



Analiza sekvenci DNA pomoću bioinformatičkih alata



Struktura molekule DNA

- povezana s funkcijom nositelja genetske informacije u živim organizmima



- struktura dvostrukice zavojnice
 - dva isprepletena lanca koji se drže zajedno vodikovim vezama između komplementarnih nukleotidnih baza (parovi adenina s timinom i parovi citozina s gvaninom)
 - specifično sparivanje baza u DNA (A-T i C-G)
 - ključno je za vjerni prijenos genetskih informacija s jedne generacije na drugu
 - omogućuje točnu replikaciju DNA, osiguravajući da svaka nova stanica dobije identičnu kopiju genetske informacije
 - slijed nukleotida duž molekule DNA
 - kodira genetske informacije koje određuju karakteristike organizma
 - geni su specifične sekvene nukleotida koji kodiraju proteine ili funkcionalne RNA molekule, koje su bitne za razne biološke procese
 - genetički kod
 - skup pravila prema kojima se informacije kodirane u DNA prevode u proteine
 - redoslijed nukleotida u DNA određuje redoslijed aminokiselina u proteinu, koji zauzvrat određuje strukturu i funkciju proteina
 - struktura kromosoma
 - u eukariotskim stanicama DNA je organizirana u kromosome koji se sastoje od dugih niti DNA omotanih oko proteina koji se nazivaju histoni
 - pomaže u zbijanju DNA i reguliranju pristupa genetskim informacijama pohranjenim u molekulii DNA

Genetički kod


- strukturiran na način da svaki od 64 mogućih tripleta RNA (kodona) sastavljenih od kombinacija 4 nukleotida (adenin, uracil, gvanin, citozin) odgovara jednoj od 20 biološki aktivnih aminokiselina, uz dodatna 3 „stop“ kodona koji terminiraju translaciju proteina (Crick, 1968.)

UUU	Phe	UCU	Ser	UAU	Tyr	UGU	Cys
UUC		UCC		UAC		UGC	
UUA	Leu	UCA		UAA	Stop	UGA	Stop
UUG		UCG		UAG		UGG	Trp
CUU		CCU		CAU	His	CGU	
CUC	Leu	CCC	Pro	CAC		CGC	
CUA		CCA		CAA	Gln	CGA	Arg
CUG		CCG		CAG		CGG	
AUU		ACU		AAU	Asn	AGU	Ser
AUC	Ile	ACC		AAC		AGC	
AUA		ACA	Thr	AAA	Lys	AGA	Arg
AUG	Met	ACG		AAG		AGG	
GUU		GCU		GAU	Asp	GGU	
GUC	Val	GCC		GAC		GGC	
GUA		GCA	Ala	GAA	Glu	GGA	
GUG		GCG		GAG		GGG	Gly

Središnja dogma molekularne biologije

Francis Crick (1958)

- DNA sadrži upute za stvaranje proteina, koje kopira RNA
- RNA zatim koristi upute za stvaranje proteina



Sekvenciranje DNA

- proces određivanja točnog redoslijeda nukleotida unutar molekule DNA





<https://www.novogene.com/eu-en/wp-content/uploads/sites/7/2021/02/novogene-blog-novogenebeginnersguide-20210203.jpg>

Sekvenciranje sljedeće generacije

engl. Next Generation Sequencing, NGS



1. Priprema uzorka

- ekstrakcija DNA iz stanica organizma
- fragmentacija ekstrahirane DNA u manje dijelove, obično duge stotine do tisuće parova baza.
- priprema knjižnice (engl. *library preparation*) - kratke sekvence adaptera dodaju se na krajeve fragmenata DNA kako bi se fragmenti vezali na platformu za sekvenciranje



3. sekvenciranje sintezom

- nukleotidi se dodaju jedan po jedan, a svaki dodatak detektira se signalom (npr. fluorescencijom) koji identificira nukleotid ugrađen na svakom položaju



2. stvaranje klastera

- fragmenti DNA pričvršćuju se na protočnu stanicu (engl. *flow-cell*) i umnožavaju dajući nakupine (engl. *clusters*) identičnih sekvenci

4. analiza podataka

- određivanje očitanih baza (engl. *base calling*) - signali otkriveni tijekom sekvenciranja prevode se u niz nukleotida (A, T, C, G)
- sastavljanje očitanih sekvenci (engl. *reads*) - kratke sekvence sastavljaju se u duže sekvence, usklađujući ih s referentnim genomom ako je dostupan ili ih sklapaju *de novo* ako referenca nije dostupna

FASTQ file

- nakon završetka sekvenciranja, slijed nukleotida i ocjena kvalitete svake očitane sekvence (engl. *reads*) pohranjuju se u formatu tekstualne datoteke FASTQ za daljnje korake analize

```
@EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG  
ACGTGTACACAGTCAGATGATAGCAGATAGGAAAT  
+  
BBBBCCCC?<A?BC?7@@??????DBBA@@@A@
```

- linija 1 počinje sa '@' znakom, a nakon nje je identifikator sekvence i opcionalan opis

- Specific to Illumina Sequences
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - FASTQ Sequence Start
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Instrument Name
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Run ID
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Flowcell ID
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Lane Number
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Tile Number
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - X-coordinate of cluster
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Y-coordinate of cluster
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - read Number (Paired 1/2)
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Filtered
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Control Number
 - @EAS139:136:FC706VJ:2:5:1000:12850 1:Y:18:ATCACG - Index Sequence

<https://www.slideshare.net/rjorton/ngs-data-formats-and-analyses>

- linija 2 je sama sekvenci (niz slova)
- linija 3 počinje s '+' znakom, a opcionalno iza njega može biti isti identifikator sekvence (i bilo koji opis) ponovo
- linija 4 predstavlja vrijednosti kvalitete za sekvencu iz linije 2; broj znakova mora biti jednak broju slova u sekvenci

Q40 is not the maximum quality score

Q-Symbol	Q-ASCII	Q-Score	P-Error
I	73	40	0.00010
H	72	39	0.00013
G	71	38	0.00016
F	70	37	0.00020
E	69	36	0.00025
D	68	35	0.00032
C	67	34	0.00040
B	66	33	0.00050
A	65	32	0.00063
@	64	31	0.00079
?	63	30	0.00100
>	62	29	0.00126
=	61	28	0.00158
<	60	27	0.00200
:	59	26	0.00251
:	58	25	0.00316
9	57	24	0.00398
8	56	23	0.00501
7	55	22	0.00631
6	54	21	0.00794
5	53	20	0.01000
4	52	19	0.01259
3	51	18	0.01585
2	50	17	0.01995
1	49	16	0.02512
0	48	15	0.03162
/	47	14	0.03981
-	46	13	0.05012
.	45	12	0.06310
,	44	11	0.07943
+	43	10	0.10000
*	42	9	0.12589
)	41	8	0.15849
(40	7	0.19953
:	39	6	0.25119
&	38	5	0.31623
%	37	4	0.39811
\$	36	3	0.50119
#	35	2	0.63096
"	34	1	0.79433
!	33	0	1.00000

$$P = 10^{(-Q/10)}$$

Q40 = 1 in 10,000 error rate

$$Q = -10 \times \log_{10}(P)$$



FASTA datoteka


- sadrži retke nukleotidnih sekvenci (adenin [A], timin [T], citozin [C] i gvanin [G]) kojima prethodi redak zaglavlja koji počinje simbolom ">"

```
>10001f
GTGTGGTAAAAAGTAGGAAGAGCAGTTAAATGCAGAATTCCACGTTAGTTGACTAAAATTCTGAGTCAGTCAGTGTAAGTAGAACCGTGAGTTAACATGCATTCAAGTTGAC
>10001r
CTGAGTTAGTCAGTGAATTCTAGTAAATCTCTCGGTTAGCTTAGTAAACAGGAAAAACTGAGATATTCAATTGAGTTCATATTAAAGCTCTGTTGGCTAGTCAGTGACTGA
>10002f
TTCGGGGTTTACATTCTCCCTCTTAAGAGATTCTCGTCGAAATCTAAGGATAAAAAATGAGCTAGATATTTCATCCAATATCTACACCCAACTACTCAATCTCAACCATT
>10002r
ATGATGTTGAAGCATGATAGAAGTCATCATTAGGAATATTGCATTCTTGGATACATAGCATGGCATTATTGCATAAAAGGTGGCAATTAAATGAGTGGACTGCCTATCTTT
>10003f
AATAATTGCTCAATACCGATTTCTTAAGAGTTCAACATTCAATTCTTAAGATTACTATAATGGTACACACTGCTTACTGATTTCACTCTTCTATTGAAGTCATATTCAATT
>10003r
AACTTTGAAATTTCATTAACGACAATAATTAAATTGTTAGCAAATGAAATTGGATATTGGATCTAACATGTGAATGTAAGGATAAGTGAAGTGAGAAAATAA
>10004f
AGGATCGAAAGTAAATTGCAACGGCTGTTCATAAATTAAAGATAATCAACTAAATTATAAATTAGAATTAGAACACAAAAAGCACAGTACCTTCTTTCAAGTTCAAGGG
>10004r
ATCTCCCAATGCAAATCGCGATACAACAAAAGAAAAAAACAAACCAAGGCGAACGCCACCAGCGATCAACGATGCCATGACTGATTGGCGGTAAGCGTATGTGGCTGCG
>10005f
TGGGCCGATAAGTGTGAGGAAGCATTCCAAGGATTGAAACACTTATTGACTAATGCACCTATGTTAGTTCCAGAAGGGATCTGGACTTAGTATGGATACAAATGCTAGTGGAACTG
>10005r
AAATCTTCCACACAACATCATTGCCAACACTGCATTGACATTTCGGCTAAGTCATCTGAAACATTATTGTCTTCTGGAGTGTGATCAATACAAAATCATAGGGCATCA
>10006f
TTTAACTAATTTATCTAAAATTGTGATACATTATCATGGTTATATCTTACTATATTACACATATATGTATGTATGTATTCAATAATTGATTTA
>10006r
CATACATATATTATTAAATGAAAAATAAATTTTATTACAAAACAATAGTACATACACATACACATTGATATATATATATTATGTGTGGTTACTCATTATT
>10007f
TTCGGATAGCCTTTGGGTGAAACTATCGTTGATGGCTACAGCGTCAATGCCAGAACACTCACTGAGACCTCGTTGACTGGTATGGCTCCGTAACCTAAAAGGGCA
>10007r
GTTACGGGAGCCATAACCAGTCAAACGAAGGTCTAGTGAGTTACGGCATTGACCGCTGTAAGCCATCAACGGATAGTTCACACCAAAAAAGGGCTATCGAACCCCAATCGGTC
>10008f
TGACGAGGGCGGTAGCGCGTGTAGTGGCGCCGTGTTGGTCAAACGTTGATGAAGTGGTTCGTTGCTGAAGAGTGTGCGTGTACTATAACTACTGTTCTGTGAGGGAG
>10008r
ATTAAATCGAATTAAAATTCAATTAAACCCAAAATTGACGGTCTCAGAACCGTCAAACAGCATCATCAAGTCAGAACATTCAATACGAACCTAGCGGAGACAACCGCGTGTAA
>10009f
GGCTACGCCATGATATAAGGCAATTATTATTCACACTTGGTGTATATTCTCTTGGAGATTGTTGATTGATGATTGGGATCGTCAATTATTCATGTGGTCAAAA
>10009r
CAAAGCCACTGCCATCACATGTGAGTCAAAATATGTACATATCAGAGTCTGAATAATAACAGAGTAGCGGAATAGTGGACAAATAAGCGCTATCTACAGCATAGCAGATAATGTCCA
>10010f
AGGTTACTTACAAAATAAACTAAATTCTCTTAAAACAAAATTCAAGTCACCTTAAAGTACTATTATAATAATTGAAAAAGAATTACTTAAATTAAACATTAA
>10010r
```


Bioinformatika

- integrira biologiju, računalnu znanost i informacijsku tehnologiju za analizu i interpretaciju bioloških podataka
- transformira neobrađene nukleotidne sekvence (engl. *raw data*) u složenu kompoziciju bioloških informacija, omogućujući znanstvenicima da dešifriraju funkcionalni, strukturni i evolucijski kontekst genoma
- kroz sofisticirane algoritme i računalne alate, pretvara sekvence u smisleni prikaz uputa za rast, razvoj, preživljavanje i reprodukciju organizma

Transformation of Raw Nucleotide Sequences into Biological Information




Uloga bioinformatike u analizi sekvenci DNA i sastavljanju genoma



Sklapanje genoma (engl. sequence assembly)

Kako se mnoštvo kratkih očitanih sekvenci generiranih metodama NGS sastavlja u sekvencu cijelog genoma?

- kontinuirana sekvenca genoma se sastavlja traženjem preklapanja između slijeda nukleotida zbirke pojedinačnih fragmenata
- proces se provodi pomoću specijaliziranog softvera i algoritama koji analiziraju preklapajuća područja sekvenci kako bi ih poravnali i spojili u veće susjedne sekvene, poznate kao kontig sekvene (engl. *contig*) - djelomično sastavljen niz od nekoliko očitanih sekvenci



T.A. Brown - Genomes 4-Garland Science (2018)

- konsenzus sekvenca - reprezentativni slijed nukleotida u kojem je svaki nukleotid onaj koja se najčešće pojavljuje na tom mjestu u različitim sekvencama

TAGATTACACAGATTACTGA TTGATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGCGTAAACTA
TAG TTACACAGATTATGACTTCATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGCGTAA CTA
TAGATTACACAGATTACTGACTTGATGGGTAA CTA

↓ ↓ ↓ ↓

TAGATTACACAGATTACTGACTTGATGGCGTAA CTA


de novo sklapanje genoma

- metoda za konstruiranje genoma iz velikog broja (kratkih ili dugih) fragmenata DNA, bez prethodnog znanja o ispravnom slijedu ili redoslijedu tih fragmenata

očitane sekvence DNA (engl. *reads*)

- fragmenti DNA koja generiraju sekvenatori - obično se kreću u veličini od 35 do 1000 bp ("kratka čitanja") ili "duga čitanja" u veličini od 1000 do 500 000 bp
- neobrađena očitana (engl. *raw reads*) općenito se pohranjuju u FastQ datoteke

kontigi - građeni od dvije ili više preklapajućih usmjerenih sekvenci
- očitane sekvence dijeli podskup ili sve parove baza



skafoldi - sastoje se od više kontiga (među kojima često ima praznina) i definiraju njihov međusobni redoslijed, orientaciju i veličinu procijepa među njima

- u koraku sastavljanja kromosoma, skafoldi se spajaju u procesu popunjavanja praznina, zatvaranja praznina ili dovršavanja genoma

kromosom - izgrađen je od dva ili više spojenih i usmjerenih skafolda

Sastavljanje genoma *de novo*

- metoda za konstruiranje genoma iz velikog broja (kratkih ili dugih) fragmenata DNA, bez prethodnog znanja o ispravnom slijedu ili redoslijedu tih fragmenata
- odnosi se na sekvenciranje novog genoma gdje ne postoji referentna sekvenca dostupna za poravnanje
- pristup referentnog genoma se može koristiti za sekvenciranje *de novo* ako je vrsta čiji se genom sekvincira povezana s drugim vrstama čiji su genomi već sastavljeni
- postojeća sekvenca koristi se kao referentni genom za sastavljanje sekvenci tražeći regije identičnosti ili sličnosti sekvenci
- kratke sekvene novog genoma bit će sastavljen u kontige prije usporedbe s referencom, kako bi se povećao stupanj točnosti na temelju preklapanja

