

# SEKVENCIRANJE NOVE GENERACIJE

---

Funkcijska genomika

2013/2014

doc.dr. Tadeja Režen

# Sekvenciranje nove generacije

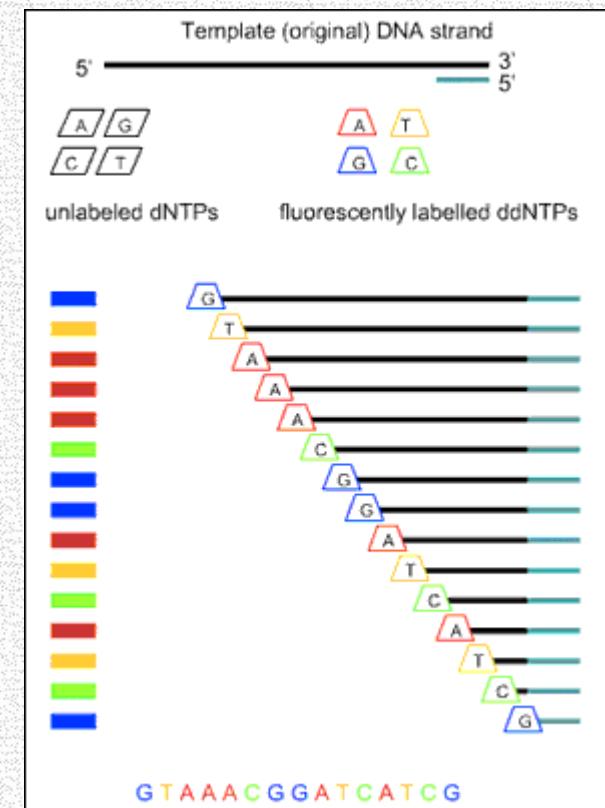
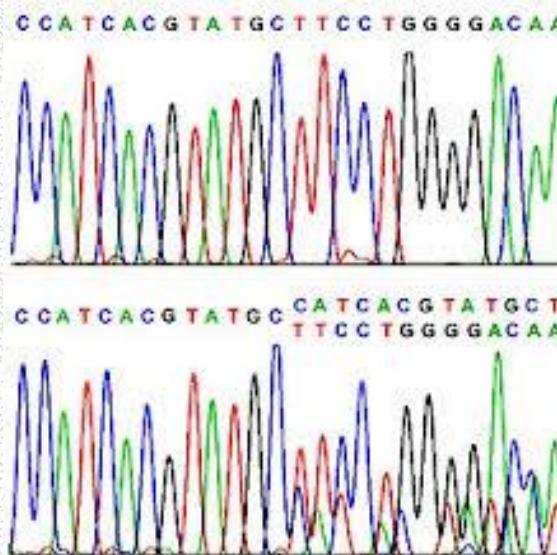
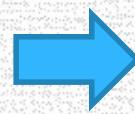
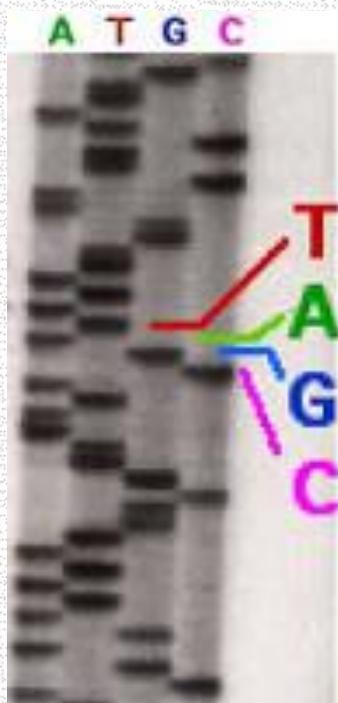
- 1) Uvod – tehnologija in aplikacije
- 2) Priprava vzorcev in sekvenciranje
- 3) Analiza podatkov
- 4) Demonstracija: GS Junior
- 5) Razprava

## NAMEN VAJE

V sklopu vaje se boste spoznali s teoretičnimi osnovami sekvenciranja nove generacije. V praktičnem delu se boste spoznali s pripravo vzorcev in analizo podatkov na napravi za določanje zaporedja GS Junior.

# Sekvenciranje prve generacije

Sangerjeva metoda – sekvenciranje z zaustavitvijo verige z dideoksinukleotidom, Frederick Sanger, 1977



# Sekvenciranje naslednje generacije

- Danes lahko sekvenciramo v eni analizi celoten človeški genom ali genom katerega koli drugega živega bitja. Lahko določimo zaporedje vseh prepisov RNA, ki so v celici. V nekaj dneh na eno bazo natančno.
- Več fragmentom naenkrat parallelno določamo zaporedje, vendar so ti med seboj prostorsko ločeni: na 20 µm kroglicah v pikotitrski ploščici (454 sistem), 1µm klonskih kroglicah (SOLiD), na klonskih kolonijah pritrjenih na podlago (HiSeq).

Poznamo drugo in tretjo generacijo:

- Druga generacija s pomočjo PCR pomnoži DNA fragmente za sekvenciranje. Pomnoževanje je nujno, da je signal fluorescence dovolj velik, da ga zazna CCD kamera.
- Tretja generacija sekvenciranja ne potrebuje pomnoževanje vzorca, ampak prebere zaporedje ene izvorne DNA molekule.

# Naslednja generacija sekvenciranja

Poznamo sekvenciranje:

- 1) S sintezo na kroglicah na pikotitrsk ploščici na sistemu 454 (GS FLX Titanium XL+, GS FLX Titanium XLR70 in GS Junior) podjetja Roche
- 2) S sintezo na pretočni celici (flow cell) na napravi HiSeq 2500q, HiSeq X Ten, NextSeq500 in MiSeq podjetja Illumina
- 3) Z ligacijo na kroglicah na napravi SOLiD 5500xl podjetja Life Technologies (Applied Biosystems); SOLiD – Sequencing by Oligonucleotid Ligation and Detection
- 4) S sintezo na kroglicah na Ion čipu na napravi Ion Torrent (Life Technologies) ; <http://www.youtube.com/watch?v=MxkYa9XCvBQ>

# Tretja generacija sekvenciranja

## **Heliscope (tSMS, angl. »true single molecule sequencing«)**

- Priprava DNA knjižnice (fragmentacija DNA in dodajanje poliA repov)
- Hibrizacija DNA fragmentov na poliT oligonukleotide, ki so pritrjeni na pretočno celico in ti s sintezo sekvencirajo paralelno. Sekvencira do 55 b.

## **SMRT (angl. »single molecule real time sequencer«)**

- Priprava DNA knjižnice s fragmentacijo.
- Čip ima več tisoč jamic, kjer je pritrjena DNA polimeraza in le ta prepisuje DNA fragment s fluorescenčno označenimi nukleotidi. Sekvencira daljše od 1000 baz.

## **RNAP (angl. » single molecule real time sequencer«)**

- RNA polimeraza je pritrjena na polistirensko kroglico in DNA fragment je pritrjen na drugo kroglico, naprava meri razdaljo med kroglicama

## **»Nanopore« naprava za določanje zaporedja**

- DNA molekula potuje skozi alfa-hemolizin poro s ciklodekstrinom, kjer nanj vezan nukleotid spremeni ionski tok skozi poro.

# Aplikacije

## DNA:

- a) sekvenciranje genoma *de novo*: sestavljanje novih genomov,
- b) resekvenciranje genoma: ponovno sestavljanje genomov, detekcija novih in pogostih različic, strukturne različice,
- c) tarčno (re)sekvenciranje , sekvenciranje amplikonov – genotipizacija,
- d) sekvenciranje celotnega eksoma,
- e) ChiP-Seq (kromatinska imunoprecipitacija): vezavna mesta TF,
- f) metilirana DNA - Met-Seq: epigentika in struktura kromatina.

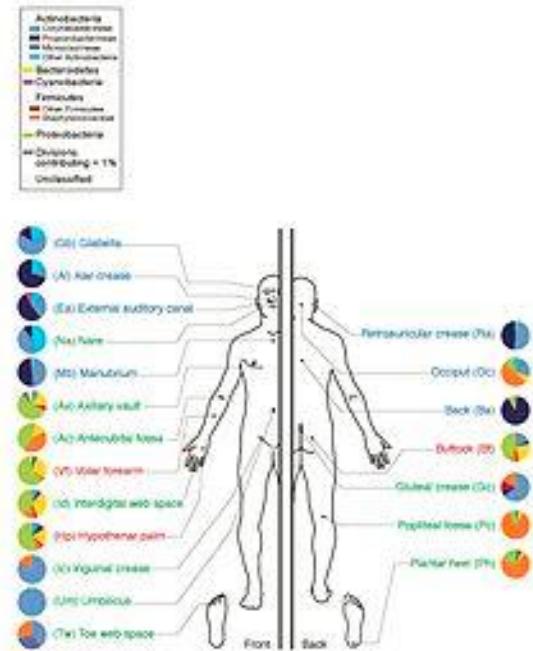
## RNA:

- a) sekvenciranje celotnega transkriptoma (RNA-Seq) in sestava *de novo*,
- b) določevanje diferenčno izraženih genov,
- c) sekvenciranje kratkih RNA: miRNA in druge nekodirajoče RNA.

# Aplikacije

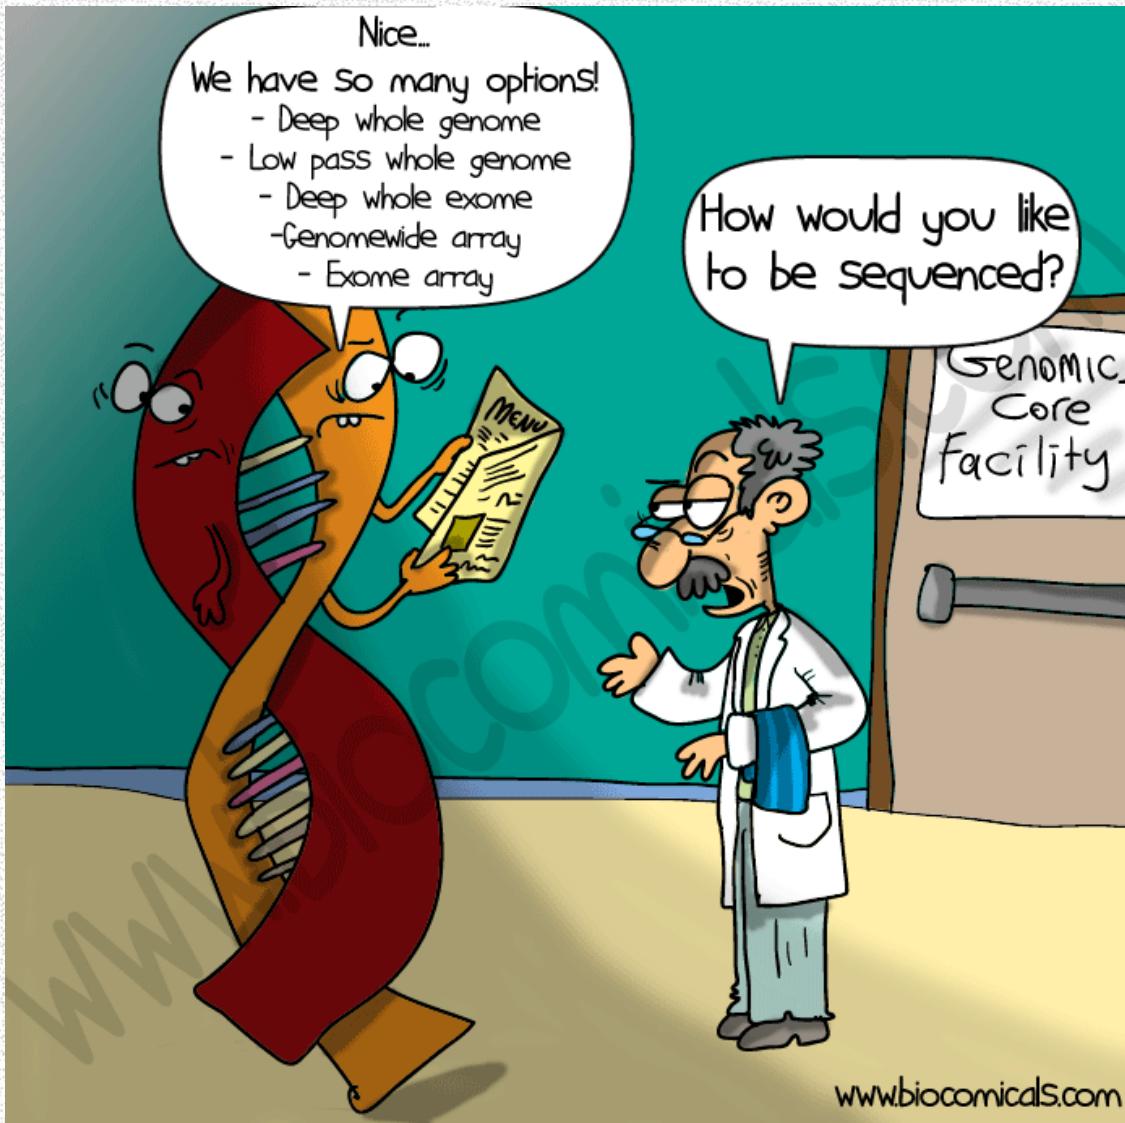
## Metagenomi:

- genetski material kompleksnih vzorcev iz okolja
  - identifikacija vrst mikrorganizmov – biodiverziteta
  - Pridobimo zaporedja vseh genov vseh mikroorganizmov v vzorcu.
- 
- Mikrobiom človeka
  - Biogorivo
  - Ekosistemi – ekologija, varstvo okolja
  - Biotehnologija



# Primerjava naprav za določevanje zaporedja

	GS Junior	GS FLX Titanium / 1K	Illumina HiSeq	Illumina GAlle	SOLiD 4	SOLiD PI
<b>Read length (bp)</b>	400	400 / 800	2x100	2x100 – 2x150	2x50 - 2x75	2x50
<b>Accuracy</b>	>99.9%	>99.9%	98%	98%	99.95+%	99.95+%
<b># reads/run</b>	100 000	1 000 000	550M	200M	640M - 2.4 B	640 M
<b>Run time</b>	10 h	10 / 16 h	8 d	10 d	16 d – 24 d	16 d
<b>Yield/run</b>	40 Mb	400 / 1,000 Mb	200 Gb	20 Gb	64-300 Gb	50 Gb
<b>Throughput (Gb/d)</b>	0.08	0.8 – 1.0	25	2	4-23	7



# Izbor metode

Izbira metode sekvenciranja je odvisna od cilja raziskave!

Cilj in namen raziskave vplivata na odločitve o:

- vrsti vzorca (genomska DNA, eksomi, transkriptom, amplikoni,...),
- globini sekvenciranja (10x – 300x),
- Pripravi vzorcev za sekvenciranje: sekvenciranje samo z ene strani (single-end), z obeh strani (paired-end), z ujemajočimi konci (mate-pair),...
- Izbera načina sekvenciranja: kratki – dolgi fragmenti (SNP, insercije/delecije, procesiranje DNA, miRNA,...)

Izbira reagentov za Illumina

<http://www.illumina.com/prebuilt/kit-selector/sequencing-sample-prep-kit-selector.html?iframe>

# Globina sekvenciranja

Globina pomeni kolikokrat bo določen fragment DNA prebran med sekvenciranjem.

Večja globina = večja statistična moč/manjši del DNA sekvenciran

Odvisna od vrste študije in vrste vzorca (velikost genoma):

- SNP v človeškem genomu (pogost, redek) : 10 – 30 x
- SNP v zarodni liniji (podedovan) : 50 x
- SNP v somatski celici : 300x
- transkriptom : odvisno od ravni izražanja genov

Lander/Watermanova enačba:

C – globina

G – dolžina haploidnega genoma

L – dolžina branja

N - število branj

$$C = \frac{L * N}{G}$$

# Globina pokritja

## HiSeq Output Calculations

### TruSeq v3 Reagents (one flow cell)

Clusters/mm <sup>2</sup> (800K @85%PF)	
%PF may vary based on library	680,000
Area of a lane (mm <sup>2</sup> )	273.6
Reads/lane	186,048,000
Genome or region size (in bases)	3,000,000,000
Coverage	30
Total number of cycles (e.g. 200 for 2x100)	200
<b>Total output required (in bases)</b>	<b>90,000,000,000</b>
Output/lane (bases/lane)	37,209,600,000
Number of lanes	2.42
Number of samples/lane	0.41

# Globina vs dolžina

Človeški genom je 3.000.000.000 baz (3 Gb) dolg.

Genom ima okoli 180.000 exonov, kar predstavlja 1% genoma.

Človeški eksom je 30.000.000 baz (30 Mb) dolg.

V povprečju sekvenciranje eksonov odkrije 12.000 različic (okoli 10 % je novih), sekvenciranje genoma pa okoli 5 milijonov različic (le nekaj % je novih).

Zato je sekvenciranje eksonov cenejše in lahko tudi dovolj informativno za iskanje mutacij v genih, ki sodelujejo v razvoju bolezni in omogoča natančnejše diagnoze pacientov.

# Priprava vzorcev in sekvenciranje

Koraki skupni vsem aplikacijam druge generacije so:

- 1) priprava DNA knjižnice,
- 2) pomnoževanje s PCR,
- 3) čiščenje in priprava za sekvenciranje,
- 4) sekvenciranje,
- 5) analiza podatkov.

Vzorci:

- DNA: genomska, plazmidna, amplikoni
- RNA: mRNA, miRNA, rRNA

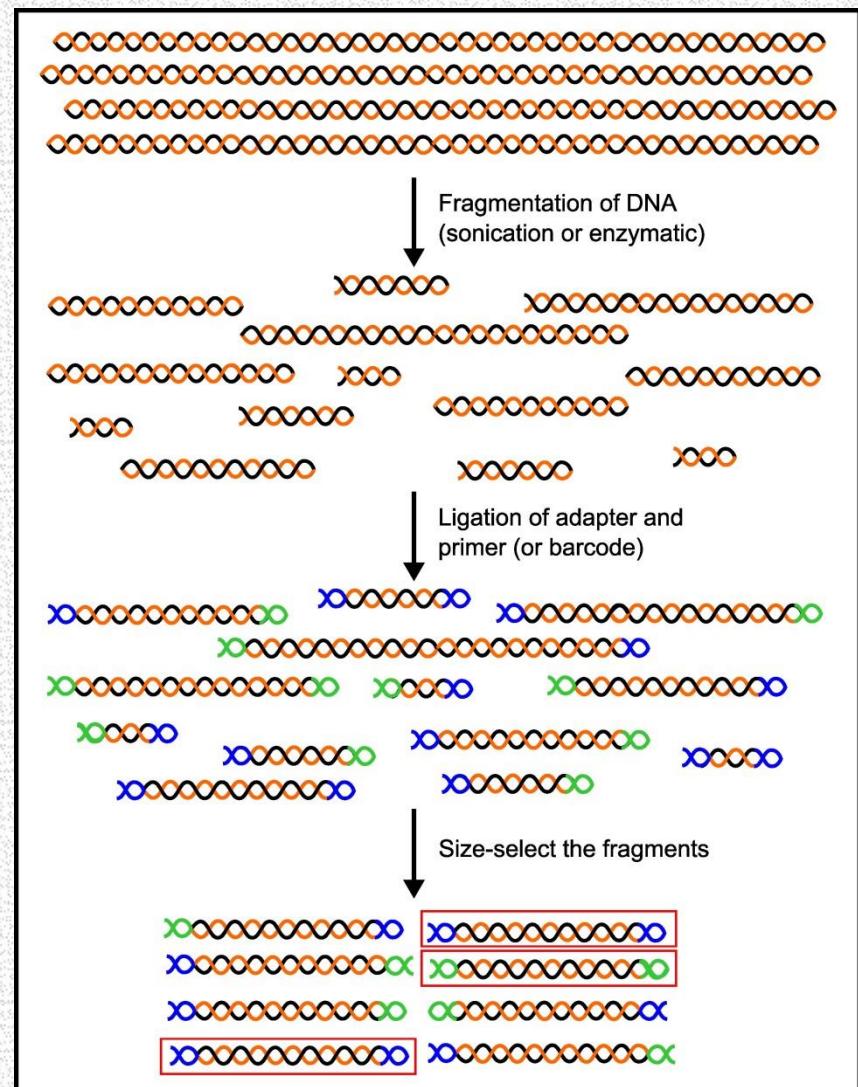
Kvaliteta je zelo pomembna!!! (260/280, 260/230, stopnja razgrajenosti)

Izbira metode izolacije ima močan učinek na kvaliteto in kvantiteto izolata!

# 1) Priprava DNA knjižnice

Intaktna genomska DNA (do 5 µg)

- 1) Fragmentacija
- 2) Poravnavo visečih koncov
- 3) Lepljenje adapterjev
- 4) Čiščenje fragmentov
- 5) Kratek PCR
- 6) Izolacija fragmentov določene dolžine in čiščenje
- 7) Analiza kvalitete DNA knjižnice



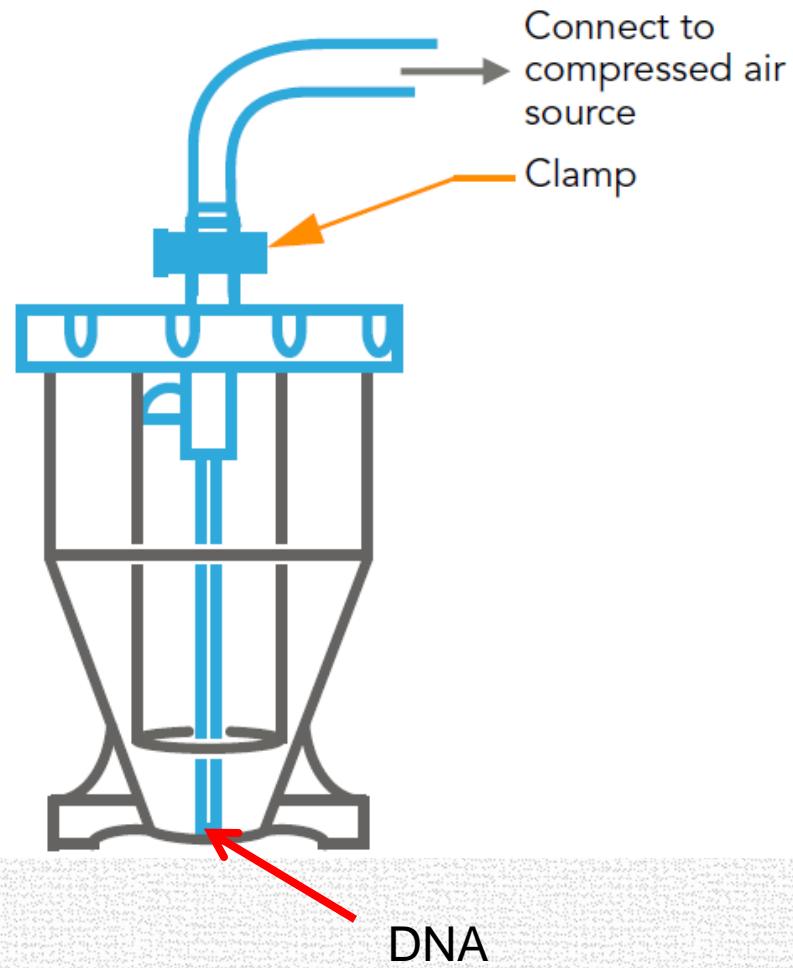
# 1) Priprava DNA knjižnice

## 1) Fragmentacija DNA

Z nebulizacijo ali z ultrazvokom („sonication“) naključno raztrgamo DNA na različno dolge fragmente.

Nebulizacija: DNA raztopino večkrat potisnemo skozi ozko odprtino s pomočjo stisnjenega zraka ali dušika.

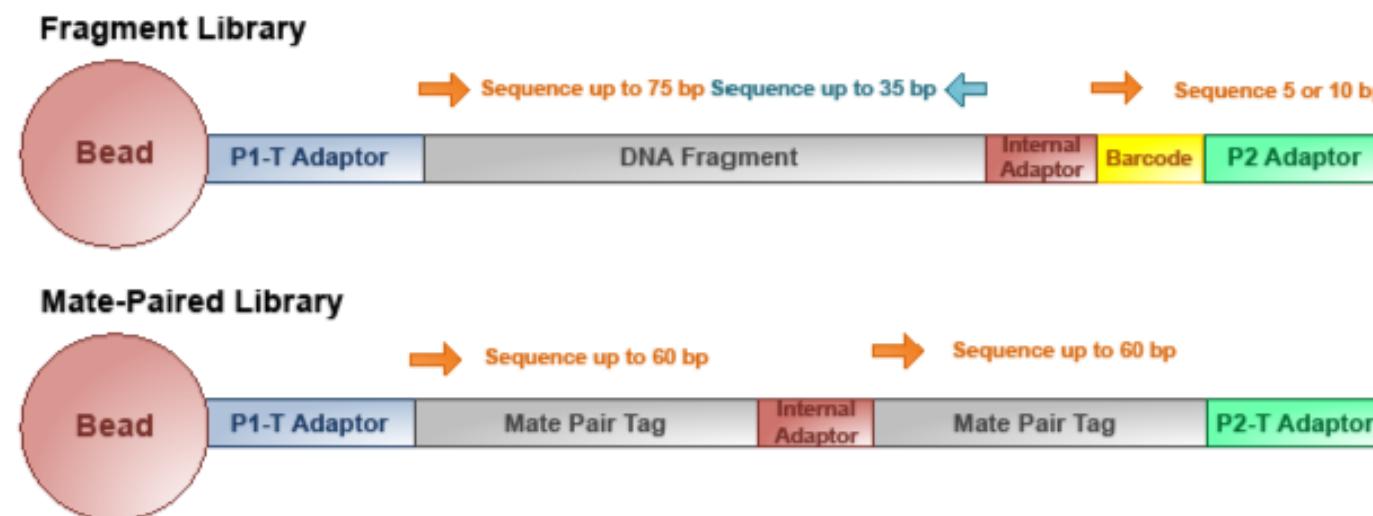
Koliko odvisno od izbrane tehnologije sekvenciranja:  
Illumina < 800 bp, SOLiD od 100 do 250 bp,...



# 1) Priprava DNA knjižnice

## 2 – 3) Poravnava visečih koncev in lepljenje adapterjev:

1. DNA je raztrgana in ima zato 5'-in 3'- viseče konce, ki se poravnajo v ravne konce in doda se dA rep.
2. Lepljenje dveh adapterjev z ligazo, vsakega na svoj konec:  
454 sistem: adapter A in B, SOLiD : adapter P1 in P2.



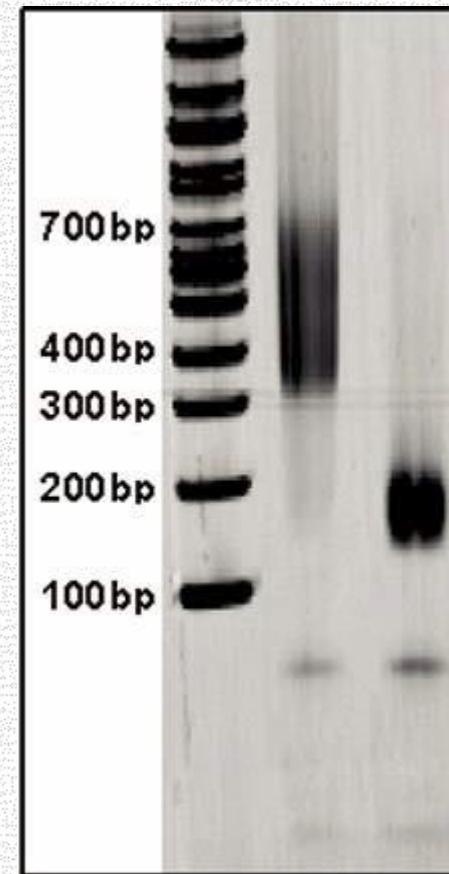
# 1) Priprava DNA knjižnice

4 – 6) Čiščenje in izolacija DNA fragmentov določene dolžine

Kratek PCR, da namnožimo fragmente z različnimi adapterjema.

Med čiščenjem z magnetnimi kroglicami

Agaroznem gelu

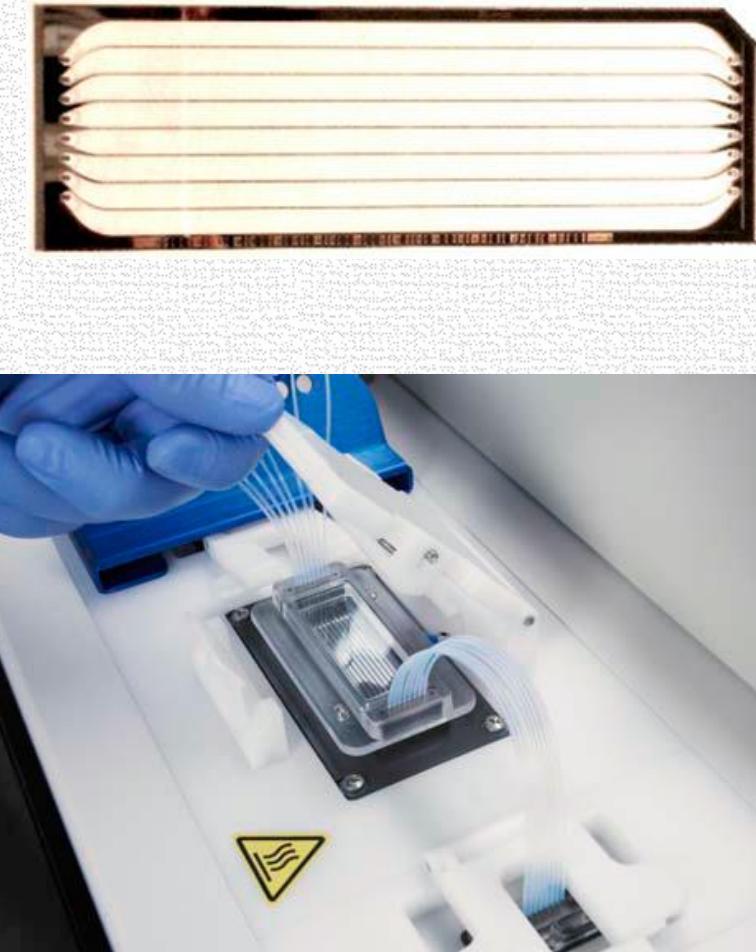
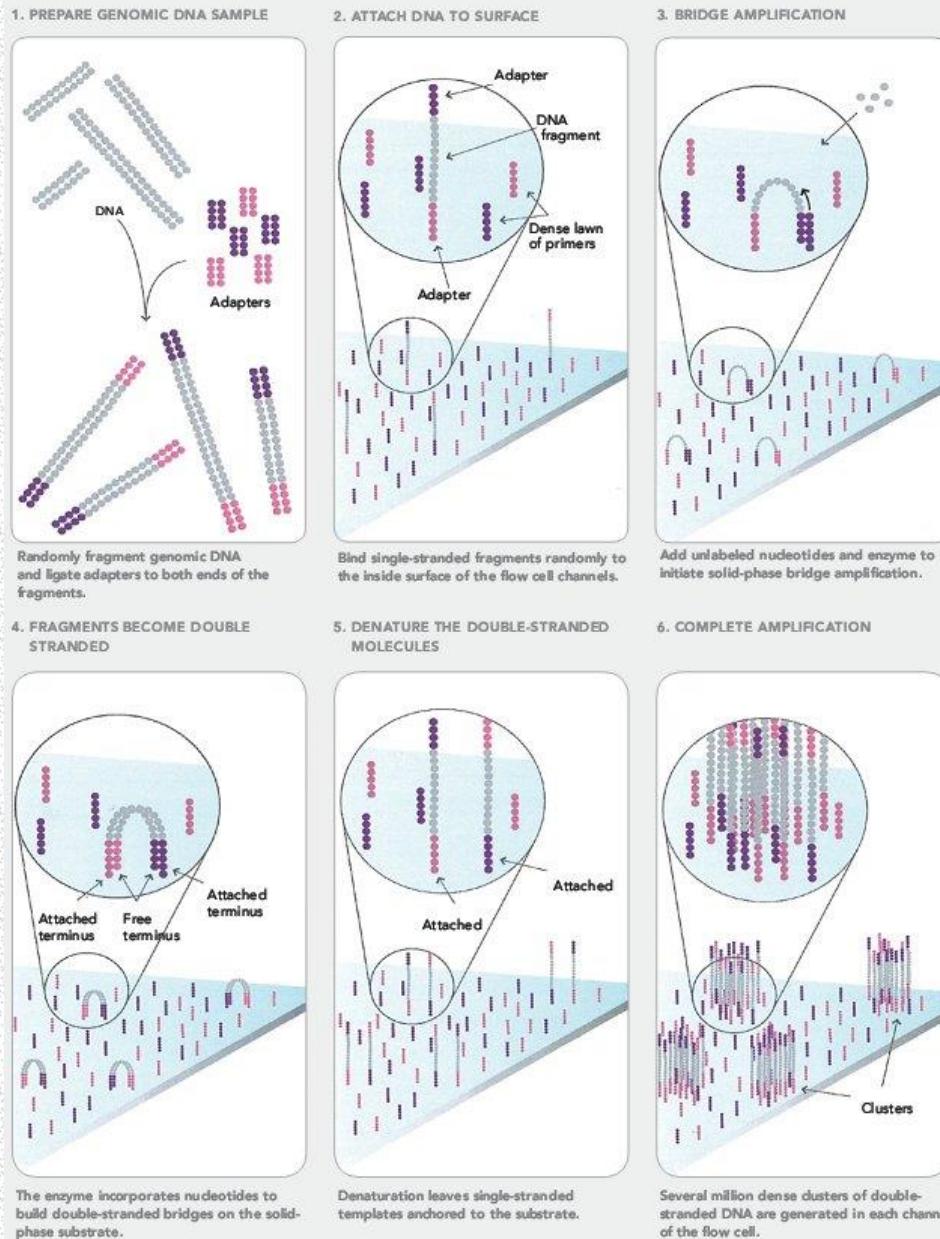


## 2) Pomnoževanje DNA knjižnice

Koraki pri pomnoževanju knjižnice DNA fragmentov:

1. DNA fragmenti se preko adapterjev vežejo na:
  - kroglice (SOLiD, Roche, Ion Torrent), po en fragment na kroglico,
  - pretočno celico (flow cell) (Illumina).
2. PCR:
  - Emulzijski na kroglicah (Roche, SOLiD, Ion Torrent)
  - Na nosilcu preko mostu (Illumina)
3. Čiščenje produktov
4. Priprava za sekvenciranje





# Sekvenciranje – detekcija fluorescence s CCD kamero

## 454 sistem (Roche):

Pomnoženi DNA fragmenti so vezani na kroglice (eden na kroglico in mešanico teh nanesemo na pikotitrsko ploščico (picotiter plate)).

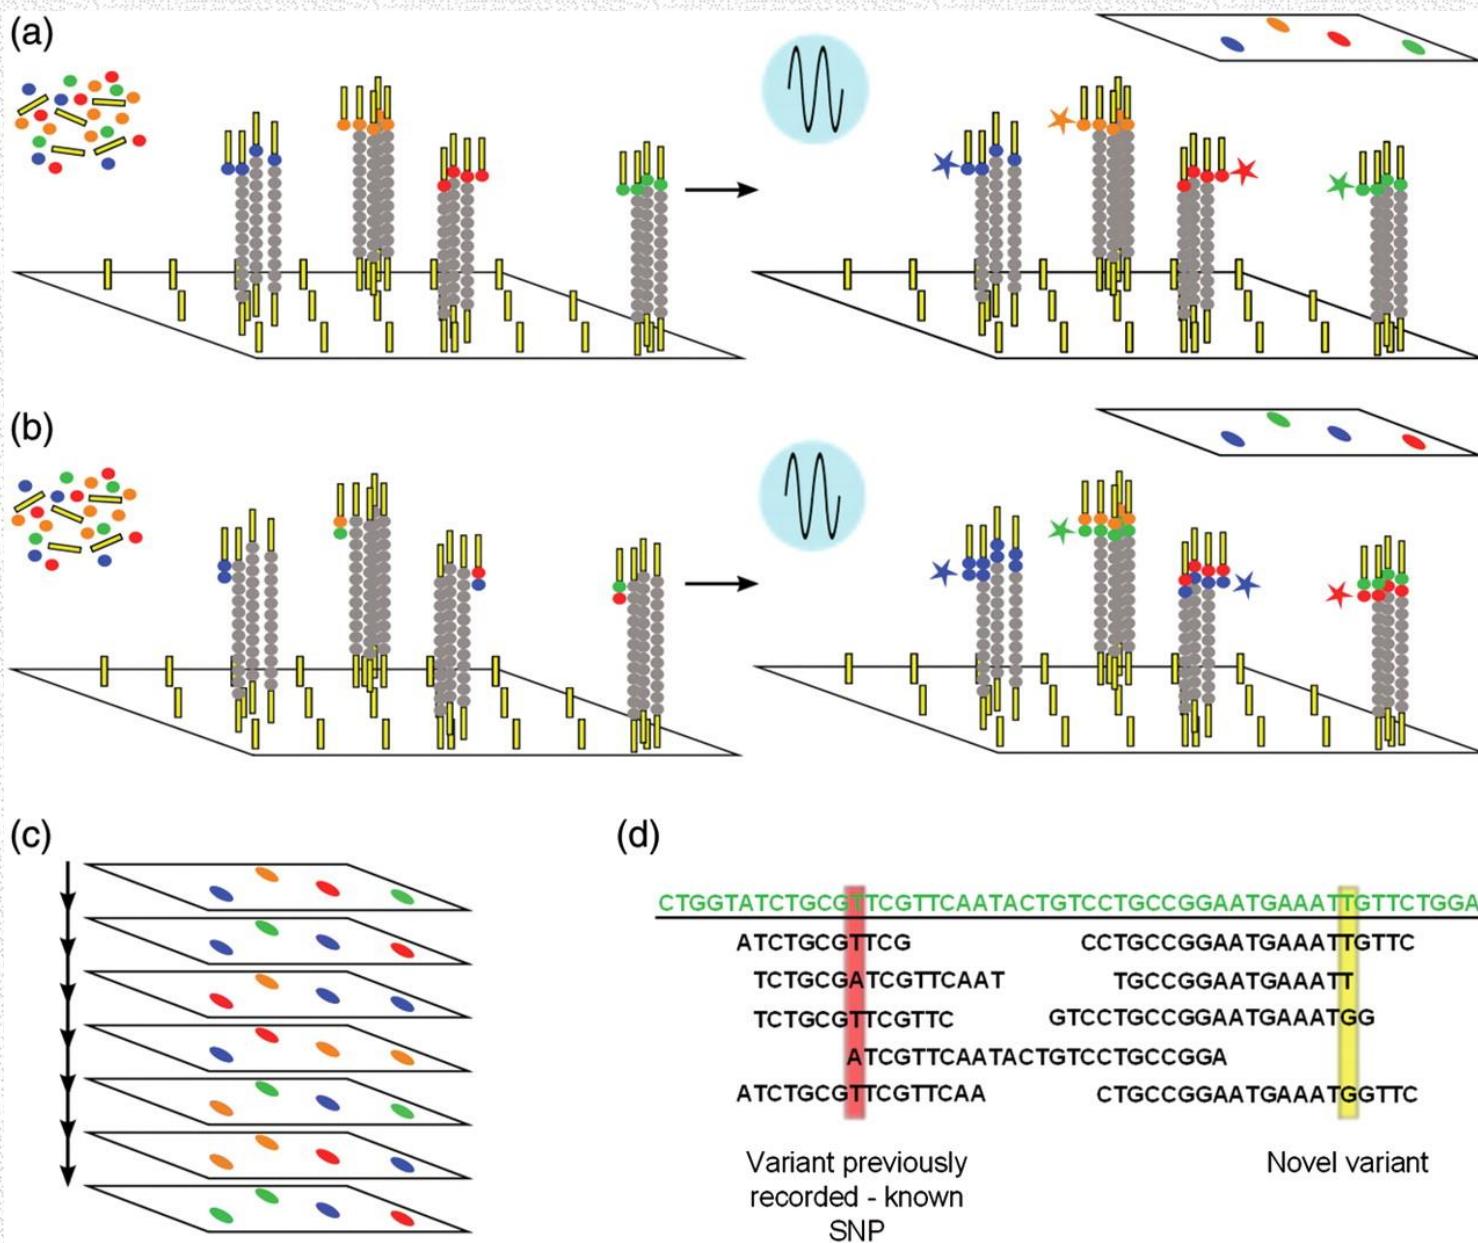
Ploščica je iz zlepljenih optičnih vlaken. Sledi določevanje zaporedja na kroglicah s sintezo DNA verige.

## SOLiD:

Pomnoženi DNA fragmenti se vežejo na stekleni nosilec. Sledi sekvenciranje z ligacijo oligonukleotida, detekcijo, odstranitvijo produkta in lepljenjem novega oligonukleotida in ponavljanje ciklov.

## Illumina:

DNA fragmenti se pomnožijo na pretočni celici in na tej poteka tudi sekvenciranje teh fragmentov preko sinteze.



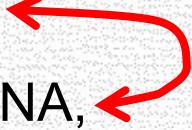
# Sekvenciranje RNA

RNA:

- Kvaliteta:
  - čistost:  $260/230 = 2,0-2,2$ ;  $260/280 = 2$ ,
  - RIN: od 7 do 10 (nad 8), vzorci naj varirajo znotraj 1 in 1,5 razreda.
- Količina: 25 ng mRNA ali 200 ng RNA brez rRNA ali do 4 ug totalne RNA.
- Odstranitev DNA
- Odstranitev rRNA
- Obogatitev mRNA

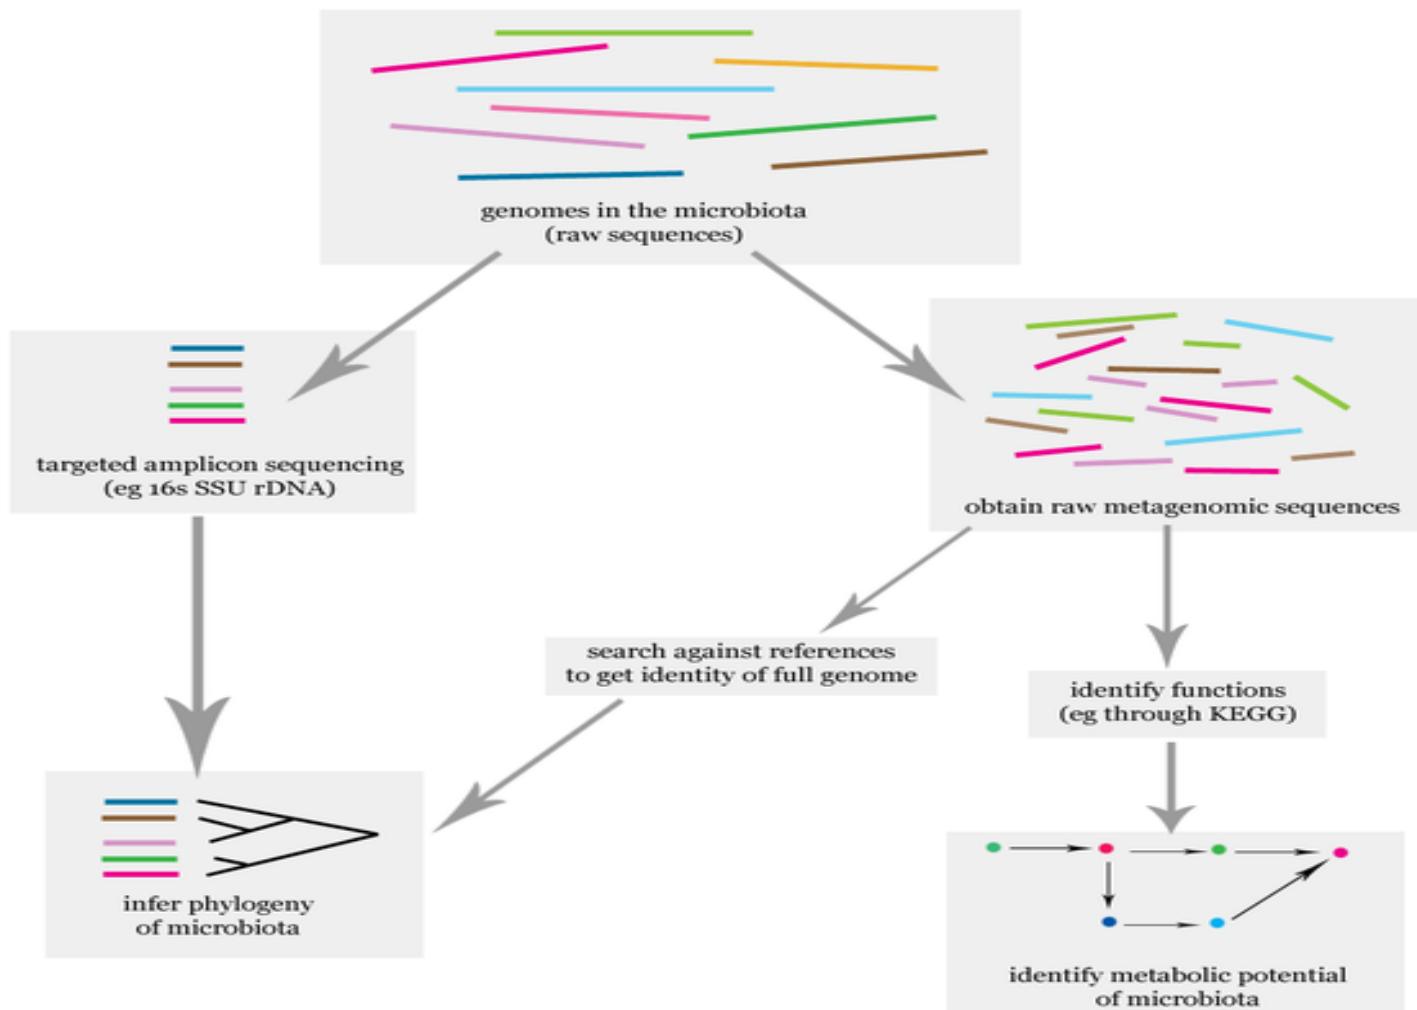
# RNA-Seq –priprava knjižnice

Koraki so:

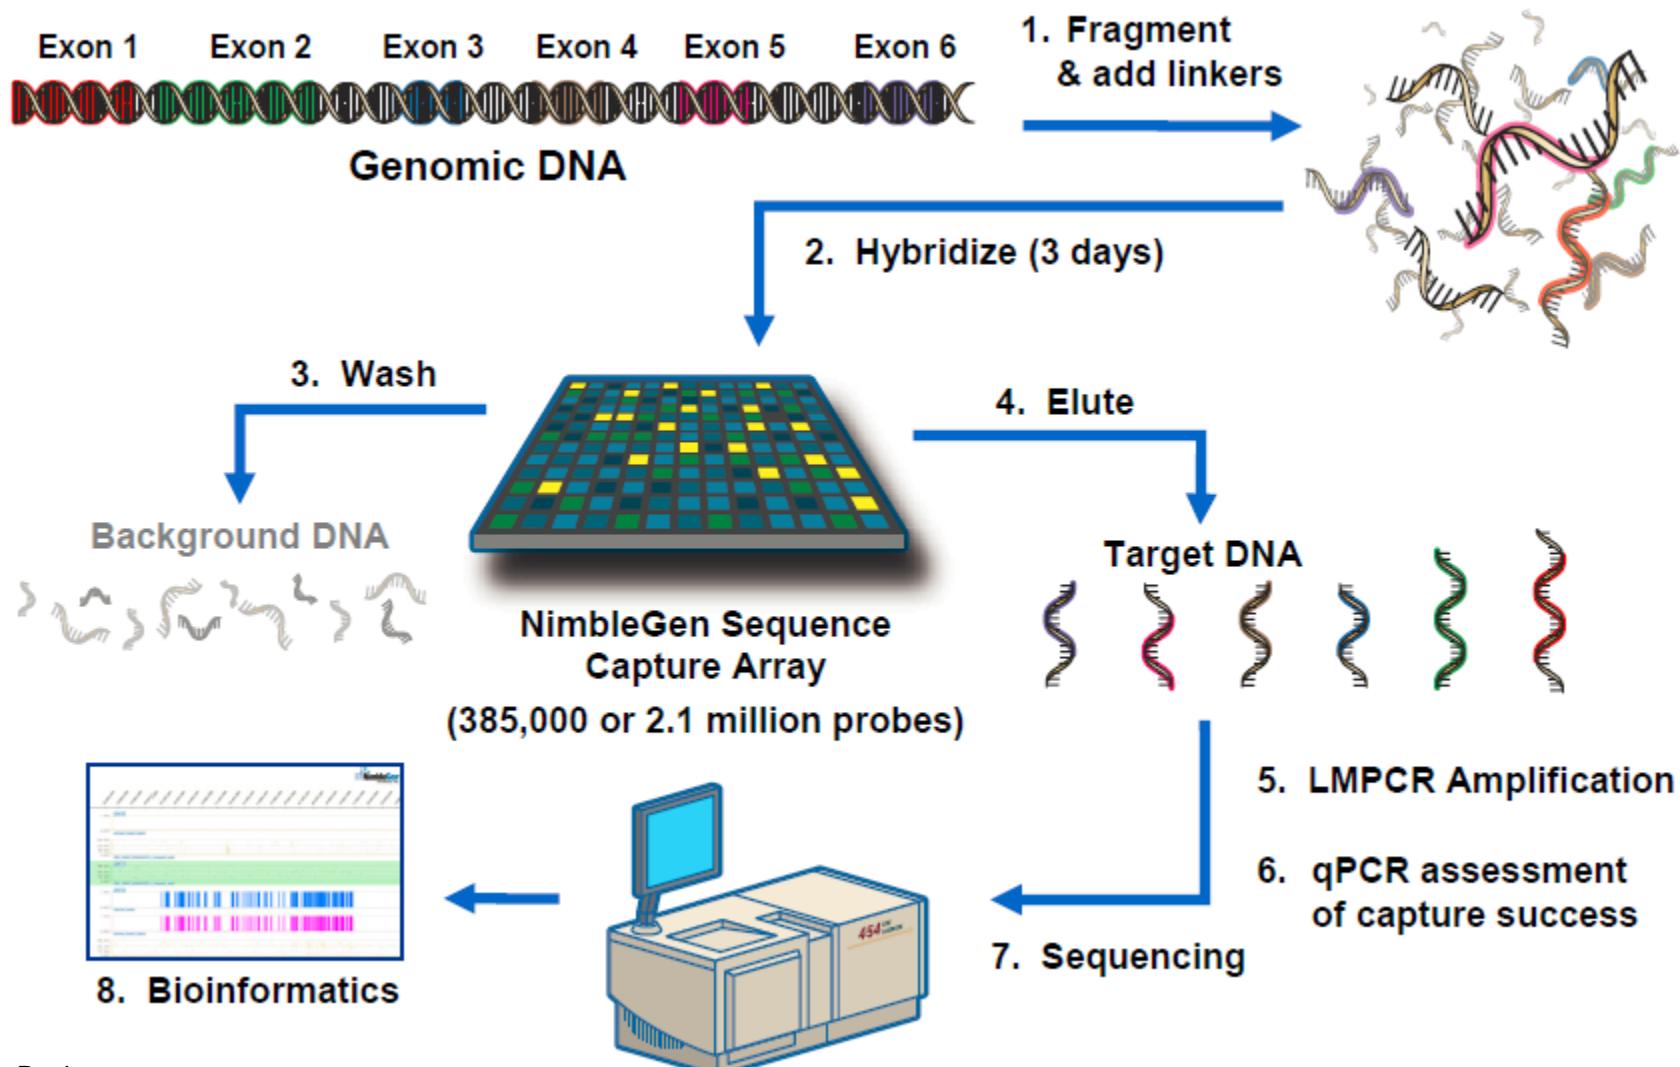
1. Če začneš s totalno RNA, sledi najprej selekcija RNA s poli A repi preko magnetnih kroglic (Illumina).
2. Če začneš z RNA brez rRNA ali že izolirano mRNA, ni selekcije.
3. Fragmentacija RNA,
4. Prepis v dvostransko cDNA, 
5. Na obe strani se doda A,
6. Lepljenje adapterjev,
7. PCR,
8. Kontrola knjižnice (velikost fragmentov, čistost in količina).

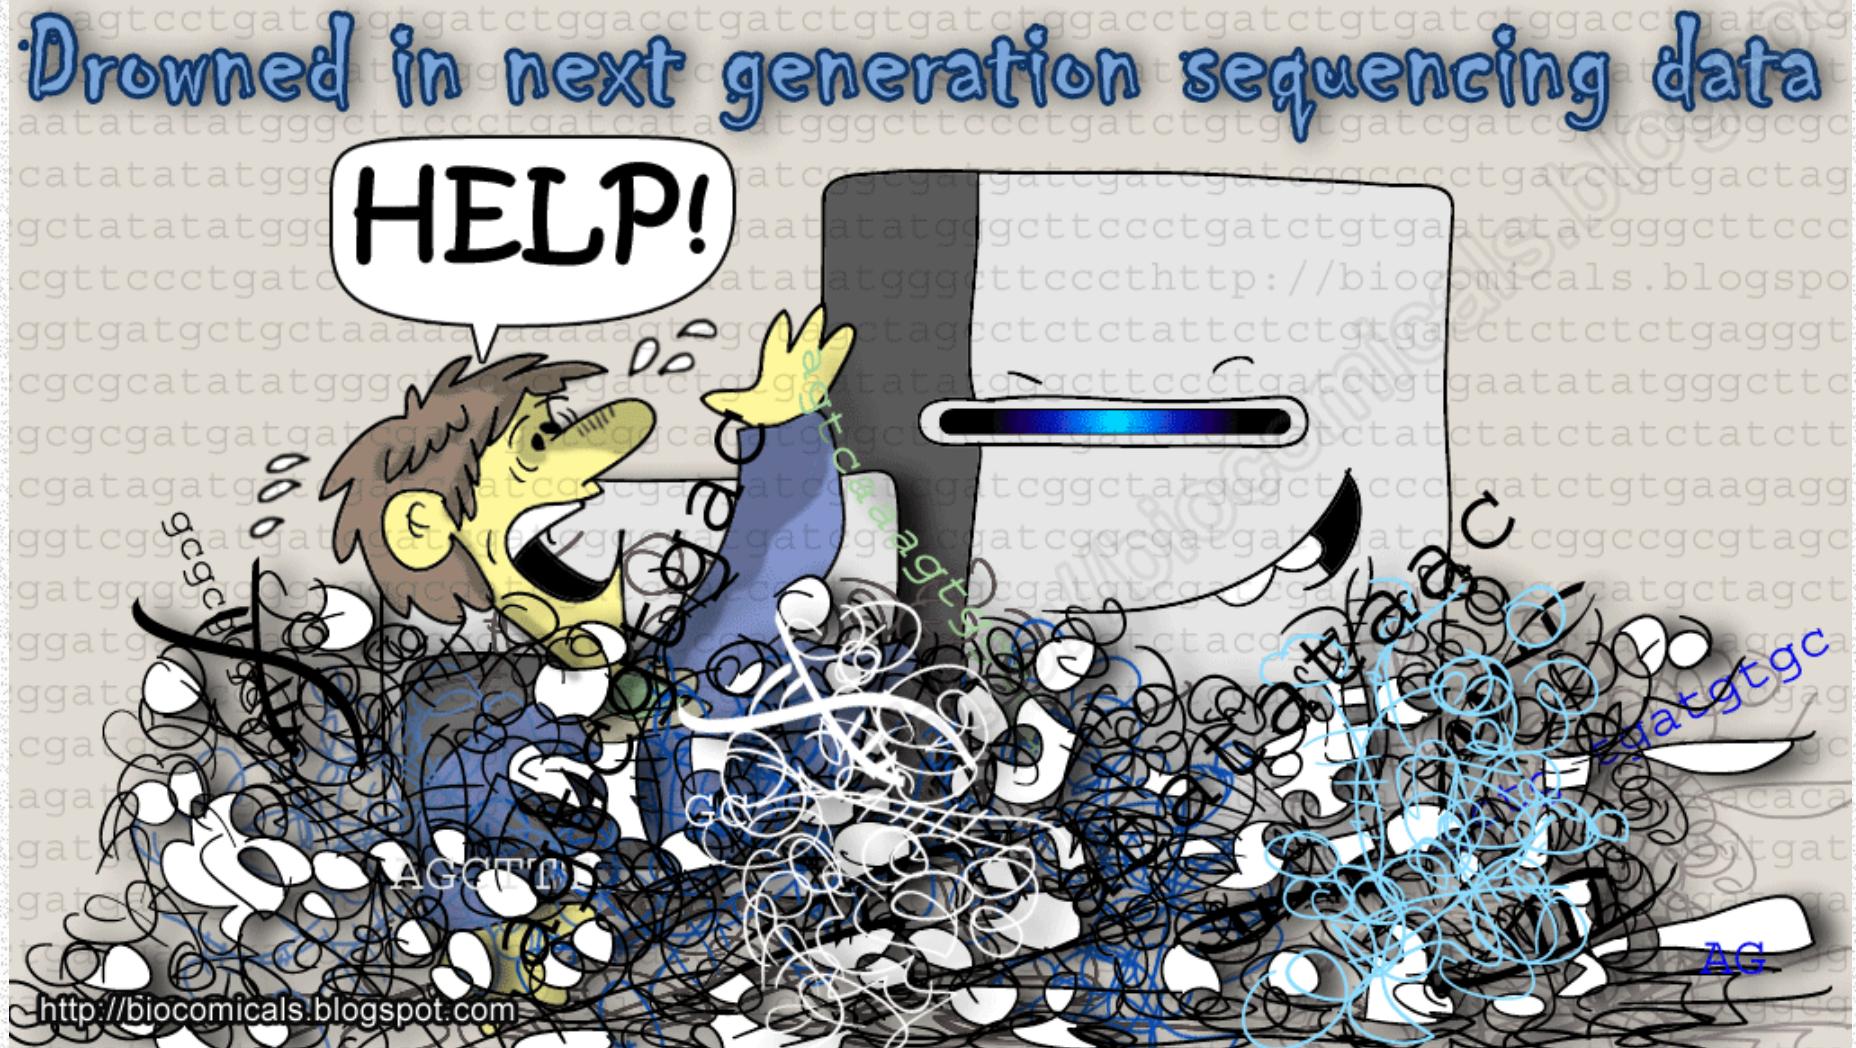
Sekvenciranje

# Mikrobiom



# Tarčno resekvenciranje - eksom





# Analiza podatkov

## □ Količina podatkov – shranjevanje in analiza (terabiti)

Roche – 500 milijonov baz na analizo

Illumina – milijardo baz na analizo

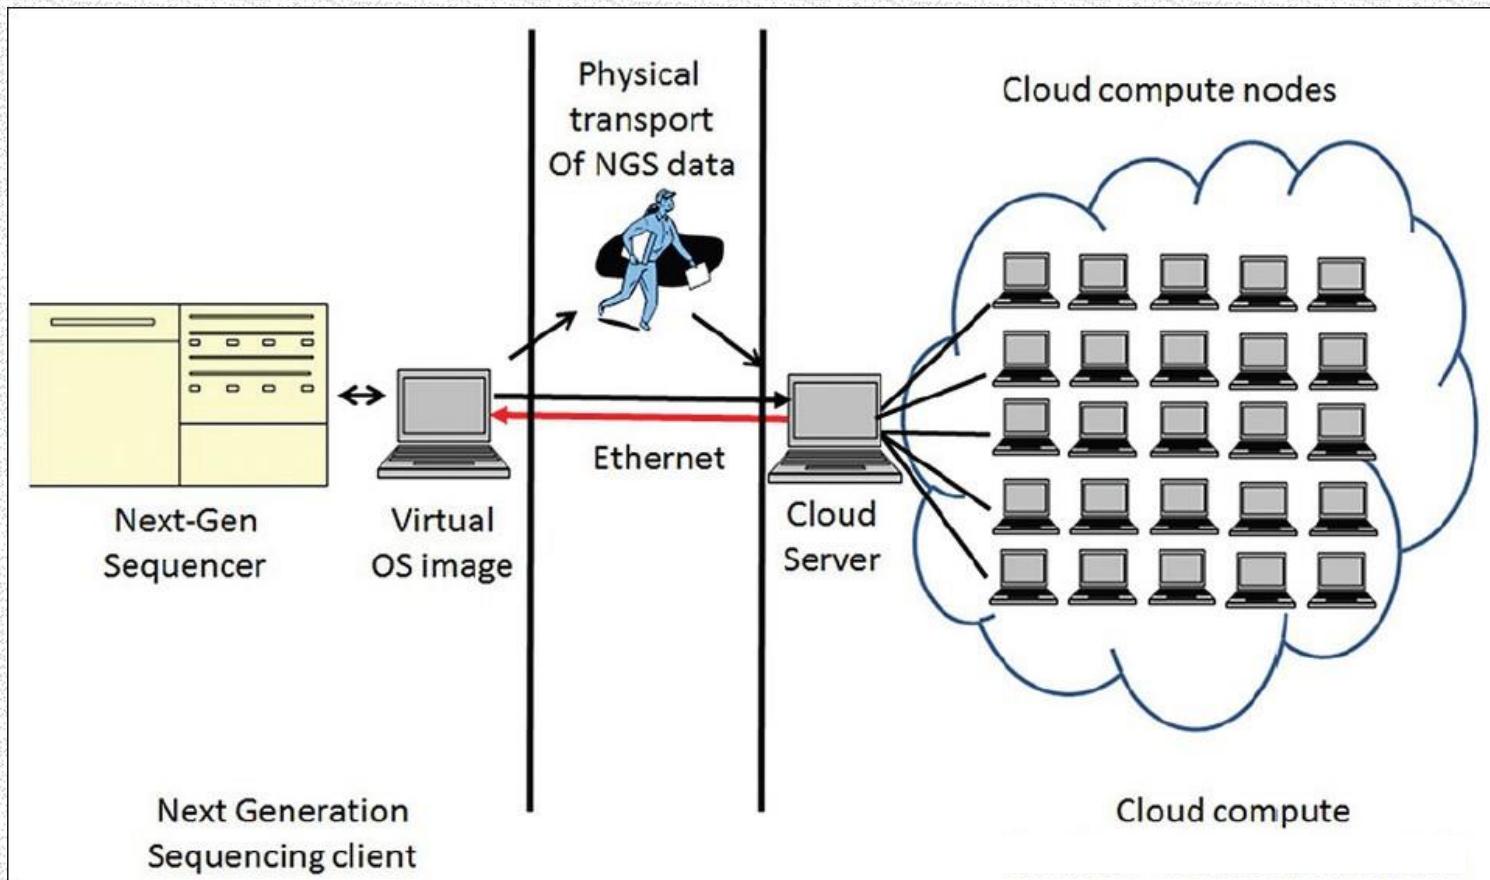
Primer: SOLiD – ena analiza = 90 do 200 gigabajz podatkov –  
vzporejanje z refenčnim genomom: 4 h na 250 serverjih

## □ Ogromna izbira programov in metod (preko 200)

Komercialni – enostavni za uporabo, podpora, dragi, ni izbire

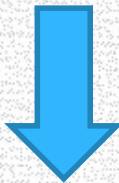
Prosto dostopni - zahtevajo več bioinformatičnega znanja (UNIX  
programiranje), ni podpore, zastonj, ni omejitev v analizi

# Analiza podatkov - oblaki

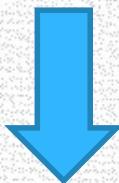


# Vzporejanje odčitkov zaporedij

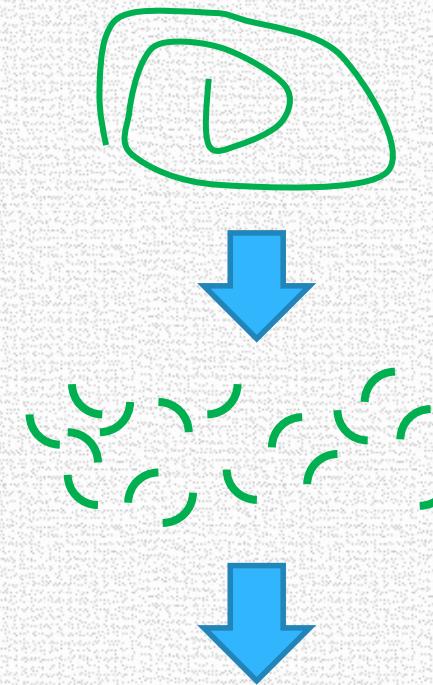
Genomska DNA



Fragmenti DNA



Vzporejanje na  
referenčni genom



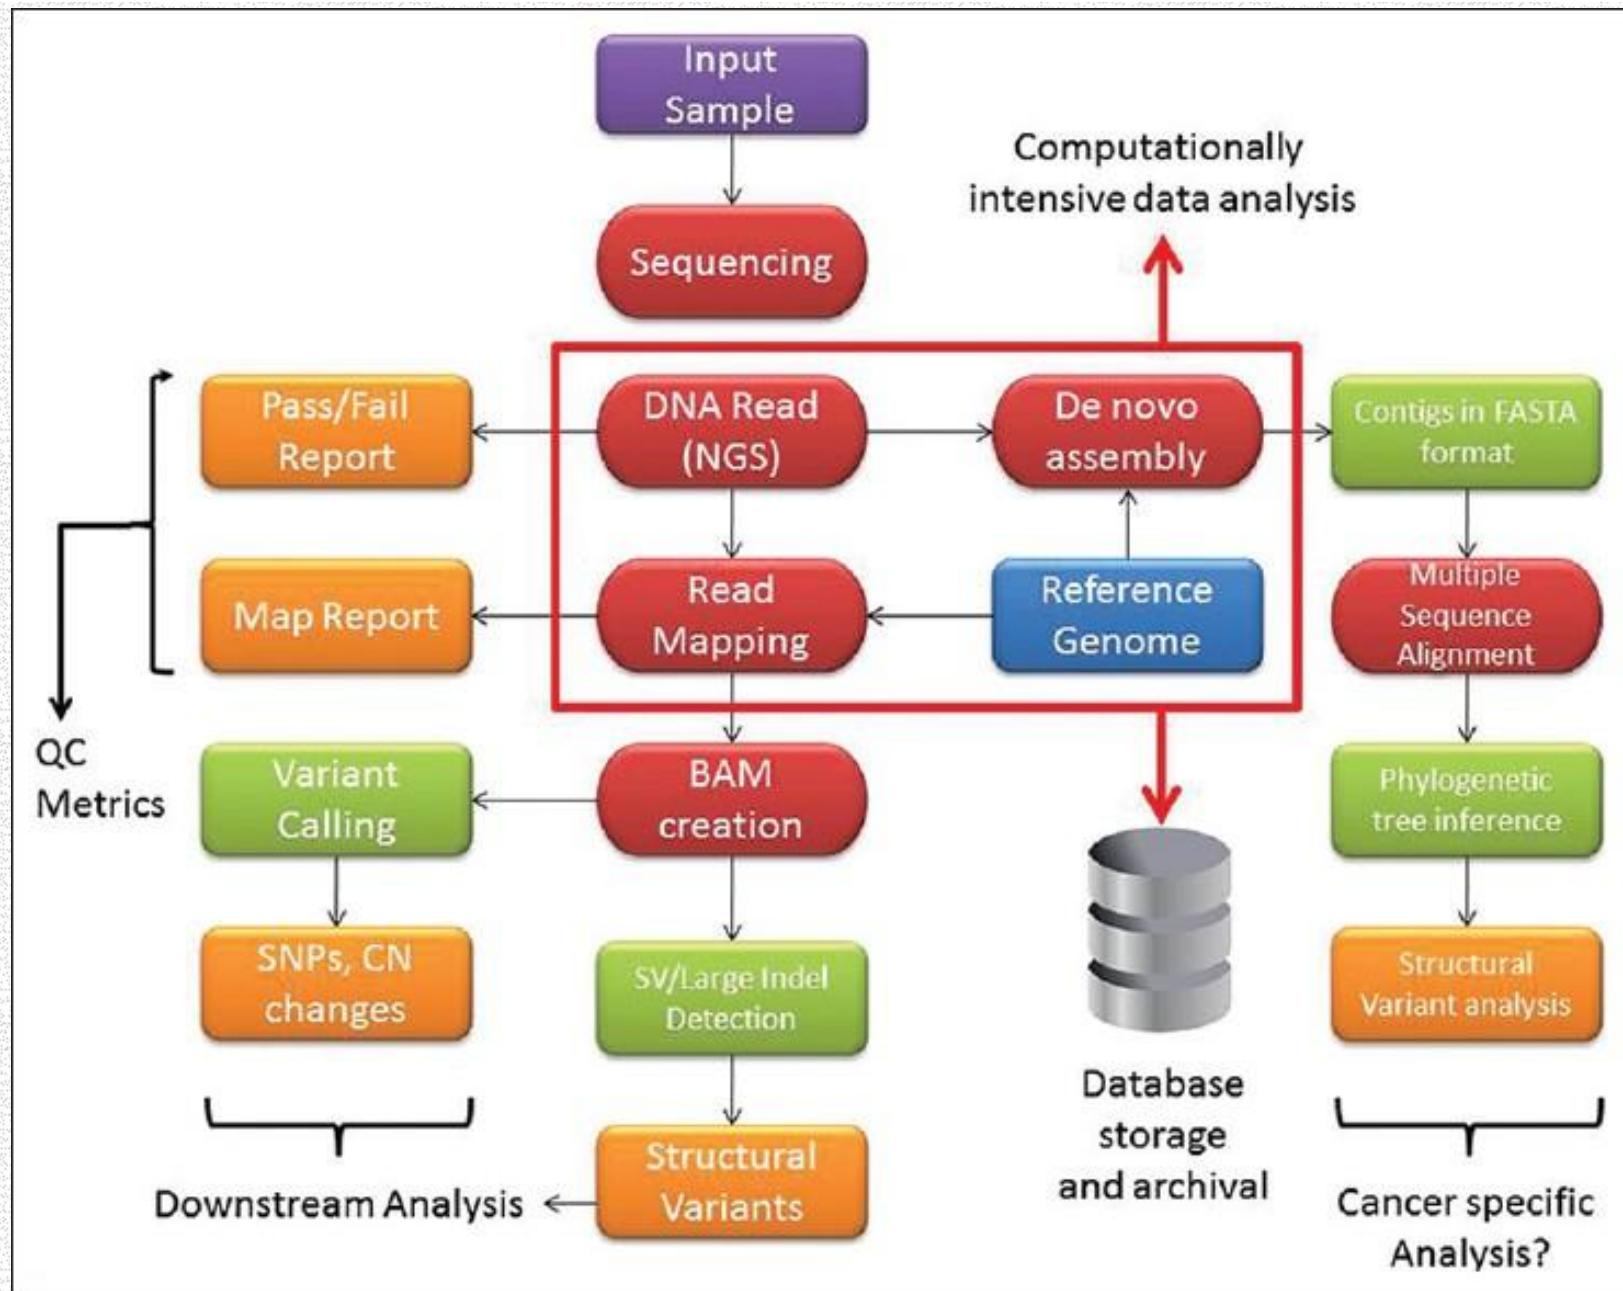
**TGACATGTCGATCGATGCTGGATCGA**  
GACATG      GATCGA            GATCGA  
GTCGAT      GCTGGA            GGATCG  
GACATG      CGATGC            GGATCG

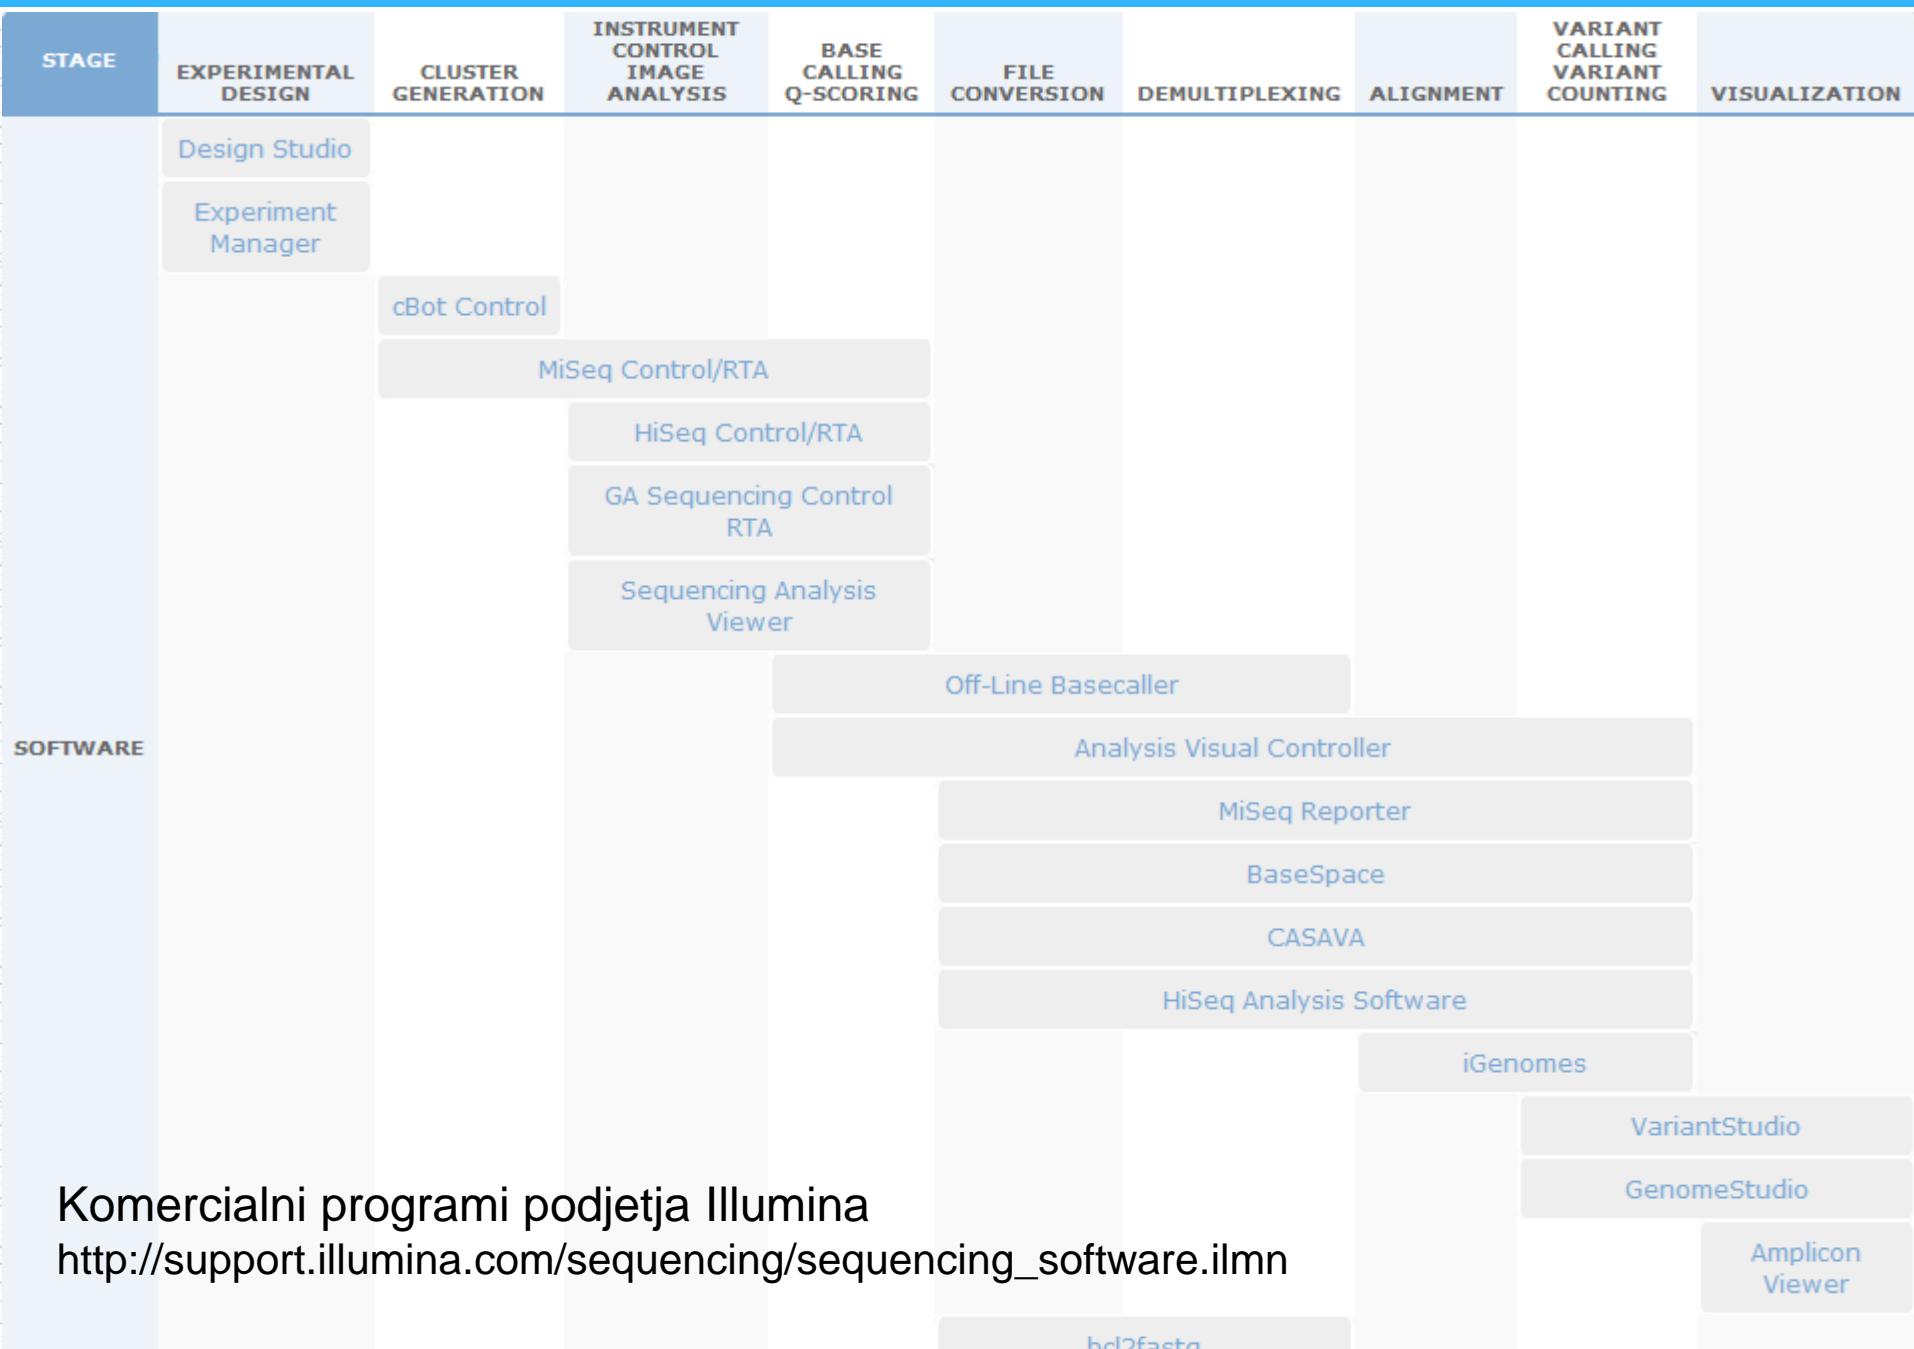
# Koraki v analizi podatkov (iskanje različic)

1. Procesiranje slike in generiranje odčitkov zaporedja (reads)
2. Ocena kvalitete odčitkov zaporedja
3. Vzporeditev odčitkov zaporedja na referenčni genom
4. Identifikacija različic (variant)
5. Anotacija različic
6. Vizualizacija

Pabinger S. et al., A survey of tools for variant analysis of next-generation genome sequencing data, 2013, Brief Bioinform, 21.

<https://www.ebi.ac.uk/training/online/course/ebi-next-generation-sequencing-practical-course>





# 1) Ocena kvalitete

- Ocena kvalitete odčitkov zaporedij. Ali smo dobili dovolj odčitkov zaporedij v analizi? Če ne, zavrnemo celotno analizo.
- Potrebno je odstraniti odčitke, ki ne ustrezajo kriterijem. So verjetno artefakti nastali med pripravo ali sekvenciranjem vzorca.
- Potrebno je skrajšati oziroma odrezati dele odčitkov, kjer branje ni več zanesljivo ali vsebuje zaporedje adapterja in drugih pomožnih zaporedij.
- Vsaka platforma ima svoje kriterije in programe, ki to omogočajo. Obstajajo tudi neodvisni programi.

## 2) Vzporeditev odčitkov zaporedij

- Problem: odkriti vir odčitka zaporedja – „paired-end“ metoda je pomembna sekvenciranje genoma ali eksonov.
- Problem vzporeditve odčitkov zaporedij, ki se ne vzporejajo dobro zaradi na primer insercije/delecije, ki je ni v referenčnem genomu; ponavljajočih se zaporedij,... Taki odčitki so izločeni iz nadalnjih analiz – izgubljena informacija.
- Pomembna izbira referenčnega zaporedja:  
UCSCS (University of Santa Cruz) – ENCODE – GRC (Genome Reference Consortium)
- Na voljo je vrsta programov vsak s svojim pristopom k poravnavi odčitkov. Bowtie, BWA, SOAP, MAQ, mrFAST, Novoalign, SSAHA2, Stumpy,...

# Identifikacija, anotacija in vizualizacija različic

- Ali identificirajo zarodne različice  
CRISP; GATTK, SAMtools, SNVer, VarScan 2,...
- Ali identificirajo somatske različice  
GATK; SAMtools, SomaticSniper, VarScan 2,...
- Identifikacija CNV – razlika v številu kopij  
CNVnator, RDXplorer, CONTRA, ExomeCNV,...
- Identifikacija SV – strukturnih različic  
BreakDancer, Breakpointer, CLEVER,....
- Anotacija različic:  
ANNOVAR, AnniTool, NGS-SNP, VARIANT, VEP,.....
- Vizualizacija različic:  
Na spletnih straneh: Ensembl, USCS, VEGA,  
Artemis, Integrative Genomics, Viewer,....

# Sestava zaporedij *de novo*

Sestava transkriptoma de novo

SOAPdenovo-Trans, Trinity, Cufflinks, Velvet/Oases,...

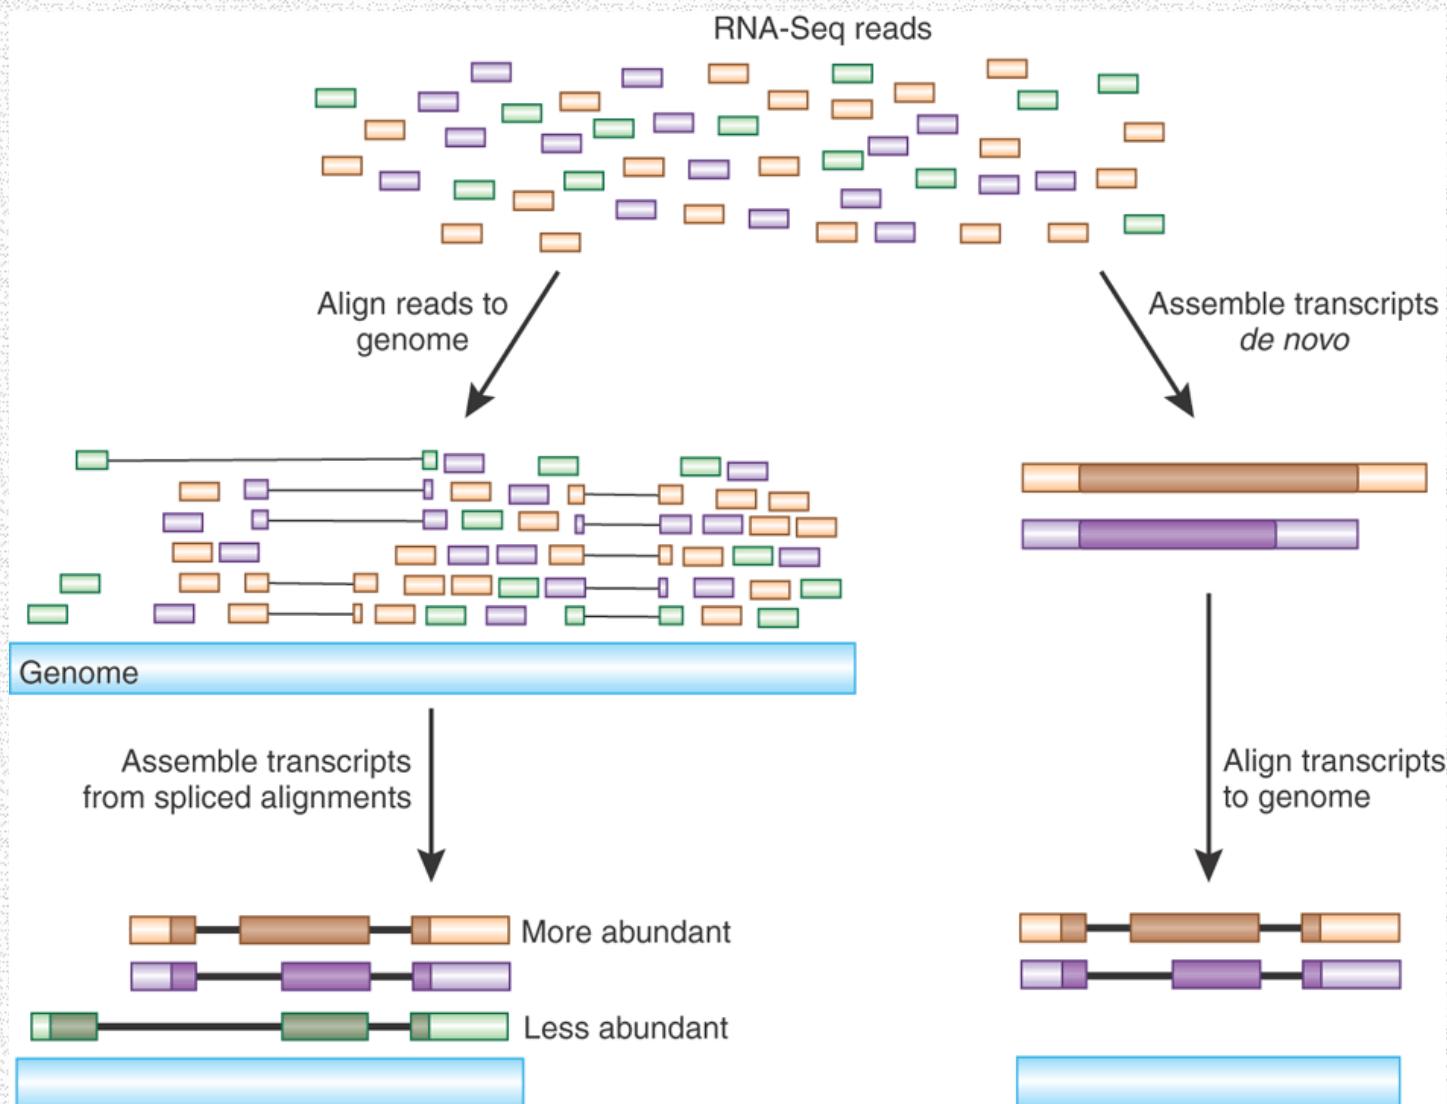
Sestava genoma de novo (velik ali mali genom, kratki ali dolgi fragmenti)

Velvet, EULER, ABySS, SOPAdenovo, MIRA3, CABOG,...

(reads – contigs - scaffolds)

Anotacija genov

# Analiza pri sekvenciranju RNA



# GS Junior

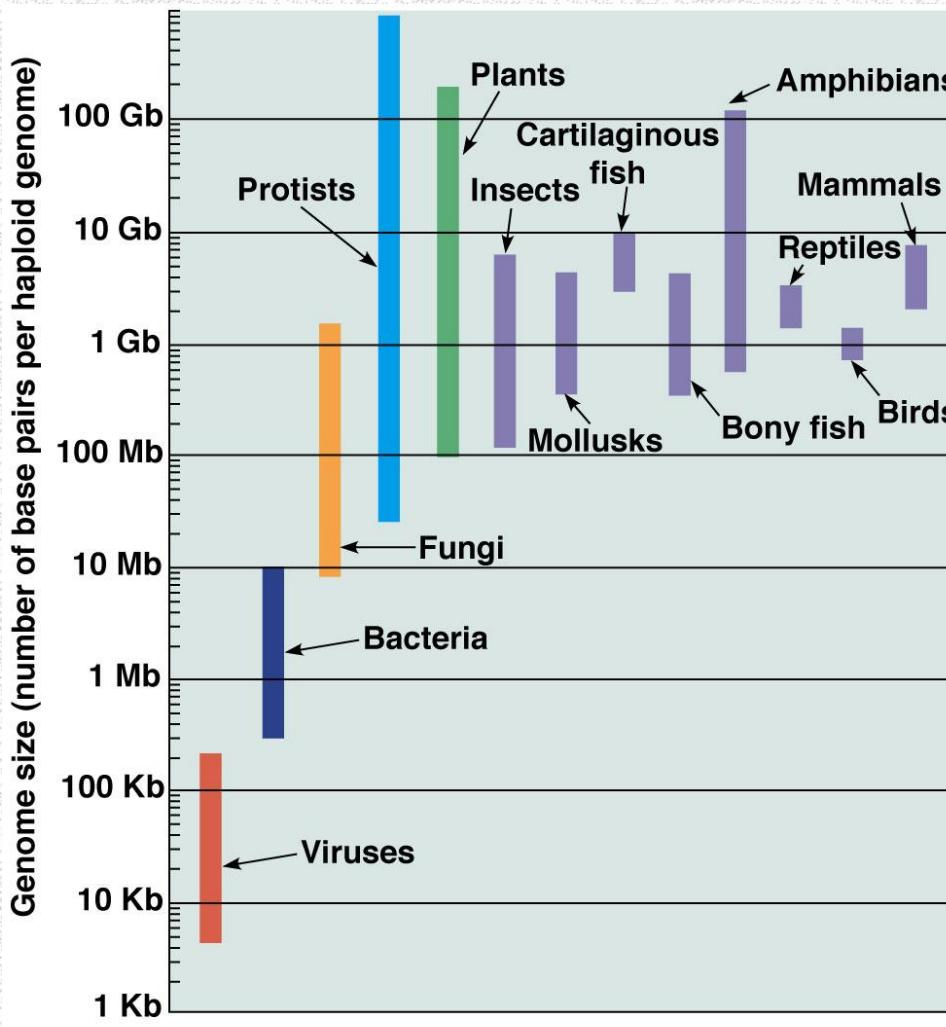


<http://vimeo.com/24229714>

# GS Junior

Pikotitrsko plošča	1
Dolžina branja	~400 bp
Učinkovitost	- 85% vseh prebranih baz je iz produktov dolgih >400 bp - 45% vsej prebranih baz je iz produktov dolgih >500 bp
Vseh prebranih baz	~35 Mb
Fragmentov na analizo	~100,000 „shot gun“, 70,000 amplikon
Natančnost	Q20 dolžine produktov je 400 baz (99% natančnost pri 400. bazi in višja za baze pred njo)
Čas analize	10 ur
Vzorci	genomska DNA, PCR produkti (amplikoni) ali cDNA,...
Hkratno sekvenciranje	do 153 vzorcev

# Velikost genomov



# GS Junior

Lahko sekvenciramo:

- celotno genomsko DNA (virusi, bakterije, glive),
- dele daljših genomskih DNA (živali, rastline) z namenom resekvenciranja,
- PCR produkte (amplikone), BAC in cDNA oziroma transkriptom.

Aplikacije so:

- Tarčno resekvenciranje: genotipizacija, detekcija redkih različic, sekvenciranje posameznih genov ali področij genoma.
- Sekvenciranje genoma: sekvenciramo SNPs, insercije, delecije, genomske regije, čista genomska DNA bakterij, rastlin, živali, gliv, virusov, BAC ali katerekoli drugega vira DNA.
- Metagenomika: diverziteta mikrobnih združb.
- Sekvenciranje transkriptoma: novi transkripti in isoforme.

# Metode priprave DNA knjižnice

Pristopi k pripravi knjižnice za sekvenciranje so:

- »Shot gun«:** dolge odseke DNA fragmentiramo v naključno dolge fragmente, jim nalepimo posebne adapterje in jim preberemo zaporedje; poseben program jih sestavi v pravo zaporedje.
- Amplikoni:** na PCR produkt ligiramo adapterje ali pa uporabimo dolge oligonukleotide, ki imajo poleg specifičnega zaporedja tudi adapter.
- »Paired end«:** genomsko DNA fragmentiramo v 20, 8 ali 3 kb dolge fragmente, na konce nalepimo adapterje in jih zlepimo v krog. Krožna DNA je fragmentirana in fragmenti z adapterji so izolirani in sekvencirani.
- cDNA knjižnica:** RNA se fragmentira in nato prepisuje v cDNA s pomočjo naključnih začetnih oligonukleotidov, doda se druga veriga, adapterji in sledi sekvenciranje.

# Izbira metode - pokritost

S katero metodo bomo sekvencirali je odvisno od tega kaj želimo detektirati. Primer je resekvenciranje določenega gena in iskanje SNP.

- Poznati moramo ali je sprememba zaporedja redka ali pogosta oziroma ali je somatskega izvora ali podedovana kajti to vpliva na pokritje/globino sekvenciranje, ki jo moramo imeti v analizi, da jo bomo lahko identificirali.
- Primer je sprememba zaporedja, ki je prisotna smo v 1% celic, kar pomeni, da jo bomo na 5000 odčitkov prebrali samo 50x. To pomeni, da lahko samo 14 vzorcev hkrati analiziramo.
- Naslednji primer je detekcija heterozigota, kjer potrebujemo 40x pokritje, da bomo imeli 99,9-odstotno verjetnost, da ga bomo detektirali.
- V eni analizi dobimo 70.000 odčitkov, kar pomeni, da z 40x pokritjem lahko preberemo 1750 amplikonov dolgih 400 bp hkrati.
- Spoznali se bomo s tarčnim resekvenciranjem gena z amplikoni.

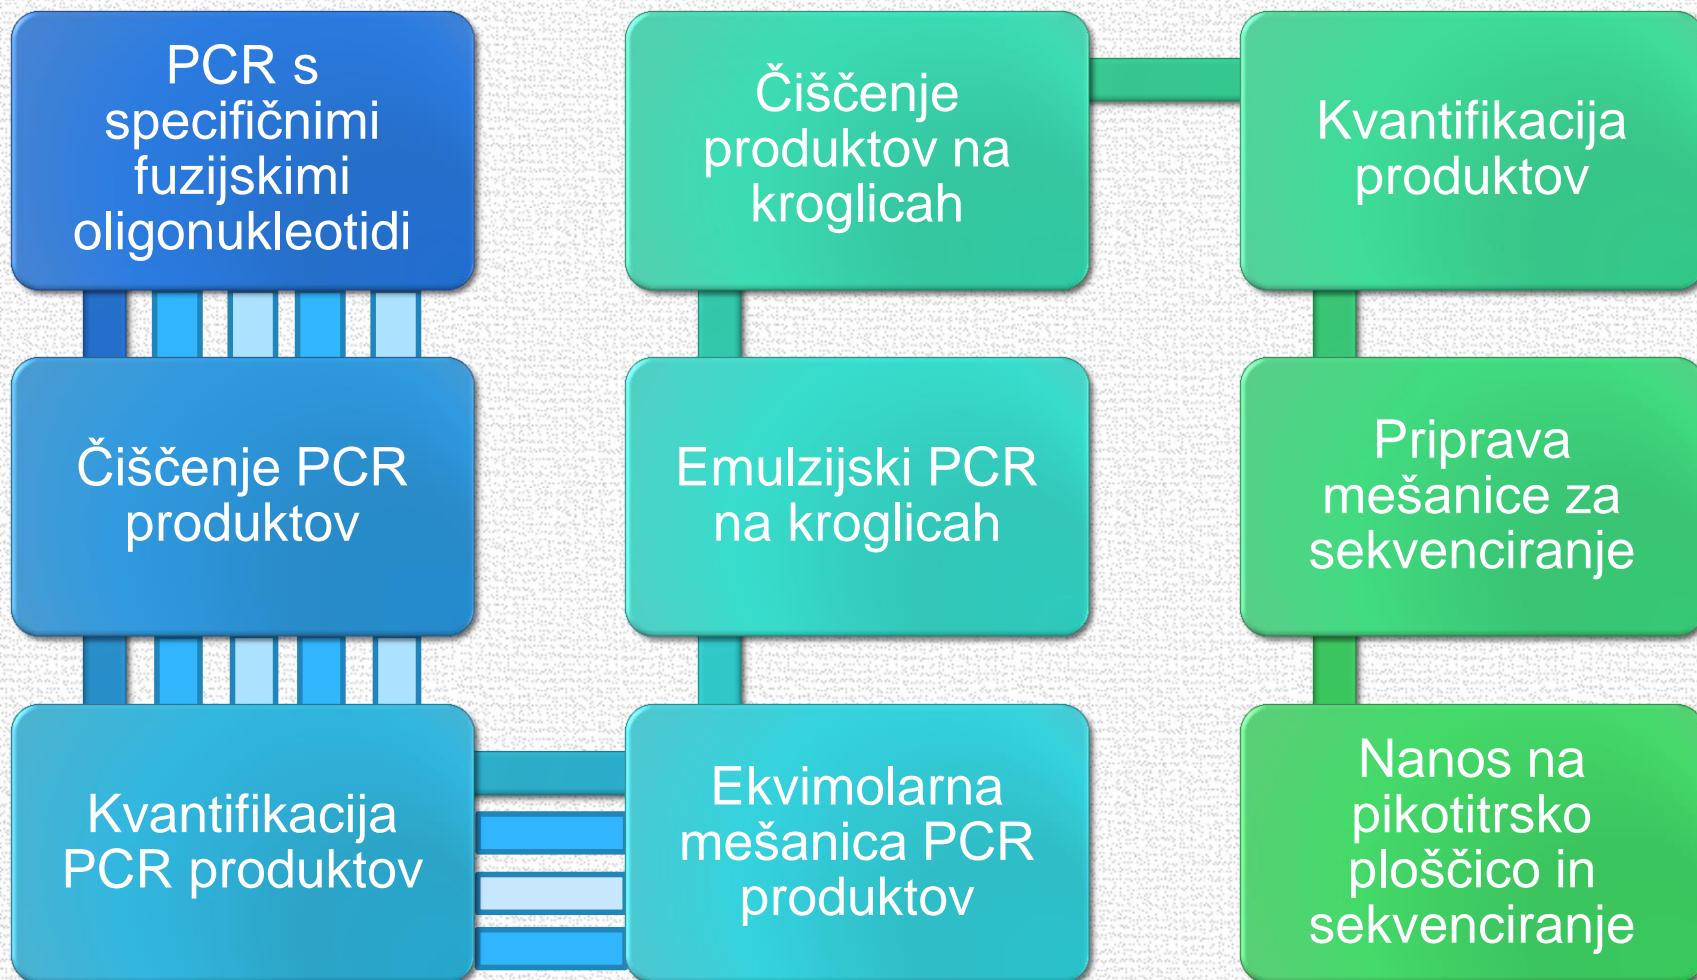
# Izbor metode

Prvi korak je izbor metode priprave PCR produktov in načina sekvenciranja.

- Odločiti se morate ali boste dodajali adapter in MID med pomnoževanjem produkta in sta ti zaporedji del začetnega oligonukleotida ali pa boste prilepili adapter, KEY in MID na PCR produkte po pomnoževanju.
- Pomembno je tudi vedeti ali želite sekvencirati kratke (pod 800 bp) ali dolge PCR produkte (nad 1500 bp) ali želite sekvenco prebrati z obeh verig ali samo z ene.

Primer: kratki PCR produkti (od 400 do 500 bp), kjer želimo prebrati DNA z obeh strani in kjer boste dodali adapter in MID med pomnoževanjem z vgnezdenim PCR.

# Priprava vzorcev (2-3 dni)



# Priprava PCR produktov s specifičnimi fuzijskimi začetnimi oligonukleotidi

PCR reakcija s „FastStart High Fidelity“ PCR sistemom:

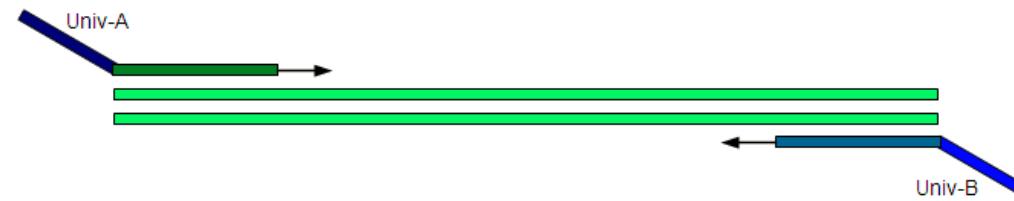
- Vsebuje „FastStart“ DNA polimerazo in termostabilen protein za kontrolno branje.

Velikost PCR produktov mora biti med 200 in 600 bp oziroma morajo biti do 150 bp različno dolgi.

5 ng genomske DNA



1. PCR



100-1000x



2. Vgnezdeni PCR

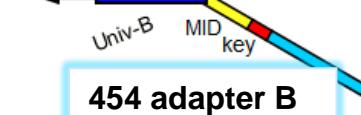
454 adapter A



key  
MID  
Univ-A



454 adapter B



# Fuzijski začetni oligonukleotidi

**454 ADAPTER – KEY – MID(multiplex identifier) – specifično zaporedje**

Smerni začetni oligonukleotid (Primer A-Key):

5'-**CGTATGCCCTCCCTCGGCCA**-TCAG-**MID**-{specifično zaporedje}-3'

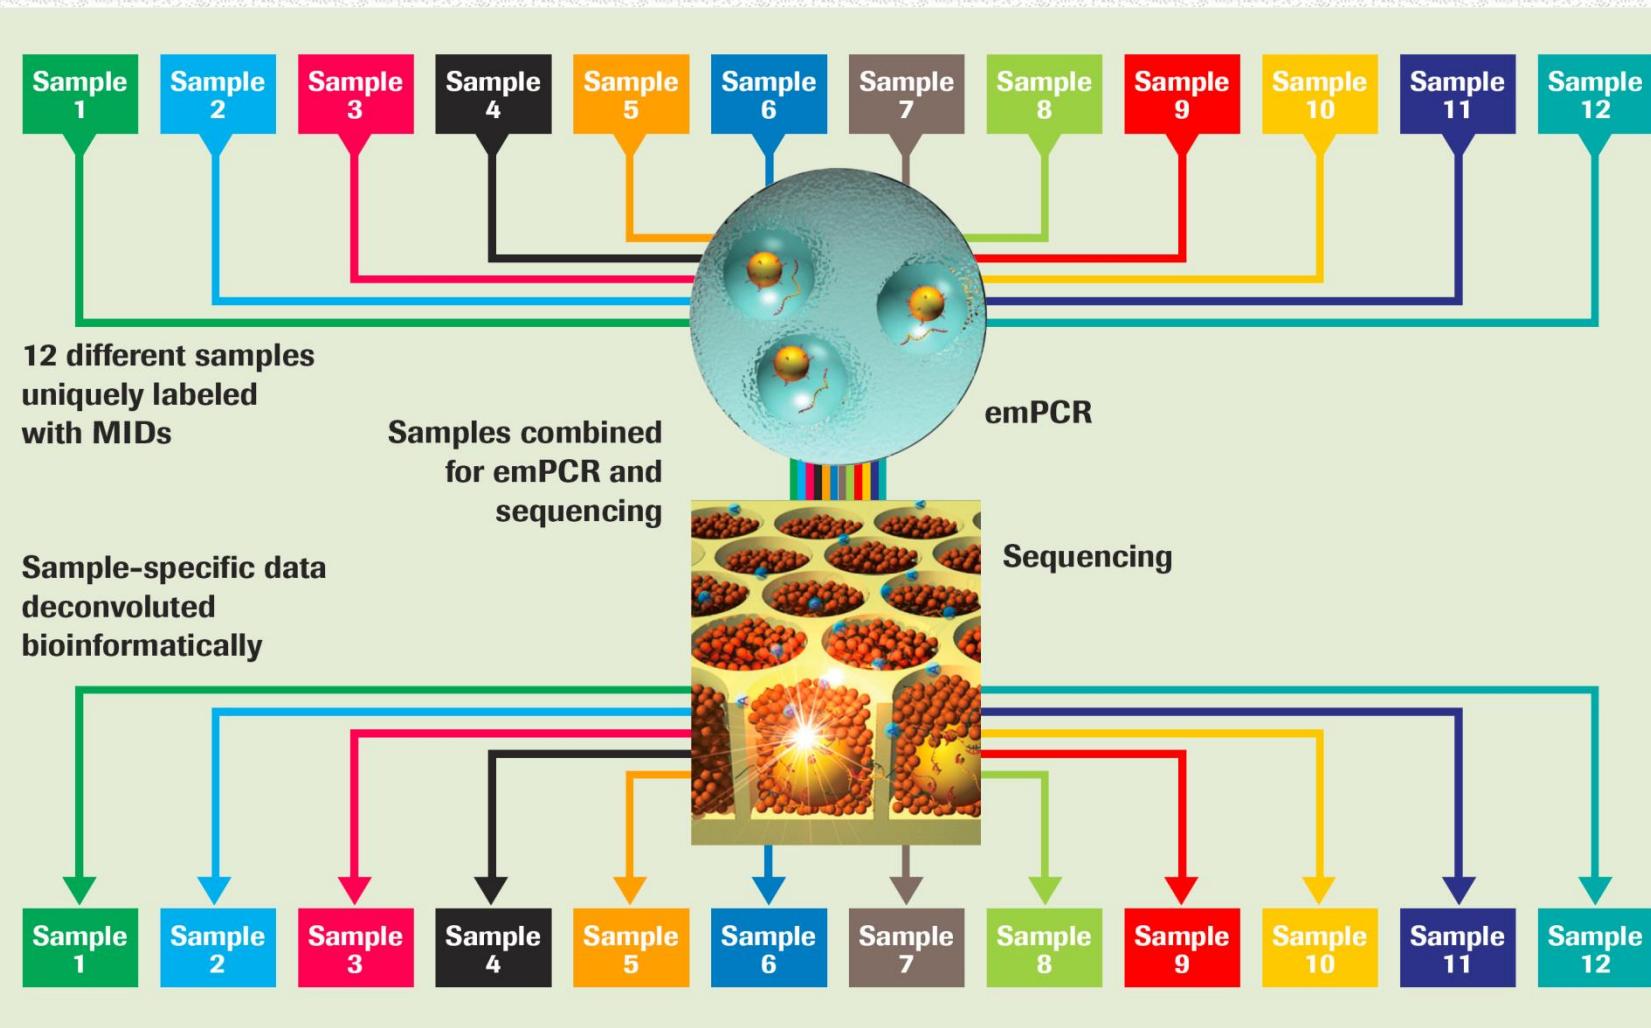
Protismerni začetni oligonukleoid (Primer B-Key):

5'-**CTATGCGCCTTGCCAGCCCCGC**-TCAG-**MID**-{specifično zaporedje}-3'

ID	MID Sequence
MID1	ACGAGTGC GT
MID2	ACGCTCGACA
MID3	AGACGCACTC
MID4	AGCACTGTAG
MID5	ATCAGACACG
MID6	ATATCGCGAG
MID7	CGTGTCTCTA

ID	MID Sequence
MID8	CTCGCGTGTC
MID9	TAGTATCAGC
MID10	TCTCTATGCG
MID11	TGATAACGTCT
MID12	TACTGAGCTA
MID13	CATAGTAGTG
MID14	CGAGAGATAAC

# Hkratno sekvenciranje vzorcev



# Čiščenje PCR produktov

Agencourt  
AMPure XP

Binding

Separation

Ethanol Wash

Elution Buffer

Transfer



1

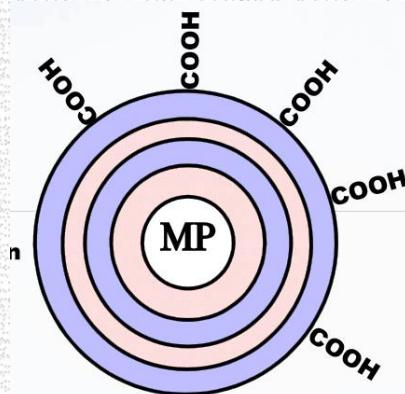
2

3

4

5

6



En PCR produkt = ena PCR  
reakcija = eno čiščenje

Čiščenje odstrani vse fragmente  
pod 200 bp.



# Kvantifikacija PCR produktov

- S PicoGreen reagentom na Nanodrop ND-3000

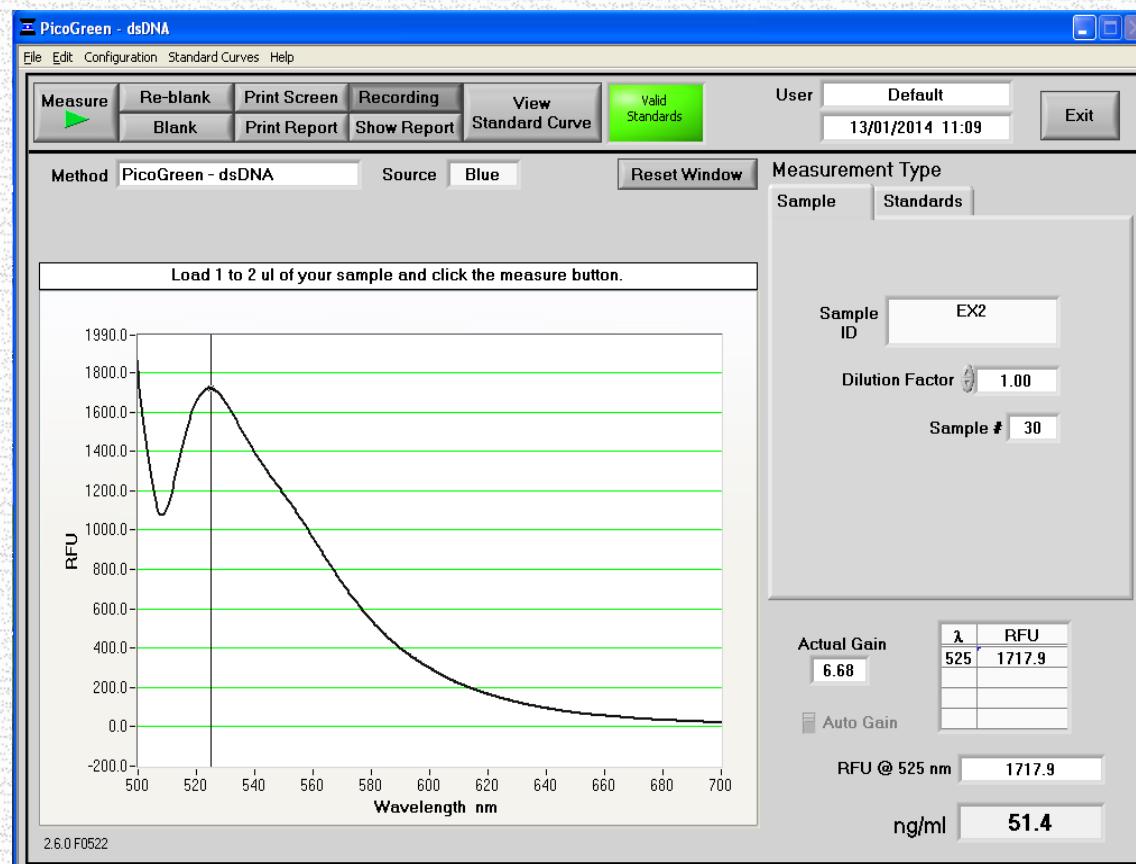
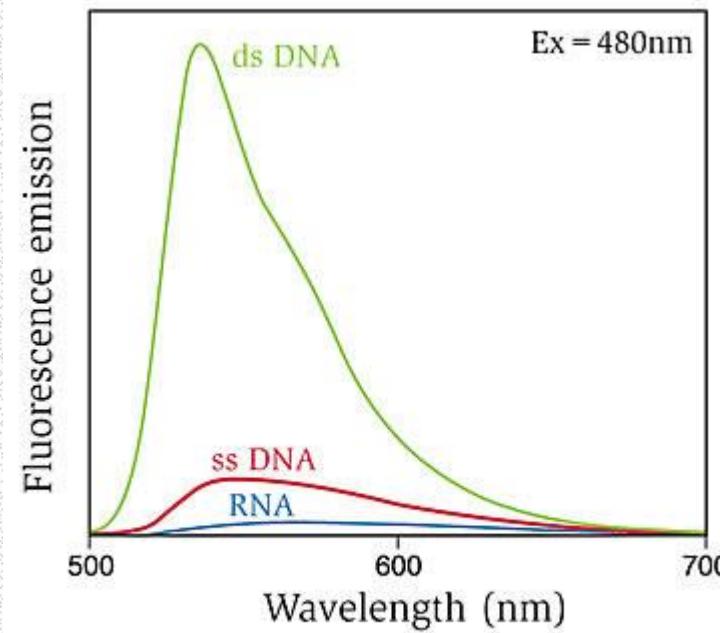


Figure 2 - dsDNA specificity



Fluorescence enhancement of the PicoGreen® Quantitation Reagent upon binding dsDNA, ssDNA and RNA.

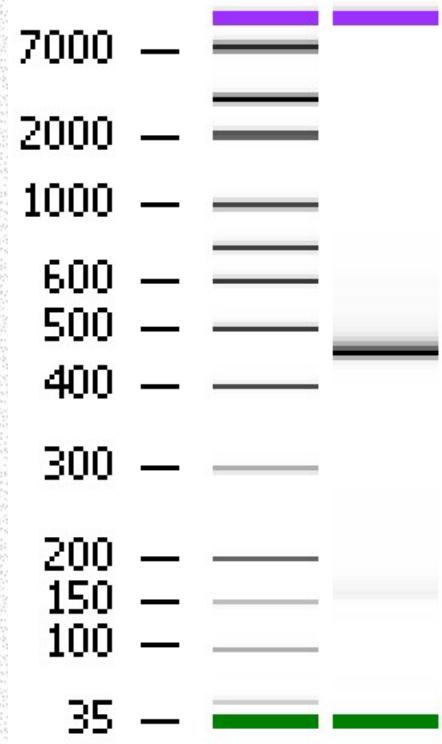
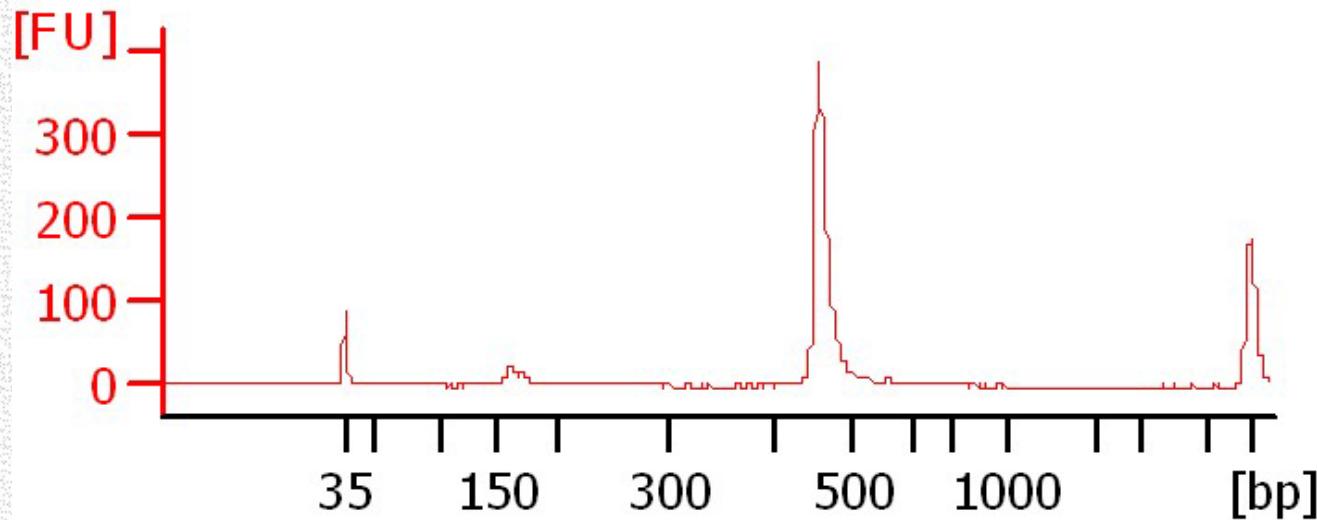
# Priprava mešanice PCR produktov

- Izračunate koncentracijo PCR produktov v molekul/ $\mu$ l.

$$\frac{\text{Molekul}}{\mu\text{l}} = \frac{(\text{koncentracija vzorca} \left[ \frac{\text{ng}}{\mu\text{l}} \right] * 6,022 * 10^{23})}{(656,6 * 10^9 * \text{dolžina amplikona [bp]})}$$

- Pripravite mešanico vseh PCR produktov, ki jih boste hkrati sekvencirali :  $1 \times 10^9$  molekul/ $\mu$ l v TE pufru.
- Preverite čistost/dolžino produktov na s High Sensitivity DNA chip na Agilent Bioanalizator 2001.

# Kvaliteta PCR produktov



Region table for sample 1 : sample 1

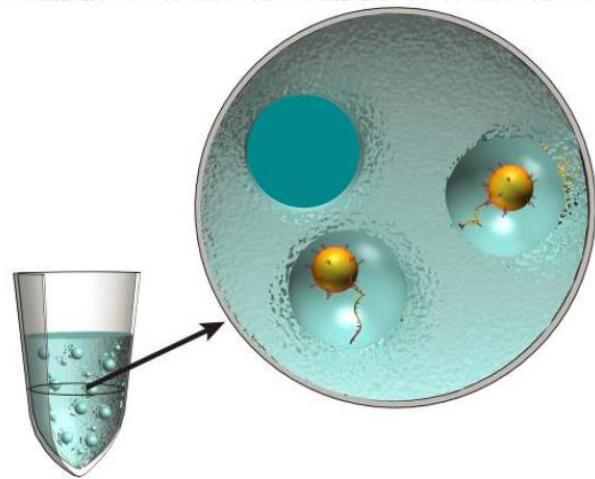
From [bp]	To [bp]	Corr. Area	% of Total	Average Size [bp]	Size distribution in CV [%]	Conc. [pg/ $\mu$ l]	Molarity [pmol/l]
200	1,000	557.9	93	464	2.4	414.74	1,354.4

# PCR na kroglicah v emulziji voda-olje

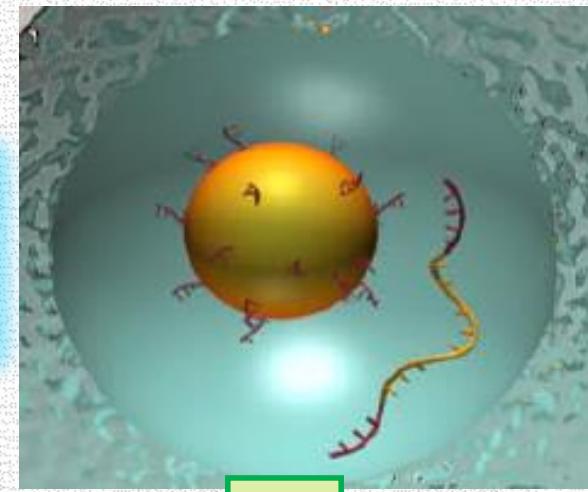
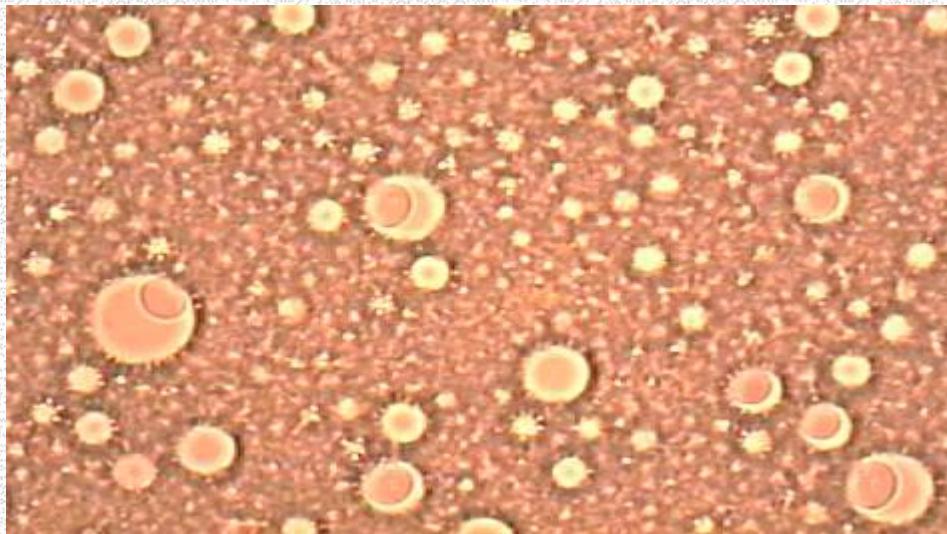
- 1) Pripravimo dve encimski mešanici (A in B), dve mešanici kroglic (A in B) in dve redčitvi knjižnice PCR produktov.
- 2) PCR produkte redčite in dodajte toliko v mešanico, da boste dobili razmerje dve molekuli na kroglico.
- 3) Vse skupaj zmešate in napravite emulzijo s posebno napravo.



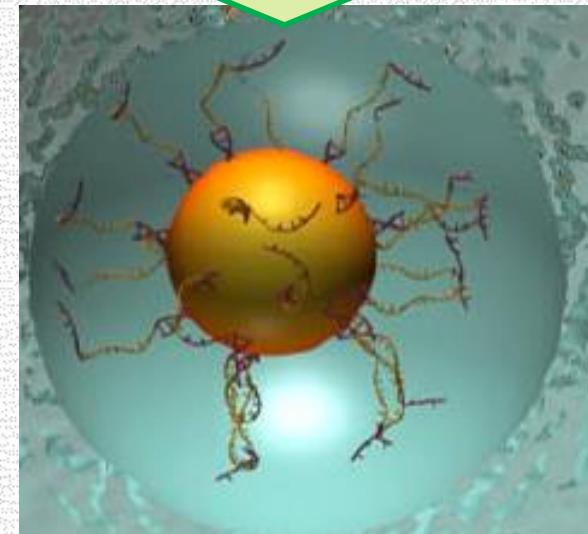
# Mikroreaktorji v emulziji ( $10^6/\text{ml}$ )



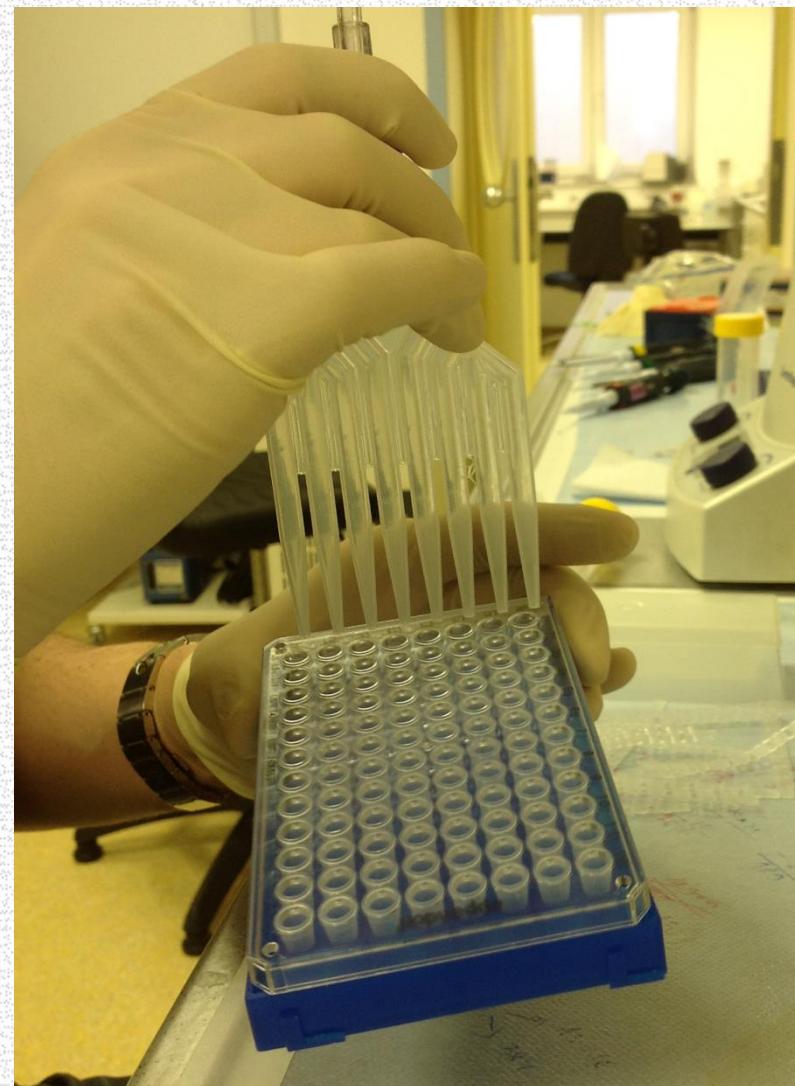
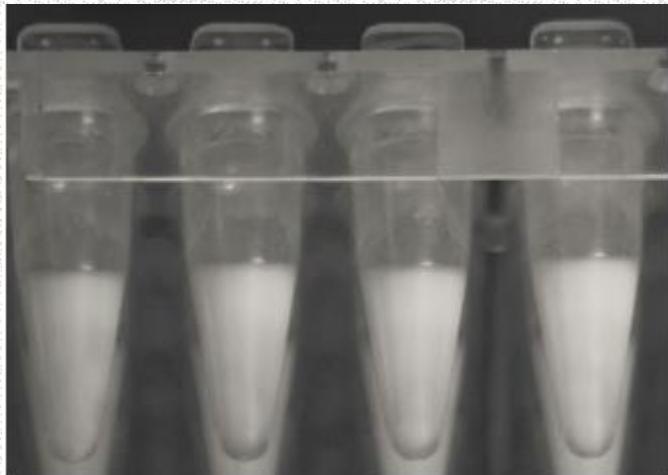
ena kroglica  
=  
en DNA fragment



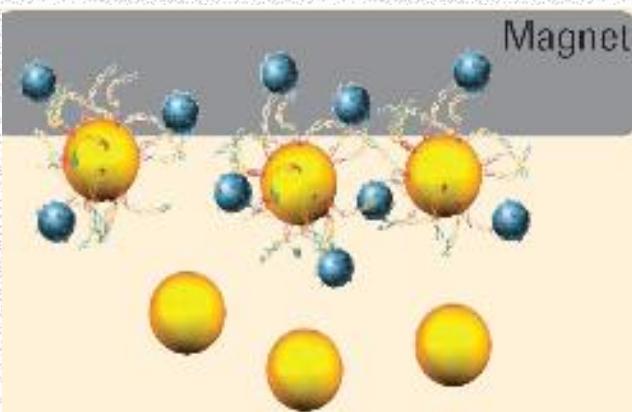
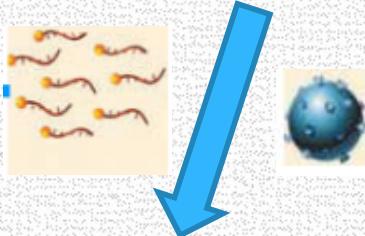
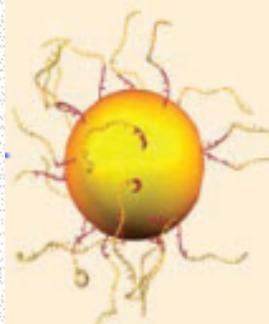
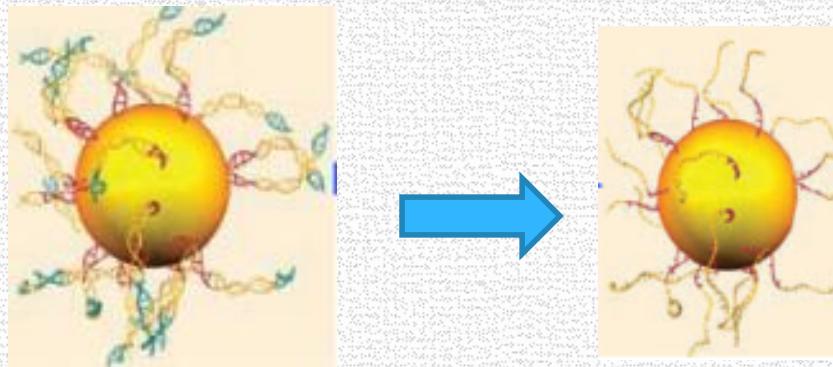
6 ur



# Izolacija kroglic s pomnoženimi fragmenti



# Izolacija kroglic s pomnoženimi fragmenti



Odstranitev ostankov PCR  
reagentov



Obogatitev kroglic z DNA  
fragmenti

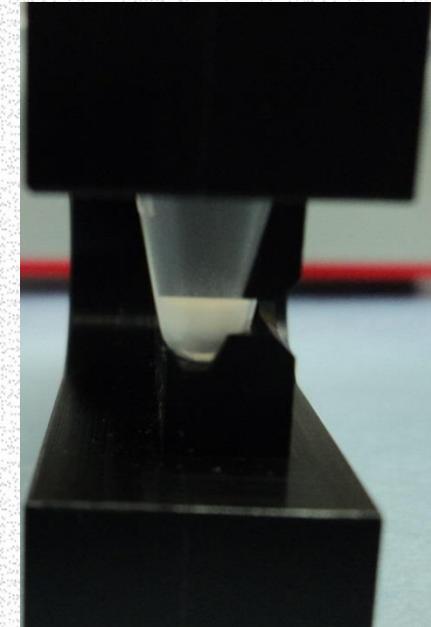
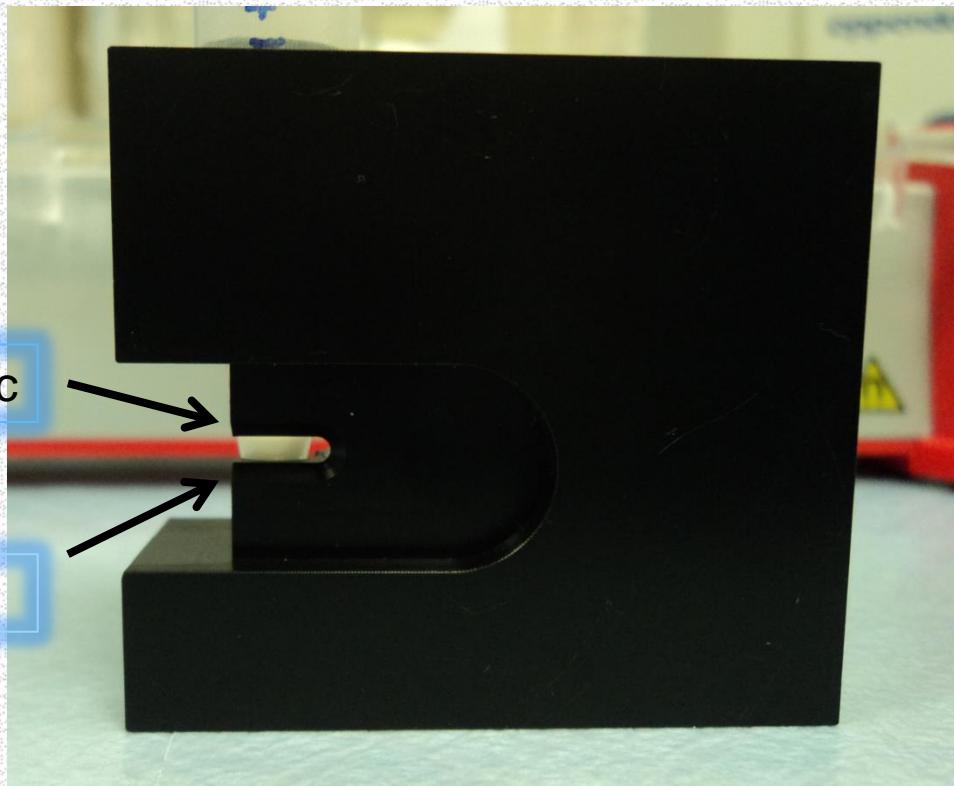


Prileganje oligonukleotidov  
za sekvenciranje



Kvantifikacija kroglic

# Kvantifikacija kroglic



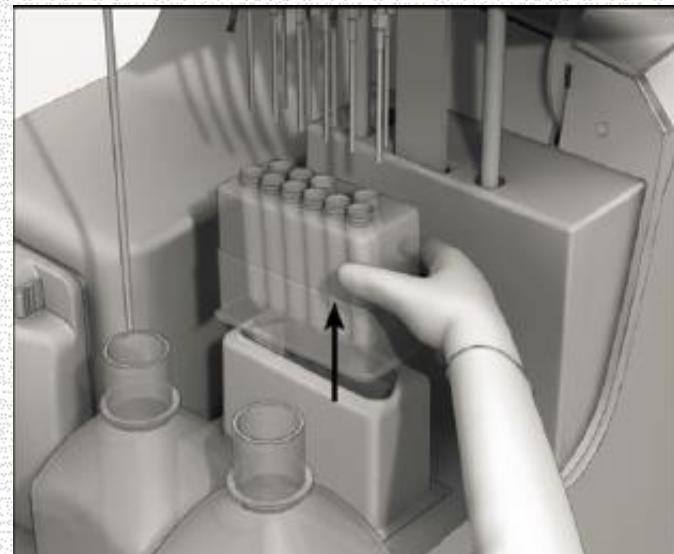
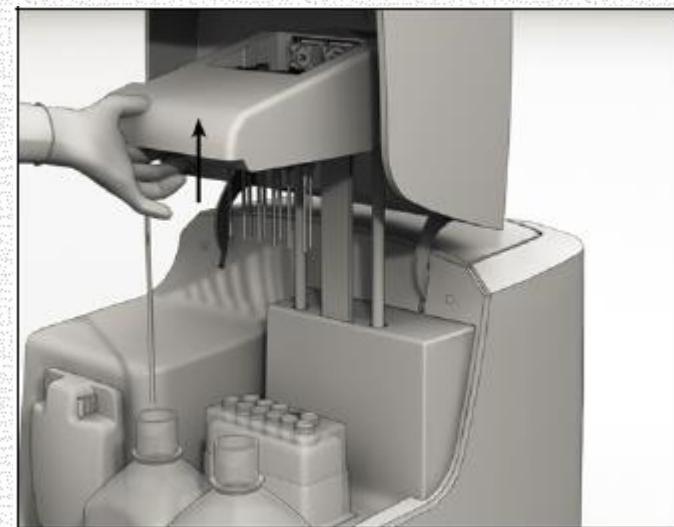
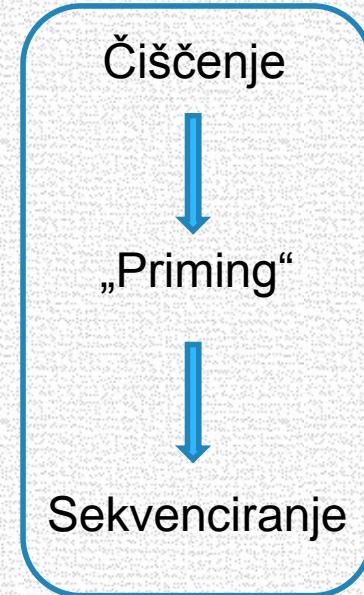
2 milijona kroglic

500,000 kroglic

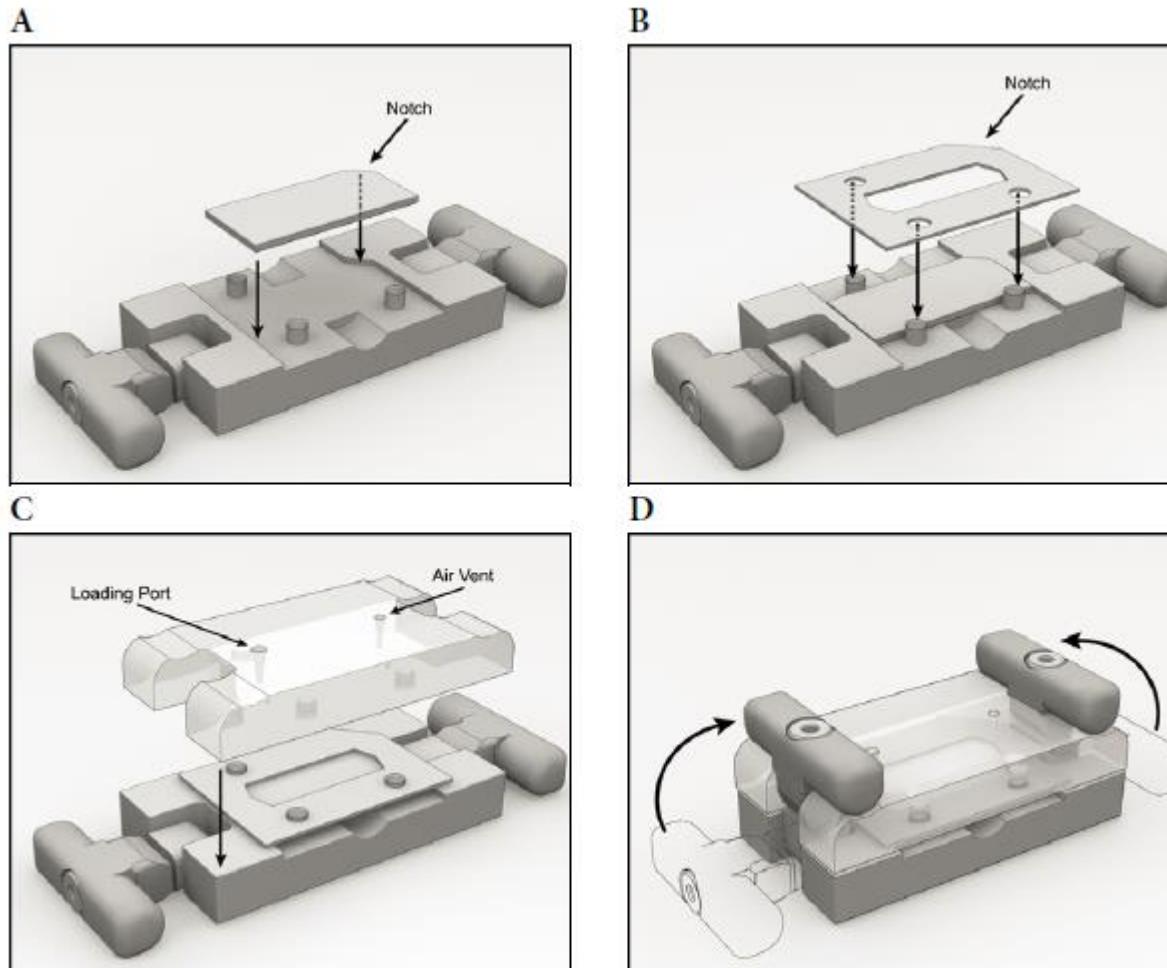
Za sekvenciranje potrebujete 500.000 kroglic.

- ✓ Če jih je več (do 2 milijona oziroma do zgornje meje), se preostanek kroglic spravi.
- ✓ Če je manj kot 500.000, jih lahko spravite.
- ✓ Če jih je več kot 2 milijona, zavrzite!

# Priprava GS Junior naprave



# Sestava naprave za nanos kroglic



# Priprava pikotitrsko ploščice

## Plast kroglic Vrsta kroglic

Plast 1 kroglice z encimi (pre)

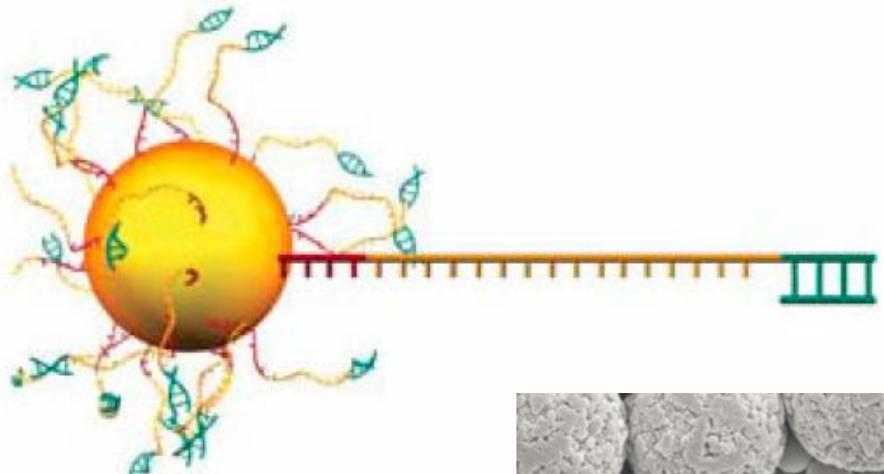
Plast 2 pakirne kroglice in kroglice z DNA

Plast 3 kroglice z encimi (post)

Plast 4 Kroglice z ppiazo

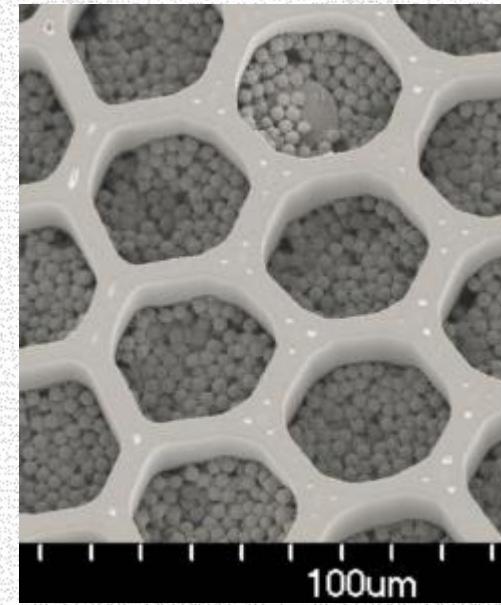
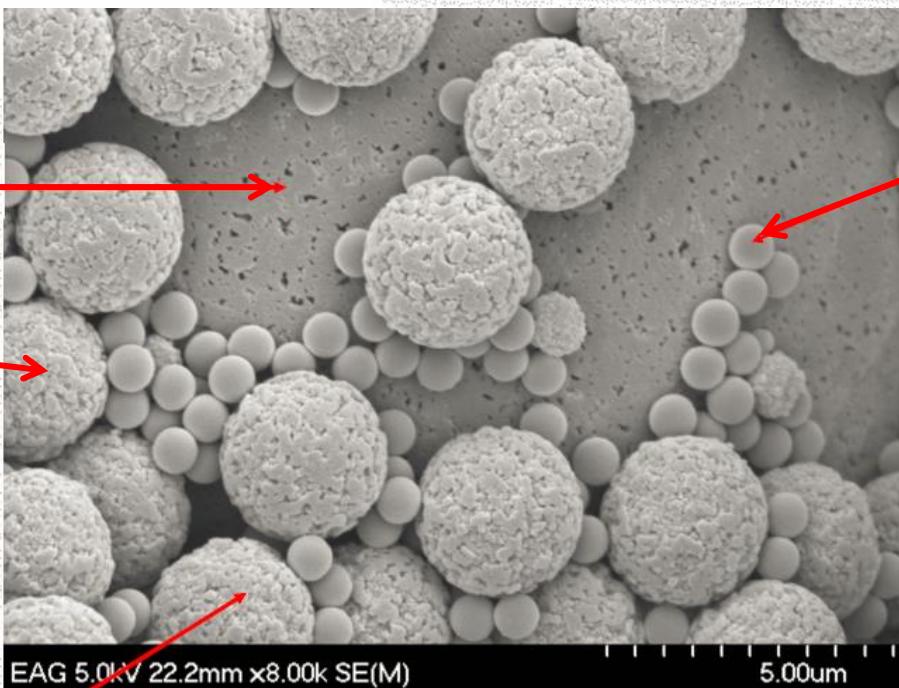


# Pikotitrská ploščica



Kroglica z DNA  
(20  $\mu\text{m}$ )

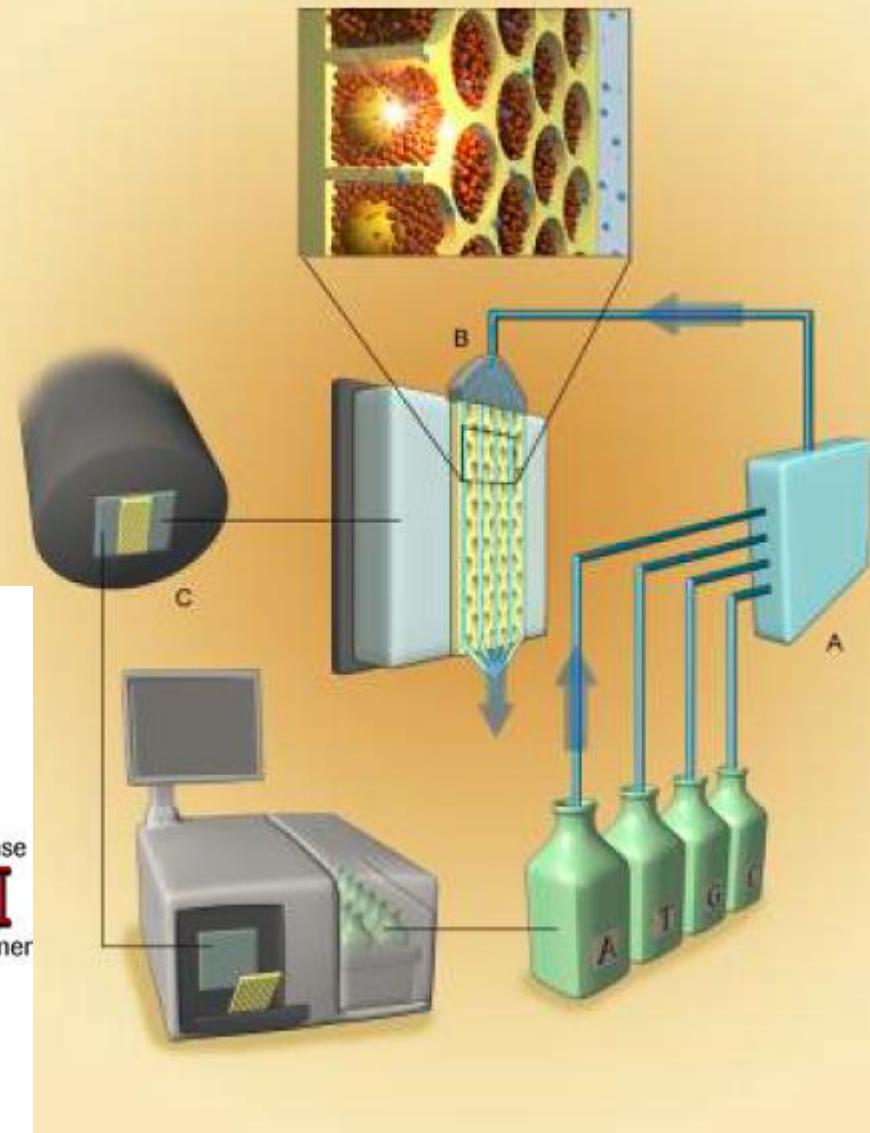
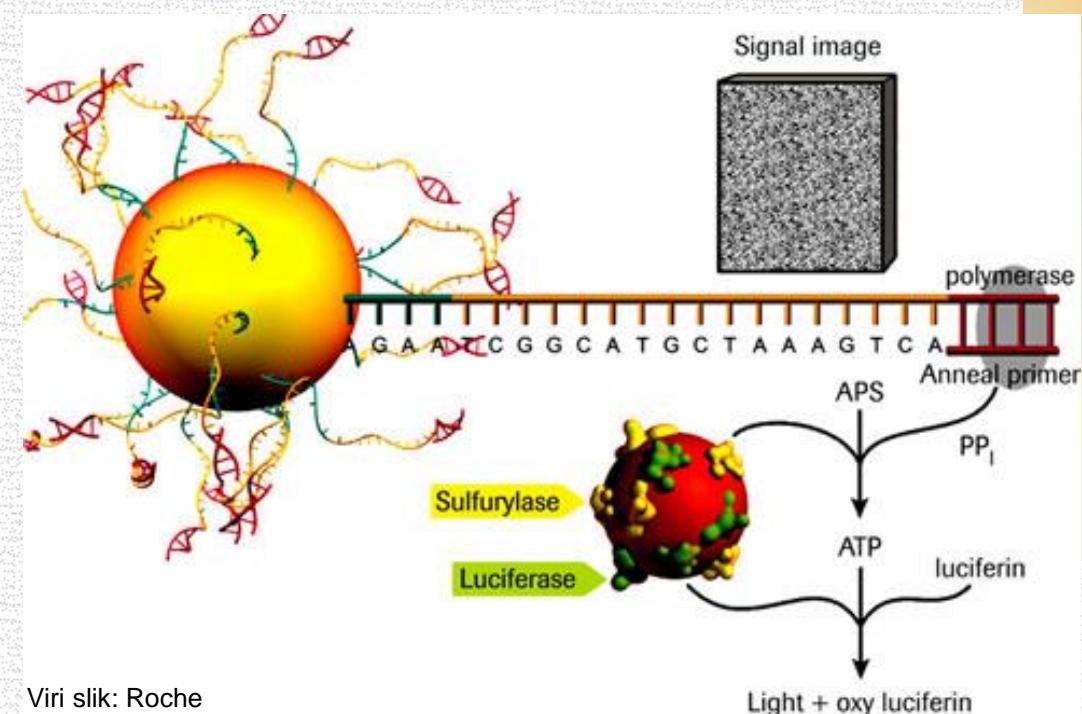
Kroglica z encimi  
(2,8  $\mu\text{m}$ )



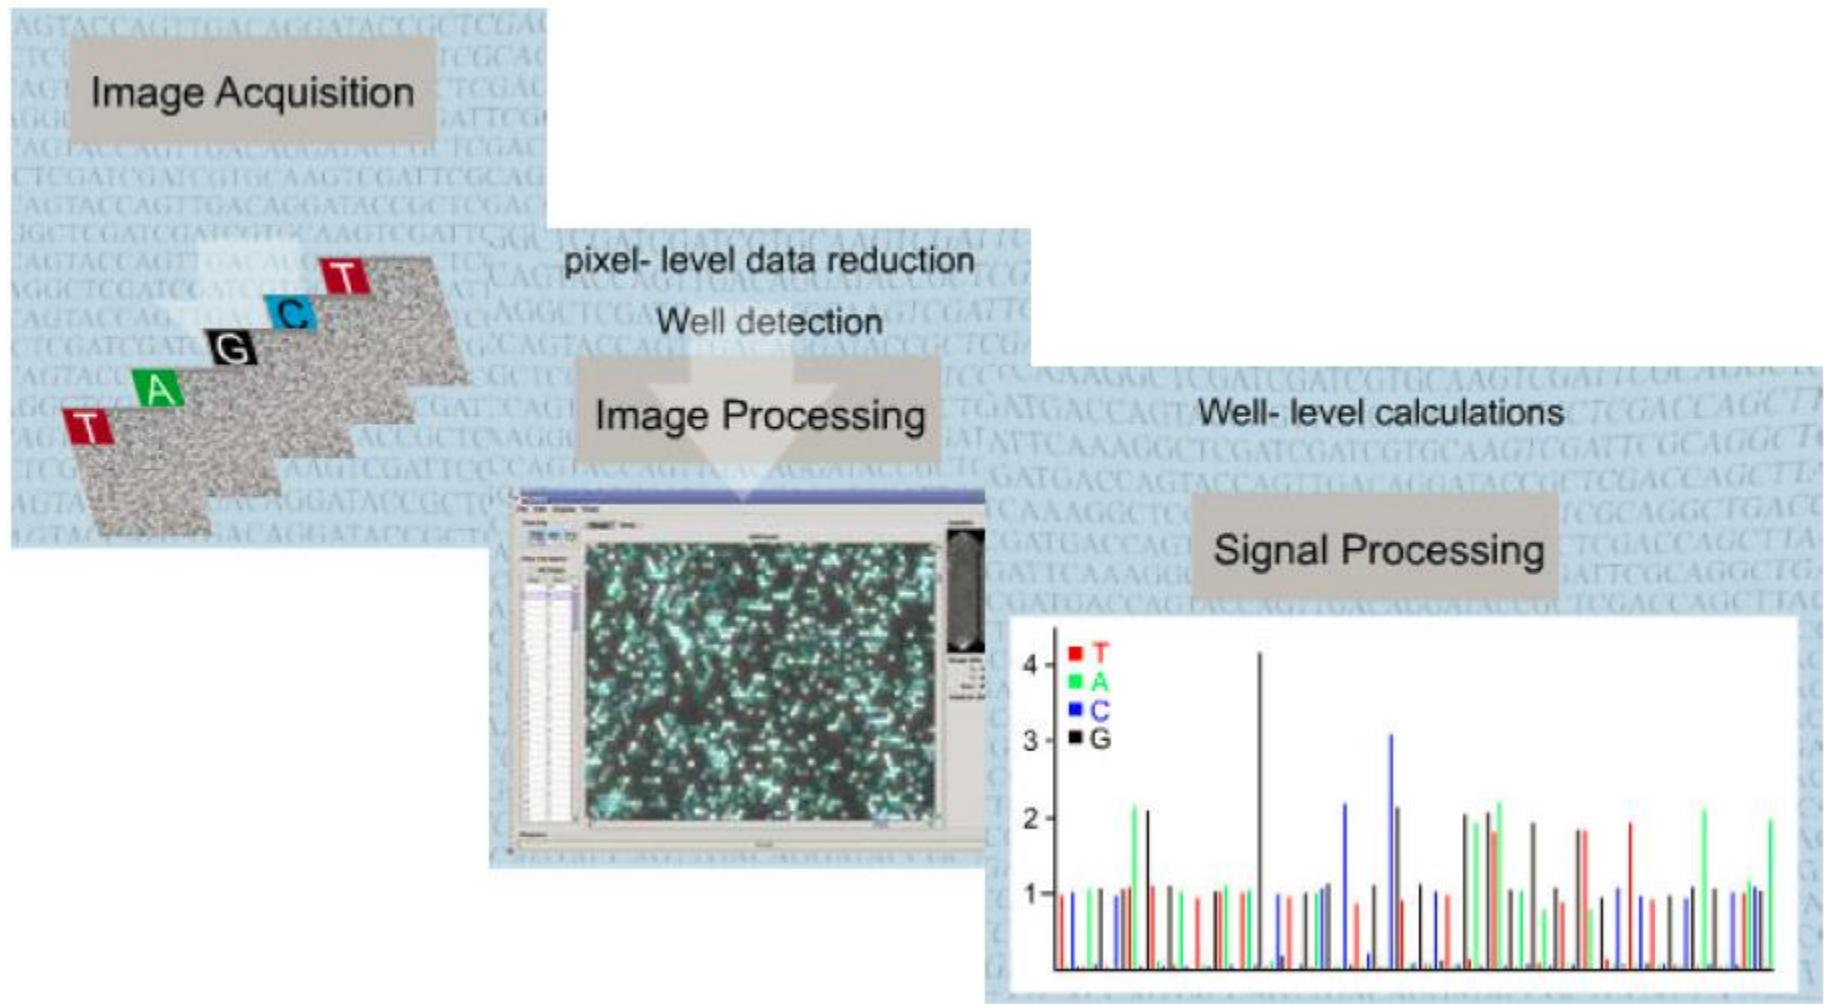
# Vrata kamere, kjer je pikotitrska ploščica



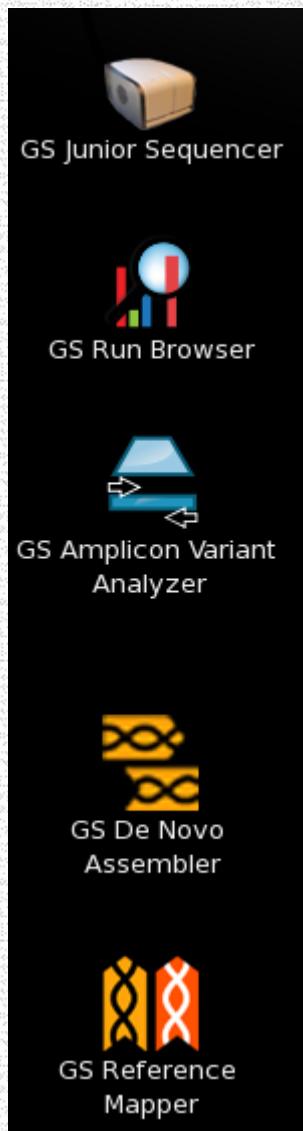
# Sekvenciranje s sintezo



# Analiza podatkov



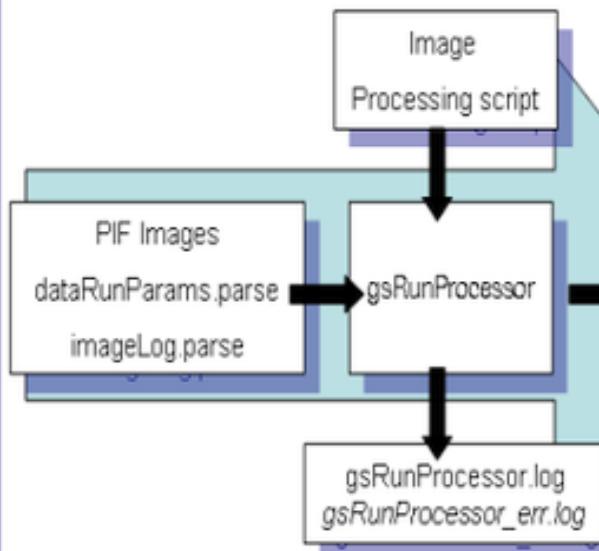
# Programi



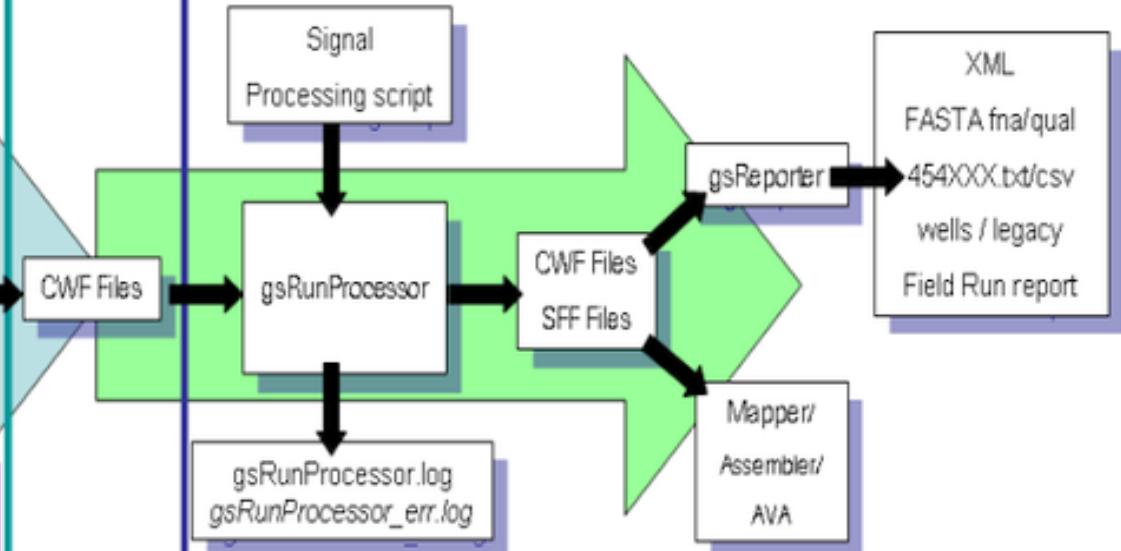
Program	Funkcija
<b>GS Junior Sequencer</b>	Upravljanje z napravo, pridobivanje slik
<b>GS Run Processor</b>	Procesiranje slik in procesiranje signala (.cwf in .sff)
<b>GS Run Browser</b>	Vizualizacija rezultatov, upravljanje programov
GS Reporter	Izvoz rezultatov v drugih formatih
GS De Novo Assembler	Sestavi nove genome.
GS Reference Mapper	Vzporedi zaporedja z referenčnim genomom in poišče SNP, insercije, delekcije in strukturne spremembe
<b>GS Amplicon Variant Analyzer (AVA)</b>	Vzporedi PCR produkte na izbrano referenčno zaporedje, detektira in kvantificira znane in nove različice

# Analiza podatkov

## Data Flow For Image Processing



## Data Flow For Signal Processing



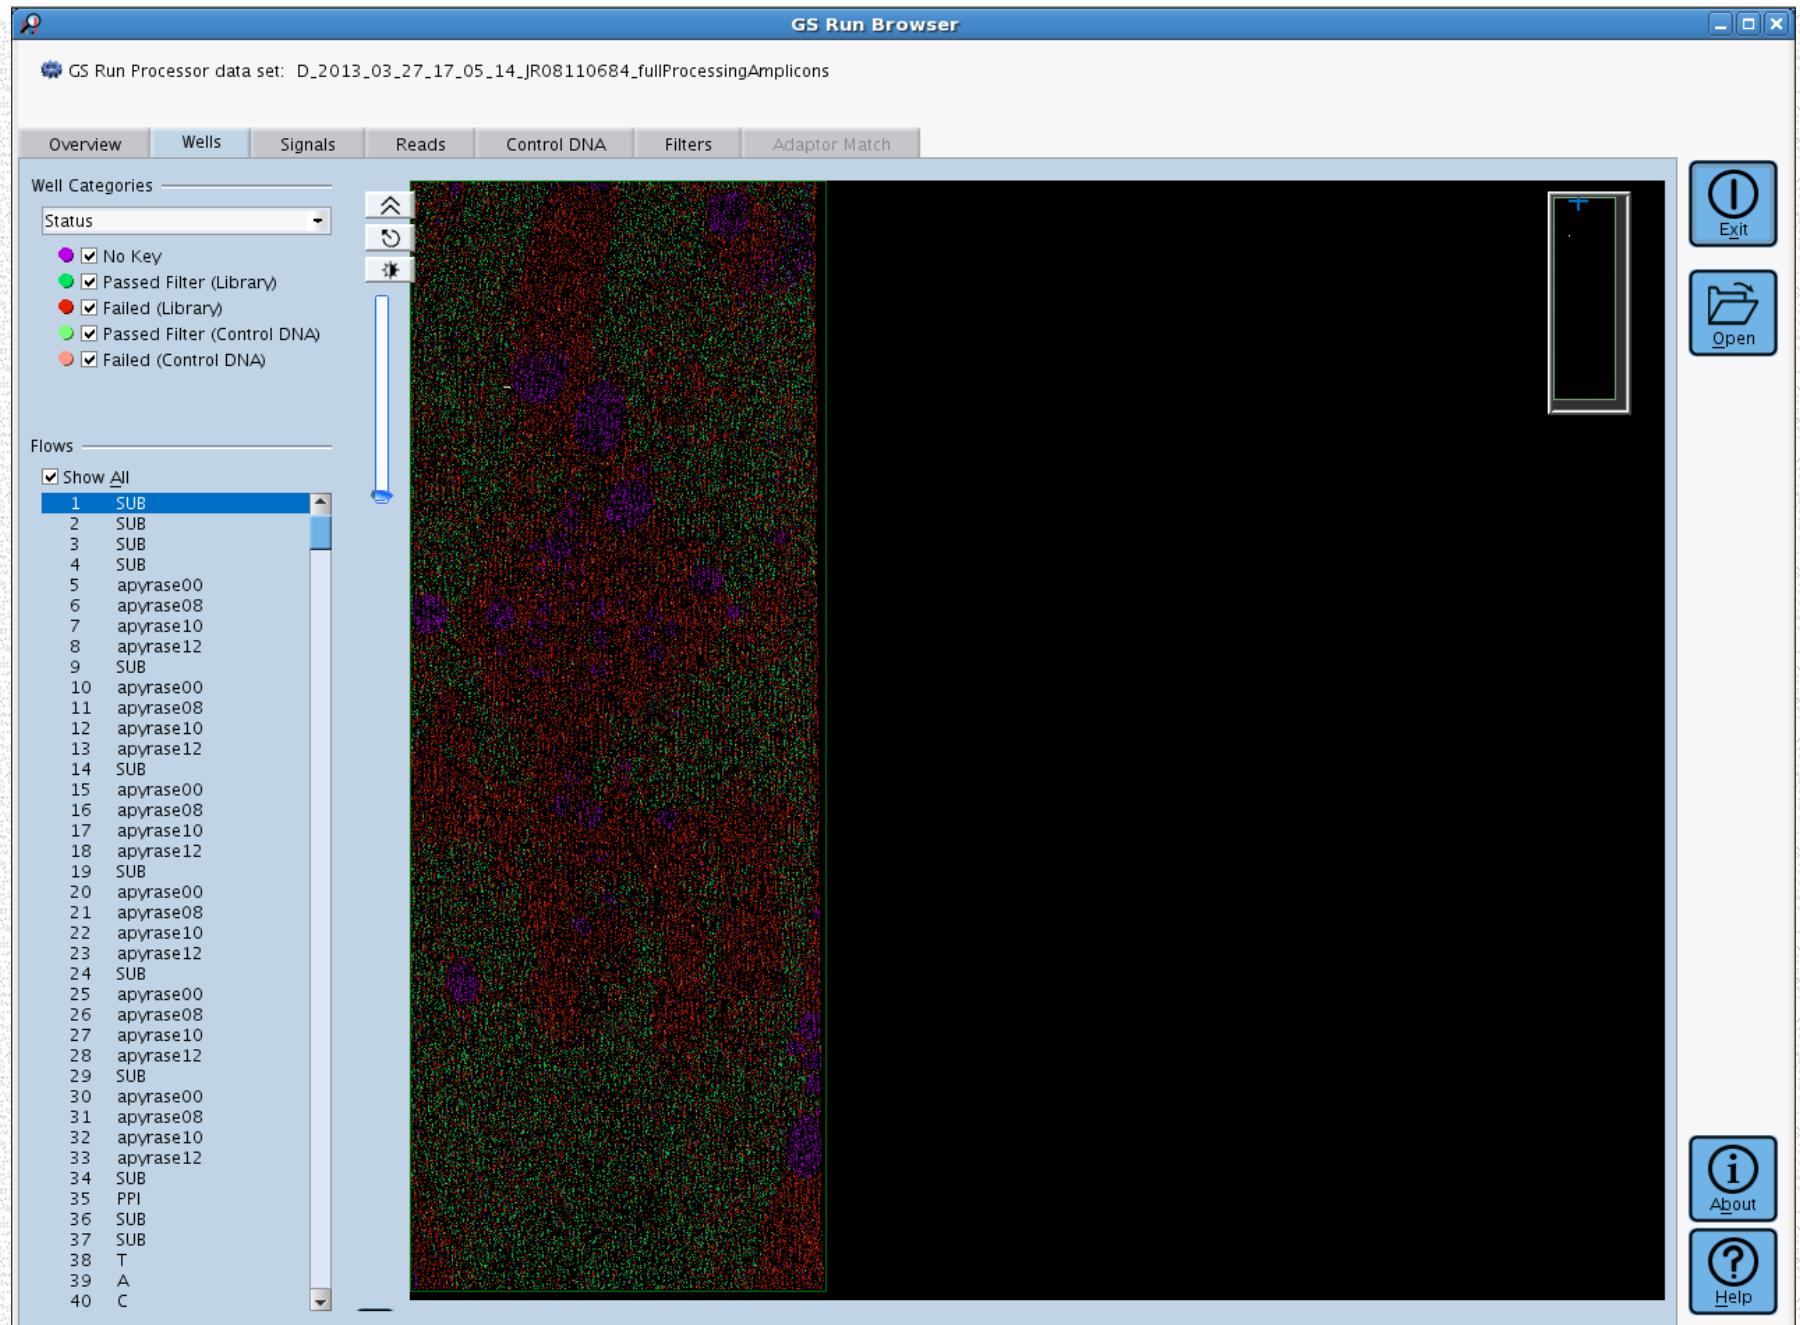
# Procesiranje signala

## GS Run Processor

- Procesira slike: normalizacija in subtrakcija ozadja, detekcija aktivnih jamic in ustvari .cwf datoteke (composite wells format).
- Procesira signal in naredi .sff (standard flowgram format).
- SFF datoteke potrebujejo nadaljnji programi.
- CWF spremeni GS Reporter v druge formate (FASTA,...).

## Procesiranje signala:

1. Ostrani se signal iz jamic, kjer je zaporedje prekratko (short), sta dva ali več fragmentov (mixed), ni signala (empty).
2. Odreže se dele zaporedja, kjer je kvaliteta preslabia in odreže se dodana zaporedja adapterjev, MID,...
3. Normalizira se za učinkovitost inkorporacije nukleotidov, motnje signala med jamicami, napake pri dovajanju reagentov za sintezo, popravek ozadja,...).
4. Prebere se zaporedje.



GS Run Processor data set: D\_2013\_03\_27\_17\_05\_14\_JR08110684\_fullProcessingAmplicons

Overview Wells Signals **Reads** Control DNA Filters Adaptor Match

Read Attributes

- Read Length
- Base Contribution
- Base Quality

Well Categories

- TCAG (Library)
- CATG (Control-Type I)
- ATGC (Control-Type II)

Number Of Library Reads

Read Length, Region Total

TCAG (Library) Region

	1	Total
Raw Wells	236,249	236,249
Key Pass Wells	212,598	212,598
Passed Filter Wells	72,895	72,895
Total Bases	29,921,526	29,921,526

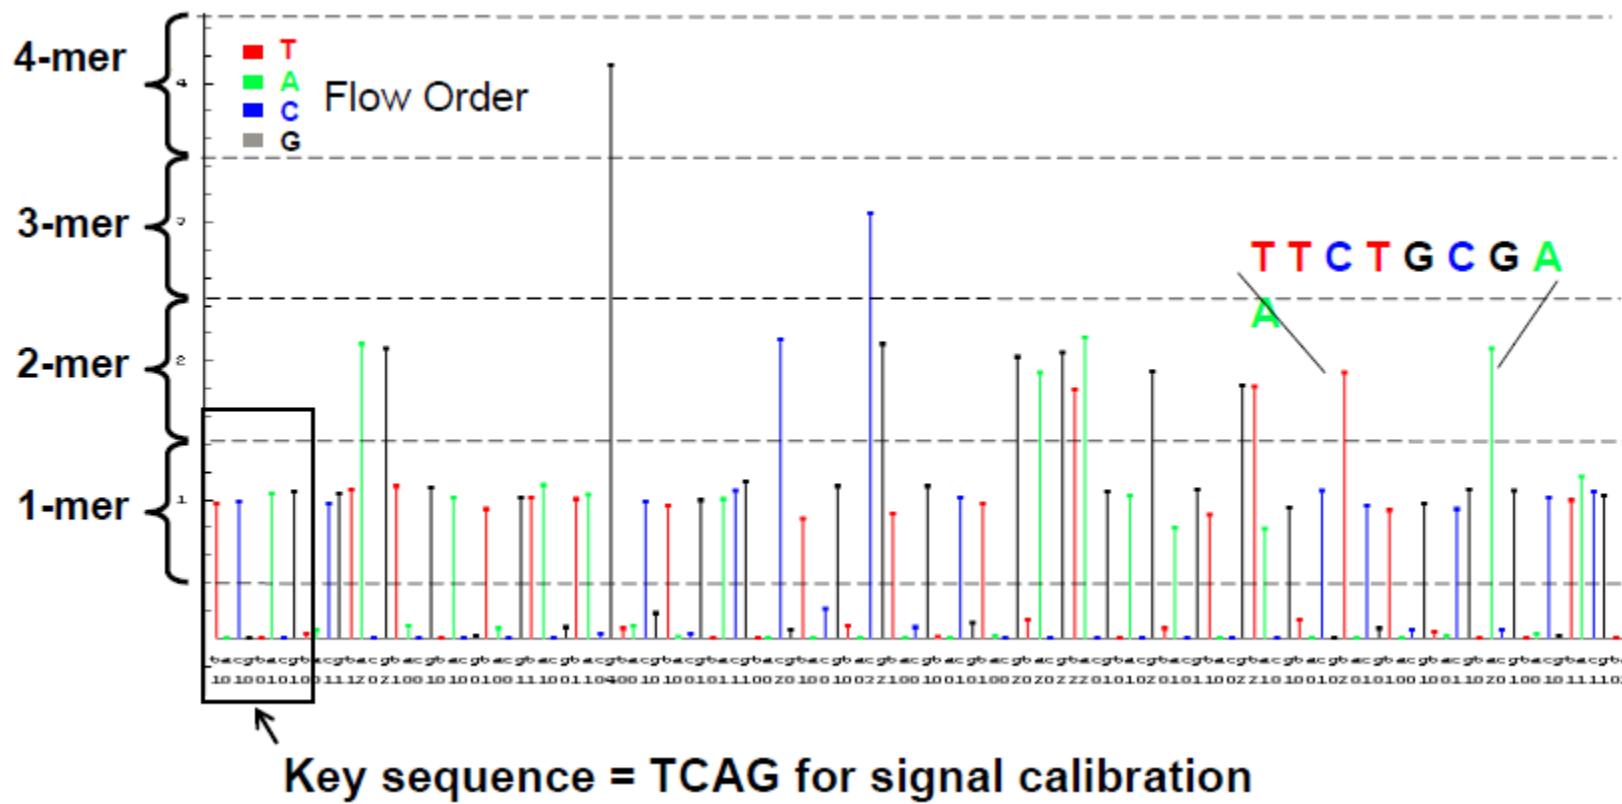
>30%  
>70.000

Average Read Length	410.47	410.47
Length Std Deviation	93.83	
Longest Read Length	1,195	1,195
Shortest Read Length	43	43
Median Read Length	437.0	437.0
Modal Read Length	411.0	411.0

Exit Open About Help

# Normaliziran „Flowgram“ signala

Inkorporacija nukleotidov je normalizirana tako, da signal 1,0 pomeni en nukleotid, 2,0 dva, itd.



Project Name: Training\_AVA\_project  
Location: /home/adminrig/Desktop/Training\_AVA\_project

Overview   Project   Computations   **Variants**   Global Align   Consensus Align   Flowgrams

**Variants**

Reference	Variant	Max	Anja	Ela	Emila	Gregor	Jaroslaw	Krystyna	Marjan	Monika	Rok	Tanja
CYP51	8903:T/-	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
CYP51	11787:G/T	100.00	100.00	0.00	0.00	0.00	-	0.00	0.00	0.00	61.11	0.00
CYP51	23809:C/T	75.51	0.00	0.00	0.00	0.00	0.00	75.51	0.00	0.00	0.00	0.00
CYP51	27481:G/C	100.00	100.00	0.00	35.96	0.00	56.18	41.56	0.00	28.24	0.00	0.00
CYP51	27607:T/C	100.00	100.00	0.00	35.96	0.00	56.18	41.56	0.00	41.18	0.00	0.00

Alignment Read Type  
 **Consensus**  
 Individual

Show values  
 Combined  
 Forward + reverse  
 All three  
 Show denominators

Filter values  
 Min = 0.00 %  
 Max = 100.00 %

Apply min/max % to  
 Forward or reverse  
 Forward and reverse  
 Available data  
 Combined also

Variant status

Compact table

No Variants To Load

Variants:  
Samples:  
Meet filter:

**GS Amplicon Variant Analyzer**

Exit   New   Open   Save   Back   About   Help

# GS Amplicon Variant Analyzer (AVA)

Reference	Variant	Max	Sample_1	Sample_2	Sample_3	Sample_4	
Exon-3	229:T/G	46.38	46.38	0.00	0.00	-	
Exon-4	98:A/C	0.59	0.14	0.59	-	0.35	
Exon-8	91:C/A	49.53	0.00	49.53	0.00	0.00	

Analiza najdenih različic:

1. Izvozite zaporedje v FASTA formatu.
2. Blast zaporedja v Genome Browser.
3. Preverite ali je različica v podatkovnih zbirkah: spletna stran Ensembl.
4. Kako različica vpliva na aminokislinkso sestavo in delovanje proteina  
uporabite programa SIFT in PolyPhen.
5. Statistična analiza.

20% > heterozigot > 80%  
  
homozygot

# Razprava

1. Kako potrdimo rezultate (nov SNP) pridobljene s sekvenciranjem nove generacije?
2. Kakšne probleme imamo pri iskanju novih vrst in kako bi jih rešili?

# Literatura

Next-generation sequencing for dummies:

[http://users.ugent.be/~avierstr/nextgen/Next\\_generation\\_sequencing\\_web.pdf](http://users.ugent.be/~avierstr/nextgen/Next_generation_sequencing_web.pdf)

<http://seqanswers.com/> - forum z odgovori

Chandra Shekhar Pareek *et al.*, Sequencing technologies and genome sequencing, 2011, J Appl Genetics, 52, 413-435.

Metzker M.L. *et al.*, Sequencing technologies – the next generation, 2010, 11: 31-46.

<http://www.454.com/>

<http://www.illumina.com/applications/sequencing.ilmn>

<http://www.lifetechnologies.com/us/en/home/life-science/sequencing.html>