

Manipulace se sekvenčními daty

Typy jednoduchých bioinformatických analýz

- 1. Přístup k datům a konverze formátů**
- 2. Konverze dat, hledání**
- 3. Výpočetní analýza sekvencí**
- 4. Sestavení celogenomových sekvencí**
- 5. Manipulace se strukturními daty**
- 6. Návrh oligonukleotidů**

1. Přístup k datům

- Přístup k nukleotidovým databázím
 - ◆ NCBI
 - ◆ EBI
 - ◆ DDBJ
- Přístup k proteinovým a strukturním databázím
 - ◆ PDB
- Zobrazení záznamů v databázích
- Získávaní dat
- Konverze formátů
- Editace

Získání a manipulace se sekvencemi

Databases

Entrez
SRS



Retrival System



Information

Sequence, Pdb, Image

DNA
NCBI-GenBANK
DDBJ
EBI-EMBL

Protein
PIR
SWISSPROT
EXPASY, PDB

Softwares

GCG
SeqWEB
Vector NTI
GenoMAX
CLC Workbench

GenBANK
GCG
FASTA
Staden
Image

Formats

Sequence
Converter

Sdílení dat v základních databázích



GenBank: <http://www.ncbi.nlm.nih.gov/>

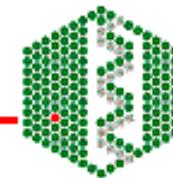
National Center for Biotechnology Information (NCBI)

EMBL: <http://www.ebi.ac.uk>

EMBL

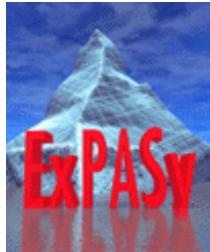
European Bioinformatics Institute (EBI)

European Bioinformatics Institute



DDBJ: <http://www.ddbj.nig.ac.jp/>

National Institute of Genetics (NIG)



ExPASy: <http://tw.expasy.org>

Expert Protein Analysis System

Zápis sekvence

- **Sekvence** – zápis posloupnosti jednoznačných znaků odpovídajících jednotlivým zbytkům (monomerům), které se nacházejí v odpovídající posloupnosti v dané makromolekule
 - ◆ **DNA nebo RNA od 5'-konce k 3'-konci**
 - ◆ 5' CAAACGT CGTCTATCAGCATTAG 3'
 - ◆ **protein od N-konce k C-konci**
 - ◆ (NH₂-) KRRLSALGP GGLTRR (-COOH)
- používají se jednopísmenové kódy dle pravidel IUPAC

Standardní kódy pro sekvence nukleových kyselin podle IUB/IUPAC

- A** adenosin
- C** cytidin
- G** guanidin
- T** thymidin
- U** uridin
- R** G/A (puRin)
- Y** T/C (pYrimidin)
- K** G/T (nukleosid s Keto skupinou)
- M** A/C (nukleosid s aMino skupinou)
- S** G/C (silná = Strong vazba)
- W** A/T (slabá = Weak vazba)
- B** G/T/C (not A)
- D** G/A/T (not C)
- H** A/C/T (not G)
- V** G/C/A (not T)
- N** A/G/C/T (jakýkoli)
- mezera (gap) neurčené délky

Využití zápisu s degenerovanými nukleotidy

TACGGT
TATAAT
TATAAT
GATACT
TATGAT
TATATT

Konsenzní sekvence: TATAAT

TATRNT

Standardní kódy pro sekvence aminokyselin podle IUB/IUPAC

A	alanin
B	kys. asparagová nebo asparagin
C	cystein
D	kys. asparagová
E	kys. glutamová
F	fenylalanin
G	glycin
H	histidin
I	isoleucin
K	lysin
L	leucin
M	metionin
N	asparagin
P	prolin
Q	glutamin
R	arginin
S	serin
T	treonin
U	selenocystein
V	valin
W	tryptofan
Y	tyrosin
Z	kys. glutamová nebo glutamin
X	jakákoli aminokyselina
*	translační stop (terminační kodon)
-	mezera (gap) neurčené délky

Běžné formáty sekvencí

http://orion.sci.muni.cz/kgmb/bioinformat/seq_samples.htm

- Prostý text
- FASTA
- FASTQ
- Genbank
- EMBL
- GCG
- PIR
- ASN1
- Výstupní data sekvenování: ABI, AB1, SCF, SFF, BAM, SAM, FASTF aj.

Formáty sekvencí obsahující mnohonásobná přiložení

- Multi FASTA
- Phylip
- PAUP / NEXUS
- Clustal
- MSF

PLAIN SEQUENCE FORMAT

Obsahuje pouze IUPAC znaky

Obsahuje jedinou sekvenci

Příklad

```
AACCTGCGGAAGGATCATTACCGAGTGC GGTCCTTGGGCCAA  
CCTCCCATCCGTGTCTATTGTACCCTGTTGCTTCGGCGGGCCCGC  
CGCTTGTGGCCGCCGGGGGGCGCCTCTGCCCCCCGGGCCCGTG  
CCCGCCGGAGACCCAACACGAACACTGTCTGAAAGCGTGCAGTC  
TGAGTTGATTGAATGCAATCAGTTAAAACCTTCAACAATGGATCT
```

FASTA FORMAT

Může obsahovat více sekvencí

Začíná specifickým záhlavím (,,>“)

Příklad:

```
>U03518 Aspergillus awamori internal transcribed spacer 1 (ITS1)
AACCTGCGGAAGGATCATTACCGAGTGCAGGTCTTGGGCCAACCTCCATCCGTGTCTATTGTACCC
TGTTGCTTCGGCGGGCCCGCCGCTGTGGCCGCCGGGGGGCGCCTCTGCCCCCCGGGCCGTGCCGC
CGGAGACCCAACACGAACACTGTCTGAAAG
```

FastQ FORMAT

Obsahuje informaci o kvalitě stanovení sekvence

Příklad:

```
@HWUSI-EAS100R:6:73:941:1973#0/1
GATTGGGGTTCAAAGCAGTATCGATCAAATAGTAAATCCATTGTTCAACTCACAGTT
+
! '' * ( ( ( ***+ ) ) % % % + + ) ( % % % % ) . 1 * * * - + * ' ' ) ) * * 55CCF>>>>>CCCCCCCC65
Nejnižší kvalita                                     nejvyšší kvalita
```

!"#\$%&'()*+,.-./0123456789:;<=>?@ABCDEFGHIJKLMNPQRSTUVWXYZ[]^_`abcdefghijklmnopqrstuvwxyz{ }~

EMBL FORMAT

Začíná řádkem s jedinečným identifikátorem (ID), následuje anotace“.

Obsahuje mnoho různých deskriptorů

Sekvence začíná symboly SQ a sekvence je ukončena „//“

Může obsahovat více sekvencí

Příklad:

```
ID AA03518 standard; DNA; FUN; 237 BP.  
XX  
AC U03518;  
XX  
DE Aspergillus awamori internal transcribed spacer 1 (ITS1) and 18S  
DE rRNA and 5.8S rRNA genes, partial sequence.  
XX  
SQ Sequence 237 BP; 41 A; 77 C; 67 G; 52 T; 0 other;  
aacctgcgga aggatcatta ccgagtgcgg gtcctttggg cccaacacctcc catccgtgtc  
tattgtaccc tggcgccgc cgcttgcgg ccggccgggg ggccgcctctg  
ccccccgggc ccgtgccgc cggagacccc aacacgaaca ctgtctgaaa gcgtgcagtc  
tgagttgatt gaatgcaatc agttaaaaact ttcaacaatg gatctttgg ttccggc  
//  
60  
120  
180  
237
```

GENBANK FORMAT

Začíná řádkem LOCUS

Obsahuje mnoho různých deskriptorů

Začátek sekvence je vyznačen ORIGIN a sekvence je ukončena „//“

Příklad:

```
LOCUS      AAU03518      237 bp      DNA          PLN      04-FEB-1995
DEFINITION Aspergillus awamori internal transcribed spacer 1 (ITS1) and 18S
             rRNA and 5.8S rRNA genes, partial sequence.
ACCESSION   U03518
VERSION     U03518.1  GI 1235658
BASE COUNT   41 a      77 c      67 g      52 t
ORIGIN
       1 aacctgcgga aggatcatta ccgagtgcggtgcctttggg cccaacacctcc catccgtgtc
       61 tattgtaccc tggcgccgc cgcttgcgg ccggccgggggg ggccgcctctg
      121 cccccccgggc ccgtgcccgc cggagacccc aacacgaaca ctgtctgaaa gcgtgcagtc
      181 tgagttgatt gaatgcaatc agttaaaaact ttcaacaatg gatctcttgg ttccggc
//
```

CLUSTAL/MUSCLE FORMAT

Začíná řádkem s definicí

Vkládá mezery do sekvence tak, aby při mnohonásobném přiložení byly identické zbytky nad sebou

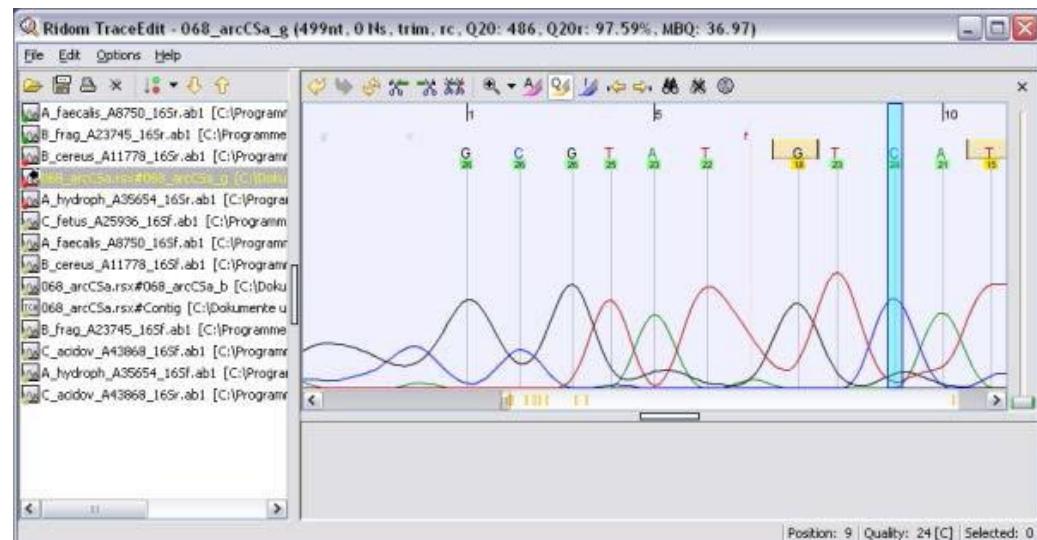
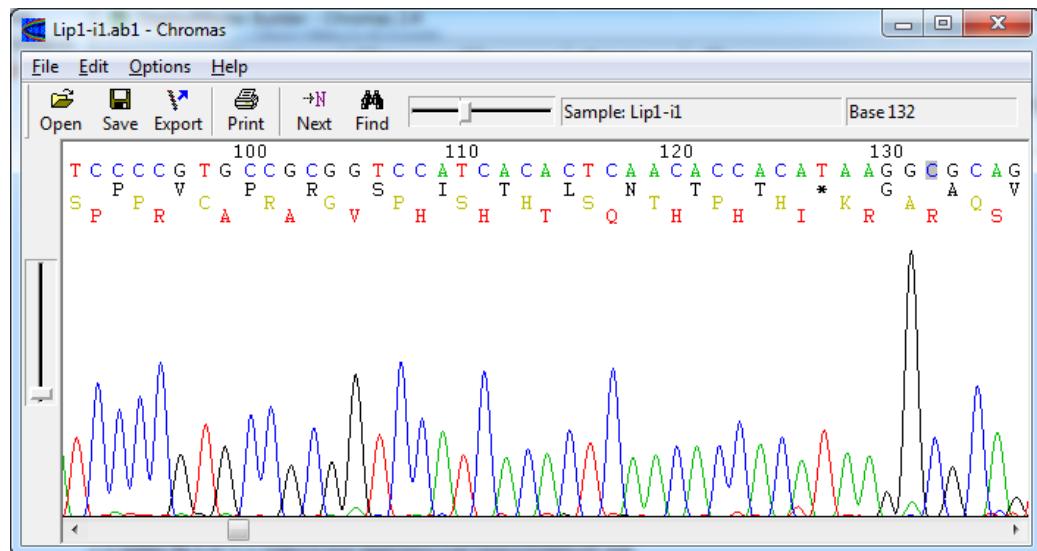
Příklad:

Poznámka k používaným fontům

- Proporcionální fonty
 - ◆ Arial, Times
 - ◆ Každý znak - jiná šířka
 - ◆ Nevhodné pro zápis sekvence
 - Neproporcionální fonty
 - ◆ Vhodné k použití
 - ◆ Všechny znaky stejná šířka
 - ◆ Courier, Monospaced
 - K editaci jsou vhodné editory, které neukládají informace o formátu textu (Notepad, vývojářské editory – PSPad, aj.)
 - Některé formáty jako např. GCG obsahují vnitřní kontrolní součty
- gaattttttt
cttaaaaaaa
- gaattttttt
cttaaaaaaa**

Surová data – elektroforetogramy ze sekvenování v kapiláře

- Různé formáty
 - ◆ *.abi
 - ◆ *.ab1
 - ◆ *.scf
 - Prohlížeče
 - ◆ Chromas Lite
 - ◆ ABIView
 - ◆ Ridom Trace Edit
 - Export
 - ◆ FASTA
 - ◆ Prostý text
 - Formáty z NGS vyžadují zpracování



Jednoduché formáty sekvencí mají omezení a neobsahují

- Data o expresi genů
- Variace a polymorfismy
- WWW odkazy na další informace
- Specifické informace o zdroji sekvence (organismu, klonech, ...)
- Informace o kvalitě

Konverze formátů sekvencí

■ UNIX-GCG

- ◆ To Genbank, To Fasta....
- ◆ From Genbank, From Fasta...

■ READSEQ, SEQRET

- <http://www.ebi.ac.uk/Tools/sfc/readseq/>

■ SMS – The Sequence Manipulation Suite v2

- ◆ <http://www.bioinformatics.org/sms2/>

- ◆ EMBL to FASTA
- ◆ GenBank to FASTA
- ◆ Reverse Complement
- ◆ Filter DNA / Protein

■ Nucleic Acid Sequence Massager

- <http://www.attotron.com/cybertory/analysis/seqMassager.htm>

2. Manipulace se sekvenčními daty

- **Převod informace mezi řetězci**
 - Reverse-complement
- **Hledání motivů**
 - Přesné
 - Podobné
- **Přepis a překlad podle ústředního dogmatu**
 - Transkripce
 - Translace – genetický kód
- **Sekvenční přiložení**
 - Párové, stanovení identity a podobnosti
 - Mnohonásobné, identifikace konzervativních motivů
- **Assembly – kompletace a sestavení genomů**
- **Spojování, rozdělování**
 - Restrikční štěpení
 - Klonování *in silico*, konstrukce vektorů a rekombinantní DNA pro přípravu proteinů

Převod informace mezi řetězci

Nástroj **Reverse Complement**

http://www.bioinformatics.org/sms2/rev_comp.html

>Sample sequence 1
5' CCRGGATATGATCTKCG 3'

Hledání motivů v sekvencích

Hledání slov = uspořádaná množina znaků

GAATTTC

GARYTC

GAAN (1–50) TTC

Standardní příklady hledání

- Restrikční místa
 - Repetice
 - ◆ přímé
 - ◆ Obrácené (vlásenky se smyčkou)
 - Konsenzní vzory
 - Uživatelem definované vzory
 - Otevřené čtecí rámce
- 
- Základ pro hledání genů a funkčních oblastí

Restrikční analýza *in silico*

- Restrikční endonukleázy třídy II
 - ◆ Sekvenčně specifické endonukleázy, které štěpí DNA v rozpoznávaných sekvencích
 - ◆ Přehled dostupný v databázi REBASE- Restriction Enzyme Database
<http://rebase.neb.com/rebase/rebase.html>
 - ◆ Sekvence rozpoznávacích míst
 - ◆ Producent enzymu
 - ◆ Reference
 - ◆ Komerční dostupnost
 - ◆ Sekvence genů
 - ◆ Krystalografická data
 - ◆ Citlivost k methylaci
 - ◆ REBpredictor – predikce rozpoznávací sekvence u nových enzymů
 - ◆ Rebase genomes – identifikace genů pro RE v genomech

Software pro restrikční mapování

- Konstrukce restrikčních map na základě analýzy sekvence DNA – vyhledání restrikčních míst
 - ◆ Nezbytný předpoklad pro klonování
 - ◆ Interpretace RFLP polymorfizmů
 - ◆ Simulace výsledků gelové elektroforézy restrikčních fragmentů
- Virtuální klonování
- Vytvoření kvalitní grafiky ilustrující restrikční mapy
 - ◆ RestrictionMapper (<http://www.restrictionmapper.org/>)
 - ◆ WebCutter (<http://www.firstmarket.com/cutter/cut2.html>)
 - ◆ NEB Cutter v2.0 (<http://tools.neb.com/NEBcutter2/>)
 - ◆ EMBOSS Restrict
(<http://bioweb.pasteur.fr/seqanal/interfaces/restrict.html>)
 - ◆ Restriction Maps
(<http://arbl.cvmbs.colostate.edu/molkit/mapper/index.html>)
 - ◆ pDRAW32 (<http://www.acaclone.com/>)

Výsledky restrikční analýzy *in silico*

- Enzymy – výstup tabulka
 - ◆ kompletní sada
 - ◆ komerční sada
 - ◆ které sekvenci neštěpí
 - ◆ které štěpí – počet a pozice rozpoznávacích míst
- Lineární nebo kružnicová mapa sekvence se znázorněním pozice restrikčních míst
 - ◆ Grafika
 - ◆ Identifikace ORF a translace do proteinu

NEB Cutter

<http://tools.neb.com/NEBcutter2/>

← → http://tools.neb... NEBcutter

NEW ENGLAND BioLabs Inc.
NEBcutter

Circular Sequence: L08752

Display: - NEB single cutter restriction enzymes
- Main non-overlapping, min. 100 aa ORFs
GC=51%, AT=49%

Help Comments

Cleavage code | Enzyme name code

- ✗ | blunt end cut
- ▲ | 5' extension
- ▼ | 3' extension
- ▼ | cuts 1 strand

Available from NEB
Has other supplier
Not commercially available
*: cleavage affected by CpG meth.
#: cleavage affected by other meth.
(enz.name): ambiguous site

ORFs:
a: 286 aa
b: 133 aa
c: 118 aa

2686 bp

*TspMI
*AvaI
*SmaI
BamHI
XbaI
*SalI
*AccI
*HincII
SbfI
PstI
BfuAI
BspMI
SphI
HindIII

BseYI
AlwNI
PciI
AflIII
BspQI
SapI
BsXI
*PluTI *SfoI *NarI *KasI
BstAPI NdeI
Eco0109I
*RatII *ZraI
SspI
NmeAIII
*BsrFI
BpmI
BsaI
XmnI
*BcgI
ScaI

WARNING: Not all enzymes shown
See linear display

100%

The circular diagram represents a 2686 bp sequence. It shows several restriction enzyme cleavage sites indicated by colored lines (red, green, blue) and arrows pointing outwards. Some sites are labeled with their enzyme names (e.g., TspMI, AflIII, BspQI). Other sites are marked with an asterisk (e.g., *TspMI, *AflIII), indicating they are affected by CpG methylation. The diagram also highlights three main non-overlapping ORFs labeled 'a', 'b', and 'c' with their respective lengths: 286, 133, and 118 amino acids. The background of the circle is grey, and the labels are in various colors (black, red, green, blue).

Vyhledání otevřených čtecích rámců

- **ORF (Open Reading Frame)**
Sada překládaných kodonů mezi iniciačním a terminačním kodonem
- Výsledek je závislý na použitém genetickém kódu
- U prokaryot, které nemají introny je základem hledání genů
- U eukaryot zpravidla využíváme analýzu sekvencí komplementární DNA (cDNA)

ORF Finder (Open Reading Frame Finder)

<https://www.ncbi.nlm.nih.gov/orffinder/>

The screenshot shows the NCBI ORF Finder web application. The page has a blue header bar with the title "ORF Finder (Open Reading Frame Finder)". Below the header is a navigation menu with links to PubMed, Entrez, BLAST, OMIM, Taxonomy, and Structure. On the left side, there is a sidebar with links to NCBI tools, GenBank submission support, and an FTP site. The main content area contains a descriptive text block about the ORF Finder tool, followed by a form for entering a GI or accession number or sequence in FASTA format. A text input field contains the sequence AF513857. Below the input field are "FROM:" and "TO:" fields, both currently empty. At the bottom, a "Genetic codes" section is shown with a dropdown menu set to "11 Bacterial Code".

The ORF Finder (Open Reading Frame Finder) is a graphical analysis tool which finds all open reading frames of a selectable minimum size in a user's sequence or in a sequence already in the database.

This tool identifies all open reading frames using the standard or alternative genetic codes. The deduced amino acid sequence can be saved in various formats and searched against the sequence database using the WWW BLAST server. The ORF Finder should be helpful in preparing complete and accurate sequence submissions. It is also packaged with the Sequin sequence submission software.

Enter GI or ACCESSION

or sequence in FASTA format

AF513857

FROM: **TO:**

Genetic codes

11 Bacterial Code

Translace *in silico*

- 6 možných čtecích rámců
- Vymezené oblasti - exony
- Jaký genetický kód?
 - ◆ Databáze genetických kódů v NCBI
 - ◆ <http://www.ncbi.nlm.nih.gov/Taxonomy/Utils/wprintgc.cgi>

EMBOSS Transeq

http://www.ebi.ac.uk/Tools/st/emboss_transeq/

The screenshot shows the EMBOSS Transeq web application. At the top, there's a header bar with the EMBL-EBI logo, a search bar, and links for Services, Research, Training, Industry, and About us. Below the header is a main title "EMBOSS Transeq". A navigation menu at the bottom of the page includes "Input form", "Web services", and "Help & Documentation", along with "Share" and "Feedback" buttons.

The main content area is titled "EMBOSS Transeq" and describes the tool as translating nucleic acid sequences to peptide sequences across six frames. It features a large text input field for pasting sequences and a file upload button. On the left, a dropdown menu allows selecting between "DNA/RNA" and "Protein" sequences. Below the input fields, a list of sequence types is shown: "F (Forward three frames)", "-1", "-2", "-3", "R (Reverse three frames)", and "6 (All six frames)". To the right of the sequence list is a "CODON TABLE" dropdown set to "Standard Code". A note below the table states: "most users and, for that reason, are not visible." At the bottom right, there's a zoom control showing "100%".

Příklady translace *in silico*



Translate Tool - Results of translation

Open reading frames are highlighted in red. Please select one of the following frames

5'3' Frame 1

LLIQQAKNSDTTPAMPLDTGAMSQGMIGYWLETEINRILTEMNSDRTVGTIVTRVEVD
KDDPRFDNPTKPIGPFYTKEEEELQKEQPDGVFKEDAGRGRYRKVVASPLPQSILEHQLI
QTLADGKNIVIACTGGGGIPVIKKENTYEGVEA

5'3' Frame 2

Y-SNKLNRTVTQRRQCHWILVVQCHRV--AIGWKLKSIAF-LK-IVIEL-AQSLHVWK-I
KMIHDLLTQLNQLVLFIRKKKLKNYKKNSQTQSLKKMDDVVIEK-LRHRYLNLY-NTS-F
KL-QTVKILSLHAVVAVFQL-KKKIPMKVLK

5'3' Frame 3

INPTS-IEQ-HNAGNAIGYLWCNVTVGYDRLLVGN-NQSHFN-NE---NCRHNRYTCGSR-
R-STI--PN-TNWSFLYERRS-RITKRTARLSL-RRCRTWL-KSSCVTTTSIYTRTPVNS
NFSRR-KYCHCMRWRYSSYKKRKYL-RC-S

Příklady translace *in silico*

EMBOSS Sixpack

Input form Web services Help & Documentation

Tools > Sequence Translation > EMBOSS Sixpack

Results for job emboss_sixpack-l20141006-192122-0940-32029869-oy

Result Summary Tool Output Submission Details

Download Sixpack File

EMBOSS_001

```
L L I Q Q A K S N S D T T P A M P L D T      F1
Y * S N K L N R T V T Q R R Q C H W I L      F2
I N P T S * I E Q * H N A G N A I G Y L      F3
1 TtattAaTccaACAAcGCTAAatCGAACaGTGACACAACGCCGGCAATGCCATTGGATACT 60
-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
1 AataaTtAggtTGTTcGATTtaGCTTGtCACTGTGTTGCGGCCGTTACGGTAACCTATGA 60
X N I W C A L D F L S V V G A I G N S V      F6
X I L G V L * I S C H C L A P L A M P Y      F5
* * D L L S F R V T V C R R C H W Q I S      F4

C G A M S Q G M I G Y W L E T E I N R I      F1
V V Q C H R V * * A I G W K L K S I A F      F2
W C N V T G Y D R L L V G N * N Q S H F      F3
61 TGTTGGTGCATGTCACAGGGTATGATAGGCTATTGGTGGAAACTGAAATCAATCGCATT 120
-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
61 ACACCACGTTACAGTGTCCCATACTATCCGATAACCAACCTTTGACTTTAGTTAGCGTAA 120
Q P A I D C P I I P * Q N S V S I L R M      F6
K H H L T V P Y S L S N T P F Q F * D C      F5
T T C H * L T H Y A I P Q F S F D I A N      F4
```

Manuální translace dle gentického kódu

STANDARDNÍ GENETICKÝ KÓD

Aminokyseliny = FFLLSSSSYY**CC*WLLLLPPPPPQQRRRRIIIMTTTNNKKSSRRVVVVAAAADDEEGGGG

Start = -----M-----

Báze1 = UUUUUUUUUUUUUUUCCCCCCCCCCCCAAAAAAGGGGGGGGGGGGGGG

Báze2 = UUUUCCCCAAAAGGGGUUUUCCCCAAAAGGGGUUUUCCCCAAAAGGGGUUUUCCCCAAAAGGGG

Báze3 = UCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAGUCAG

Rámec +1

DNA: ATG GAT GTA AAA GAA ATT AAT TAA

mRNA:

Protein: M D

Rámec +2

DNA: A TGG ATG TAA AAG AAA TTA ATT AA

mRNA:

Protein: W M *

Klonování *in silico*, konstrukce vektorů

- Kombinace segmentů sekvencí
 - ◆ známé/neznámé funkce
- Plazmidy
 - ◆ přebírané z databáze
 - ◆ zpravidla známé funkce
 - ◆ regulační sekvence pro expresi
- Inzerty – obvykle nové sekvence
 - ◆ charakterizované restrikční mapou
 - ◆ charakterizované sekvencí DNA
 - ◆ charakterizované funkcí
- Nomenklatura pro konstrukty není stanovena

Clone Manager (Sci-Ed Software)

http://www.scied.com/pr_cmbas.htm

Clone Manager

File View Clone Map Primer Align Discover Operations Window Help

SYNPUC18V (2686bps)

ApoI
EcoRI
BanII
Eco53kI
SacI
Acc65I
KpnI
AvaI
SmaI
XmaI
BamHI
XbaI
AccI
HincII
SalI
BspMI
SbfI
PstI
SphI
HindIII
AlwNI
GsaI
BseYI
PciI
AflIII
SapI
KasI
NarI
SfoI
BstAPI
NdeI
PfoI
EcoO109I
AatII
ZraI
SspI
AhdI
BsaI
BsrFI
BpmI
NmeAIII
XmnI
TsoI
ScaI

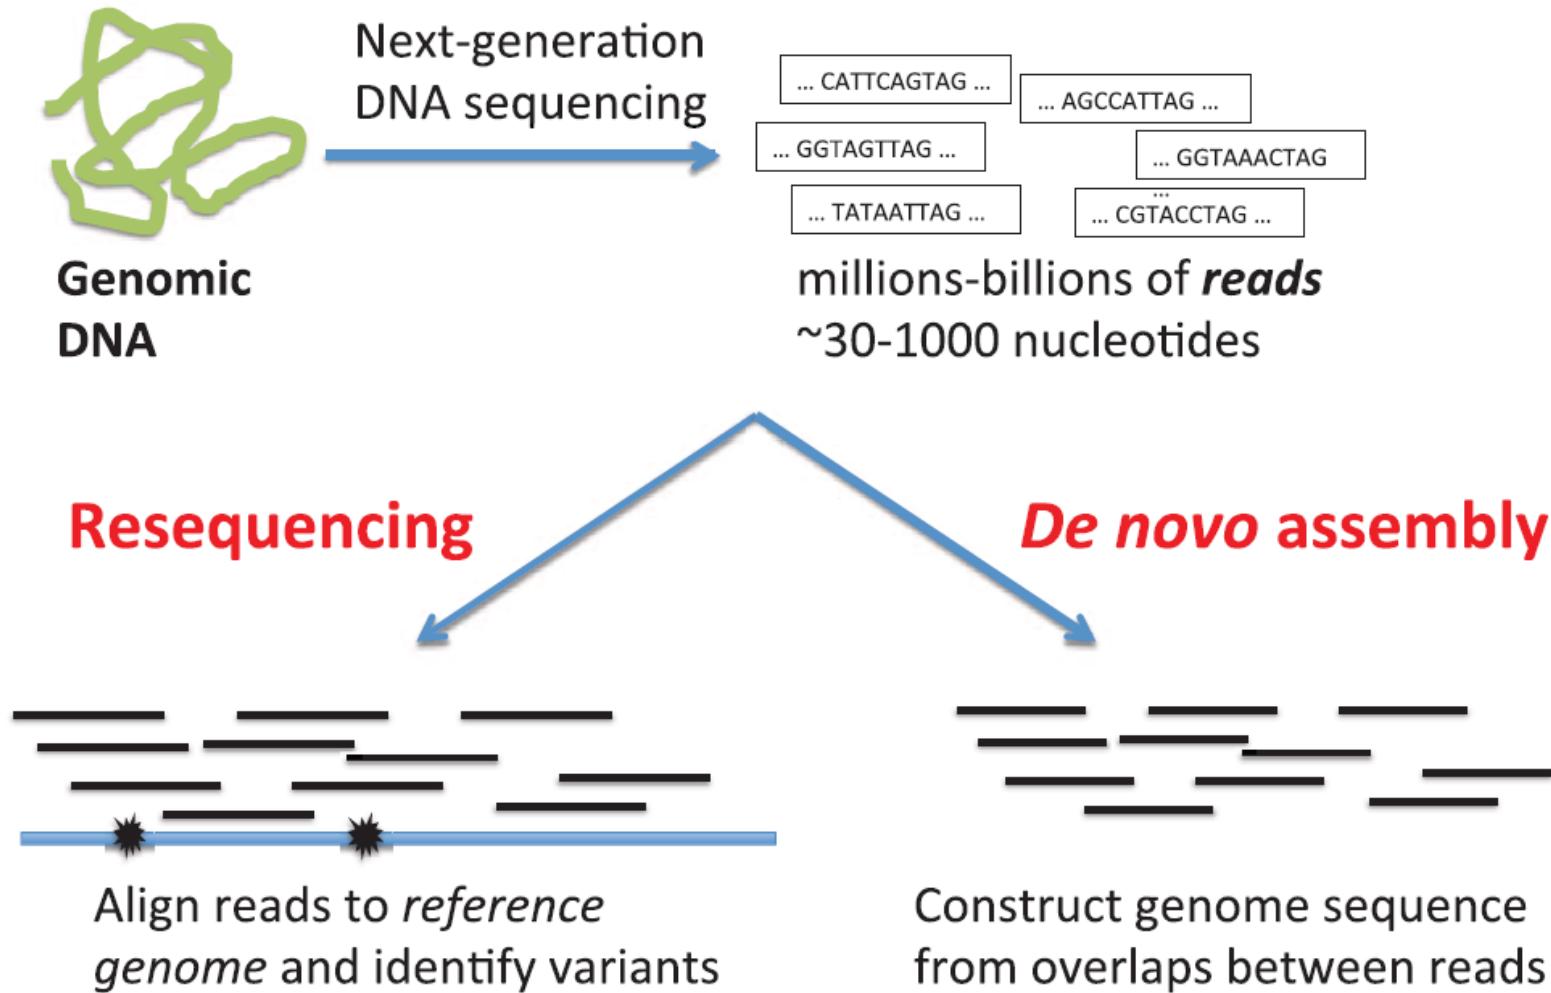
Enzyme Sites 44

Name	Pos	Type
ApoI	230	sc 5'
EcoRI	230	sc 5'
BanII	236	sc 3'
Eco53kI	236	sc bl
SacI	236	sc 3'
Acc65I	242	sc 5'
KpnI	242	sc 3'
AvaI	246	sc 5'
SmaI	246	sc bl
XmaI	246	sc 5'
BamHI	251	sc 5'
XbaI	257	sc 5'
AccI	263	sc 5'
HincII	263	sc bl
SalI	263	sc 5'
BspMI	267	sc 5'
SbfI	268	sc 3'
PstI	269	sc 3'
SphI	275	sc 3'
HindIII	281	sc 3'

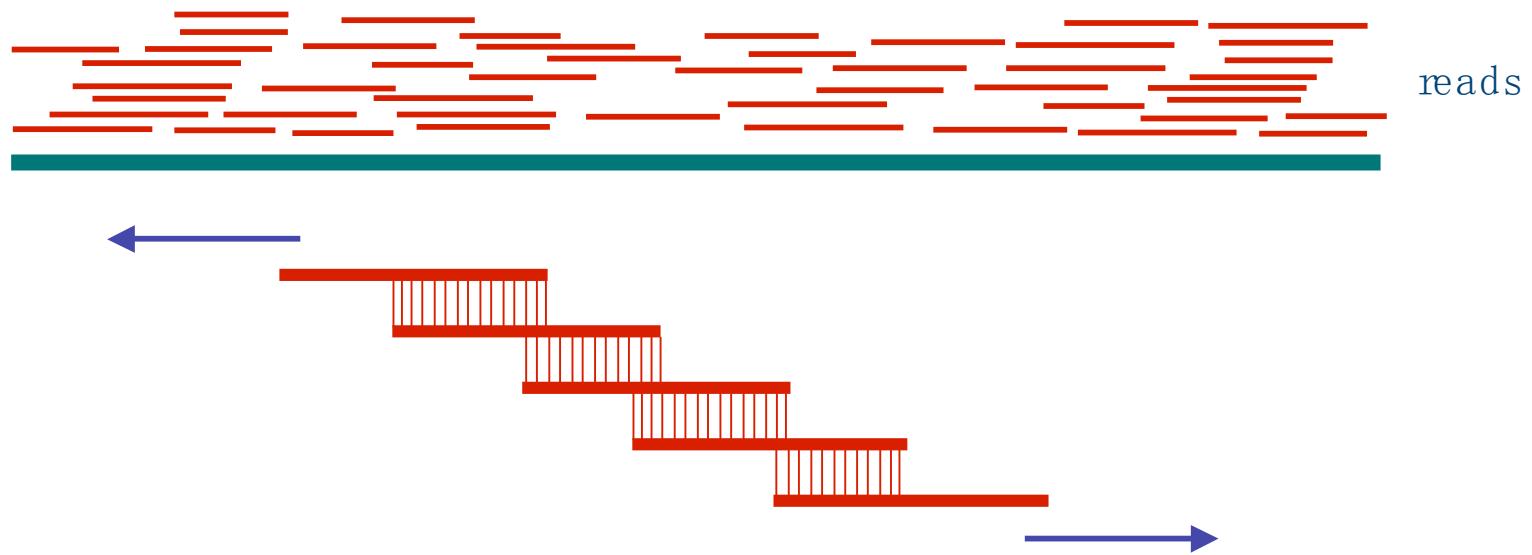
Zoom Map RMap Sequence Features Info

Assembly/ kompletace a sestavení

Resekvenování vs. *de novo* sekvenování



Princip assembly



Pokrytí oblastí $>x$ -násobnou redundancí

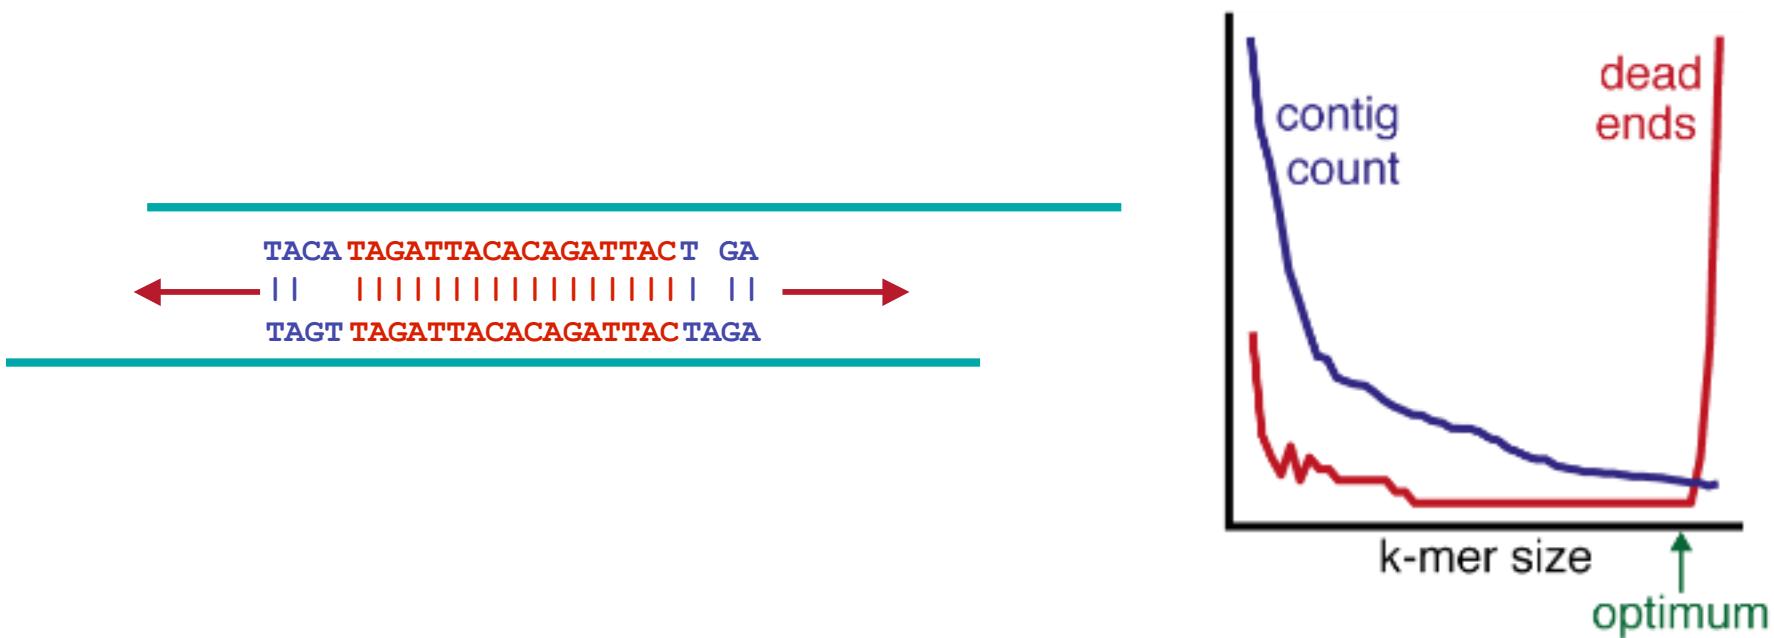
Identifikace překryvů, sekvenční přiložení
a rekonstrukce sekvence

De novo assembly

- Nezávislé na referenčním genomu
- Parametry
 - Délka čtení
 - Pokrytí genomu (coverage)
- Velké množství dostupných algoritmů
 - Znakové metody
 - Grafové metody
- Výpočetně náročné

Princip hledání překryvů

- Vytvoření všech k -merů ve čteních, (např. $k \sim 24$)
- Roztrídění čtení do skupin, které sdílejí k -mer
- Přiložení párů, které sdílejí k -mer
- Mapování a rozšíření sekvenčních přiložení

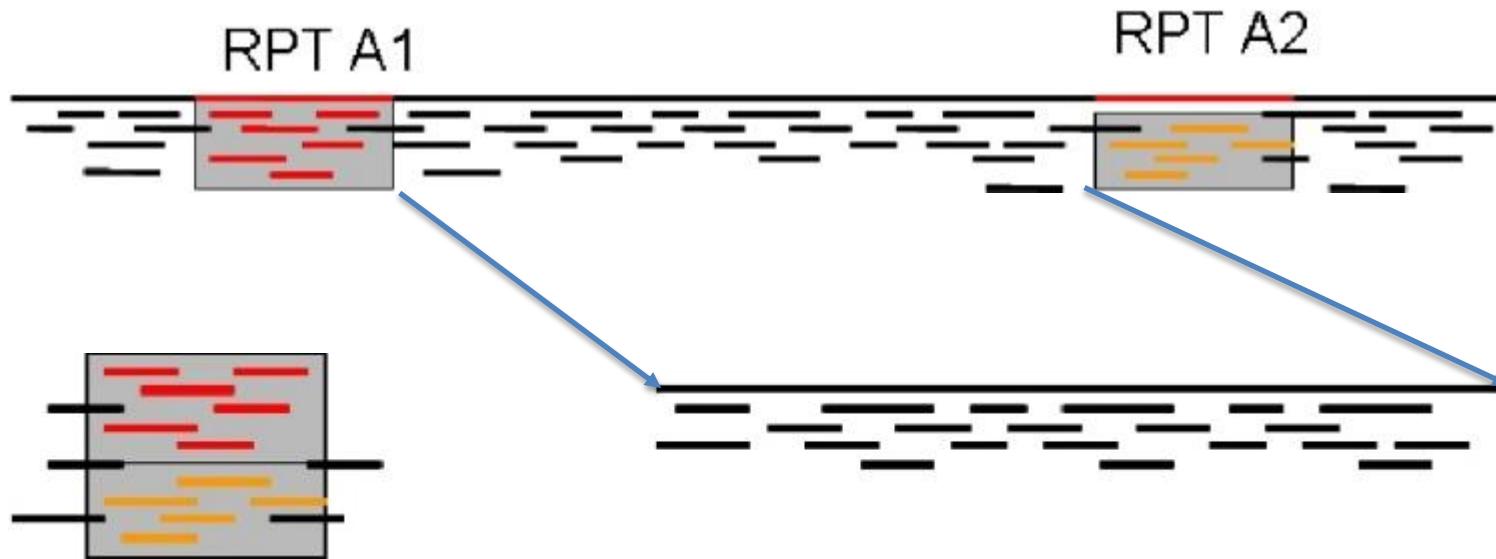


Mapování

Vytvoření sekvenčního příložení z jednotlivých čtení



Repetice jsou příčinou rozdělení genomů do kontigů



Čtení z mnoha podobných repetic vedou k vytvoření kontigů s pozměněnou strukturou

Kontig tvořený jedinečnou sekvencí, ohrazený repetitivními sekvencemi

Grafové metody využité v *de novo* sestavení

- Dva přístupy
OLC (overlap layout consensus)
DBG (de Bruijn graph)
- Graf je vygenerován s použitím čtení a jejich překryvů
- OLC
 - vrcholy (uzly) sestavené sekvence
 - hrany mezi vrcholy reprezentují překryvy
 - optimální průchod – každý vrchol je navštíven pouze jednou
- DBG
 - vrcholy (uzly) jsou překryvy
 - hrany mezi vrcholy reprezentují unikátní sekvenci každého čtení
 - optimální průchod - každá hrana je navštívěna pouze jednou

Příklady assemblerů

Znakové

- SSAKE
- VCAKE

Grafové

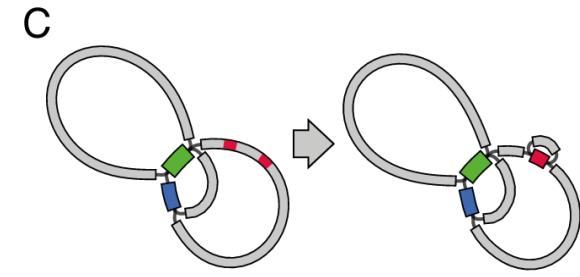
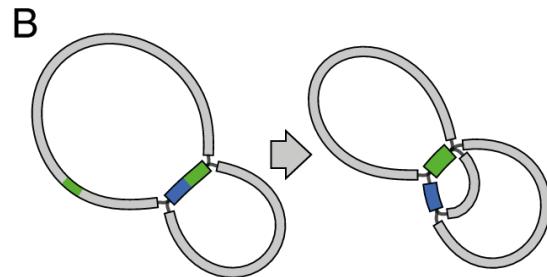
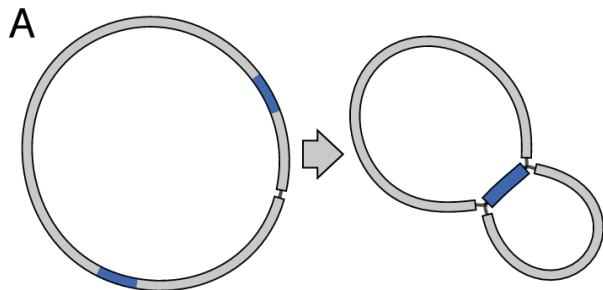
OLC (overlap layout consensus)

- Celera
- Edena
- Newbler
- SMRT Analysis

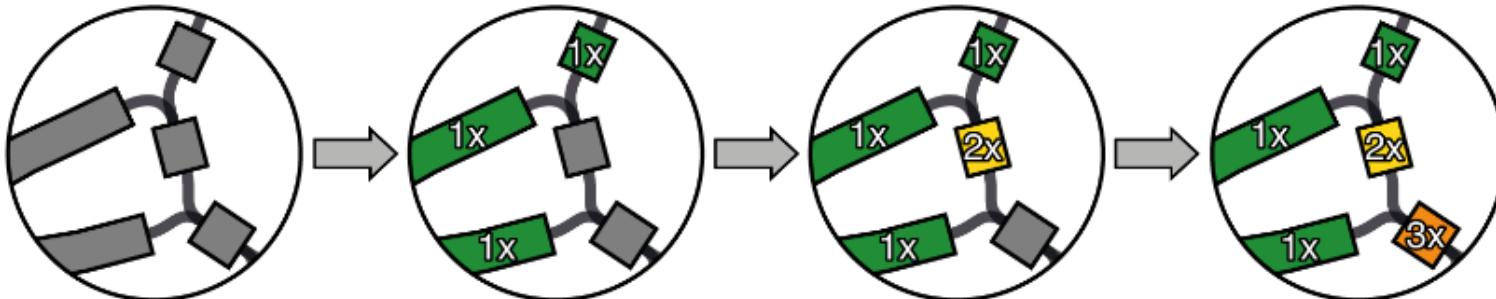
DBJ (de Bruijn graph)

- EULER
- Velvet
- SOAPdenovo
- ALLPATHS-LG
- MIRA
- SPADES
- A5-miseq

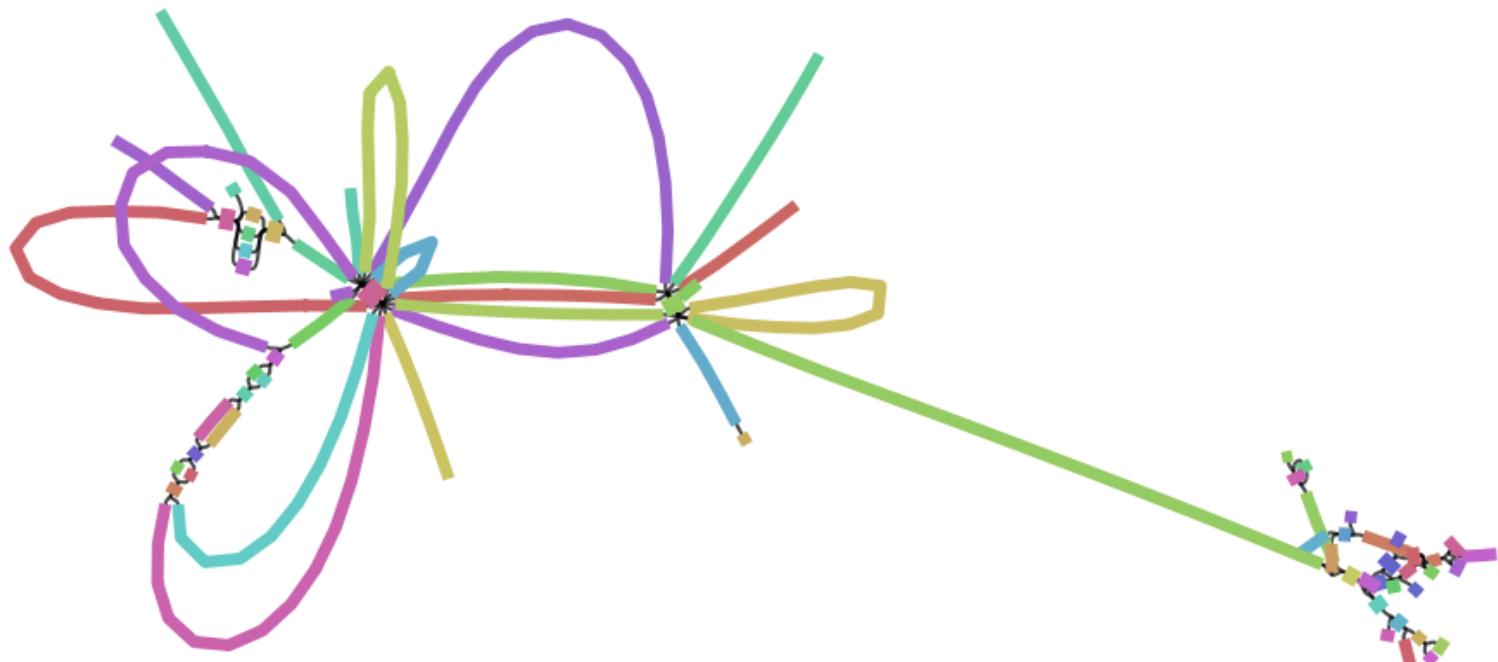
Znázornění repetic v grafu



- Krátká čtení, hlavní příčina omezení kompletního sestavení
- Stejná sekvence se vyskytuje v genomu vícekrát
- Délka čtení není schopna překlenout tuto repeticí
- Pokrytí může indikovat multiplicitu



Příklad de Bruijnova grafu u plasmidu



—

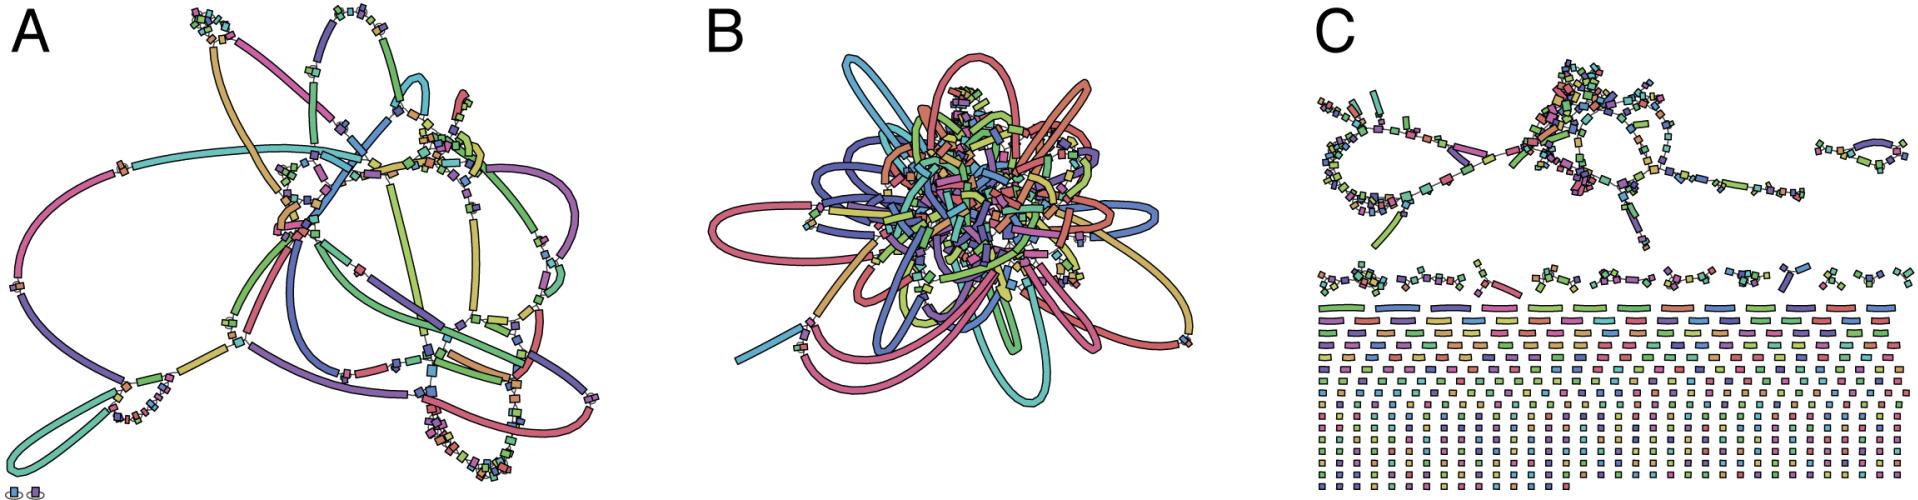
—

—

—

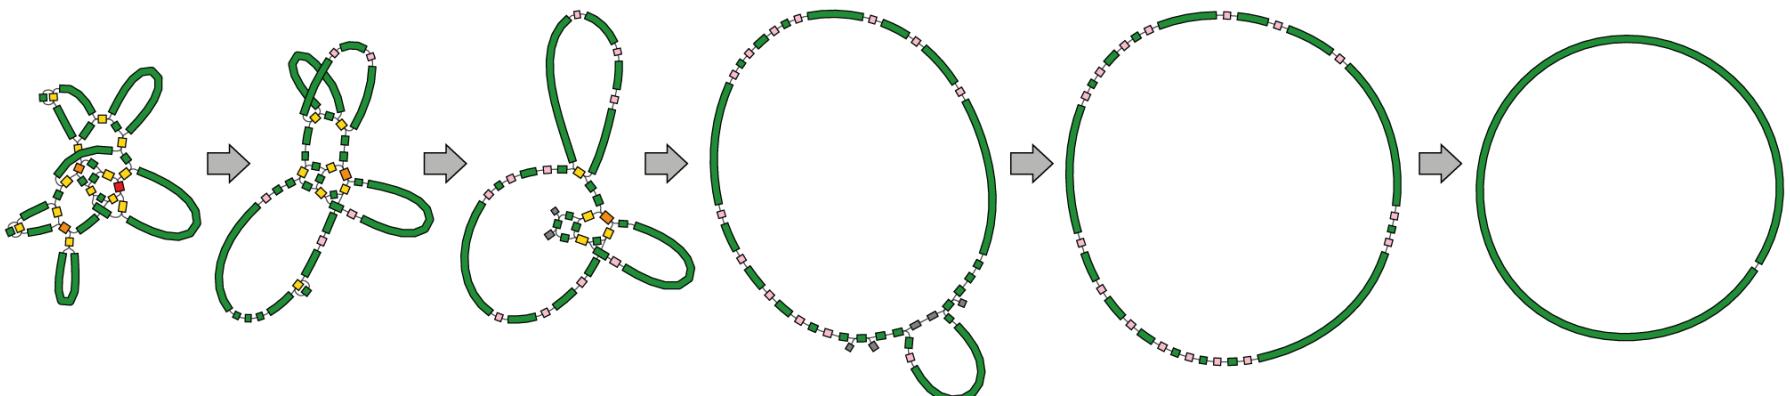
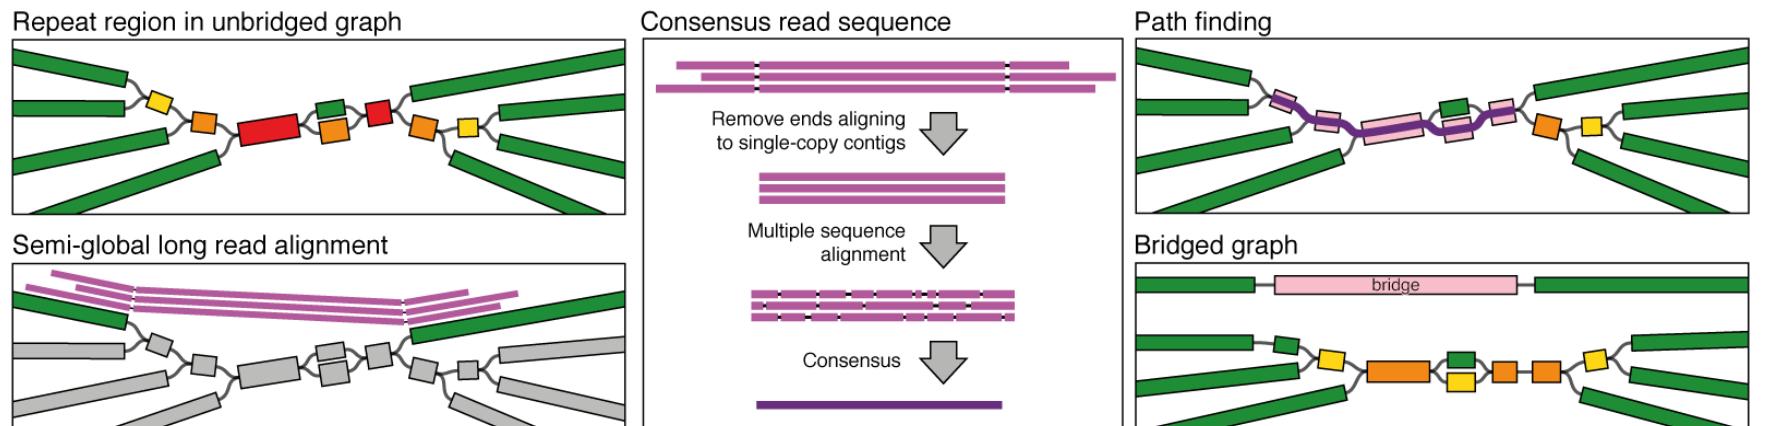
—

Příklad de Bruijnova grafu u mikrobiálního genomu (Illumina)



Hybridní assembly a bridging

- Kombinace krátkých čtení (Illumina, IonTorrent) a dlouhých čtení (PacBio, Nanopore) umožňuje hybridní assembly
- Dlouhá čtení: hledání cesty mezi repeticemi



Odvození konsensní sekvence, identifikace jednonukleotidových polymorfismů

TAGATTACACAGATTACTGA TTGATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGCGTAAACTA
TAG TTACACAGATTAT**T**GACTTC**C**ATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGGTAA CTA

↓ ↓ ↓ ↓

TAGATTACACAGATTACT**G**ACTTGAT**GG**CGTAA CTA

Derive **multiple alignment** from pairwise read alignments

Derive each consensus base by **weighted voting**

3. Výpočetní analýza sekvencí

- Počet residuí
- Frekvence residuí
- Analýza využití kodonů
- Design oligonukleotidů a primerů

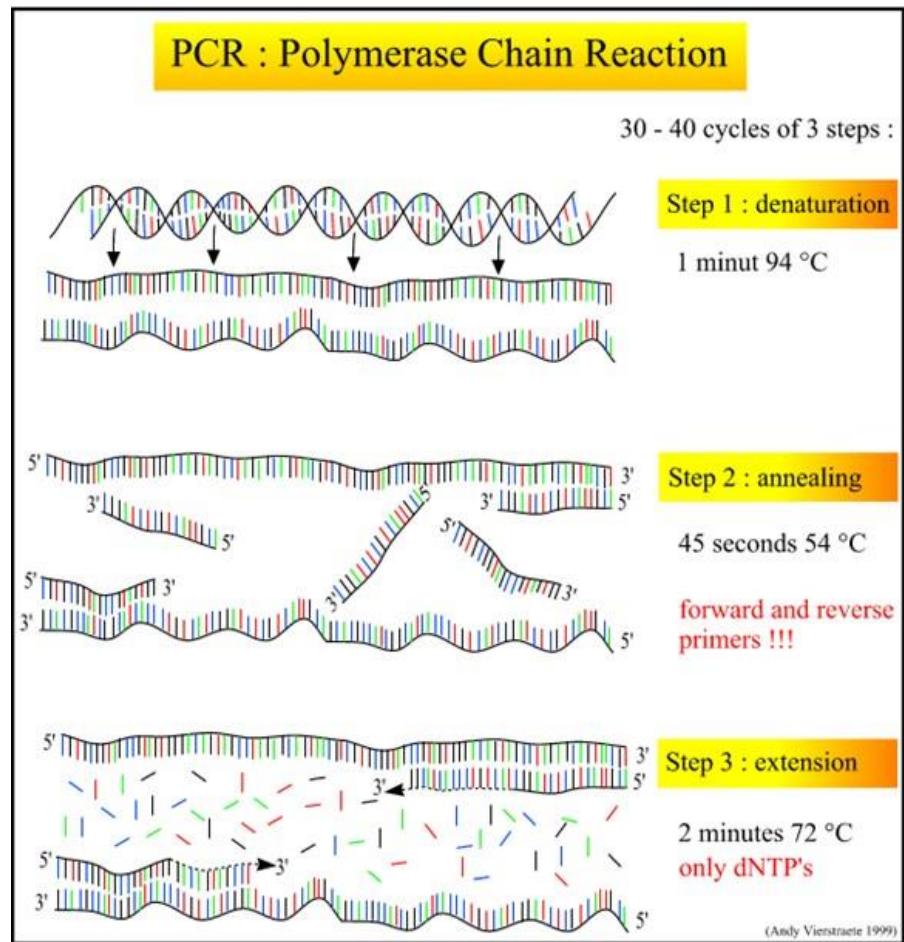
Analýza využití kodonů (codon usage)

- Využití synonymních kodonů
 - ◆ není náhodné
 - ◆ je rozdílné u různých genomů, které mají určité preferované kodony pro určité aminokyseliny
 - ◆ může být problémem při expresi rekombinantních proteinů
- Databáze využití kodonů
<http://www.kazusa.or.jp/codon/>

The Human Codon Usage Table															
Gly	GGG	17.08	0.23	Arg	AGG	12.09	0.22	Trp	TGG	14.74	1.00	Arg	CGG	10.40	0.19
Gly	GGA	19.31	0.26	Arg	AGA	11.73	0.21	End	TGA	2.64	0.61	Arg	CGA	5.63	0.10
Gly	GCT	13.66	0.18	Ser	AGT	10.18	0.14	Cys	TGT	9.99	0.42	Arg	CGT	5.16	0.09
Gly	GCC	24.94	0.33	Ser	ADC	18.54	0.25	Cys	TGC	13.86	0.58	Arg	CGC	10.82	0.19
Glu	DAO	38.82	0.59	Lys	AAG	33.79	0.60	End	TAC	0.73	0.17	Aln	CAG	32.95	0.73
Glu	DAA	27.51	0.41	Lys	AAA	22.32	0.40	End	TAA	0.95	0.22	Aln	CAA	11.94	0.27
Asp	DAT	21.45	0.44	Asn	AAT	16.43	0.44	Trp	TAT	11.80	0.42	His	CAT	9.56	0.41
Asp	DAC	27.06	0.56	Asn	AAC	21.30	0.56	Trp	TAC	16.48	0.58	His	CAC	14.00	0.59
Val	DTG	28.60	0.48	Ile	ATG	21.86	1.00	Leu	TTG	11.43	0.12	Leu	CTG	39.93	0.43
Val	DTA	6.09	0.10	Ile	ATA	6.05	0.14	Leu	TTA	5.55	0.06	Leu	CTA	6.42	0.07
Val	DTT	10.30	0.17	Ile	ATT	15.03	0.35	Phe	TTT	15.36	0.43	Leu	CTT	11.24	0.12
Val	DTG	15.01	0.25	Ile	ATC	22.47	0.52	Phe	TTC	20.72	0.57	Leu	CTC	19.14	0.20
Ala	CGG	7.27	0.10	Thr	ACG	6.80	0.12	Ser	TGG	4.38	0.06	Pro	CCG	7.02	0.11
Ala	CGA	15.50	0.22	Thr	ACA	15.04	0.27	Ser	TCA	10.96	0.15	Pro	CCA	17.11	0.27
Ala	GCT	20.23	0.28	Thr	ACT	13.24	0.23	Ser	TCT	13.51	0.18	Pro	CCT	18.03	0.29
Ala	GCC	28.43	0.40	Thr	ACC	21.52	0.38	Ser	TCC	17.37	0.23	Pro	CCC	20.51	0.33

Navrhování sekvencí primerů pro PCR

- Standardní primery
- Modifikované oligonukleotidy na 5'-konci pro klonování
- Oligonukleotidy jako hybridizační sondy pro real-time PCR
 - ◆ specifičnost
 - ◆ jedinečnost



PCR - Syntéza obou řetězců u specifické sekvence



Výběr vhodné strategie před návrhem primerů

- K čemu jsou primery určeny
 - ◆ Standardní end-point PCR
 - ◆ Sekvenování
 - ◆ Detekce jednonukleotidových polymorfismů (SNP) nebo variací
 - ◆ Studium metylace
 - ◆ Real-time PCR
 - ◆ Sondy pro microarray
 - ◆ Degenerovaná PCR
 - ◆ Multiplex PCR
- Z jakých dat vycházíme
 - ◆ Jednoduchá sekvence DNA / proteinu
 - ◆ Sekvenční přiložení DNA / proteinu
 - ◆ GenBank ID/Gene ID/rsSNP ID

Pravidla pro design primeru pro PCR

- Relativně snadná výpočetní záležitost – prohledávání sekvence a identifikace krátkých sekvencí splňujících určitá kritéria
 - ◆ Délka primeru
 - ◆ Obsah G+C
 - ◆ Teplota Tm
 - ◆ Specificita
 - ◆ Komplementarita primerových sekvencí
 - ◆ Sekvence 3'-konce

Jedinečnost primeru

- Na jedinečnost primeru a jeho hybridizační vlastnosti (annealing) má vliv délka primeru a velikost templátové DNA
 - ◆ Délka (17 – 28 bází dlouhé)
 - Možná hybridizační místa primeru by se také neměla nacházet na DNA tvořících případné kontaminace vzorků

Templátová DNA

5' ... TCAACTTAGCATGATCGGGTA... GTAGCAGTTGACTGTACAACTCAGCAA... 3'

TGCTAAGTTC

CAGTCACTGCTAC

TGCT AGTG

Primer 1 5' -TGCTAAAGTTG-3'

Není jedinečný!

Primer 2 5' -CAGTCAACTGCTAC-3'

Jedinečný!

Zastoupení bází

- Zastoupení bází ovlivňuje vlastnosti hybridizace a reasociace primeru
- Žádoucí je náhodná distribuce bází bez oblastí bohatých na AT nebo GC
- Obvyklý obsah G+C, který poskytuje stabilní hybridy je 40-60 %, ale závisí také na obsahu G+C templátu

Templátová DNA

5' ...TCAACTTAGCATGATCGGGCA...AAGATGCACGGGCCTGTACACAA...3'

T_{GC}_{CC}_G A_T C_A T_G C_T

Teplota Tm (Melting temperature)

- ◆ mají T_m teplotu 50 – 65 °C

$$T_a = 0,3 \times T_m^{\text{Primer}} + 0,7 \times T_m^{\text{Produkt}} - 25$$

kde T_m^{Primer} je hodnota T_m nejméně stabilního páru primer-matrice a T_m^{Produkt} je hodnota T_m amplifikačního produktu.

- Orientačně lze vypočítat T_a podle vztahu:

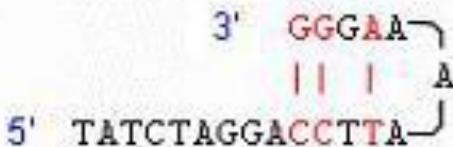
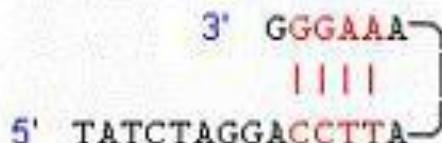
$$T_m = 2(A+T) + 4(G+C)$$

$$T_a = T_m - 5 \text{ } ^\circ\text{C}$$

Vnitřní sekvence a struktura primeru

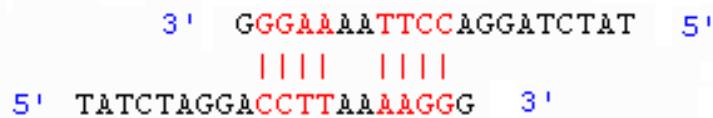
- nejsou komplementární navzájem na 3'-koncích, takže nevytvářejí navzájem nebo samy se sebou duplexy
- neobsahují vnitřní sekundární struktury
 - ◆ Chybně navržená dvojice primerů, která vytváří stabilní duplex na 3'-konci:
5' ATTCAACCGTTCAAA CAAGCC 3'
 | | | |
 3' GTTCGG CCTACCTTATTCTC 5'
 - ◆ Správně navržená dvojice primerů, která vytváří pouze málo stabilní duplex na 5'-konci; na 3'-konci je G nebo C zaručující stabilní párování s templátem:
5' CG AAATAAGACTAGTAAAGC 3'
 | | | |
 3' CCTTACTCCAC GC CTAATACAATCC 5'
 - ◆ Chybně navržený primer, vytvářející vlásenku:
5' T TTT TCAAGG
 | | | |
 3' AAA AGAGAT

Hairpin



Self-Dimer

8 bp



Dimer

forward primer



4 bp



reverse primer

GC svorky a 3'- koncová stabilita

■ GC svorka

- ◆ Přítomnost G nebo C mezi posledním 4 bázemi na 3'-konci primeru
- ◆ Zásadní pro zvýšení prevence falešného prodlužování a zvýšení specifičnosti primeru
- ◆ >3 G nebo C v blízkosti 3'-konce jsou však nežádoucí

■ Maximální 3'- koncová stabilita

- ◆ Maximalizace ΔG posledních 5 bází na 3'-konci primeru.

Jedinečnost primerů

na matricové DNA nemají falešná vazebná místa

- Nesprávně navržený primer s falešnými vazebními místy na templátové DNA:

5'(1029) AAGGCTAGAGAAAAAATATGG (1048)3'
3'(948) tttcttaccctttt-tacc (966)5'

5'(1029) AAGGCTAGAGAAAAAATATGG (1048)3'
3'(1191) tttgtattgcattatataacc (1210)5'

5'(1029) AAGGCTAGAGAAAAAATATGG (1048)3'
3'(395) tcacattttcttttatctt (414)5'

- Správně navržený primer, který nemá falešná vazebná místa na templátu:

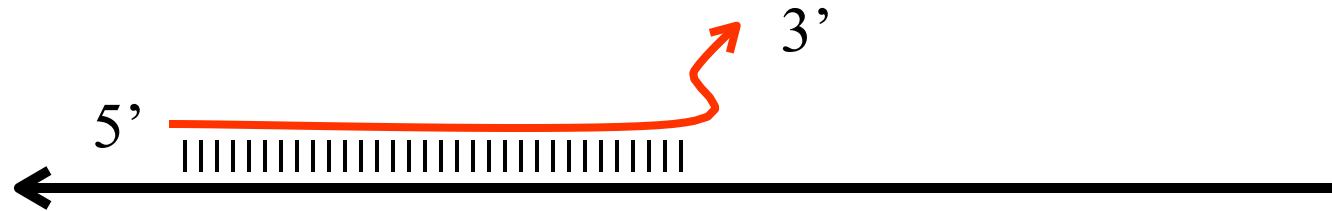
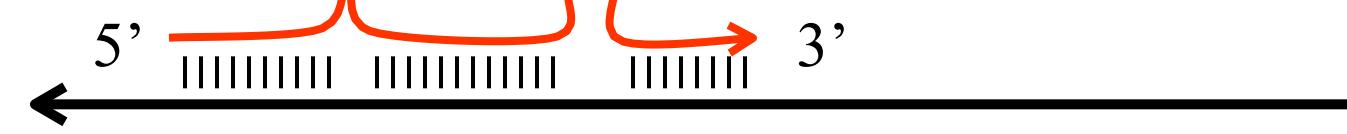
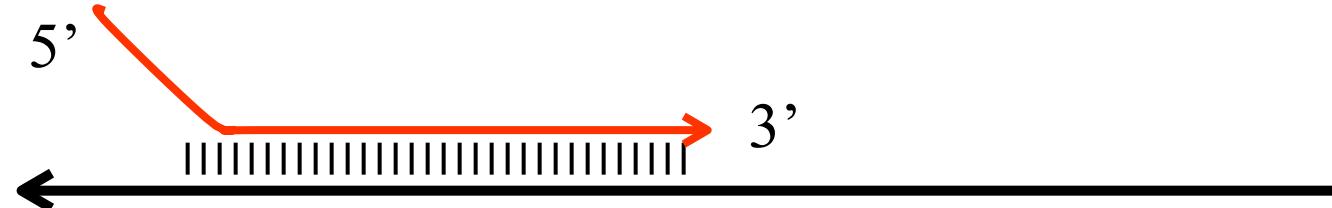
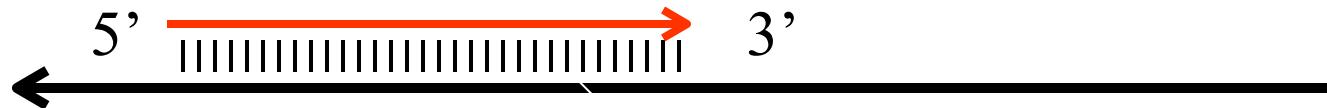
5'(2476) CCTAACATAATCCGCACCTCATTCC (2452)3'
3'(787) taaatctatttagttcacacataacc (811)5'

5'(2476) CCTAACATAATCCGCACCTCATTCC (2452)3'
3'(3211) caattgttaactataactgcgttatac (3235)5'

5'(2476) CCTAACATAATCCGCACCTCATTCC (2452)3'
3'(1194) gtattgcattatataacctctgttag (1218)5'

5'(2476) CCTAACATAATCCGCACCTCATTCC (2452)3'
3'(1469) atattgtta-tatacgaactaaatct (1492)5'

Kdy je primer ještě primerem?



Pro návrh primerů se obvykle používá specializovaný software

Melting Temperature [21-mer]

PUC19.SEQ + (2686)

Graph Zoom Options pos: 20 T_m: 64.5

T_m [1 10 20 30 40 50]

Dot display mode Bar graph mode

Lower Primer False Priming Sites

M13MP18

Lower Primer - M13MP18:6310L19 (positive strand)
Priming efficiency of the perfect match is 428 (above the threshold)

Priming efficiency : 428 (above the threshold)
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(6328) ccaaaagggtcagtgtc (6310)5'

Priming efficiency : 205 (above the threshold)
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(626) agcaatggtc--tgc (610)5'

Priming efficiency : 194 (above the threshold)
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(808) gtaatatgtcagtgtc (790)5'

Priming efficiency : 185 (above the threshold)
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(5125) tctaagggtcagtgtc (5108)5'

Priming efficiency : 121
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(5989) agaaaagggtc-gcttc (5971)5'

Lower Primer - M13MP18:6310L19 (negative strand)
Priming efficiency of the perfect match is 428 (above the threshold)

Priming efficiency : 76
5'(6328) GGTTTTCCCGTCACGAGC (6310)3'
3'(5744) caaaaaggcgggaaactgc (5762)5'

Selected Primers

pCBiu3.seq

Current Oligo (+ strand)

Sequence Length: 1842
5' CCCGCCCTGATGAATGCTCATC 3'
Length: 21-mer
5' Position: 1373
T_m: 72.1 °C
ΔG (25 °C): -42.7 kcal/mol
Degeneracy: 1
P.E.*: 492
1/E: 5.30 nmol/A₂₆₀
34.0 µg/A₂₆₀

Current Oligo (- strand)

5' GATGAGCATTTCATCAAGGGGG 3'
P.E.*: 537
4.80 nmol/A₂₆₀
1/E: 31.7 µg/A₂₆₀

pCBiu3:269U21 Upper Primer

5' CGCGGCCAGATCTGGTACCCA 3'
Length: 21-mer
5' Position: 269
T_m: 76.9 °C
ΔG (25 °C): -46.1 kcal/mol
Degeneracy: 1
P.E.*: 542/542
1/E: 5.12 nmol/A₂₆₀
33.1 µg/A₂₆₀

pCBiu3:817L21 Lower Primer

5' TACCGGGTTGGACTCAAGACG 3'
Length: 21-mer
5' Position: 817
T_m: 69.5 °C
ΔG (25 °C): -41.4 kcal/mol
Degeneracy: 1
P.E.*: 502/502
1/E: 4.89 nmol/A₂₆₀
32.0 µg/A₂₆₀

PCR

pCBiu.seq

Optimal Annealing Temperature: 58.3° (Max: 72.0°)

	Position and Length	T _m [°C]	GC [%]	P.E.*
Product	1352	88.0	51.3	-----
Upper Primer	37	21	72.2	452
Lower Primer	1368	21	79.9	506

Product T_m - Upper Primer T_m: 15.8
Primers T_m difference: 7.6

	Concentration	
Upper Primer	200.0	nM
Lower Primer	200.0	nM
Monovalent Cation	50.0	mM
Free Mg ²⁺	0.7	mM

Terminal stability of the Lower Primer is too high.

Total Na⁺ Equivalent: 155.8

Počítačový návrh primerů

- Umoňuje řada molekulárně biologických programů
- Některé jsou volně dostupné na internetu
 - ◆ Primer3
 - ◆ Primer3Plus
 - ◆ PrimerZ
 - ◆ PerlPrimer
 - ◆ BioTools
 - ◆ WebPrimer
- Kalkulátory vlastností primerů
 - ◆ IDT Oligo Analyzer
(<http://eu.idtdna.com/SciTools/SciTools.aspx?cat=DesignAnalyze>)
 - ◆ BioMath (<http://www.promega.com/biomath/calc11.htm>)
 - ◆ PrimerBlast
 - ◆ UCSC In-Silico PCR
 - ◆ AutoDimer

Oligo Calculator

Oligo Calc: Oligonucleotide Properties Calculator

Enter Oligonucleotide Sequence Below
OD calculations are for single-stranded DNA or RNA

[Nucleotide base codes](#)

Reverse Complement Strand(5' to 3') is:

[5' modification](#) (if any)

[3' modification](#) (if any)

Select molecule

ssDNA

50 nM Primer

1 Measured Absorbance at 260 nanometers

50 mM Salt (Na⁺)

Calculate

Swap Strands

BLAST

mfold

Physical Constants

Length: 0

Molecular Weight: 4

GC content: %

1

°C (Basic)

1 ml of a sol'n with an Absorbance of 1 at 260 nm

is microMolar 5 and contains micrograms.

Melting Temperature (T_M) Calculations

2

°C (Salt Adjusted)

3

°C (Nearest Neighbor)

Thermodynamic Constants Conditions: 1 M NaCl at 25°C at pH 7.

RlnK cal/(°K*mol)

deltaH Kcal/mol

deltaG Kcal/mol

deltaS cal/(°K*mol)

Deprecated Hairpin/self dimerization calculations

5 (Minimum base pairs required for single primer self-dimerization)

4 (Minimum base pairs required for a hairpin)

Check Self-Complementarity

Primer 3 <http://primer3.sourceforge.net/webif.php>

Primer3 Input (version 0.4.0) - Mozilla Firefox

Soubor Úpravy Zobrazení Historie Záložky Nástroje Nápověda

http://frodo.wi.mit.edu/primer3/input.htm

Primer3 Input (version 0.4.0)

Primer3 (v. 0.4.0) Pick primers from a DNA sequence.

[Checks for mispriming in template.](#) [disclaimer](#) [Primer3 Home](#)
[Primer3plus interface](#) [cautions](#) [FAQ/WIKI](#)

Paste source sequence below (5'->3', string of ACGTNacgtn -- other letters treated as N -- numbers and blanks ignored). FASTA format ok. Please
N-out undesirable sequence (vector, ALUs, LINEs, etc.) or use a [Mispriming Library \(repeat library\)](#):

```
>SA44kb001 [org=Staphylococcus aureus] [strain=CCM 885] [clone=7/ IV] Staphylococcus aureuss
EcoRI-clone from common 44 kb SmaI fragment
GAATTCAAAACCAGCAAAAGCTGTGAAAAAGCCATTACCAAGTAAAGATAATTTGGCTATATTGTATGGAGAAGGATTCATATTGTAAAGGCG
AATTATTGGAAAACATCGACATGGTGAAGATTGTCTGTTCTGTTAGAAGTTTAAGTGATTAATCAAGCACACTCAAATAGTGTATAATTAT
AAATGAATATGGTTGGATAAGTCTGAGACAATGCATGTTCAGGTTTAATTGTGTATAAAAGTTTGGTGATTGCATAAGAGATGGCGGTACTA
AATGTTATTATTAAGTGTGCACGCAGTATCATTAGTTATAAAATGTAGCTGTTAAAAGTCAAAATACATCGAATGTAGTTAGGCATATAATATA
```

Pick left primer,
or use left primer below:

Pick hybridization probe (internal
oligo), or use oligo below:

Pick right primer, or use right primer below
(5' to 3' on opposite strand):

Pick Primers **Reset Form**

Sequence Id: A string to identify your output.

Targets: E.g. 50,2 requires primers to surround the 2 bases at positions 50 and 51. Or mark the [source sequence](#) with [and]: e.g. ...ATCT[CCCC]TCAT.. means that primers must flank the central CCCC.

Hotovo

Primer3 Input (version 0.4.0) - Mozilla Firefox

Soubor Úpravy Zobrazení Historie Záložky Nástroje Nápověda



http://frodo.wi.mit.edu/primer3/input.htm



Google



Primer3 Input (version 0.4.0)

[Pick Primers](#) [Reset Form](#)

Sequence Id: A string to identify your output.

Targets: E.g. 50,2 requires primers to surround the 2 bases at positions 50 and 51. Or mark the [source sequence](#) with [and]: e.g. ...ATCT[CCCC]TCAT.. means that primers must flank the central CCCC.

Excluded Regions: E.g. 401,7 68,3 forbids selection of primers in the 7 bases starting at 401 and the 3 bases at 68. Or mark the [source sequence](#) with < and >: e.g. ...ATCT<CCCC>TCAT.. forbids primers in the central CCCC.

Product Size Ranges

Number To Return Max 3' Stability

Max Repeat Mispriming Pair Max Repeat Mispriming

Max Template Mispriming Pair Max Template Mispriming

[Pick Primers](#) [Reset Form](#)

General Primer Picking Conditions

Primer Size Min: Opt: Max:

Primer Tm Min: Opt: Max: Max Tm Difference: [Table of thermodynamic parameters:](#)

Product Tm Min: Opt: Max:

Primer GC% Min: Opt: Max:

Hotovo

Primer3 Output (primer3_results.cgi release 0.4.0) - Mozilla Firefox

Soubor Úpravy Zobrazení Historie Záložky Nástroje Nápověda

http://frodo.wi.mit.edu/cgi-bin/primer3-web-cgi-bin-0.4.0/primer3_results.cgi

Primer3 Output (primer3_results.cgi...)

PRIMER PICKING RESULTS FOR SA44kb001 [org=Staphylococcus aureus] [strain=CCM 885] [clone=7/ IV] Staphylococcus aureus

No mispriming library specified
Using 1-based sequence positions

OLIGO	start	len	tm	gc%	any	3'	seq
LEFT PRIMER	159	25	57.21	32.00	6.00	2.00	AATCAAGCACACTCAAATAGTGTAA
RIGHT PRIMER	429	25	58.40	36.00	4.00	3.00	AACTCCTATGAAGACAAACCTTTTC

SEQUENCE SIZE: 2052
INCLUDED REGION SIZE: 2052

PRODUCT SIZE: 271, PAIR ANY COMPL: 5.00, PAIR 3' COMPL: 3.00
TARGETS (start, len)*: 200,200

1 GAATTCAAAACCAGCAAAAGCTGTGAAAAAGCCATTACCAAGTAAAGATAATTTGGCTAT

61 ATTGTATGGAGAAGGATTCATATTGTAAAGCGAATTATTGGAAAACATCGACATGG

121 TGAAGATTGTCTGTTCTGTTAGAAGTTTAAGTGATTAATCAAGCACACTCAAATAGTG
>>>>>>>>>>>>>>>

181 TTATAATTATAATGAATATGGTTGGATAAGTCTGAGACAATGCATGTTAGGCTTA
>>>*****

241 ATTGTGTATAAGTTGGTGATTGCATAAGAGATGGCGGTACTAAATGTTATTATTAAG

301 TGTGCACGCAGTATCATTAGTTATAAAATGTAGCTGTTAAAGTCAAAAATACATCGAAT

361 GTAGTTAGGCATATAATATAAAAGAGTTTCATTACTCAATAGAAAAAGGTTGTCTTC
***** <<<<<<<<<<<

Primer3Plus – rozšířené rozhraní (2007) Primer 3

<http://www.bioinformatics.nl/cgi-bin/primer3plus/primer3plus.cgi>

The screenshot shows the Primer3Plus web application interface. At the top, there's a header bar with a back/forward button, a search bar containing the URL, and a tab labeled "Primer3Plus". Below the header are two rows of links: "Primer3Manager" and "Help" in the first row, and "About" and "Source Code" in the second row. The main content area has a title "Primer3Plus" and a subtitle "pick primers from a DNA sequence". A "Task" dropdown menu is set to "Detection". A descriptive text box says "Select primer pairs to detect the given template sequence. Optionally targets and included/excluded regions can be specified." To the right are "Pick Primers" and "Reset Form" buttons. Below this, there are tabs for "Main", "General Settings", "Advanced Settings", "Internal Oligo", "Penalty Weights", and "Sequence Quality", with "Main" being the active tab. The "Main" tab contains fields for "Sequence Id" (with a text input box), "Paste source sequence below" (with a text input box and "Procházet..." button), and "Or upload sequence file" (with a file input box and "Upload File" button). There's also a large text area for pasting the source sequence. Below these fields are buttons for "Mark selected region": '< >', '[]', '{ }', and "Clear", along with a "Save Sequence" button. At the bottom, there are three checkboxes: "Pick left primer or use left primer below.", "Pick hybridization probe (internal oligo) or use oligo below.", and "Pick right primer or use right primer below (5'→3' on opposite strand)". The status bar at the bottom right shows a magnifying glass icon, "90%", and other icons.

Primer3Plus
pick primers from a DNA sequence

Task: Detection Select primer pairs to detect the given template sequence. Optionally targets and included/excluded regions can be specified.

Main General Settings Advanced Settings Internal Oligo Penalty Weights Sequence Quality

Sequence Id:

Paste source sequence below Or upload sequence file: Procházet...

Excluded Regions: < >
Targets: []
Included Region: { }

Pick left primer
or use left primer below.

Pick hybridization probe
(internal oligo) or use oligo below.

Pick right primer or use right primer
below (5'→3' on opposite strand).

90%

Primer Z: streamlined primer design for promoters, exons and human SNPs

<http://genepipe.ngc.sinica.edu.tw/primerz/beginDesign.do>

The screenshot shows the 'beginDesign' page of the GenePipe PrimerZ bioinformatics pipeline. The top navigation bar includes links for VarioWatch, PrimerZ, QualiSeq, Affyrmation, SeqTool, NCBI 37.3 (selected), and a link to switch to NCBI 36.3. The main content area features a banner for 'Primer Z: streamlined primer design for promoters, exons and human SNPs' by Tsai et al. (2007). It includes a 'Species' dropdown set to 'Human', a 'Query By' dropdown set to 'Primer for Promoter regions and exons (NCBI)', and a 'Gene Name (NCBI Official Symbol)' input field with a maximum of 200 genes. There are two options: 'Input Genes' (selected) and 'Upload a File'. Below these are two text input fields: 'ex. ACE' and 'Mask SNPs'. A 'Result Preview' section shows a small preview table. At the bottom right are 'Upload Parameters' and a zoom control set to 90%.

Oligo



PCR Primer Mapping

– UCSC In-Silico PCR

<http://genome.ucsc.edu/cgi-bin/hgPcr?db=mm9>

Home Genomes Blat Tables Gene Sorter Session FAQ Help

UCSC In-Silico PCR

Genome:

Mouse

Assembly:

Jul. 2007

Forward Primer:

TGCACCACCAaCTGCTT

Reverse Primer:

GGATGCAGGGATGATG

Max Product Size: 50000

Min Perfect Match: 18

Min Good Match: 18

Flip Reverse Primer:

About In-Silico PCR

In-Silico PCR searches a sequence database with a pair of PCR primers, using an indexing strategy for fast performance.

Configuration Options

Genome and Assembly - The sequence database to search.

Forward Primer - Must be at least 15 bases in length.

Reverse Primer - On the opposite strand from the forward primer. Minimum length of 15 bases.

Max Product Size - Maximum size of amplified region.

Min Perfect Match - Number of bases that match exactly on 3' end of primers. Minimum match size is 15.

Min Good Match - Number of bases on 3' end of primers where at least 2 out of 3 bases match.

Flip Reverse Primer - Invert the sequence order of the reverse primer and complement it.

Output

When successful, the search returns a sequence output file in fasta format containing all sequence in the database that lie between and include the primer pair. The fasta header describes the region in the database and the primers. The fasta body is capitalized in areas where the primer sequence matches the database sequence and in lower-case elsewhere. Here is an example:

```
>chr22:31000551+31001000  TAACAGATTGATGATGCATGAAATGGG  CCCATGAGTGGCTCTAAAGCAGCTGC  
TtACAGATTGATGATGCATGAAATGGGgggtggccagggtgggggtga  
gactgcagagaaggcagggtctggttcataacaagctttgtcgatccc  
tatgacagctgaagtccacggggctgatggtgagccagtgagggtaa  
tacacacaaatccatcagagaaaaccctattccctaaagattaaaaataaa
```

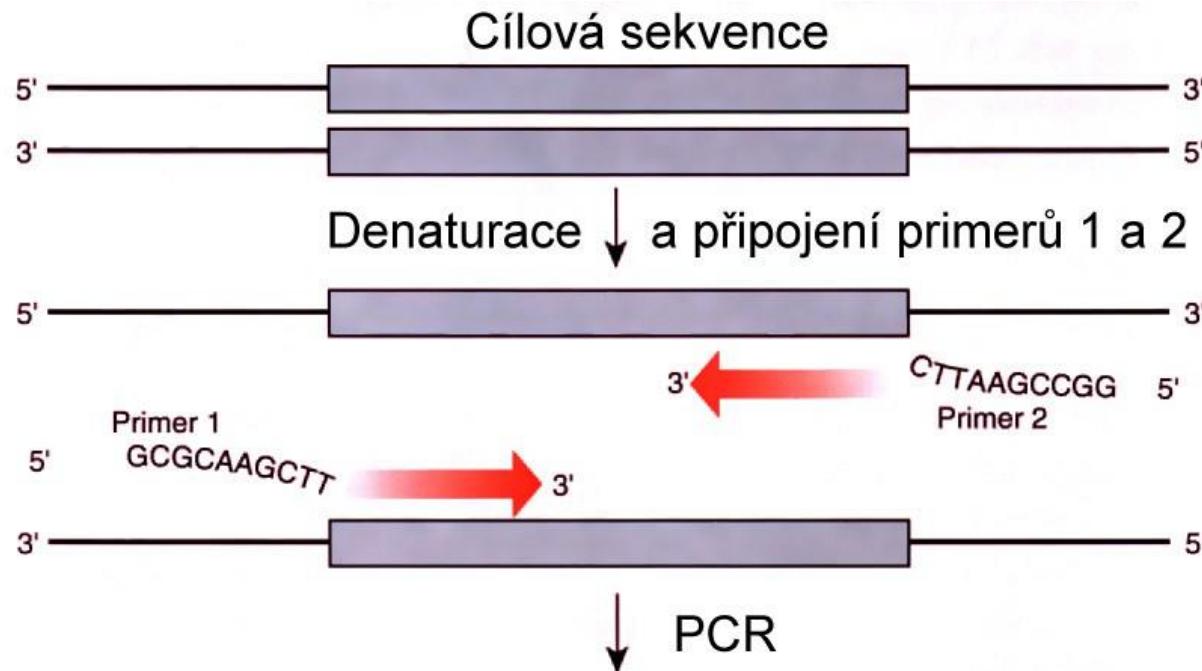
Výsledky

- Výběr optimálního páru primerů
- Sekvence primerů
- Délka primerů a hodnota T_m
- Velikost produktu
- Posouzení sekundárních struktur
- Podmínky reakce
- Alternativní primery

Pokročilý návrh primerů

- Alelově specifické primery
- Molekulární diagnostika
- Vícenásobné detekce - primery pro multiplex PCR
 - ◆ Zajištění kompatibility primerů v reakci
- Konsenzní primery
 - ◆ Pro klonování
 - ◆ Pro PCR-RFLP (např. 16S rRNA)
 - ◆ Vyžaduje identifikaci konzervativních oblastí na základě mnohonásobných přiložení sekvencí (multiple alignment)
- Primery pro modifikaci konců produktů PCR

Modifikace konců DNA, Připojení sekvencí prostřednictvím 5'-konců primerů



The diagram illustrates a 'sticky foot' mechanism. A horizontal red bar is shown at the top. A red arrow originates from the left side of the bar and points upwards towards its right end, indicating a pulling or lifting action.

- Přidávané sekvence
 - ◆ RE místa
 - ◆ Promotory
 - ◆ Terminátory
 - ◆ Translační signály

Zdroje pro návrh multiplex PCR

- NCBI/ Primer-BLAST
- MultiPLX (<http://bioinfo.ebc.ee/multiplx/>)
- PrimerStation (<http://ps.cb.k.u-tokyo.ac.jp/index.html>)
 - ◆ Lidský genom
 - ◆ Specifikace exonů
 - ◆ Vyloučení variabilních oblastí se SNP
- Oligo Explorer (<http://www.genelink.com/tools/gloe.asp>)
 - ◆ Posouzení dimerů primerů v multiplexovém uspořádání

Webové zdroje pro design primerů pro real-time PCR

- NCBI Probe Database
- RTPrimerDB
- Primer Bank
- qPrimerDepot
- PCR-QPPD
- PerlPrimer
- Komerční databáze (např. ROCHE,...)

Nejčastěji používané softwarové balíky pro manipulaci se sekvencemi

- Accelrys GCG Package (Accelrys Inc., San Diego, CA)
- Vector NTI® (Life Technologies, Carlsbad, CA)
- CLC Genomics Workbench (CLC bio, Cambridge, MA)
- The Bioinformatics Toolbox rozšíření pro MATLAB®
- Hitachi DNASIS® MAX Sequence Analysis Software (Helixx Technologies, Inc., Canada)
- DNASTAR Lasergene (DNASTAR, Inc., Madison, WI)
- Ugene (<http://ugene.net/>) freeware