekvence proteinů
- ▶ Struktura proteinů
- ▶ Údaje o aktivitě genů DNA čip, microarray, RNA-Seq
- ▶ Údaje o expresi proteinů 2-D gely + MS
- ▶ Mapy interakcí mezi proteiny a DNA - Chip-Seq
- ▶ Mapy interakcí mezi proteiny navzájem - Y2H
- ▶ Literatura



Sekvenční data

AUGACAGUUGACGAGUGCA
ATAGCAGTGCGCATGCAGT
MASAQSFYLLMDDHLAVFM



Sekvenční data

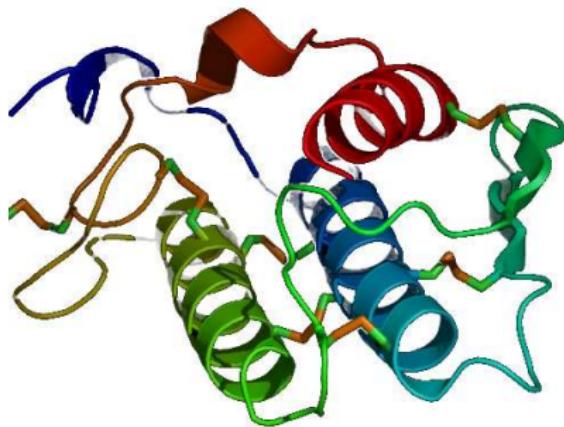
DNA ATAGCAGTGCGCATGCAGT

RNA AUGACAGUUGACGAGUGCA

Protein MASAQSFYLLMDDHLAVFM



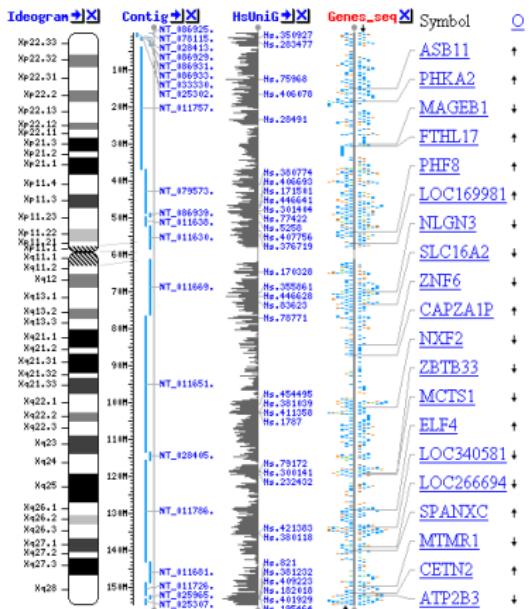
Strukturní data



Zobrazení struktury proteinu



Spřístupnění dat uživatelům – NCBI Genome Viewer



Zobrazení informací o genech na chromozomu



Spřístupnění dat vývojářům

- ▶ Grafika je zbytečná. Prvořadá je rychlosť a možnosť automatizácie manipulácie s dátami
- ▶ BioJava, BioPerl, BioPython, Bioconductor (R) a ďalšie knihovny pre väčšinu jazykov a prostredí
- ▶ servery poskytujúci syrová dátá (holý text, obrázky, XML a ďalšie štruktury pre HTTP, SOAP, ODBC)



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



Stopy bioinformatiků na webu

výraz	Google (tis. výskytů)	
	2004	2011
<i>et tu brutus</i>	212	195
<i>in vino veritas</i>	162	1130
<i>veni vidi vici</i>	132	2340
<i>in vivo</i> (biolog)	19100	11400
<i>in vitro</i> (biochemik)	12900	18000
<i>in silico</i> (bionformatik)	349	1790



Práce bioinformatika

- ▶ Umí pracovat s velkými datovými soubory
- ▶ Moudrými triky ovláda výkonné počítače
- ▶ V datech hledá zajímavé subsekvence
- ▶ Srovnává podobné sekvence
- ▶ Předpovídá strukturu a funkci genů a proteinů
- ▶ Studuje vývoj sekvencí a organismů
- ▶ Data a výsledky analýz zobrazuje graficky



Způsob nahlížení na data

KLASIK směs biologie, chemie, fyziky atd.

MECHANIK živé buňky jsou stroje, které chceme pochopit a ovládat

HRA sekvence jsou definiční soubory hráčů

SEMIOTIK život je signalizace a interpretace signálů

JAZYK sekvence se skládají z modulů (slov) s určitou funkcí vykazujících gramatické uspořádání



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



Kořeny a zdroje bioinformatiky

1951	Pauling	struktura proteinů
1952	Turing	chem. základy vývoje
1953	Watson, Crick, Franklin	struktura DNA
1956	Gamow et al.	genetický kód
1959	Chomsky	gramatiky
1962	Shannon a Weaver	informační teorie
1966	Martin-Lof	náhodné řetězce
1966	Neumann	automata
1969	Britten a Davidson	génová regulace

Historie bioinformatiky do sformování disciplíny

- 1967 Fitch and Margoliash: sestrojení prvních fylogenetických stromů z bilogické sekvence
- 1970 Needleman and Wunsh: zarovnání dvou sekvencí
- 1974 Chou and Fasman: predikce sekundární struktury proteinů
- 1978 Dayhoff: první sbírka sekvencí proteinů
- 1981 Kabsch and Sander: modelování struktury proteinů
- 1987 Feng and Doolittle: mnohonásobné zarovnání sekvencí
- 1990 Altschul et al.: efektivní hledání lokálních podobností
- 1998 The Journal Comp Appl Biosci se přejmenovává na Bioinformatics



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů

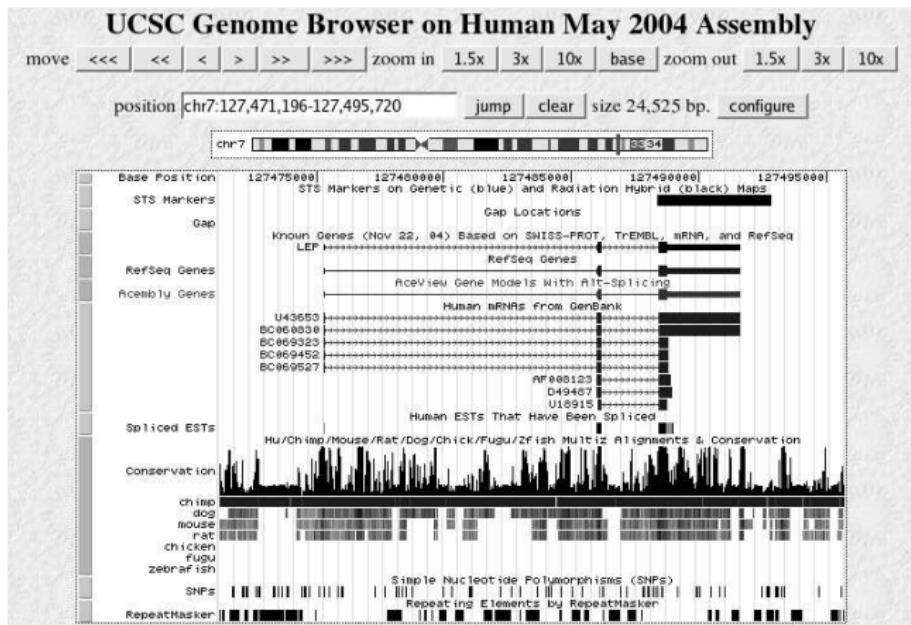


- ▶ Jim Kent – autor Aegis Animator, Cyber Paint a Autodesk Animator
- ▶ po shlédnutí 12-ti CD vývojového prostředí Windows 95 přechází k bioinformatikům s posteskem, že lidský genom se vejde na jedno CD
- ▶ autor webové aplikace Genome Browser
- ▶ sehrává důležitou roli v honičce o přečtení a skompletování lidského genomu (program GigAssembler)

Převzato z Jim Kent: "The Genes, the Whole Genes, and Nothing But the Genes", BioCon 2003.



UCSC Genome Browser

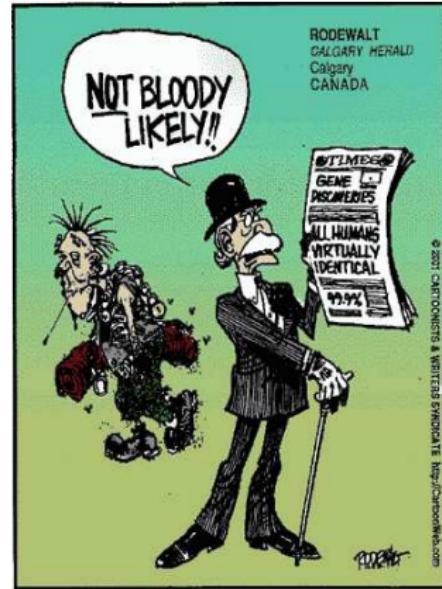


Flexibilní nástroj určen k interaktivnímu prohlížení genomů



Homo/Homo

- ▶ rozdíl každých 1000 nukleotidů
 - ▶ 90% variace je mezi africkými populacemi
 - ▶ na Zemi je tolik lidí a četnost mutací je tak vysoká, že každý ze jmenovaných nukleotidů je v dané generaci mutován několik krát
 - ▶ lidský genom obsahuje Většina je recessivních je mají oba rodiče



Převzato z Jim Kent: "The Genes, the Whole Genes, and Nothing But the Genes" BioCon 2003.

Homo/Pan

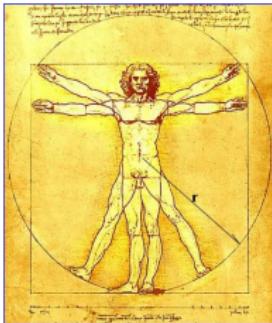


- ▶ rozdíl každých 100 nukleotidů
- ▶ transpozon každých 50000 nukleotidů
- ▶ dva chromozomy spojené, jinak podobná struktura

Podle Jim Kent: "The Genes, the Whole Genes, and Nothing But the Genes", BioCon 2003.



Homo/Mus

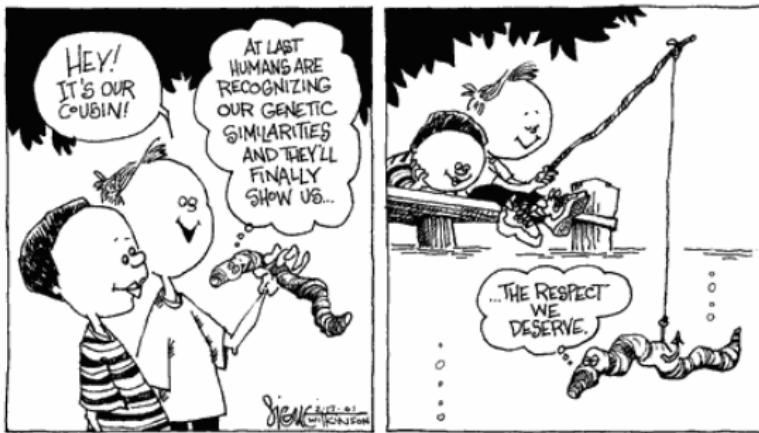


- ▶ 40% nukleotidů byli od dob společného předka změněny
- ▶ Ve funkčních oblastech se změnilo jenom 15% nukleotidů
- ▶ úseky podobnosti mezi genomy člověka a myši jsou kandidáti na biologické funkce

Převzato z Jim Kent: "The Genes, the Whole Genes, and Nothing But the Genes", BioCon 2003.



Homo/Caenorhabditis



Asi 80% nukleotidů změněno (35% ve funkčních oblastech)

Převzato z Jim Kent: "The Genes, the Whole Genes, and Nothing But the Genes", BioCon 2003.



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



Objem dat bude nadále narůstat

- ▶ Základní výskum
- ▶ Medicína a jiné aplikace
- ▶ Bezpečnost na molekulární úrovni
- ▶ Komerční data

V současnosti např. nastupuje "osobní genomika"



HT-Seq: objem dat z jednoho mereni a cena za 1 Mbp

- ▶ Solexa pyrosequencing (Illumina) 18 Gbp \$2
- ▶ 454 (Roche) 0.5 Gbp \$60 (ale delší sekvence)
- ▶ SOLiD (Life Technologies) 24 Gbp \$2
- ▶ Heliscope (Helicos) 28 Gbp \$1
- ▶ Polonator (Danaher Motion) 8 Gbp \$1
- ▶ Zero-mode waveguide sequencing (Pacific Biosciences)
10 Gbp? \$10?
- ▶ Nanoball sequencing (CompleteGenomics) 70 Gbp \$1
- ▶ FRET sequencing (Visigen) ?
- ▶ Nanopore sequencing (Oxford Nanopore) ?



Porovnávání sekvencí

>P11633 NONHISTONE CHROMOSOMAL PROTEIN 6B.

Score = 54.8 bits (155), Expect = 1e-10 Identities = 19/43
(46%), Positives = 24/43 (62%)

Query: 2 TKKFKDPNRPPSAFFLFCSEYRKIKGEHPGLSIGDVAKKLGEM 52

: T : KDPNR SA: F :E R I E:P :: G V : LGE

Sbjct: 5 TTRKKDPNRGLSAYMFFANENRDIRSENPDVTFGQVGRILGER 55



Analogie biosekvence – jazyk

1. Mam z toho velkou radost.
2. Mam toho kocoura dost.

Mamztohovelk ouradost.
::: :::: : :::::::::::::
Mam toho kocouradost.



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

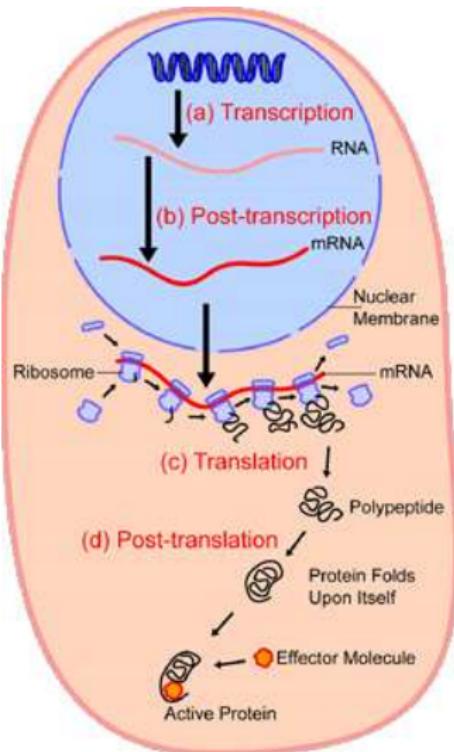
Struktura DNA

Transkripce a translace

Struktura proteinů



Informace v DNA určuje existenci proteinů v buňce



Příště struktura DNA a preotinů

- ▶ Struktura DNA
- ▶ Struktura proteinů
- ▶ Přenos genetické informace



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů

Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů



Outline

Úvod do bioinformatiky

Organizační záležitosti

Zaměření bioinformatiky

Bioinformatická data

Objekty: geny, molekuly, buňky

Bioinformatická data

Práce bioinformatika

Historie bioinformatiky

Zkoumání lidského genomu

Aktuální problémy

Molekulární biologie v kostce

Centrální dogma

Struktura DNA

Transkripce a translace

Struktura proteinů

