

# Next-generation sequencing (NGS)

# Sanger sequencing

Primer - F - AAGTCAGTCTAA=O

Primer - F - AAGTCAGTCTA=O

Primer - F - AAGTCAGTCT=O

Primer - F - AAGTCAGTC=O

Primer - F - AAGTCAGT=O

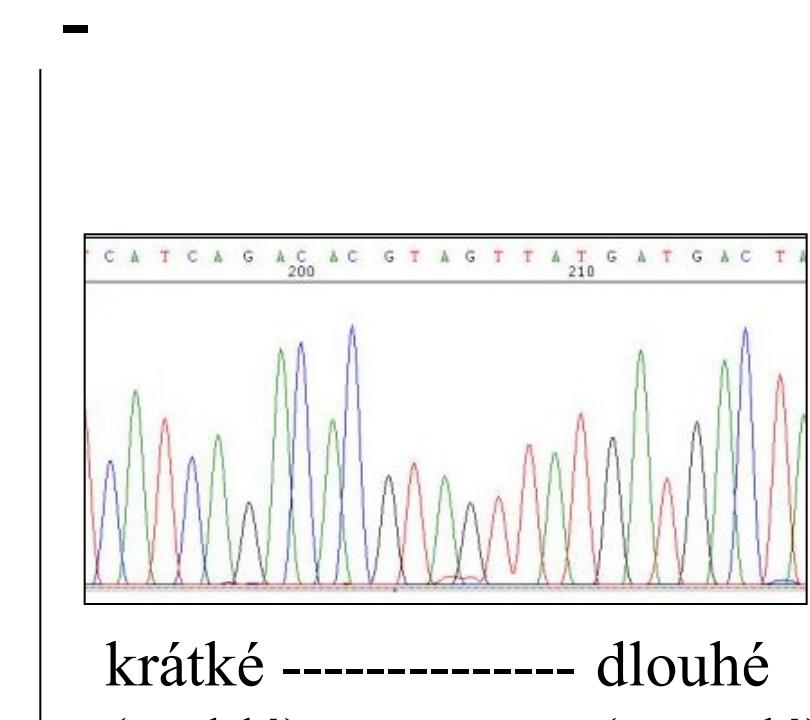
Primer - F - AAGTCAG=O

Primer - F - AAGTC=O

Primer - F - AAGT=O

Primer - F AAGTCAGTCTAAATGCGATTGGGA Rev. Primer - R

Rev. Primer - F TTCAGTCAGATTACGCTAACCCCT Primer - R



+

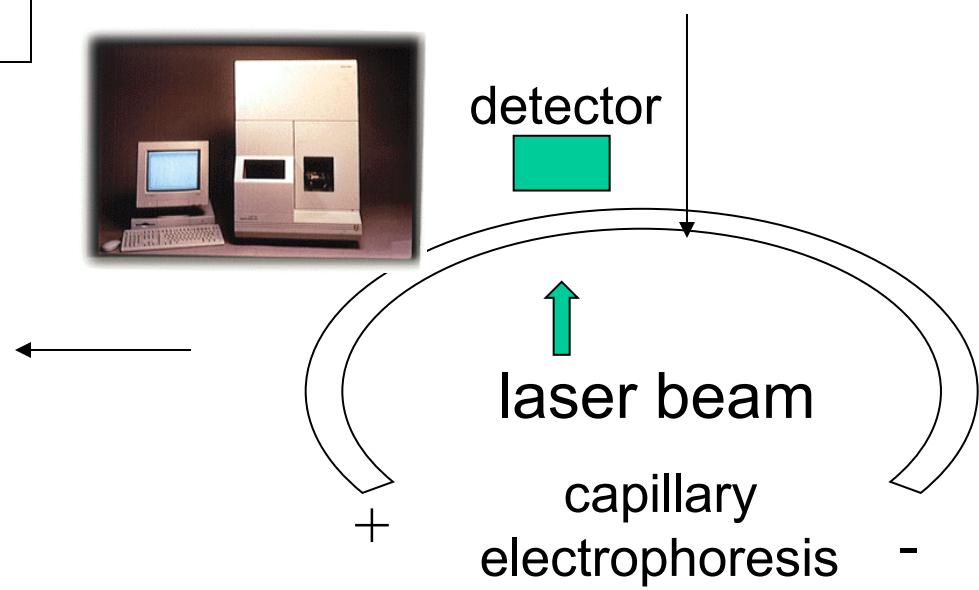
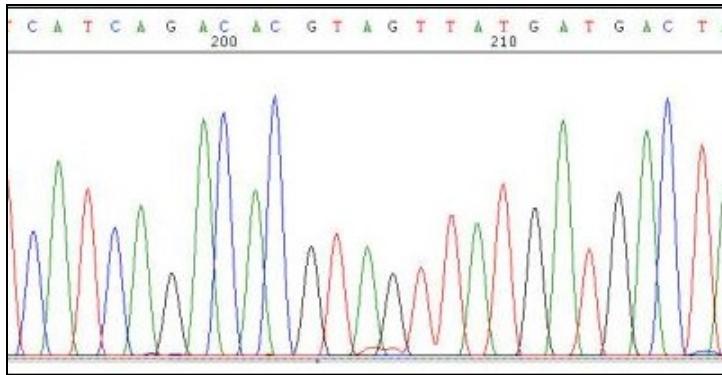
# 4-kapilární sekvenátor

=

96 x 500 bp/12 hodin

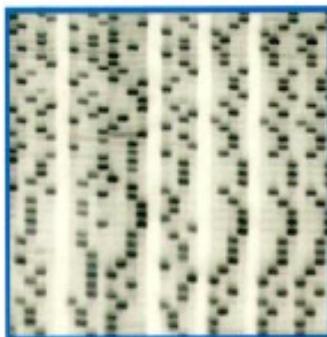
=

cca 100 000 bp/den



# Evoluce Sangerova sekvenování

Pre-1992  
“old fashioned  
way”



S35 ddNTPs  
Gels  
Manual loading  
Manual base calling

1992-1999  
ABI 373/377



Fluorescent ddNTPs\*  
Gels  
Manual loading  
Automated base calling\*

1999  
ABI 3700



Fluorescent ddNTPs  
Capillaries\*  
Robotic loading\*  
Automated base calling  
Breaks down frequently

2003  
ABI 3730XL



Fluorescent ddNTPs  
Capillaries  
Robotic loading  
Automated base calling  
Reliable\*

# 96-kapilární sekvenátor

=

$2304 \times 500 \text{ bp}/12 \text{ hodin}$

=

**cca 2 400 000 bp/den**

## NGS (Illumina HiSeqX10)

=

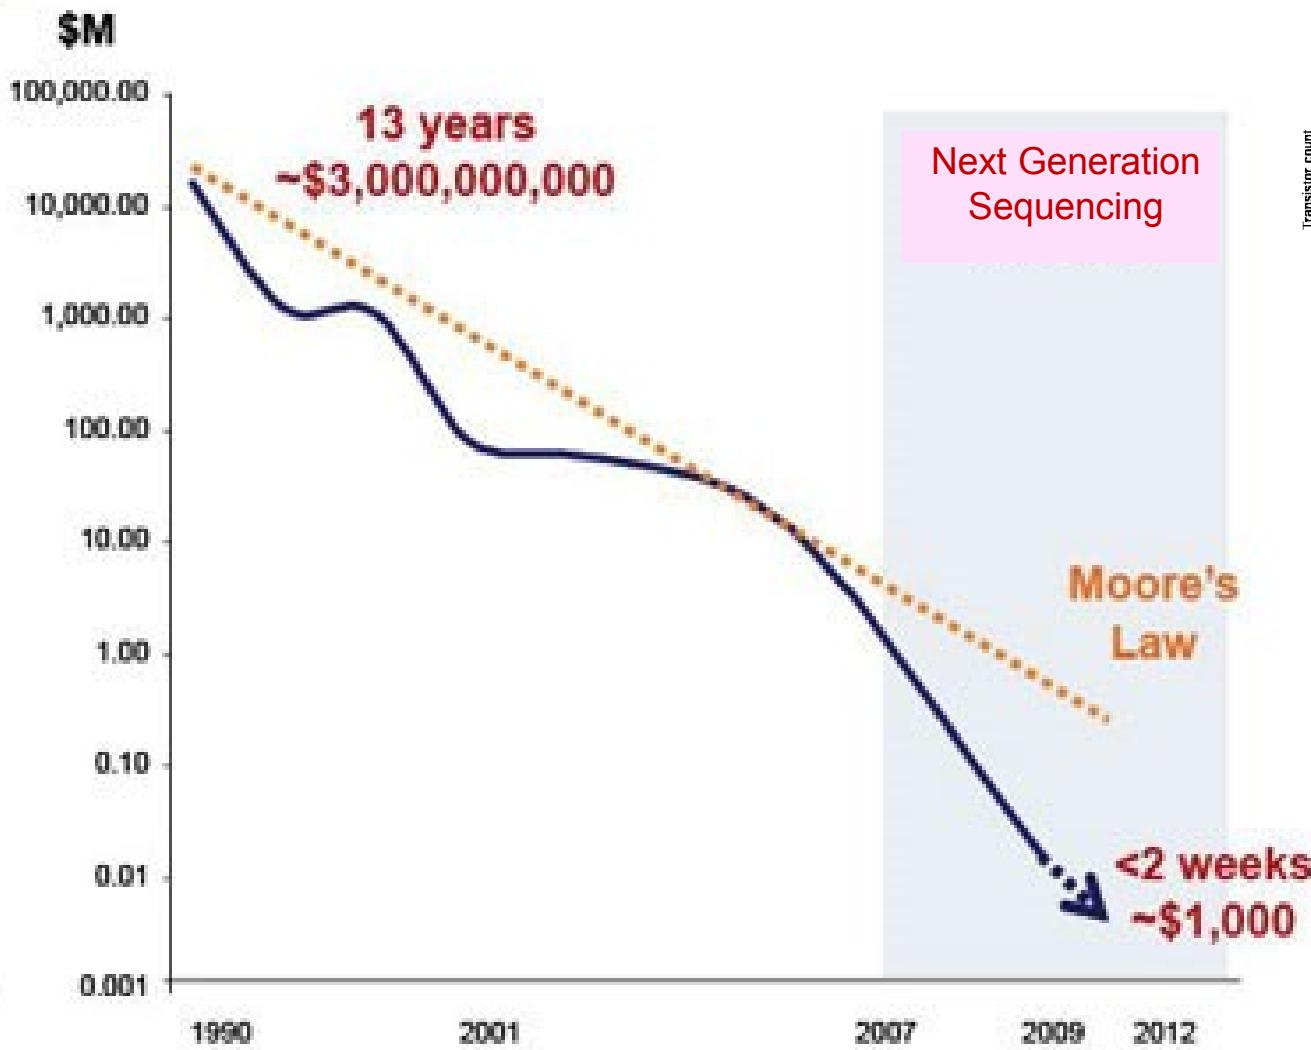
**cca 600 000 000 000 bp/den**

electrophoresis

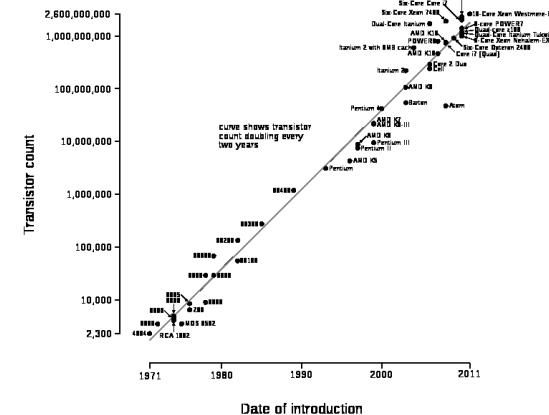
# Next-generation sequencing (NGS)



# Cost per Human Genome



Microprocessor Transistor Counts 1971-2011 & Moore's Law



# Illumina HiSeqX10



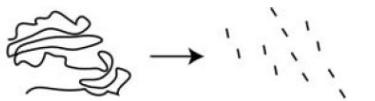
**\$1M** per machine

**1.8 Tbase** per machine per 3 days

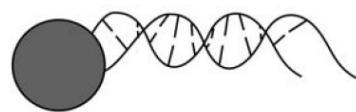
**1800** human genomes per machine per year

# Historie „Next generation sequencing“

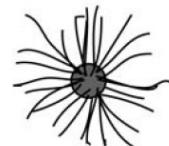
1) Randomly fragment many molecules of target DNA



2) Immobilize individual DNA molecules on solid support



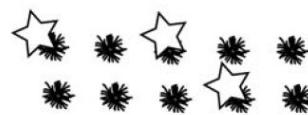
3) Amplify DNA in clonal 'polymerase colony'



4) Sequence DNA by adding liquid reagents to immobilized DNA colonies



5) Interrogate sequence incorporation *in situ* after each cycle using fluorescence scanning or chemiluminescence



454 pyrosequencing ... první komerčně dostupná NGS technologie od srpna 2007

2016 – ohlášené stažení z trhu (Roche)

# Široké spektrum technologií



# Ale jen některé přežijí



# Dnes dostupné NGS platformy

- Roche 454
- **Illumina HiSeq a MiSeq**
- ABI SOLiD
- IonTorrent (Life Technologies)
- SMRT (Pacific Biosciences)
- Oxford Nanopore
- ...

# 454 pyrosequencing

- emulzní techniky amplifikace pikolitrové objemy
- simultánní sekvenování na destičce z optických vláken detekce pyrofosfátů uvolňovaných při inkorporaci bazí
- První generace GS20  
→ 200 000 reakcí najednou (zhruba 20 milionů bp)  
FLX systém → 400 000 reakcí najednou = eukaryotní genom za týden!!!
- Délka jednotlivých sekvencí 100 - 400 (800 bp)



Molecular Ecology (2008) 17, 1629–1635

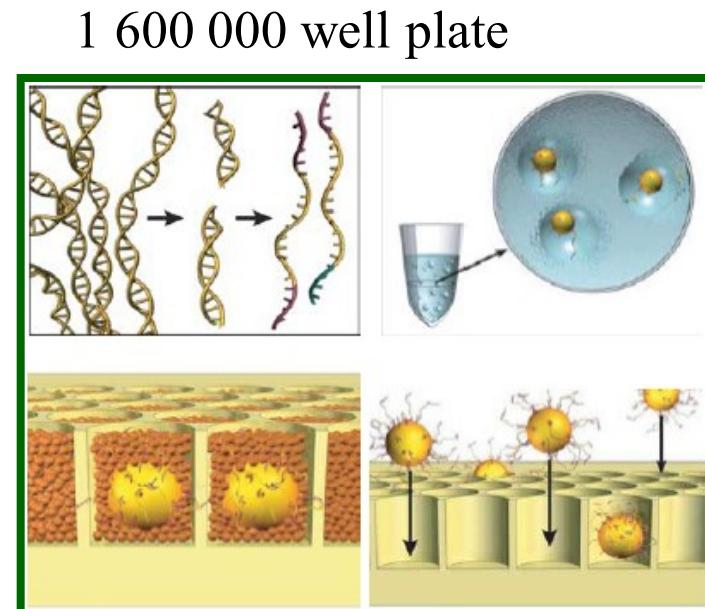
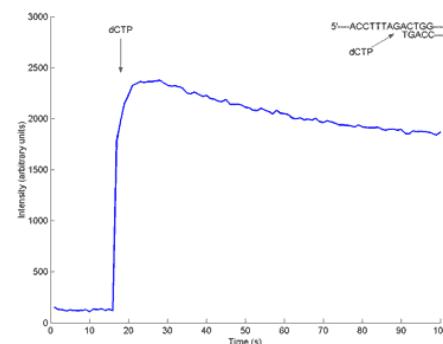
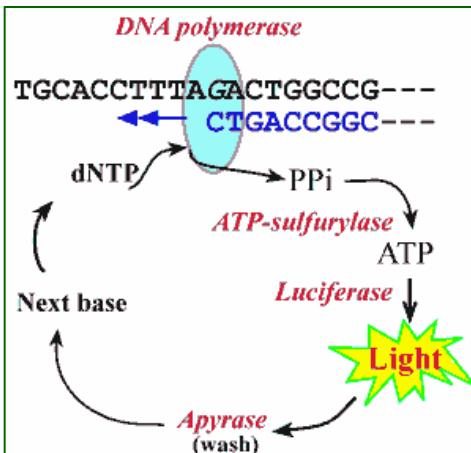
## NEWS AND VIEWS

### PERSPECTIVE

Sequencing goes 454 and takes large-scale genomics into the wild

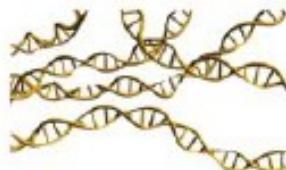
HANS ELLEGREN

Department of Evolutionary Biology, Uppsala University,  
Norbyvägen 18D, SE-75236 Uppsala, Sweden

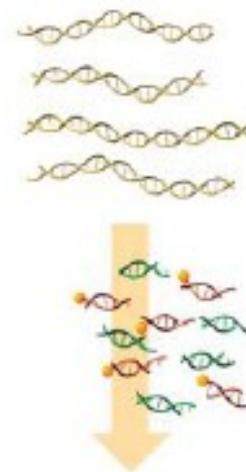


# 1. Příprava jednořetězcové DNA knihovny (ssDNA library preparation)

1 DNA Fragmentation  
(Nebulization):



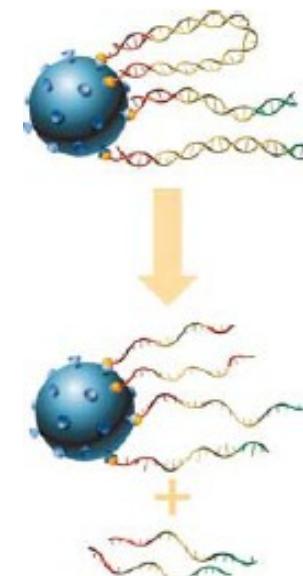
5 Adaptor Ligation:



7 Library Immobilization:



9 ssDNA Library Isolation:



## Adaptor A + Adaptor B

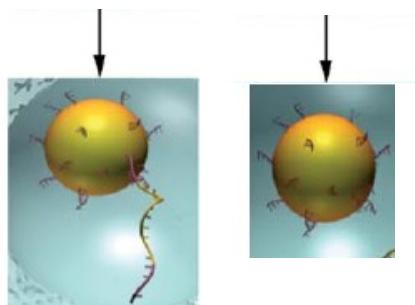
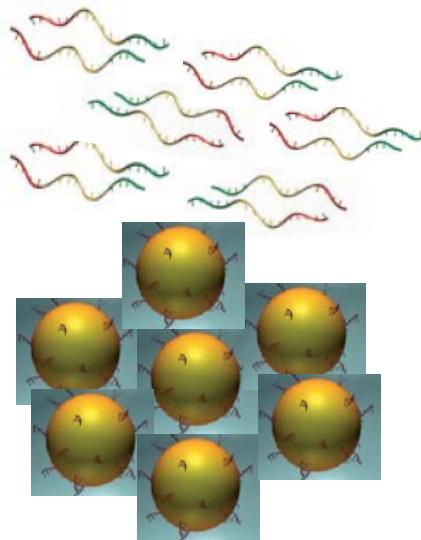
-Slouží jako vazebné místo primerů pro následnou PCR amplifikaci a sekvenování

-Slouží k uchycení na kuličky (na adaptor B je připojen biotin)

## 2. Namnožení každé jednotlivé molekuly pomocí emulzní PCR (emPCR)

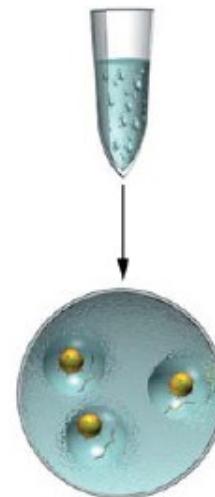
### 1 DNA Library Capture:

- poměry nastavít tak aby  
1 kulička  $\leq$  1 molekula DNA

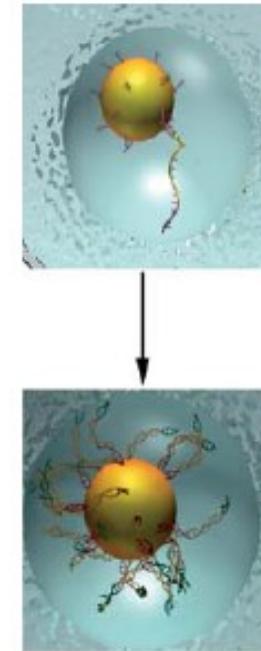


### 2 Preparation of the Amplific. Mixes

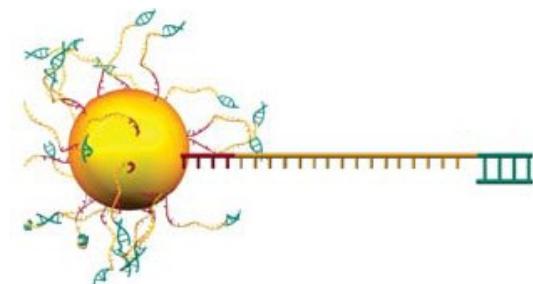
### 3 Emulsification:



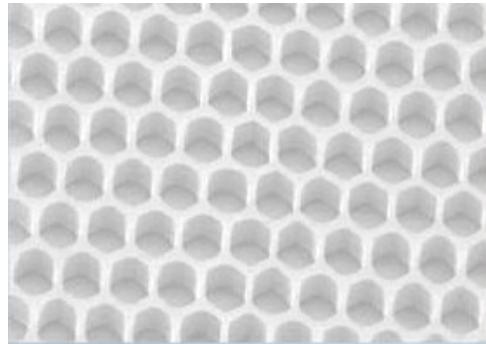
### 4 emPCR Amplification:



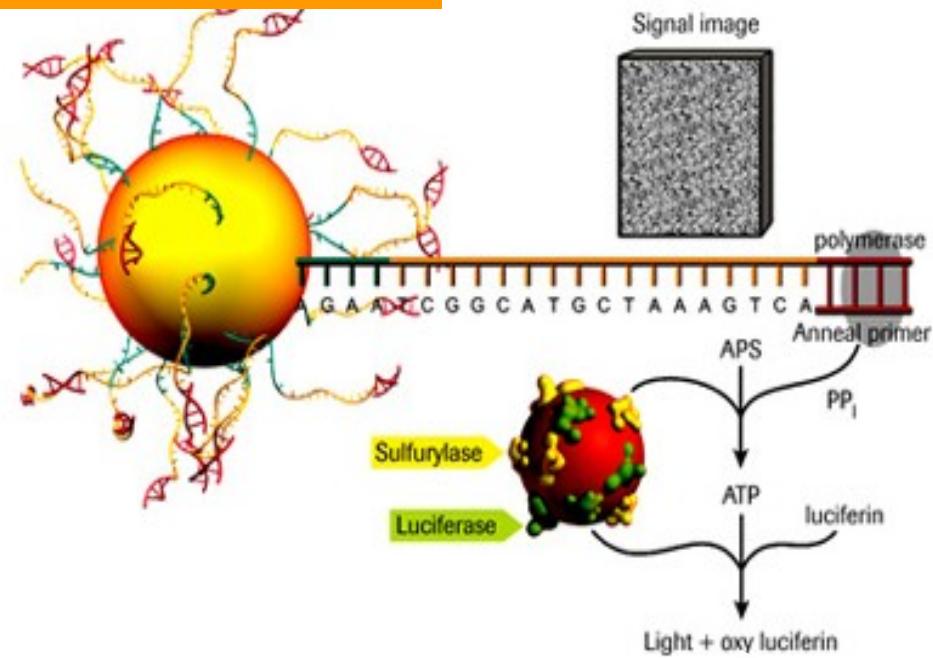
### 7 Sequencing Primer Annealing:



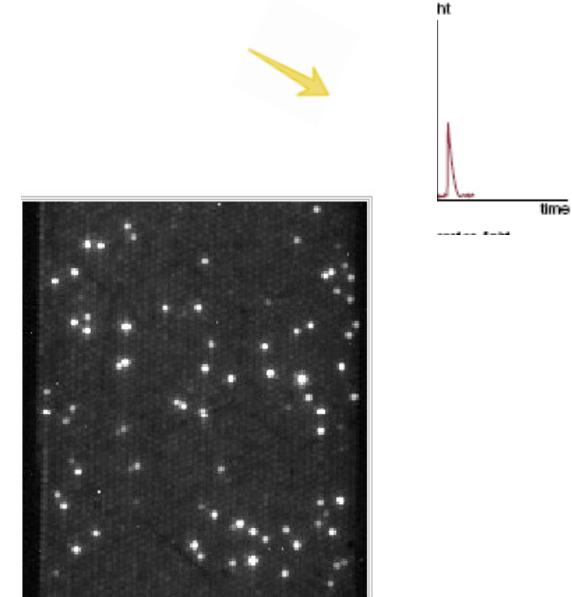
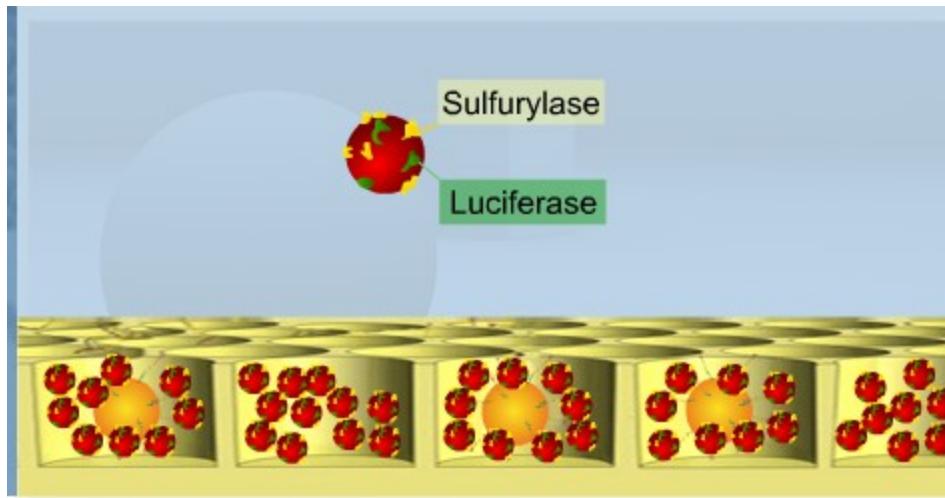
### 3. Pyrosekvenování („sequencing by synthesis“)



pikotitrační destička



Na jedné desticče 400 000 až 1 milión jamek



### 3. Pyrosekvenování - detekce signálu

- postupně se přidávají nukleotidy v definovaném pořadí: např. TACG TACG TACG
- po přidání každého nukleotidu a detekci signálu se nukleotid odemyje a přidá se další

DNA sekvence: **C T C C G**

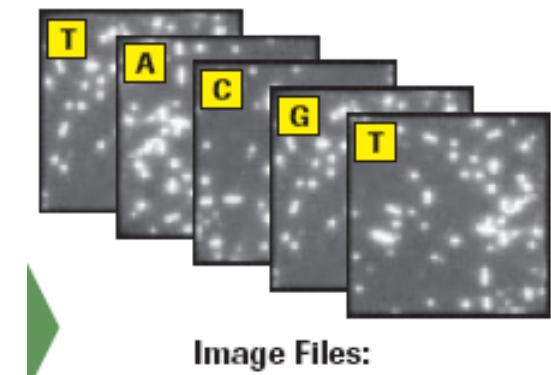
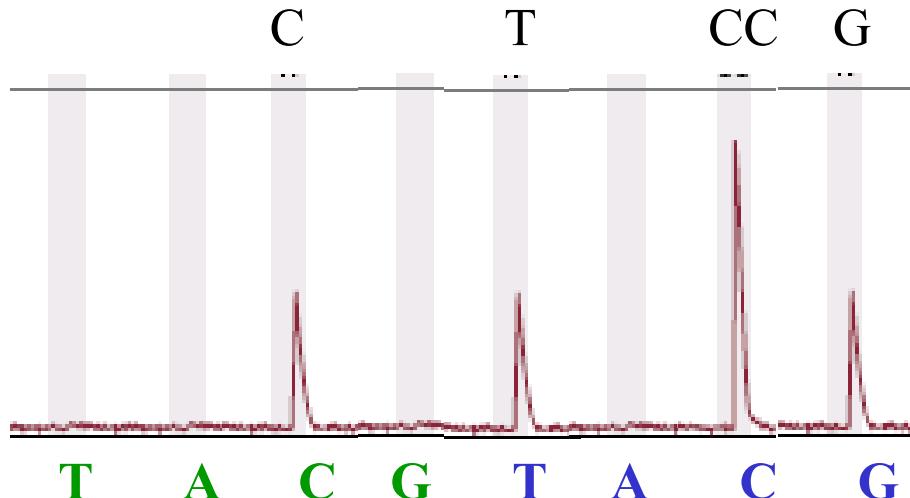


Image Files:  
12-15 gigabytes  
per run

Problém!!!! Homopolymer např. AAAAAAAA

<http://www.youtube.com/watch?v=bFNjxKHP8Jc>

# High-throughput - paralelní sekvenování

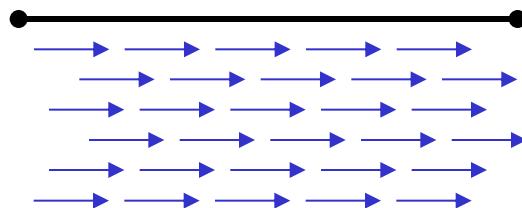
## 454 Platform Updates

GS20	• 100bp reads, ~20Mbp / run
GS-FLX	• 250bp reads ~100 Mbp / run (7.5 hrs)
GS-FLX Titanium	• 400bp reads ~400 Mbp / run (10 hrs)
GS-FLX Titanium Plus	• 700 bp reads ~700 Mbp/run (18 hrs)
GS Junior	• 400 bp reads ~ 35Mbp/run (10 hrs)



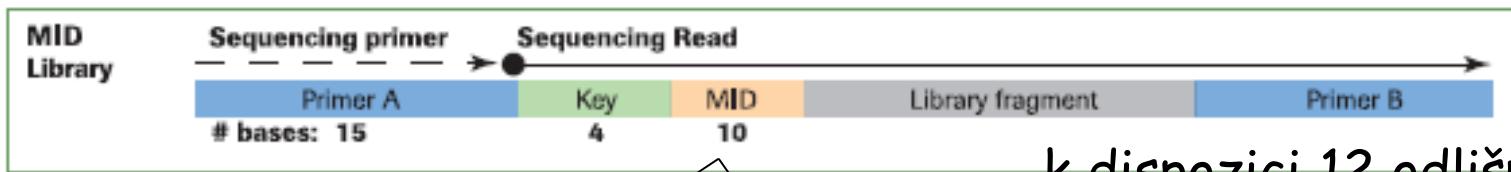
!!! Samozřejmě nestačí mít každou bázi osekvenovanou 1x !!!

- Pospojování (**reads assembly**) do souvislé sekvence
- Nepřesnosti - pokrytí (**coverage**)



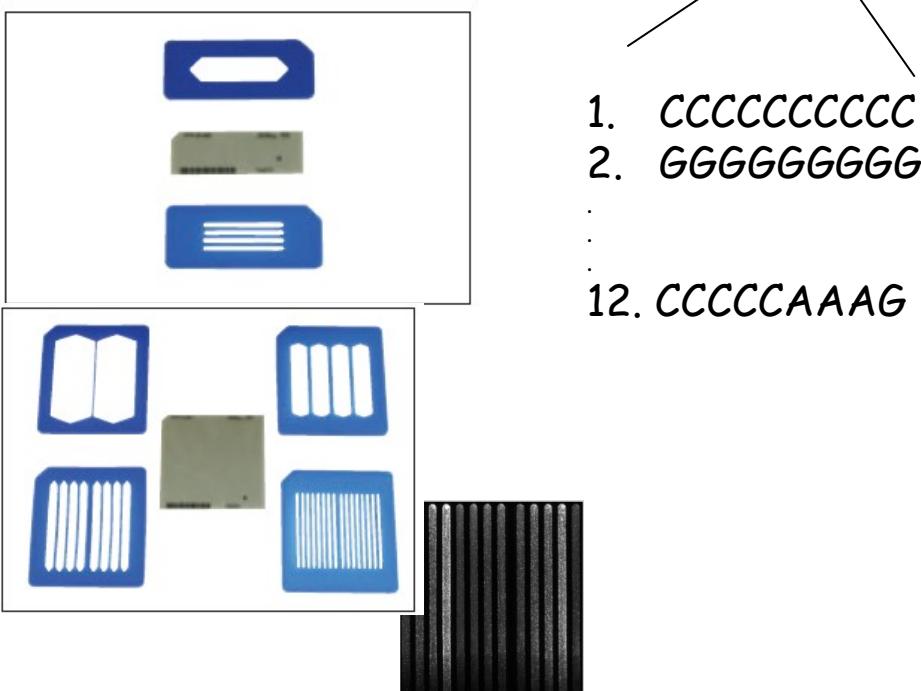
# Kapacita destičky 400 Mb (GS FLX Titanium):

Mus:	2700 Mb	→ 7 run 1x coverage
Caenorhabditis:	100 Mb	→ 1 run 4x coverage
E. coli:	5 Mb	→ 1 run 80x coverage
mitoch. Mus:	0.016 Mb	→ 1 run 25000x coverage
HIV:	0.01 Mb	→ 1 run 40000x coverage



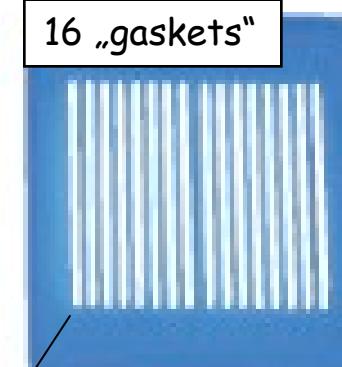
- k dispozici 12 odlišných MID

(„multiplexing“)



1. CCCCCCCCCCC
2. GGGGGGGGGG
- .
- .
12. CCCCCAAAG

16 „gaskets“



$$\begin{array}{l} 12 \text{ MID} \\ \times \\ 16 \text{ gaskets} \\ = \\ \text{max. 192 vzorků} \end{array}$$

V každém max. 12 vzorků  
(každý označen svým MID)

# Illumina HiSeq/MiSeq

- v současné době nejrozšířenější typ (cca 70%) na trhu
- v horizontu následujících let její používání spíš poroste

[https://www.youtube.com/watch?annotation\\_id=annotation\\_228575861&feature=iv&src\\_vid=womKfikWIxM&v=fCd6B5HRaZ8](https://www.youtube.com/watch?annotation_id=annotation_228575861&feature=iv&src_vid=womKfikWIxM&v=fCd6B5HRaZ8)

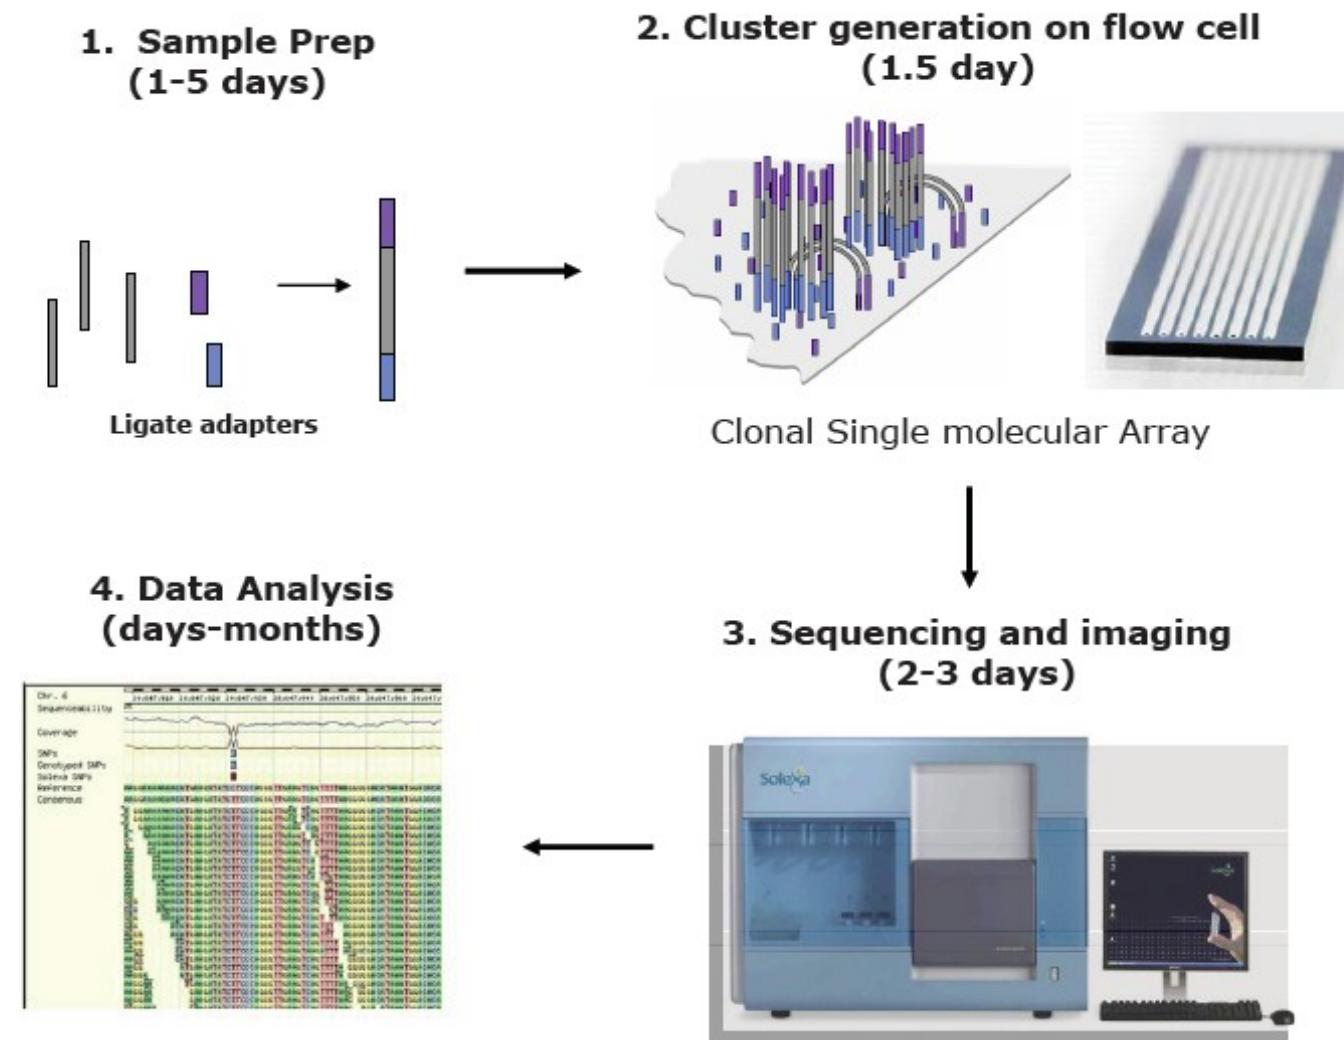
Illumina HiSeq



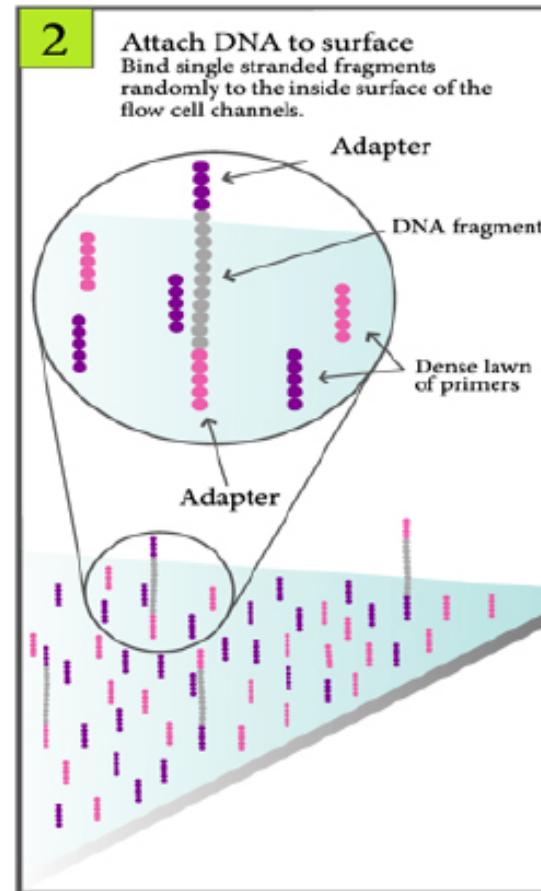
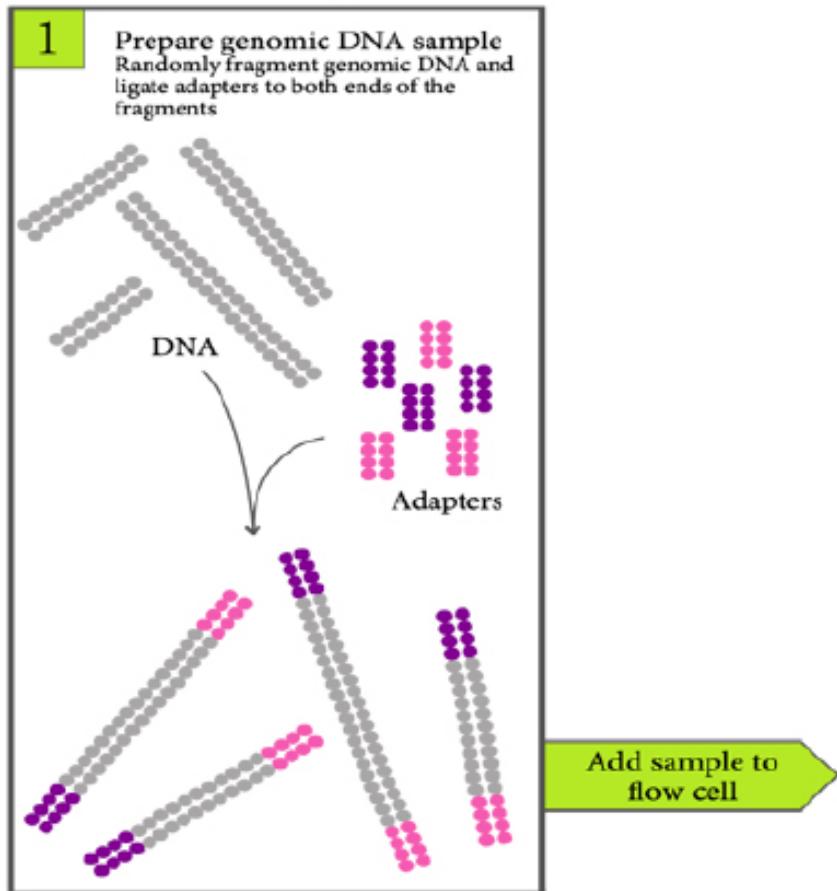
Illumina MiSeq



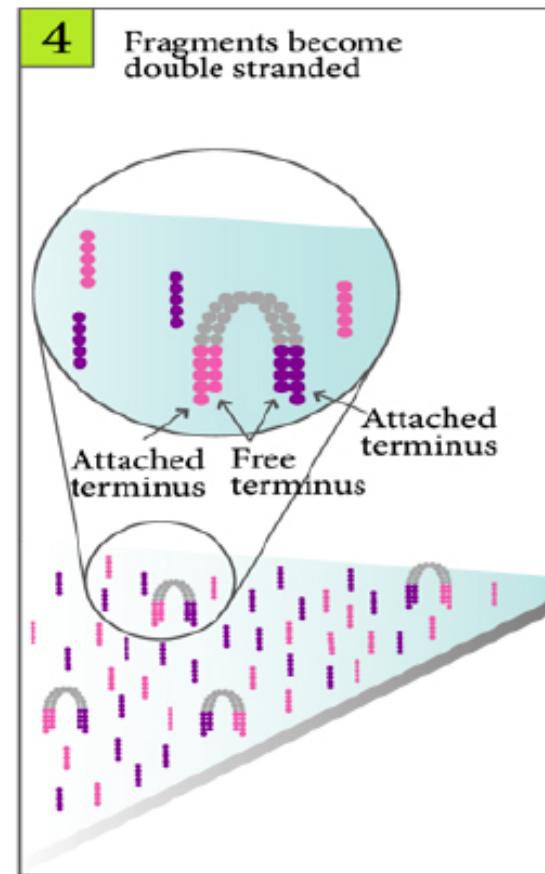
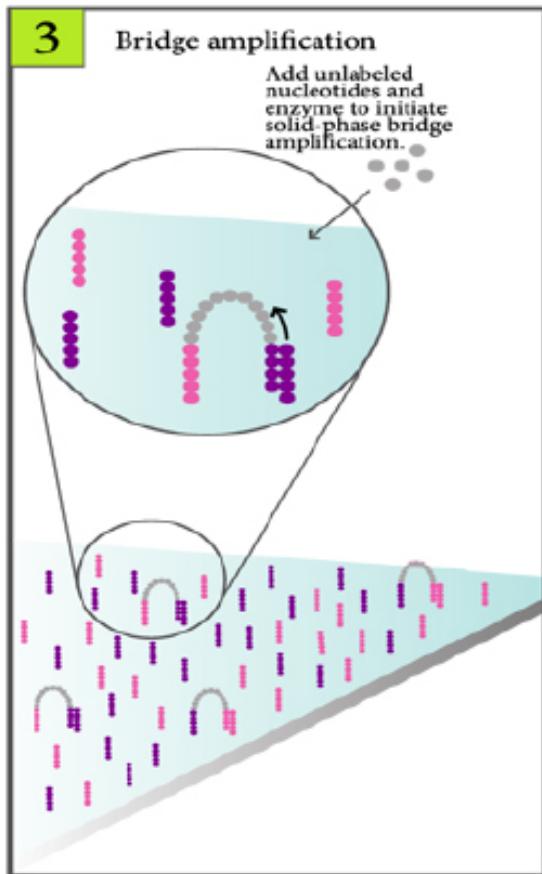
# Illumina Sequencing pipeline



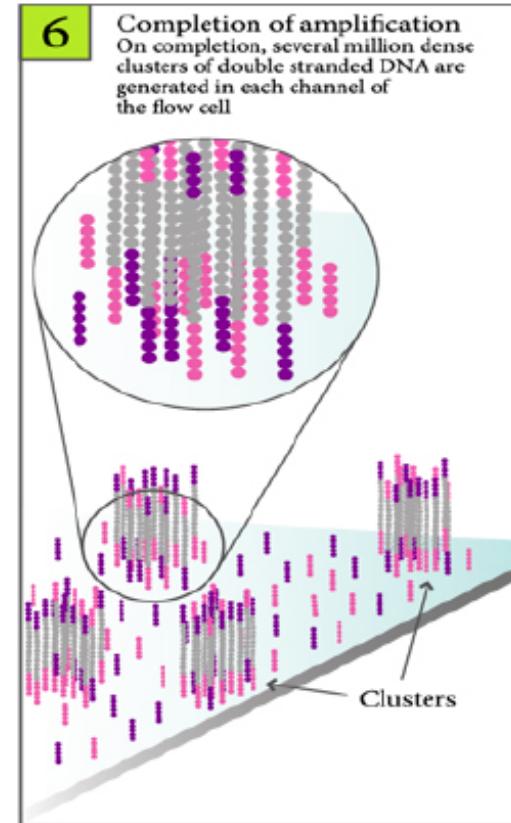
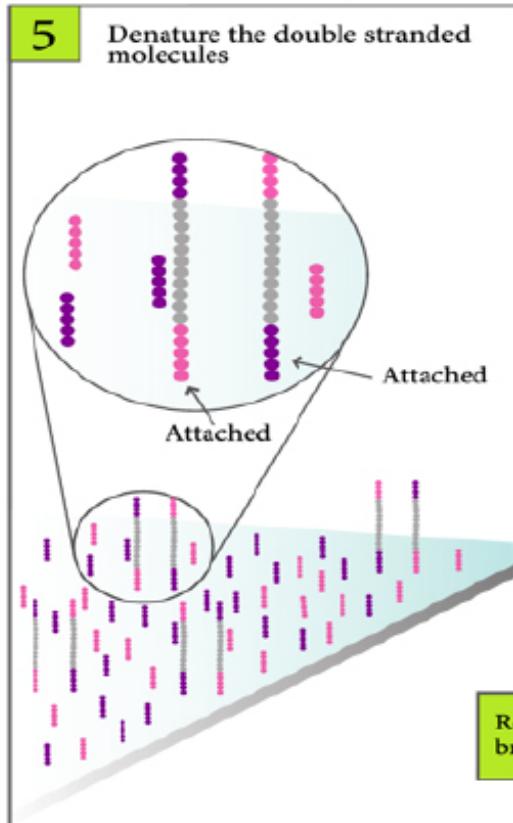
# Attach DNA to flow cell



# Bridge Amplification

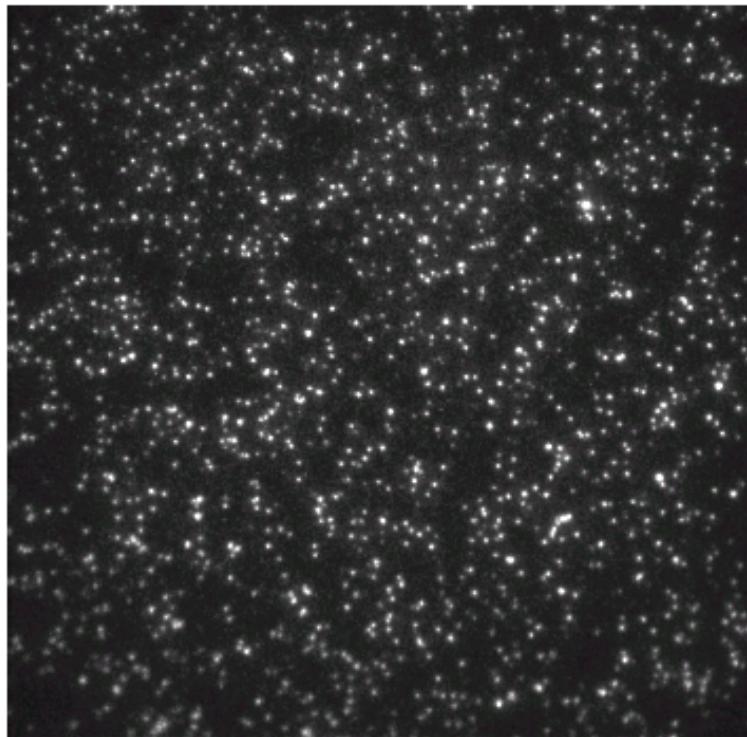


# Cluster Generation



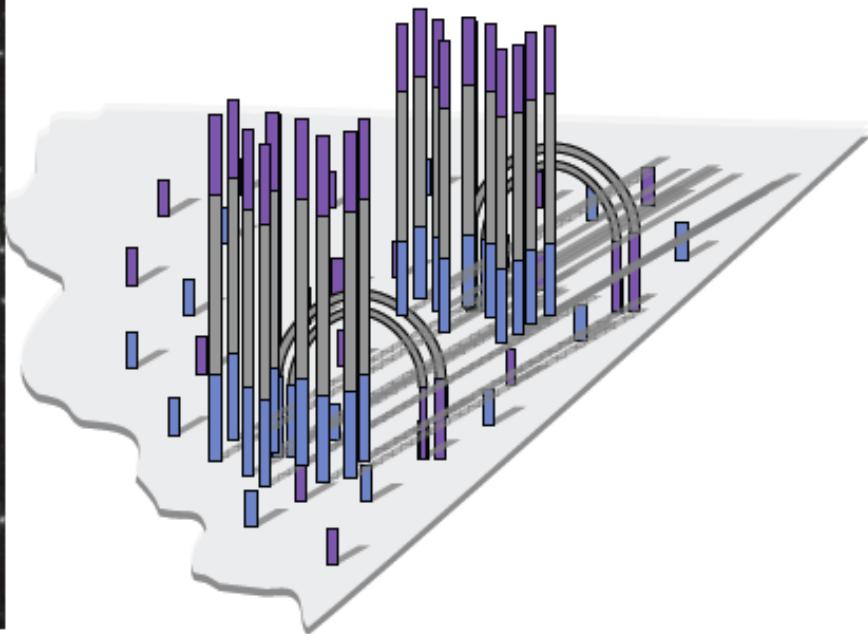
Clonal Single molecular Array

# Clonal Single molecule Array



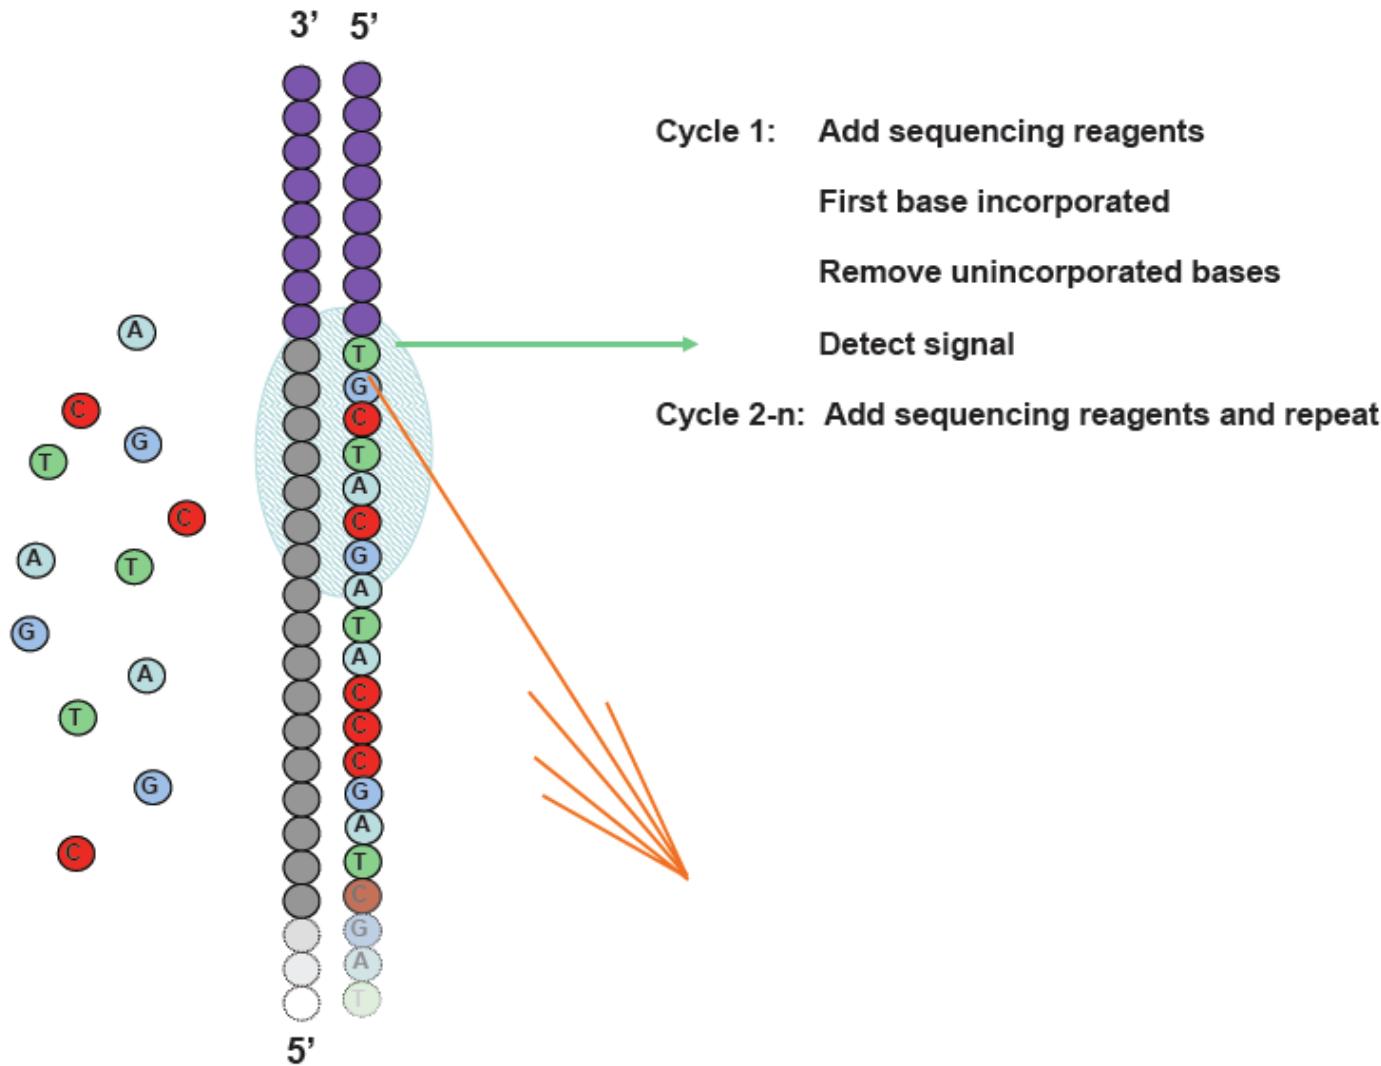
100um

Random array of clusters



**~1000 molecules per ~ 1 um cluster  
~20-30,000 clusters per tile  
~40 M clusters per flowcell**

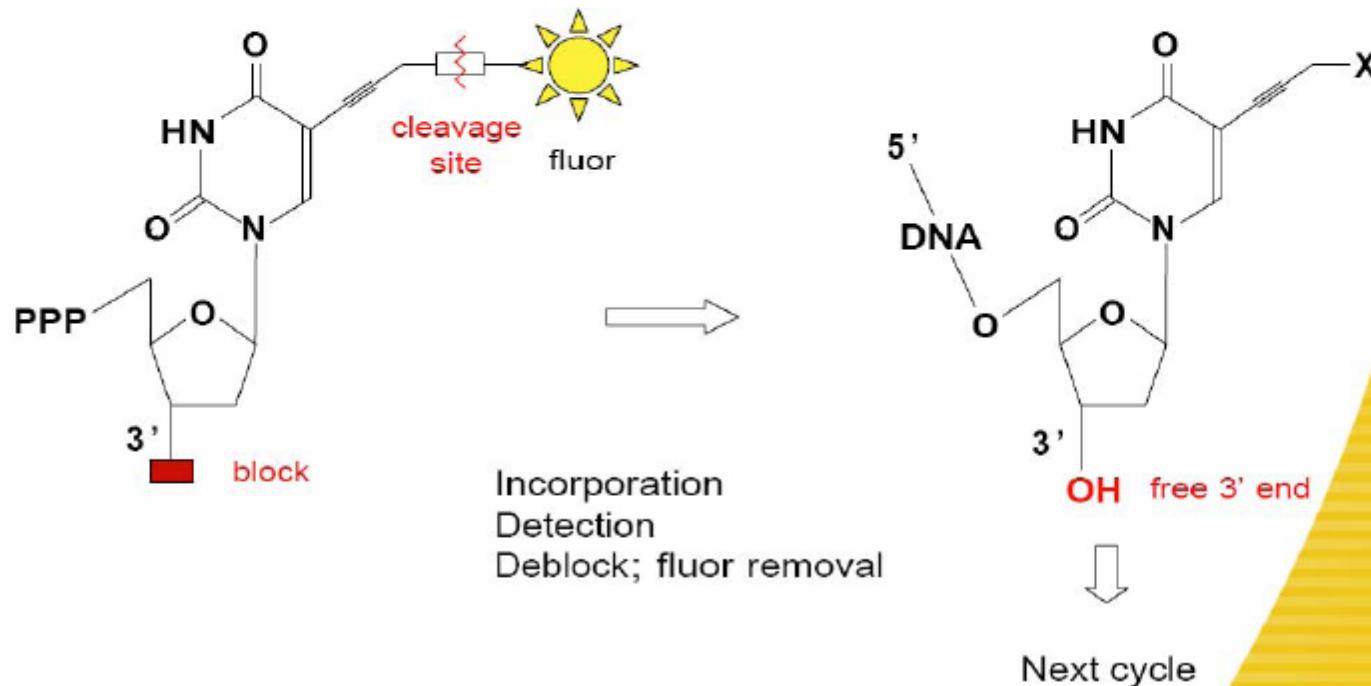
# Sequencing By Synthesis (SBS)



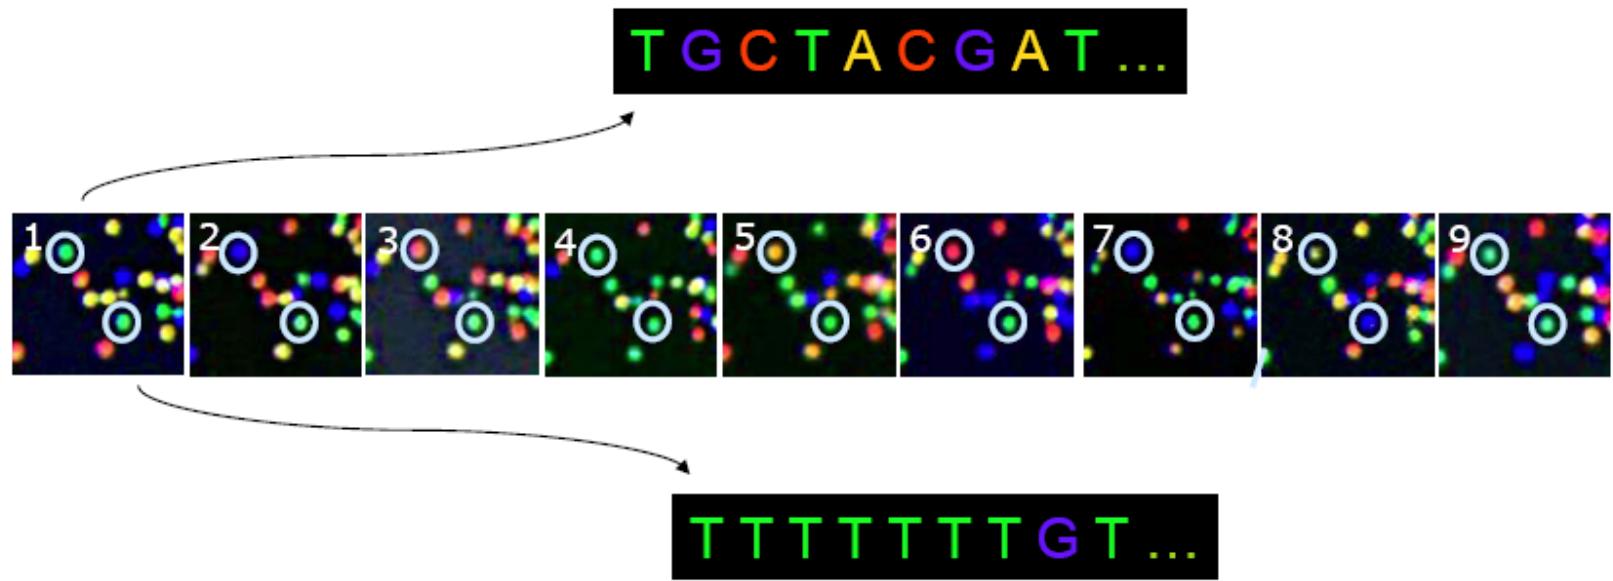
# Reversible Terminator Chemistry



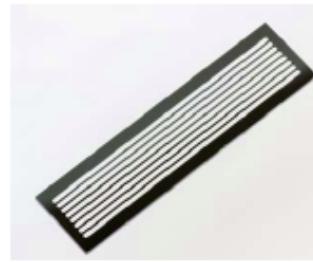
- All 4 labelled nucleotides in 1 reaction
- Higher accuracy
- No problems with homopolymer repeats



# Base Calling From Images



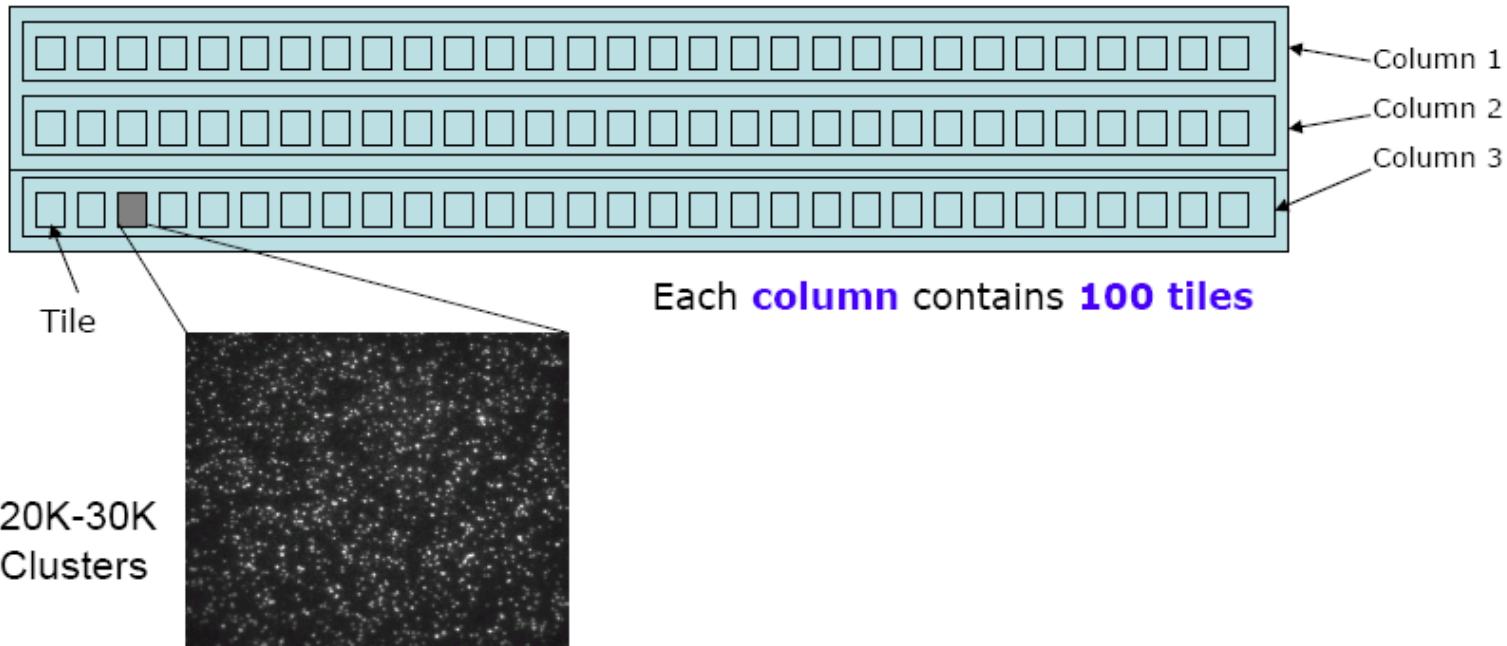
The identity of each base of a cluster is read off from sequential images



A **flow cell** contains eight lanes



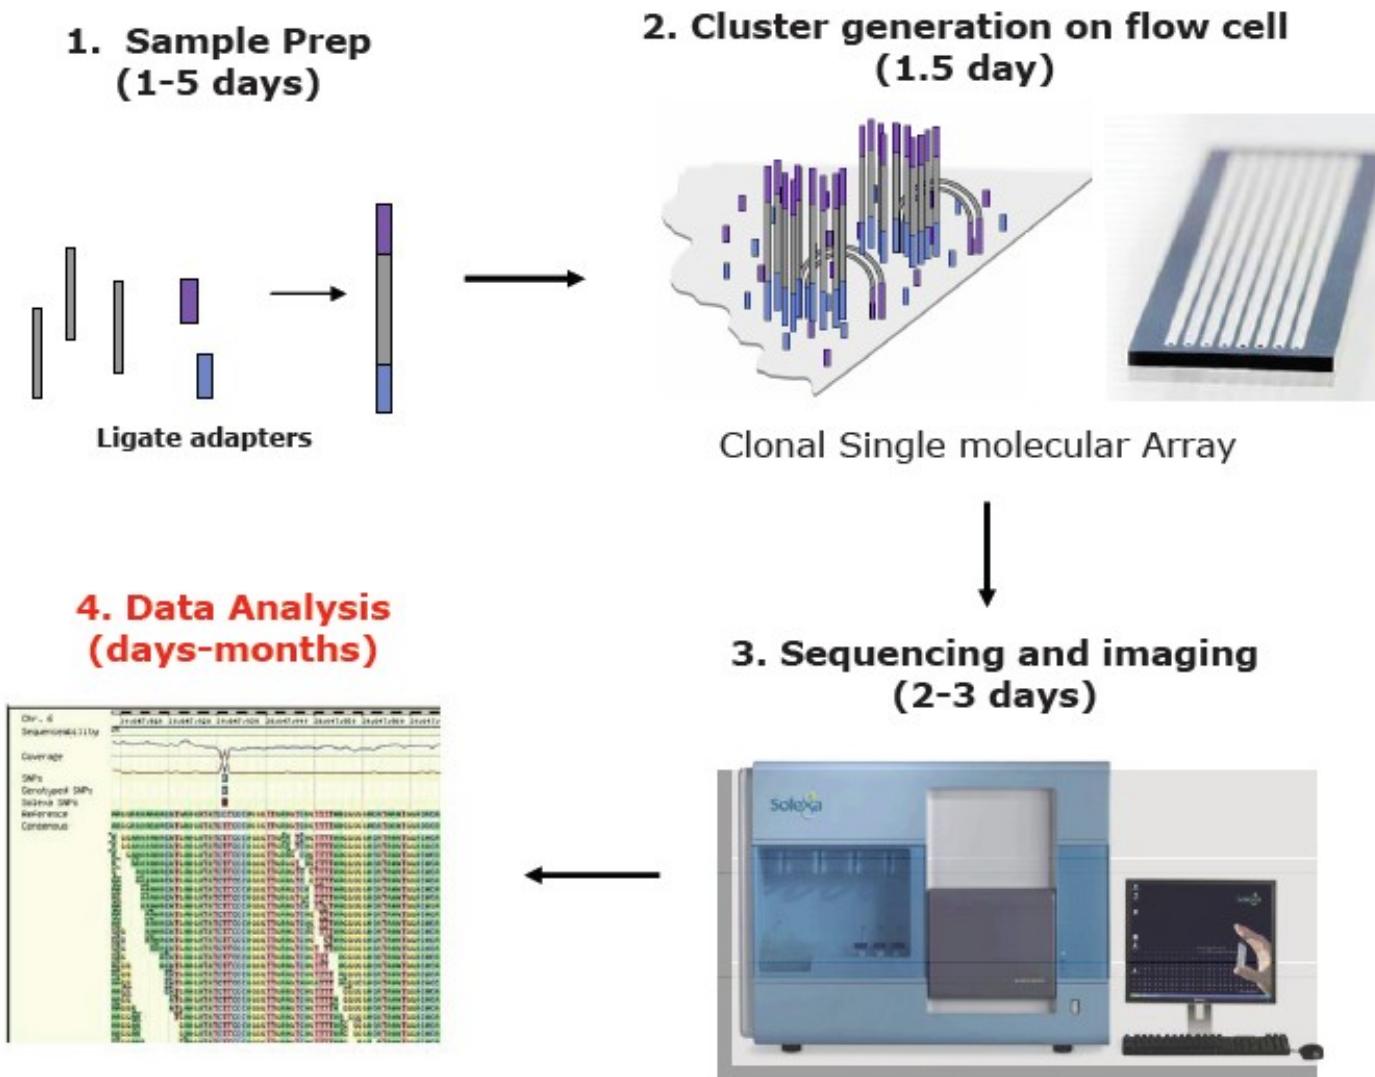
Each **lane/channel** contains **three columns** of tiles



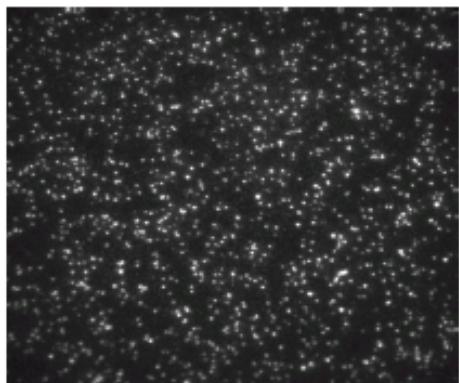
350 X 350  $\mu\text{m}$

[https://www.youtube.com/watch?annotation\\_id=annotation\\_228575861&feature=iv&src\\_vid=womKfikWIxM&v=fCd6B5HRaZ8](https://www.youtube.com/watch?annotation_id=annotation_228575861&feature=iv&src_vid=womKfikWIxM&v=fCd6B5HRaZ8)

# Illumina Sequencing pipeline



# Data Analysis Pipeline



tiff image files  
(345,600)

T	135	343	140	9	147	7	339	1	24946	9	201	2	299	7	297	0	21984	4
T	180	621	231	3	341	9	497	7	21423	9	228	2	382	9	14818	0	20217	9
T	245	626	210	4	356	0	581	6	21362	3	385	5	319	7	467	9	17474	3
T	241	899	187	7	382	7	577	4	35747	7	5485	2	16841	3	181	0	482	7
T	238	295	172	5	212	1	681	1	20362	8	6297	1	12746	0	159	4	546	8
T	155	544	170	2	339	5	539	3	15466	9	397	6	419	8	384	9	17171	9
T	236	544	210	4	323	4	522	2	2048	2	584	4	508	7	530	9	201	5
T	275	694	210	4	323	4	522	2	2048	2	584	4	508	7	530	9	201	5
T	242	522	287	9	513	0	696	8	19056	7	4281	6	10442	1	3894	7	2441	9
T	196	522	220	2	455	9	486	6	18895	6	589	5	552	8	12299	1	14115	7
T	237	622	167	8	457	7	511	0	19025	8	711	8	592	0	116	4	17714	3
T	169	528	172	0	469	7	513	9	18486	6	1285	7	8508	8	381	3	524	1
T	164	549	205	7	385	0	490	4	18485	6	1410	3	8508	3	786	7	381	6
T	279	381	201	2	316	9	501	1	18485	6	1285	7	8508	8	381	3	524	1
T	240	523	216	0	469	7	513	9	18486	6	1285	7	8508	8	381	3	524	1
T	138	583	243	5	558	9	563	7	18183	9	226	8	503	0	13825	1	15157	3
T	221	658	225	5	496	0	553	2	18176	5	533	8	16288	8	315	3	594	6
T	269	597	194	0	229	0	600	2	21426	2	294	7	598	6	629	0	20946	9
T	238	532	249	8	559	6	630	9	21401	5	679	9	11276	3	692	5	177	3
T	159	537	216	7	349	4	598	6	17715	6	341	3	8448	9	377	4	521	7
T	242	541	192	5	275	9	670	4	23603	5	4711	9	11481	0	199	9	604	9
T	244	541	226	3	457	9	513	9	18486	6	1285	7	8508	8	381	3	524	1
T	178	520	226	3	338	4	457	9	17172	1	279	5	508	5	187	3	14274	3
T	271	582	230	4	566	4	606	1	21249	9	4696	6	10581	2	146	3	211	9
T	271	598	179	8	391	5	587	3	21895	2	1901	2	11093	1	158	1	699	8
T	186	503	236	4	389	5	485	4	16829	3	4091	1	8308	2	289	5	579	6
T	201	592	181	8	378	0	532	6	21548	7	8013	1	15221	0	89	6	1211	8
T	248	548	189	7	625	1	583	4	14512	3	5840	8	16851	3	195	3	564	8
T	147	517	208	7	366	0	508	1	16468	5	1775	0	830	2	155	7	581	8

Firecrest

intensity files

Bustard

8	7	135	543	TTTGAAACAGATATTGGCGACACG
1	7	180	621	TGTTCCTTTCATTTTTTTTGACACAC
1	7	245	626	TTCGATCAGGGTTTCGTCGTCGAC
1	7	241	559	TCTCTTGCGCTGAACGCTCGCTG
1	7	214	565	TACAAATCCGTGCCATATGGAGCTT
1	7	153	544	TTCATCTGCATGTCGTCAGTTTAC
1	7	301	507	TCCUUCCTTATTCATCTTTTNTT
1	7	175	614	TTCGAAACCGGTTTAAGAGGAGACG
1	7	242	522	TAACTTATACTACAGGATTTCTCAA
1	7	196	522	TGTCACAGGGAGGAAACAGCGCTGAC
1	7	237	612	TTGCTCAGAGTCAGAAACACACTTC
1	7	160	528	TCTGATTTTTACAGTAACTAGAAAC
1	7	164	543	TCTCAGAACACGCTGCTGCGCG
1	7	179	581	TTCGAACTCTGCACTGCTTGG
1	7	224	623	TATTCAGGCGCATGTCGCTGCGCC
1	7	139	583	TGTGCTGCGCTGCGCTGCGCTG
1	7	220	618	TCCGAACTCTGTTAAATTTAGACGCA
1	7	260	507	TTATTGTTGGAGTAATAATGTTCCAGTA
1	7	334	512	TAGTGTGTTGACCTAAATGTTGGAGATC
1	7	155	517	TCCRCAABGAGGAAAAAAAGGGAGGR
1	7	343	541	TATGGTCCATGTCGTAATGAGTAGAT
1	7	241	608	TATTCAGGCAAGTGTGTTGTTACACC
1	7	174	520	TTTTTGTATAGAGATGGGATTTCACCR
1	7	371	592	TATTCGTTATGNNACAGGCGCTAGGCGG
1	7	271	508	TCTCTGGAAATATTAGCTTACCGAGA
1	7	195	503	TACRGAZGTTGGGCCCTGGTGTGATCCTG
8	7	500	500	.....

Sequence files

Additional  
Data Analysis

← Alignment to Genome

Eland

# Illumina fastq

1            2            3            4            5            6 7            8

```
@HWI-ST226:253:1101:2743:29814 1:N:0 ATCACG
TGCAGGAAGGATCATTGTGGAATTCTCGGGTGCCAAGGAACTCCAGTCACATCACGATCTGTATGCCGTCTCTGCTT
GAAAAAAAAAAAAAAATT
+
B@CFFFFFHHFFHJIIGHIHIJJJIIJJGDCHIIIIJJJJJJGJGIHHEH@)=F@EIGHHEHFFFFDCBBD:@CC@C
:<CDDDD50559<B#####
```

1. unique instrument ID and run ID
2. Flow cell ID and lane
3. tile number within the flow cell lane
4. 'x'-coordinate of the cluster within the tile
5. 'y'-coordinate of the cluster within the tile
6. the member of a pair, /1 or /2 (*paired-end or mate-pair reads only*)
7. N if the read passes filter, Y if read fails filter otherwise
8. Index sequence

# All this generates a lot of Data!

## 1.5 TB data/run

- 1 Gig of Space
  - 125,000 pages of text
  - 11 CDs of Music
  - 4000 (1024x768) JPEG images
  - 40,000 pages of PDF
- 1 TB of space
  - 220 Million pages of text
  - 300 hours of video
  - 4,000,000 JPEG images
  - 1,000 copies of the Encyclopedia Britannica
  - 1/10 of the printed Library of Congress

## Illumina sequencers

### Illumina MiSeq

4 millions reads/run  
150 bp/read



### Illumina GAIIx

300 millions reads/run  
150 bp/read



### Illumina HighSeq

1500 – 3000 millions reads/run  
100 bp/read



## NovaSeq 6000 Sequencing System (2017)

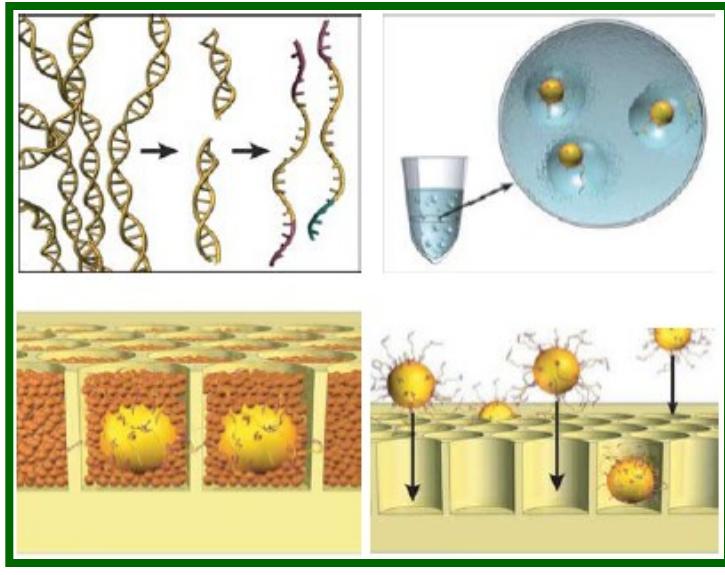
ca. 48 human genomes/run

### Sequencing Output per Flow Cell

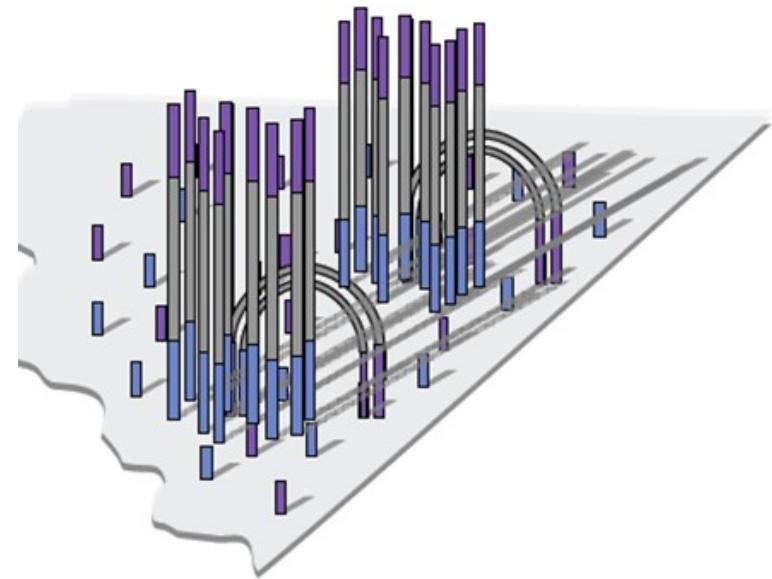
Flow Cell Type	NovaSeq 6000 System		
	S1	S2	S4
2 × 50 bp	134–167 Gb	333–417 Gb	N/A*
2 × 100 bp	266–333 Gb	667–833 Gb	N/A*
2 × 150 bp	400–500 Gb	1000–1250 Gb	2400–3000 Gb

Specifications based on Illumina PhiX control library at supported cluster densities.  
\* N/A: not applicable

# NGS technologie



454 pyrosequencing  
(Roche)



Illumina

# Ion Torrent technology



Microbial  
sequencing



Targeted  
sequencing



Transcriptome  
sequencing



Exome  
sequencing



Ion PGM™ Sequencer

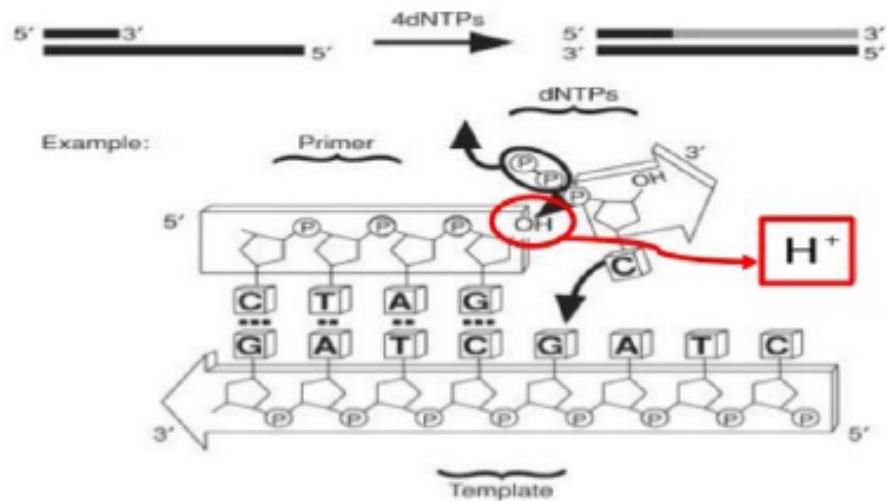


Ion Proton™ Sequencer

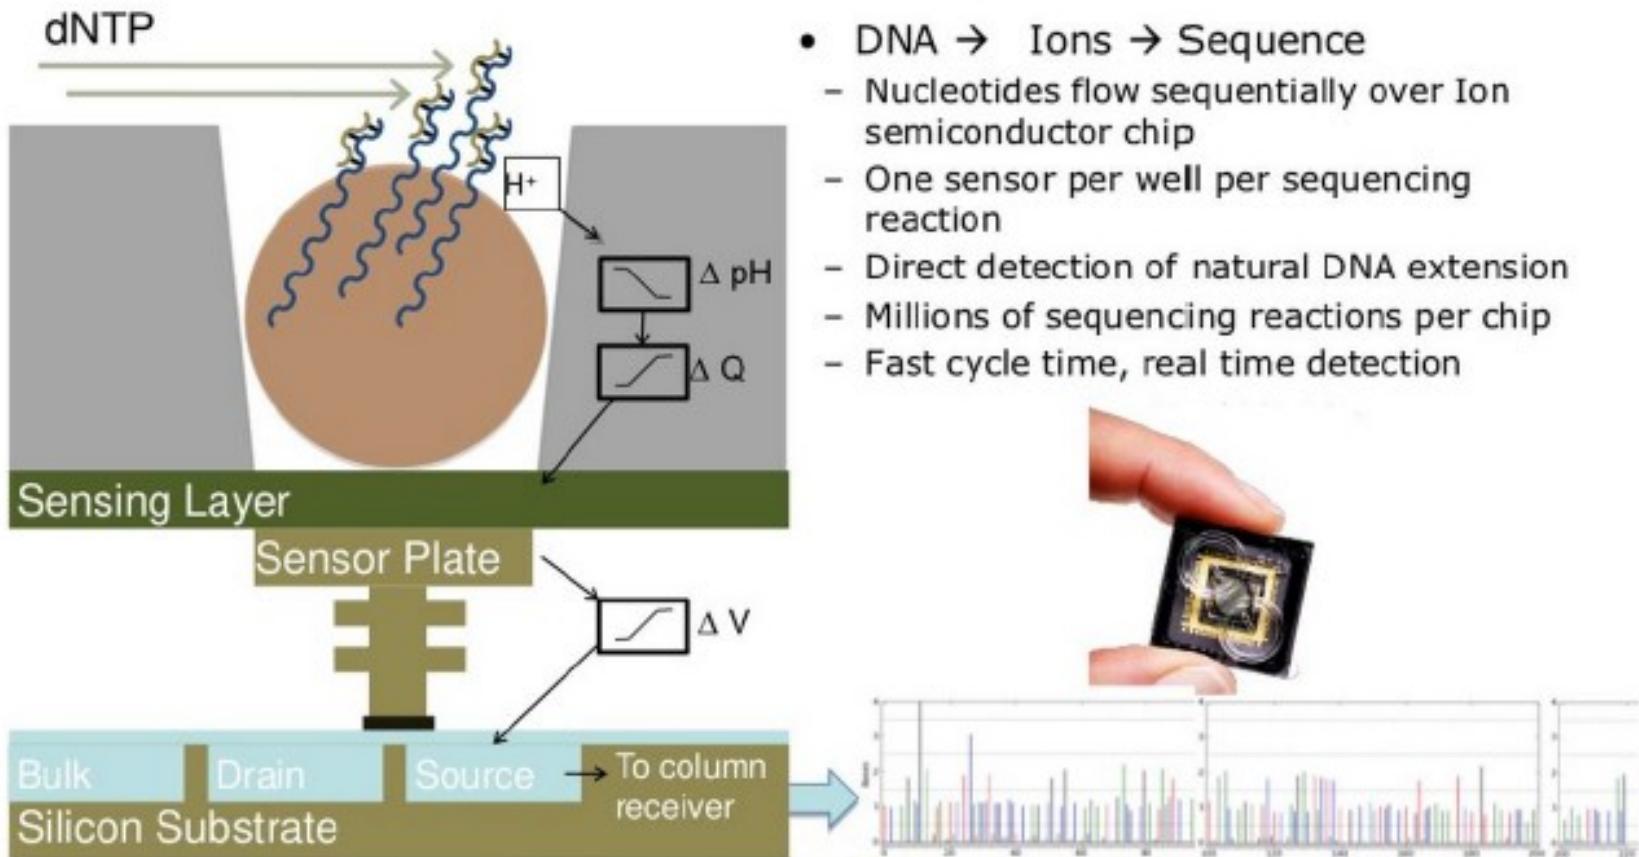
## Ion sequencing: Life Technologies

# Využívá změny pH při syntéze DNA

- Ion Semiconductor Sequencing
- Detection of hydrogen ions during the polymerization DNA
- Sequencing occurs in microwells with ion sensors
- No modified nucleotides
- No optics



# Ion Torrent



# Ion Torrent: System Updates

314 Chip

- 100bp reads ~10 Mb/run (1.5 hrs)

316 Chip

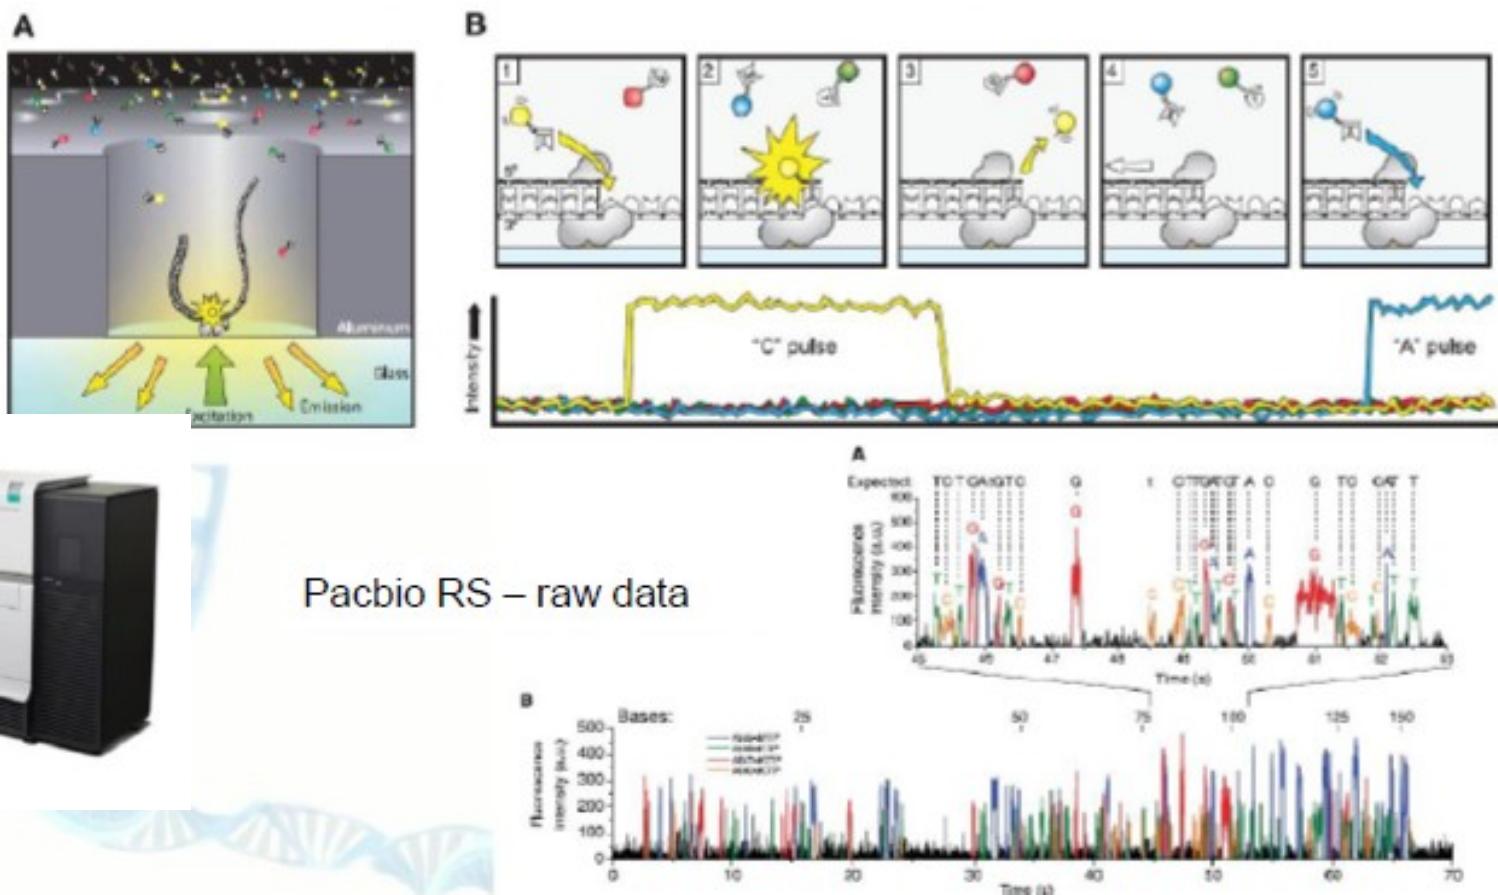
- 100 bp reads ~100 Mbp / run (2 hrs)
- 200 bp reads ~200 Mbp/run (3 hrs)

318 Chip

- 200 bp reads ~1 Gbp / run (4.5 hrs)

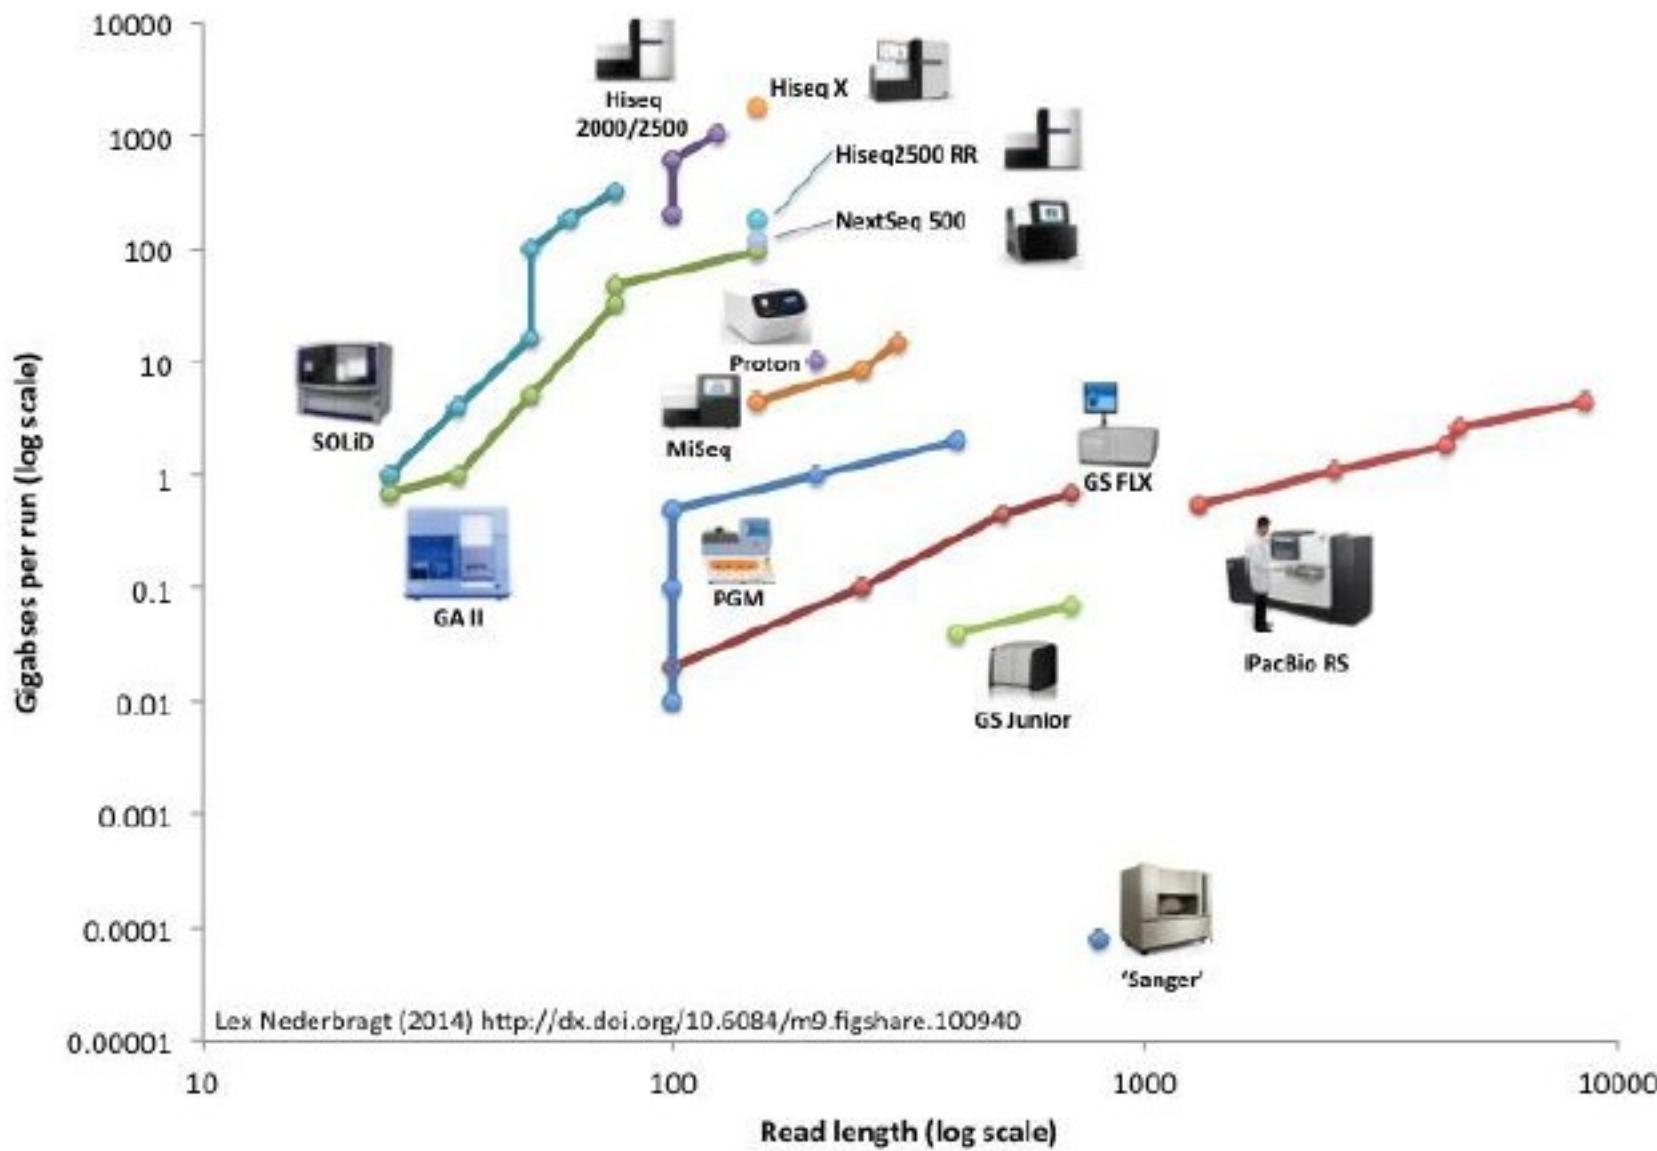
400 bp reads

# SMRT („single molecule real-time sequencing“) – Pacific Biosciences



dlouhé čtení (15 kb), hodně chyb

## Developments in High Throughput Sequencing



Lex Nederbragt (2014) <http://dx.doi.org/10.6084/m9.figshare.100940>

# 3rd generation: Oxford Nanopore



**GridION**  
5 000 pores



**MinION**  
512 pores

# Future Sequencing Technologies

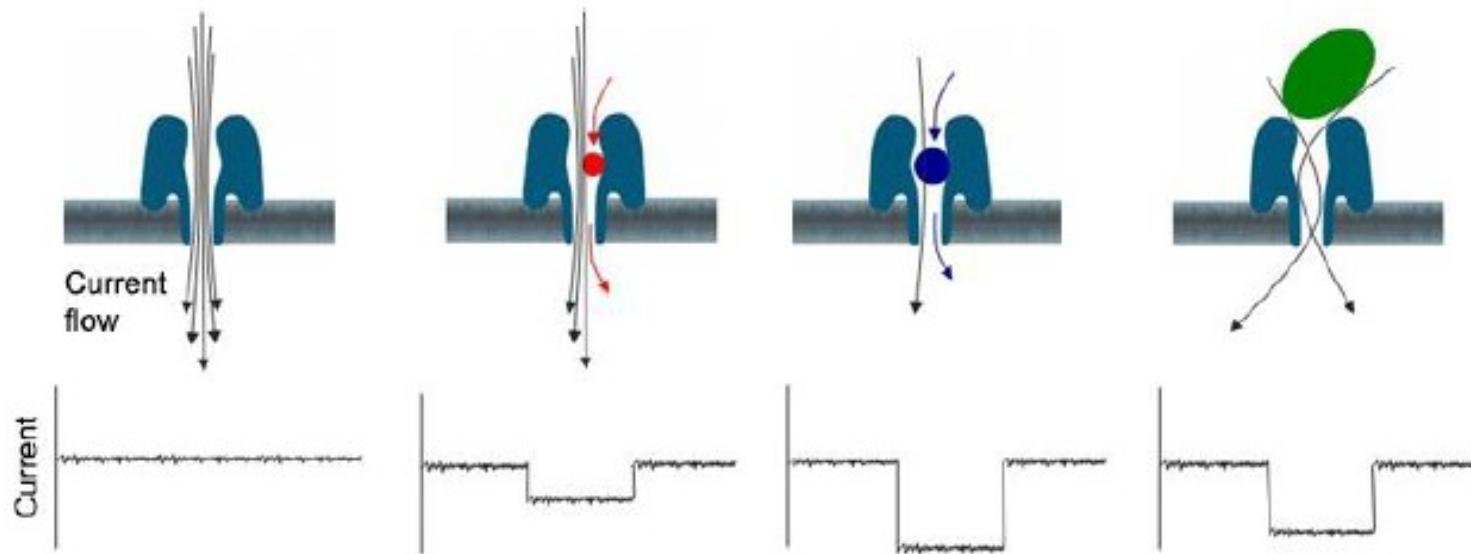
## Oxford Nanopore

Nanopore sequencing  
up to 50 kb

„Run until sequencing ...“



# Princip technologie



<http://www.youtube.com/watch?v=3UHw22hBpAk>

# Sekvenování přímo v terénu (?)



Ebola outbreak

Quick et al., Nature 2016



# Přehled současných metod NGS

Platform	Year	Sequencing Method	Amplification	Detection	Features
454	2005	Pyro-sequencing	Emulsion PCR	Light	First NGS
Illumina	2007	Synthesis	Bridge PCR	Light	90% of Market
SOLID	2008	Ligation	Emulsion PCR	Light	Lowest Error Rate
Ion Torrent	2010	Synthesis	Emulsion PCR	Hydrogen Ion	Semiconductor Chip
Pacific Biosciences	2010	Synthesis	None = Single Molecule	Light	Anchored Polymerases
Oxford Nanopore	2012	Nanopore	None = Single Molecule	Electrical Conductivity	"Run Until" Sequencing

# Výkonnost jednotlivých metod

Instrument	Run time	Millions of Reads/run	Bases / read	Yield MB/run
3730xl (capillary)	2 hrs	0.000096	650	0.06
PacBio RS	2 hrs	0.01	860 – 1,500	5-10
454 GS Jr. Titanium	10 hrs	0.1	400	50
Ion Torrent – 314 chip	2.5 hrs	0.25	200	50
454 FLX Titanium	10 hrs	1	400	400
454 FLX+	20 hrs	1	650	650
Ion Torrent – 316 chip	3 hrs	1.6	200	320
Illumina MiSeq	26 hrs	4	150+150	1200
Ion Torrent – 318 chip	4.5 hrs	4	200	800
Illumina GAIIx	14 days	300	150+150	96,000
SOLiD – 5500xl	8 days	>1,410 <sup>d</sup>	75+35	155,100
Illumina HiSeq 1000	8.5 days	≤1500	100+100	≤300,000
Illumina HiSeq 2000	11.5 days	≤3000	100+100	≤600,000

# Chybovost jednotlivých metod

Platform	Primary Errors	Single-pass Error Rate (%)	Final Error Rate (%)
<b>3730xl (capillary)</b>	Substitution	0.1-1	0.1-1
<b>454</b>	Indel	1	1
<b>Illumina</b>	Substitution	~0.1 (85% of reads)	~0.1 (85% of reads)
<b>SOLiD</b>	A-T bias	~5	≤0.1
<b>Ion Torrent</b>	Indel	~1	~1
<b>PacBio RS</b>	CG deletions	~15	≤15
<b>Oxford Nanopore</b>	Deletions	≥4	4

## Traditional Sequencing vs. Next Generation Sequencing: Data Throughput

**1 x Illumina GAI**



**200+ of 3730xl**

**Vs.**



### Days vs. Years

**The Sequencing Landscape is Changing**

# Bioinformatika - největší brzda dalšího rozvoje

Basically, analyzing genomes in interaction with their environment is now feasible and accessible to anyone



# Sekvenační strategie

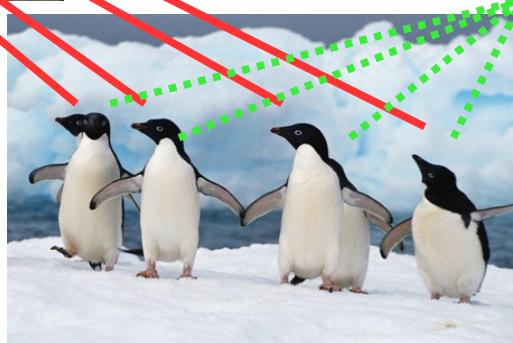
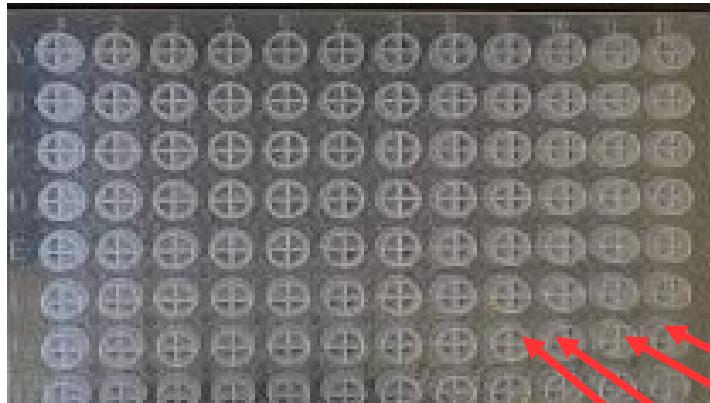
- nutno velmi dobře počítat než se začne sekvenovat
- celkový výtěžek sekvenování = **počet „reads“ \* délka „reads“ \* coverage**
- zásadně závisí na konkrétním cíli výzkumu a použité technologii

# Sekvenační strategie

...JEDEN VZOREK NA RUN JE MÁLO

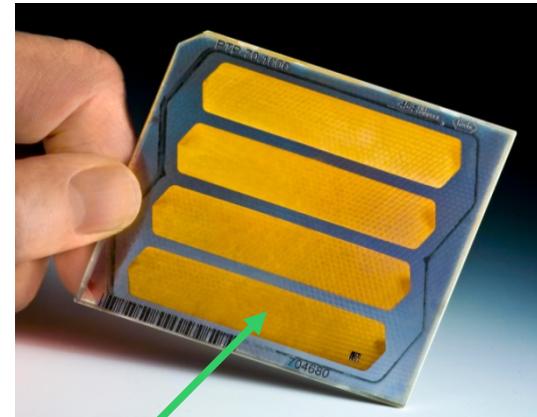
## Kapilární sekvenátor

U kapilárních sekvenátorů není problém přiřadit sekvenci k jednotlivým vzorkům na základě pozice na platíčku



## Sekvenátor druhé generace

U sekvenátorů druhé generace se najednou sekvenuje pool desítek až stovek vzorků



# Sekvenační strategie

...JEDEN VZOREK NA RUN JE MÁLO

Jednotlivé vzorky pro sekvenátory druhé generace se značí tzv. barcody  
(midy, tagy)

Krátká (obvykle 6-12bp) oligonukleotidová sekvence před primerem, která je specifická pro daný vzorek

Přiřazení identity jednotlých sekvencí k vzorkům probíhá bioinformaticky

BARCODE      PRIMER      SEQUENCE

<u>A</u> GCCTAGGTCA <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	
<u>T</u> TCGTAGGTCA <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	
<u>G</u> GGTAGGTCA <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	
<u>T</u> GCCTAGGTCA <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	
<u>T</u> GCGCAGGTCA <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	
<u>T</u> GCGTTGGTCAT <del>TTCGATGCGGT</del> CATGCCTGGATTAAAGCT.....	

# Sekvenační strategie

## AMPLIKONOVÉ SEKVENOVÁNÍ

PCR Amplifikace konkrétního úseku daného genomu pomocí specifických primerů (se sekvenačními adaptory)

Následná sekvenace

Taxonomické složení daného vzorku („metabarcoding“), variabilita konkrétních genů apod.

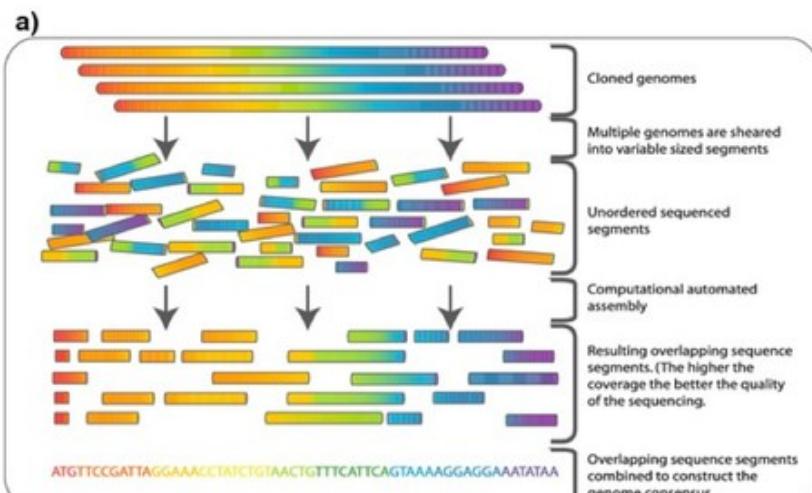
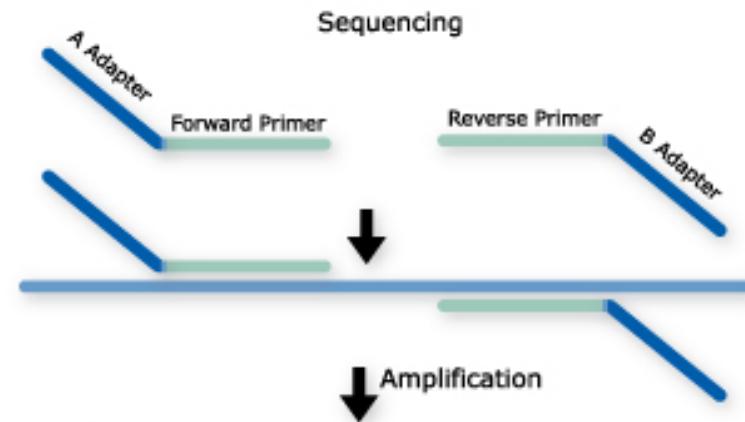
## SHOT GUN SEKVENOVÁNÍ

Fragmetace celogenomové DNA

Ligace sekvenačních adaptorů

Následná sekvenace náhodných fragmentů

*De novo assembly, resekvenování, transkriptomika, funkční složení daného společenstva*



**TO NENÍ VŠECHNO.....**

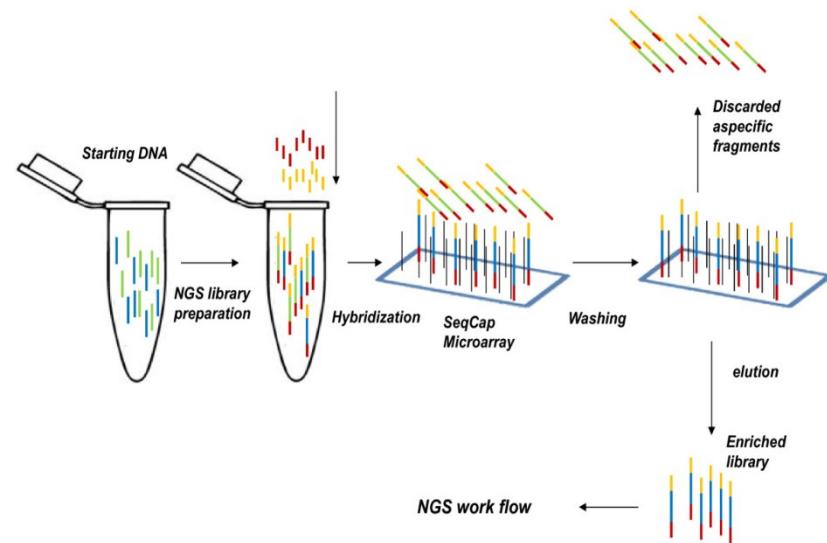
# Sekvenační strategie

Sequence capture + shot gun

Separace úseků genomu které nás zajímají na základě jejich hybridizace

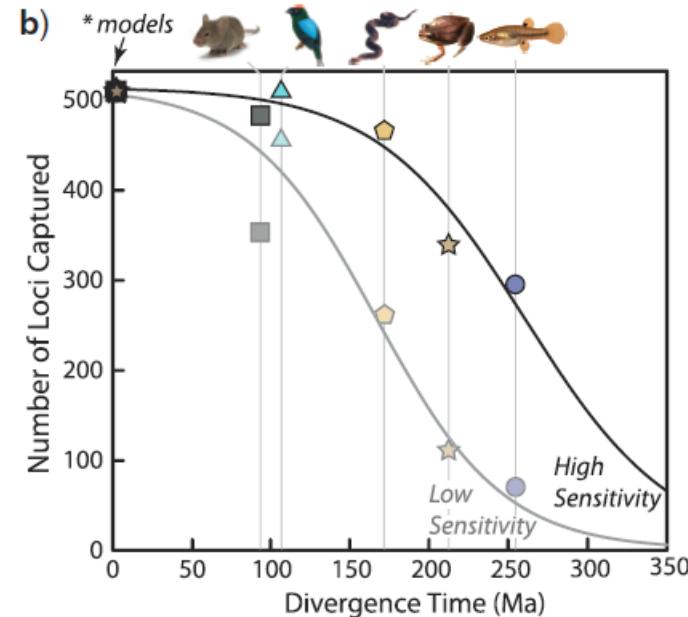
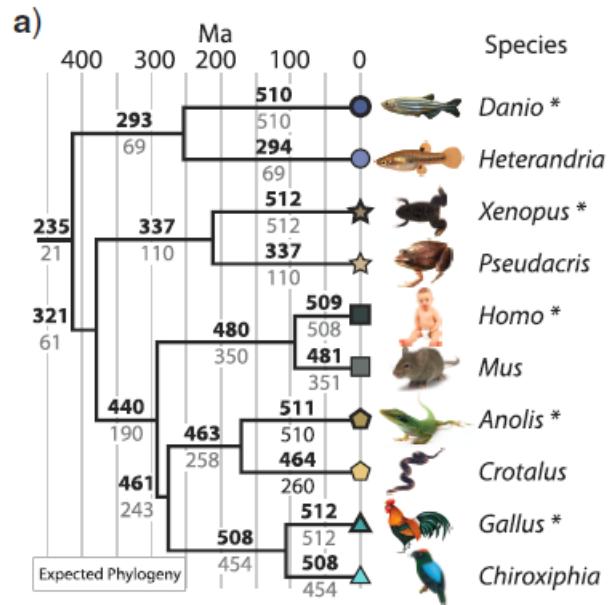
Následná sekvenace obohacených knihoven („enrichement“)

Nové markery (mikrosateličtvo apod.), kódující oblasti genomu („exom“), „anchored phylogenomics“ apod.



## Anchored phylogenomics

- hundreds of conserved loci
- hybridization enrichment
- u velmi příbuzných taxonů bude málo variability





CENTER FOR  
**ANCHORED PHYLOGENOMICS**  
ACCELERATING THE RESOLUTION OF LIFE™



: Juana, E. Handbook of the Birds of the World Alive (Lynx Edicions, 2015).

## A comprehensive phylogeny of birds (Aves) using targeted next-generation DNA sequencing

Richard O. Prum<sup>1,2\*</sup>, Jacob S. Berv<sup>3\*</sup>, Alex Dornburg<sup>1,2,4</sup>, Daniel J. Field<sup>2,5</sup>, Jeffrey P. Townsend<sup>1,6</sup>, Emily Moriarty Lemmon<sup>7</sup> & Alan R. Lemmon<sup>8</sup>



Nature Paper Resolves Bird Tree of Life

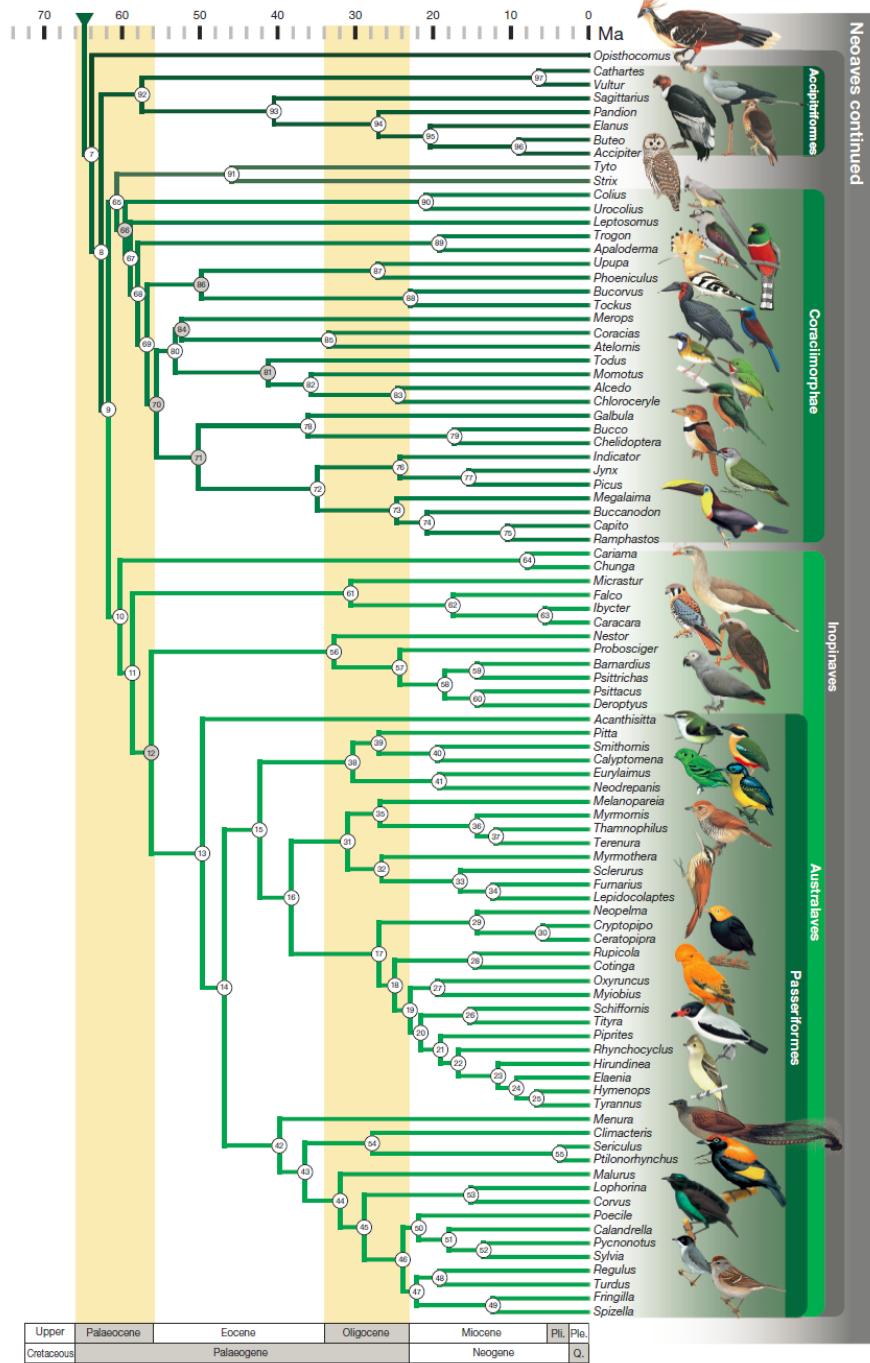
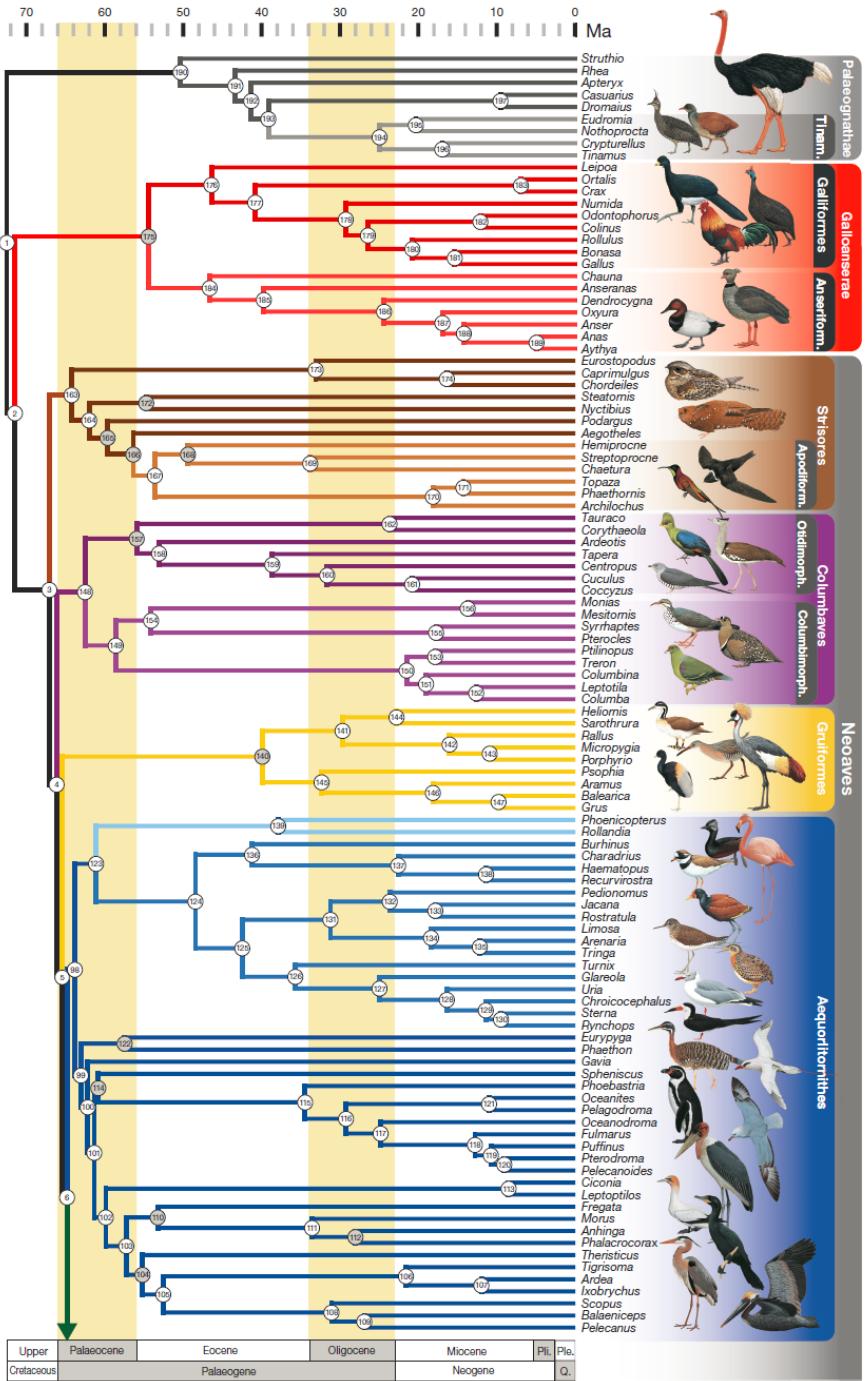
October 2015

Posted on October 6, 2015 by ameer

198 species

259 nuclear loci (ca 1500 bp each)

> 390 000 bp

**Aves**

Neoaves continued

# Sekvenační strategie

Long range PCR + shot gun

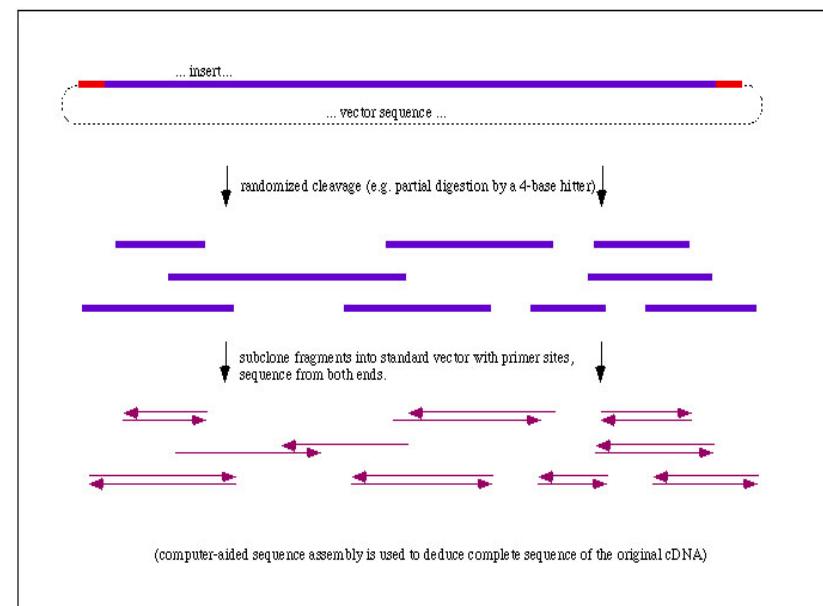
Dlouhé PCR produkty, které nejdou vcelku osekvenovat

Jejich fragmentace

Sekvenování fragmentů

Zpětná rekonstrukce původní sekvence („assembly“)

Použitelné pokud nás zajímá variabilita v jednolitém úseku DNA. Např. sekvenace mitochondrální DNA (3 různé PCR produkty).



# Sekvenační strategie

Sekvenování podél restrikčních míst

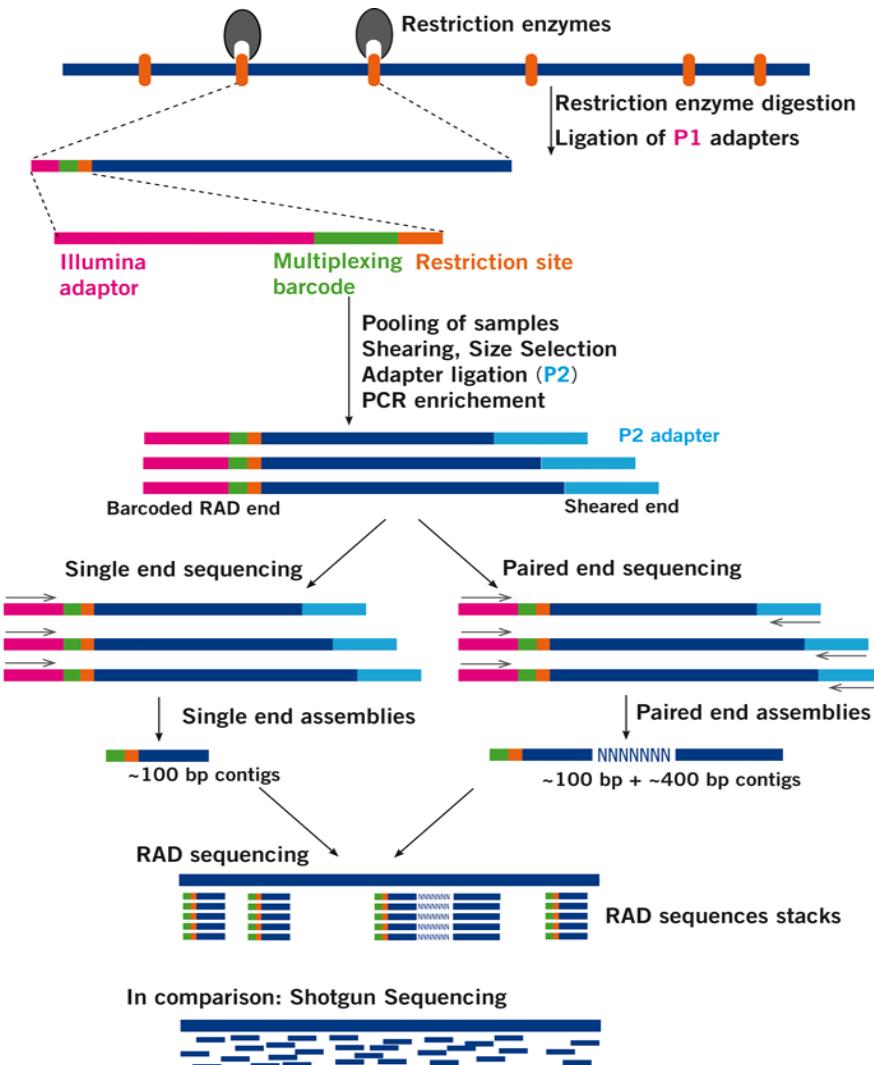
Fragmetace gelogenomové DNA po mocí restrikčních enzymů

Ligace sekvenačních adaptorů na výsledné fragmenty

Následná sekvenace podél restrikčních míst

Celogenomové scany genetické variabilnosti

Hledání SNPs, populační genomika (např. RAD-SEQ) apod.



# Aplikace

1. Celogenomové sekvenování de novo
2. Celogenomové resekvenování
3. Sekvenování amplikonů (PCR produktů)
4. Další aplikace - např. hledání klasických DNA markerů (mikrosatelity, SNPs)

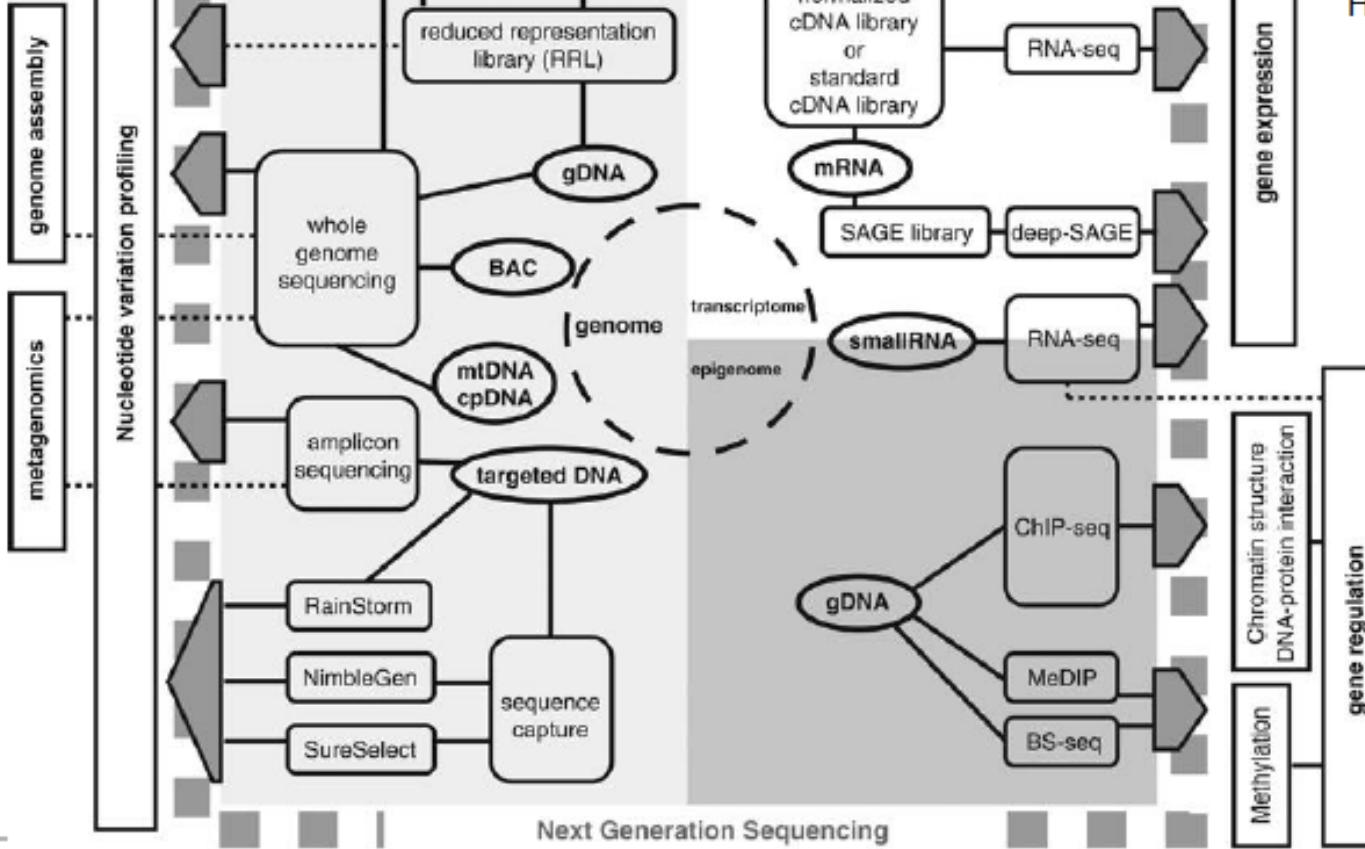
- Kinship analysis
- Pedigree reconstruction
- Outlier analysis
- Phylogeography
- Demography
- Introgression
- Host-parasite coevolution
- Genomic capture

- QTL mapping
- Association studies
- Admixture mapping

- Functional characterization
- Genome annotation
- Comparative genomics
- Alternative splicing
- Microarray design
- Candidate genes
- Exon capture

### development of molecular markers

### characterization



Applications of next generation sequencing in molecular ecology of non-model organisms, Heredity, 2011

# 1. Celogenomové sekvenování de novo

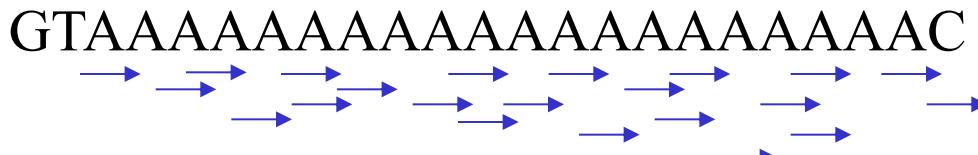
Problém: KRÁTKÝ READ LENGTH

- 400bp 454 FLX Roche (dnes i Illumina), 35-75bp Solid vs 800-1000bp Sanger
- nové technologie (PacBio, Nannopore) už s tím takový problém nemají

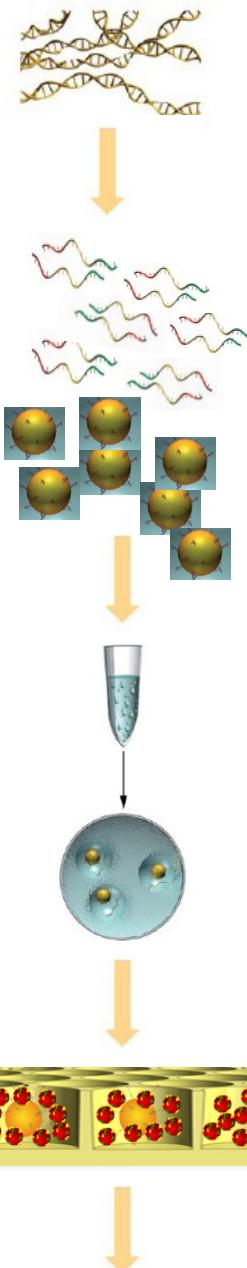


→ Uspořádání (assembly) ještě stále může být problém z hlediska výpočetní kapacity

!!!!!! REPETITIVNÍ OBLASTI delší než read length !!!!!



Zvláště komplexní eukaryotické genomy - úseky souvislých oblastí přerušených mezerami



# 1. Celogenomové sekvenování de novo

- získání kompletní uspořádané sekvence celých velkých eukaryotních genomů pomocí next-generation sequencing de novo je problém (ale to je nakonec i u Sangera)
- viry, prokaryota, malá eukaryota, mitochondrie/plastidy/plasmidy

**Genetic Detection of Lujo Virus, a New Hemorrhagic Fever in Southern Africa**

Thomas Briese<sup>1,2\*</sup>, Jan Gustavo Palacios<sup>1</sup>, Maia Gubler<sup>3</sup>, Stuart T. Nichol<sup>3</sup>, W. Ian Lipkin<sup>4</sup>, and Christopher D. Goldsmith<sup>5</sup>

<sup>1</sup> Center for Infection and Immunity, <sup>2</sup> National Institute for Communicable Diseases, <sup>3</sup> Rocky Mountain Laboratories, Centers for Disease Control and Prevention, <sup>4</sup> Department of Epidemiology, Columbia University, <sup>5</sup> Biotechnology Core Facility, University of Texas Health Science Center at San Antonio

**Abstract**

Lujo virus (LUJV), a new Old World discovered in nosocomial transmission extracts from serum arbovirus isolates. LUJV is a novel, genetically distinct, highly pathogenic arenavirus.

**b**



2009

2015

## 2. Celogenomové resekvenování

- podobné problémy jako u de novo, ale méně (větší strukturální přestavby..)

### KOMPARATIVNÍ GENOMIKA

- viry, prokaryota, malá eukaryota
- mitochondrie/plastidy/plasmidy

### ANCIENT (mt) DNA

- různé směsné, degradované vzorky, např. fosilie



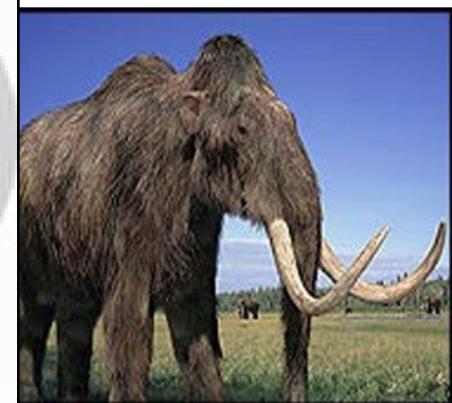
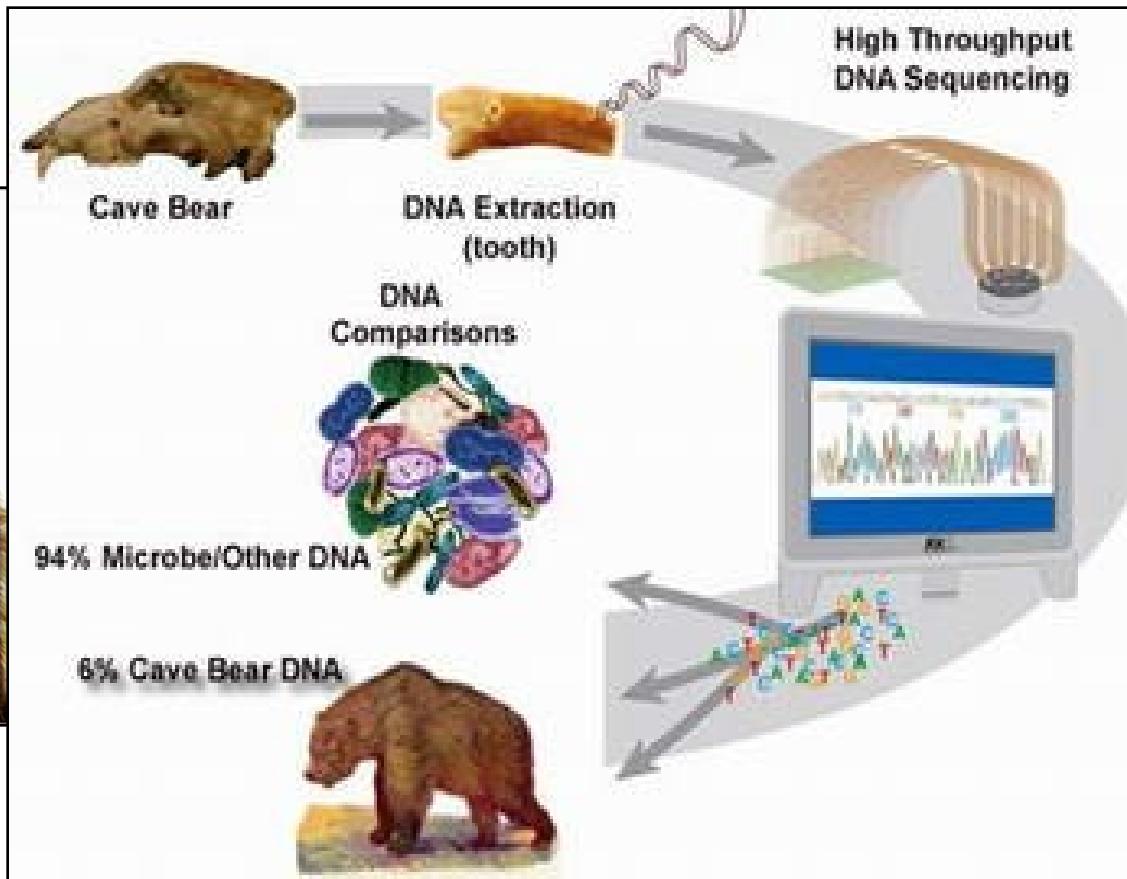
---

### A Complete Neandertal Mitochondrial Genome Sequence Determined by High-Throughput Sequencing

Richard E. Green,<sup>1,\*</sup> Anna-Sapfo Malaspinas,<sup>2</sup> Johannes Krause,<sup>1</sup> Adrian W. Briggs,<sup>1</sup> Philip L.F. Johnson,<sup>3</sup> Caroline Uhler,<sup>4</sup> Matthias Meyer,<sup>1</sup> Jeffrey M. Good,<sup>1</sup> Tomislav Maricic,<sup>1</sup> Udo Stenzel,<sup>1</sup> Kay Prüfer,<sup>1</sup> Michael Siebauer,<sup>1</sup> Hernán A. Burbano,<sup>1</sup> Michael Ronan,<sup>5</sup> Jonathan M. Rothberg,<sup>6</sup> Michael Egholm,<sup>5</sup> Pavao Rudan,<sup>7</sup> Dejana Brajković,<sup>8</sup> Željko Kučan,<sup>7</sup> Ivan Gišić,<sup>7</sup> Mårten Wikström,<sup>9</sup> Liisa Lakkonen,<sup>10</sup> Janet Kelso,<sup>1</sup> Montgomery Slatkin,<sup>2</sup> and Svante Pääbo<sup>1</sup>

# Ancient Genomes Resurrected

- Degraded state of the sample → mitDNA sequencing
- Nuclear genomes of ancient remains: cave bear, mammoth, Neanderthal ( $10^6$  bp)



Problems: contamination modern humans and coisolation bacterial DNA

### 3. Sekvenování amplikonů (PCR produktů)

SMĚSNÉ VZORKY - paralelní sekvenování nahrazuje klonování

#### Metagenomika (= hlavně prokaryota)

- Celé společenstvo půdních, vodních mikroorganismů, střevní mikroflóra - **mikrobiom**
- PCR genu 16S rRNA
- lze i kvantifikovat

#### Metabarcoding (= hlavně eukaryota, ale dnes používáno jako obecný termín)

- COI gen, příp. jiný barcodingový marker
- složení potravy, monitoring společenstev

# Metabarcoding: Taxonomické složení společenstva v environmentální DNA na základě taxonomicky informativního úseku DNA (cyt b, COI, ITS, rRNA...)

## Princip

- Směsný vzorek environmentální DNA
- Amplifikace pomocí primerů specifických pro cílovou skupinu, pokrývající taxonomicky informativní úsek (COI, 16s/18s RNA...)
- Paralelní sekvenování
- Filtrování nekvalitních sekvencí
- Klastrování na základě sekvenční podobnosti do OTUs („operational taxonomic units“)
- Jejich taxonomické zařazení na základě referenčních databází

Využití: Analýza druhového vzorku kde lze makroskopicky jednotlivé druhy obtížně odlišit

- Potravní analýza z trusu
- Vzorky půdy
- Mikrobiální společenstva
- Permafrost
- Exotická/špatně probádaná společenstva
- Druhově bohatá společenstva („insect traps“ v tropech)
- Rutinní analýza velkého množství vzorků

# Metabarcoding

Taxonomické složení společenstva na základě taxonomicky informativního úseku DNA

Alternativy:

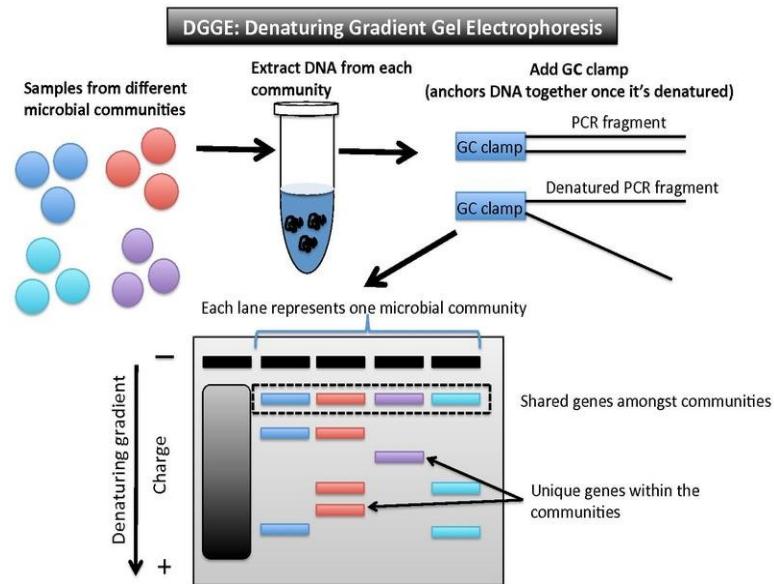
- Klonování amplikonů a sekvenování klonů
- Specifické elektroforézy - např. DGGE

Výhody paralelního sekvenování

- Cenově i časově míň nákladné
- Lépe se zachytí vzácné taxony (zlomky promile)

Ale:

- Riziko umělého navýšení diversity díky chybám při procesování dat
- Do jaké míry jsou referenční databáze dostatečné ke klasifikaci vzorků?
- Lze použít tato data kvantitativně a nebo vypovídají jen o přítomnosti/nepřítomnosti?



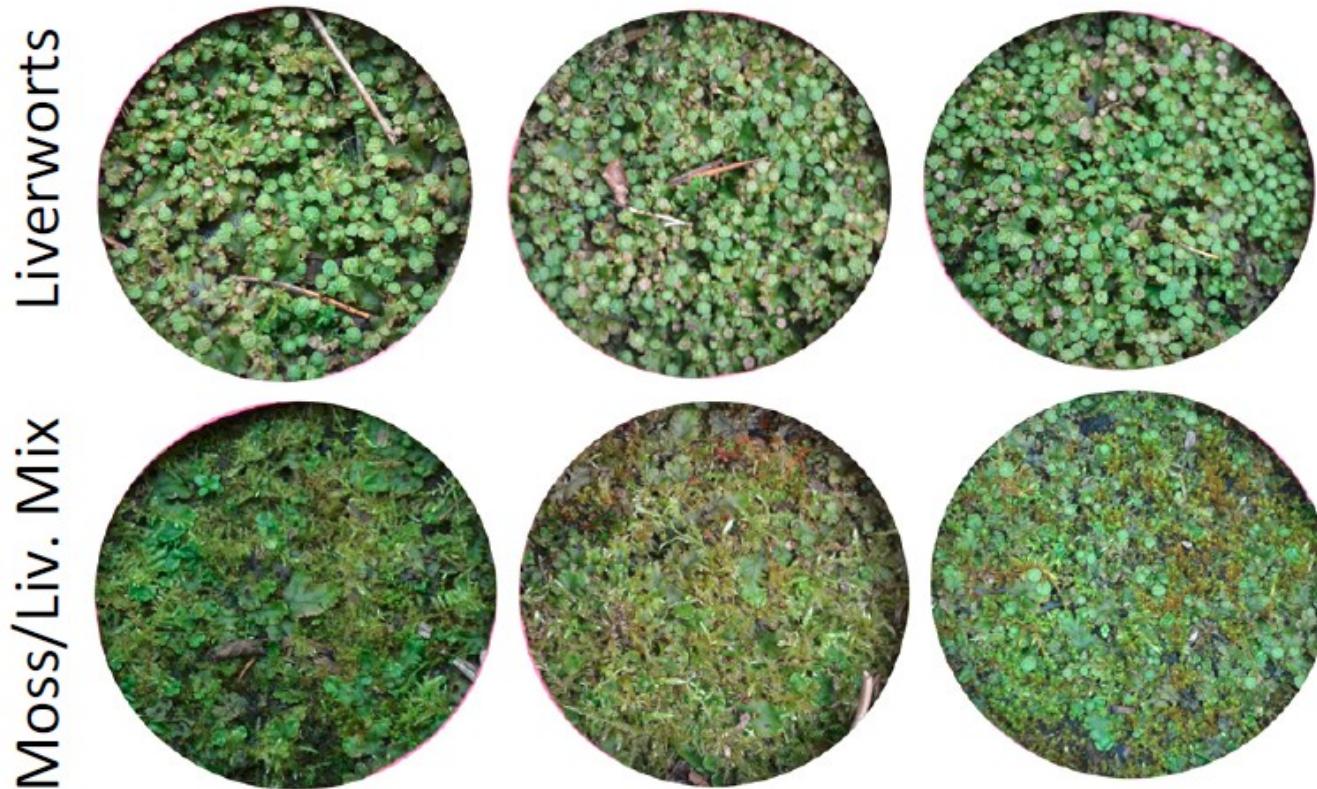
# Metabarcoding – příklady využití

- Liverwort only vs. Mixed moss/liverwort (50:50)
- Collected at fixed distance from each other
- 3 replicates each



Společenstvo eukaryot ve vrchní vrstvě půdy

# Metabarcoding - příklady využití



Společenstvo eukaryot ve vrchní vrstvě půdy

Mark Blaxter, Edinburgh Genomics

# Metabarcoding – příklady využití



## Eukaryotic nSSU barcoding

6 samples

3 replicates each of two ecosystems

1200 clusters/mm<sup>2</sup>

2% phiX174 spike-in

17 million raw pass filter pairs

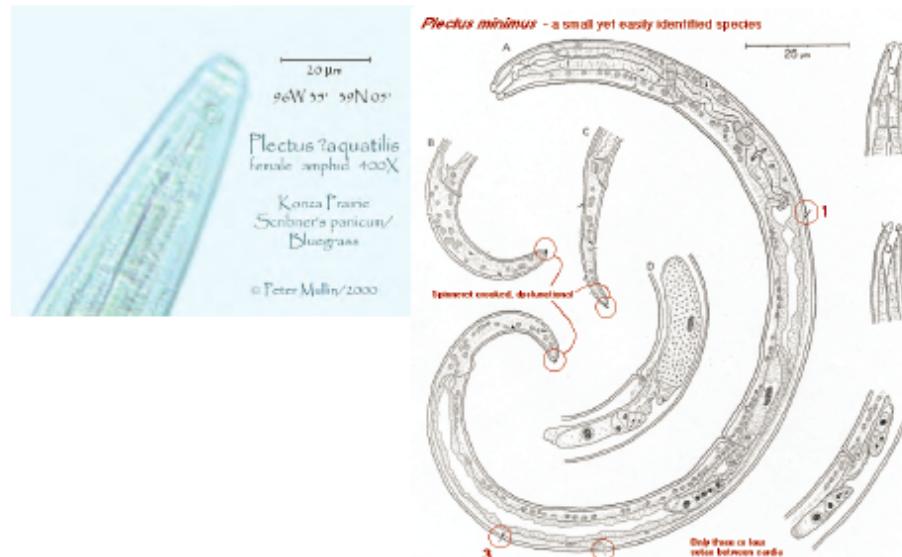
# Metabarcoding – příklady využití

Phylum	98% MOTU	proportion of total reads
<b>Nematoda</b>	2862	.3275761886787317
Dikarya	6965	.1894664458485315
Cercozoa	4254	.085598403024025
<b>Annelida</b>	682	.0688691096605889
<b>null</b>	<b>4867</b>	<b>.0579833558234776</b>
Streptophyta	614	.0579039901203119
Oomycetes	487	.0569565860018453
Bacillariophyta	666	.0250973907279004
<b>Archropoda</b>	286	.0218196255280743
Fungi_incertae_sedis	417	.0195828162900598
<b>Tardigrada</b>	158	.0169930788889338
Chytridiomycota	473	.0138886146448126
Ciliophora	544	.009428990604366
Chlorophyta	473	.0080418161403385
Synurophyceae	34	.005969106037372
Centraeobidea	288	.0053245951821951
<b>Platyhelminthes</b>	94	.0051997954895359
Chrysophyceae	198	.005026302829234
Nucleariaeidae	61	.0048583696022456
Tubulinida	194	.0025431531840504
Blastocladiomycota	76	.002108558862609
Apicomplexa	74	.0016743479503615
Flabellinea	53	.0013524759319671
Dinophyceae	139	.000952196733392
Bicosoecida	46	.0007160166698649
Uncultured_banisveld_eukaryote	17	.0005992685702805
Micronuclearia_podoventralis	20	.0005377313946375
Codonosigidae	30	.0005166438889655
Ichthyophionida	28	.0004928725189351
Px_clade	60	.0004213667042472
Fungal_endophyte_sp_sx01	4	.0003439180470516
Heterotrophicidae	27	.0002599514335574
Hypothochytriomycetes	9	.0002386722232883
Salpingoecidae	13	.000235604949736
Fungal_sp_gmg_c6	37	.0002262114244821
Eustigmatophyceae	14	.0001882539142724
Capsaspora	10	.0001878705050784
Stramenopile_sp_mast_l2_kkts_d3	15	.000173684364899
Raphidophytes	31	.0001799826956958
Schizoprymida	16	.0001593457036558
Entomostoma_samples	8	.0001591916745086
Trichoptera_perforans_atcc50562	5	.0001546275147474
Labyrinthulida	16	.00015521436503991
<b>Gastropoda</b>	—	.00015998975531
Telomata	—	.00010991077377918
<b>Mollusca</b>	26	.0000968072826276
Apacomyidae	3	.000025897814932
Scilimnoeidae	11	.000013478493141
Acanthocystidae	4	.0000297142125379
Voromorpha	4	.000019119165908
Lekanostriidae_sp_atcc_pra-24	1	.000015231452343986
<b>Isopoda</b>	10	.0000231962542993
Acyrtosomatidae	3	.0000090101160599
Periscidae	3	.000004609103264
Hystricidae	3	.0000044592057314
Echinidae	2	.0000038340919404
Glomeromycota	2	.000003672735523
Eukaryote_marine_close_mel-24	—	.0000030045651642
Fungi_sp_3cas90	—	.0000021067505672
Cryptonematidae	2	.000001502275821
Malawimorpha	—	.0000009175820
Phascolosomophyceae	—	.000000916523551
Chordata	—	.000000384919194
Uncultured_silicoflag	—	.000000191704597

Eight animal phyla represented

Most frequent are **Nematoda**

Most frequent “98% MOTU” is  
**Plectus (cf aquatilis)**



Mark Blaxter, Edinburgh Genomics

# Metabarcoding – příklady využití

Monitoring vzácných, nedávno popsaných druhů savců na základě sekvenování krve pijavic

Výrazně větší úspěšnost prokázání přítomnosti než za použití klasických technik – fotopasti, terénní pozorování apod.

## Correspondences

### Screening mammal biodiversity using DNA from leeches

Ida Bærholm Schnell<sup>1,2,†</sup>,  
Philip Francis Thomsen<sup>2,†</sup>,  
Nicholas Wilkinson<sup>3</sup>,  
Morten Rasmussen<sup>2</sup>,  
Lars R.D. Jensen<sup>1</sup>, Eske Willerslev<sup>2</sup>,  
Mads F. Bertelsen<sup>1</sup>,  
and M. Thomas P. Gilbert<sup>2,\*</sup>

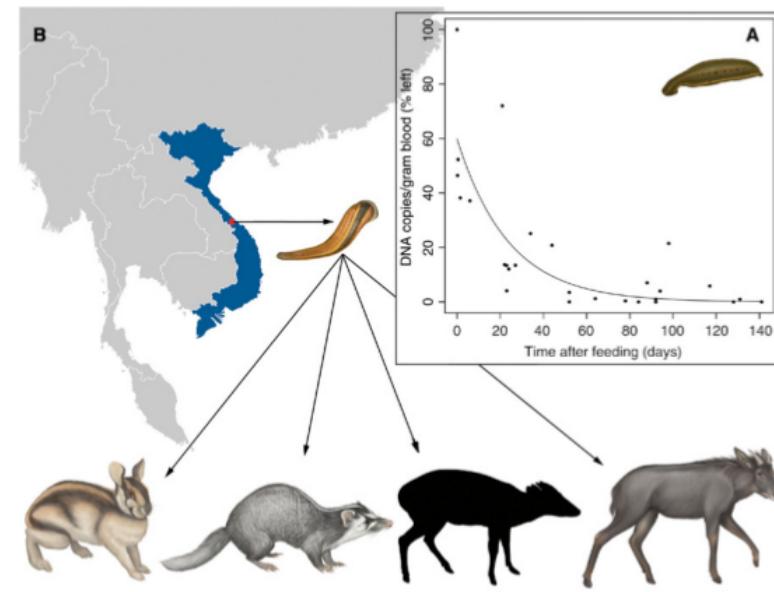


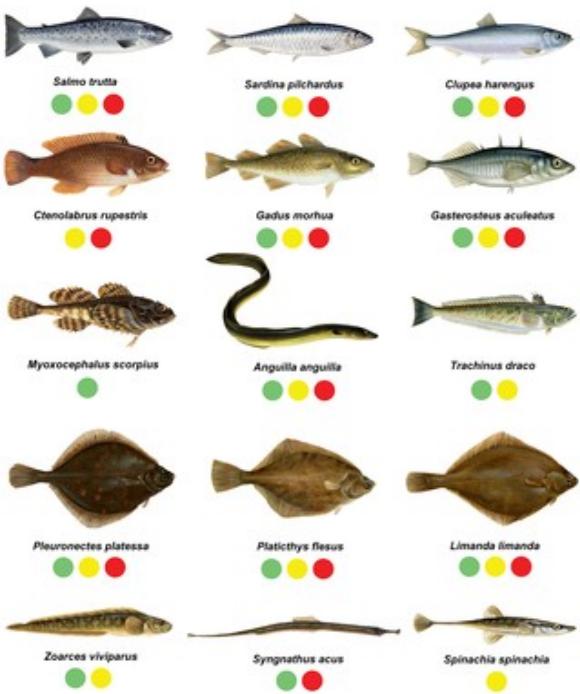
Figure 1. Monitoring mammals with leeches.

(A) Survival of mtDNA in goat blood ingested by *Hirudo medicinalis* over time, relative to freshly drawn sample (100%, ca.  $2.4E+09$  mtDNA copies/gram blood). Mitochondrial DNA remained detectable in all fed leeches, with a minimum observed level at  $1.6E+04$  mtDNA/gram blood ingested. The line shows a simple exponential decay model,  $p < 0.001$ ,  $R^2 = 0.43$  (Supplemental information). (B) Vietnamese field site location and examples of mammals identified in *Hæmodipsa* spp. leeches. From left to right: Annamite striped rabbit, small-toothed ferret-badger Truong Son muntjac (coat coloration and markings remain unknown), serow. Pictures do not reflect true size proportions. See also Supplemental information.

# Metabarcoding – příklady využití

Detekce ryb pomocí izolace eDNA z mořské vody

-také jedna z nejefektivnějších metod



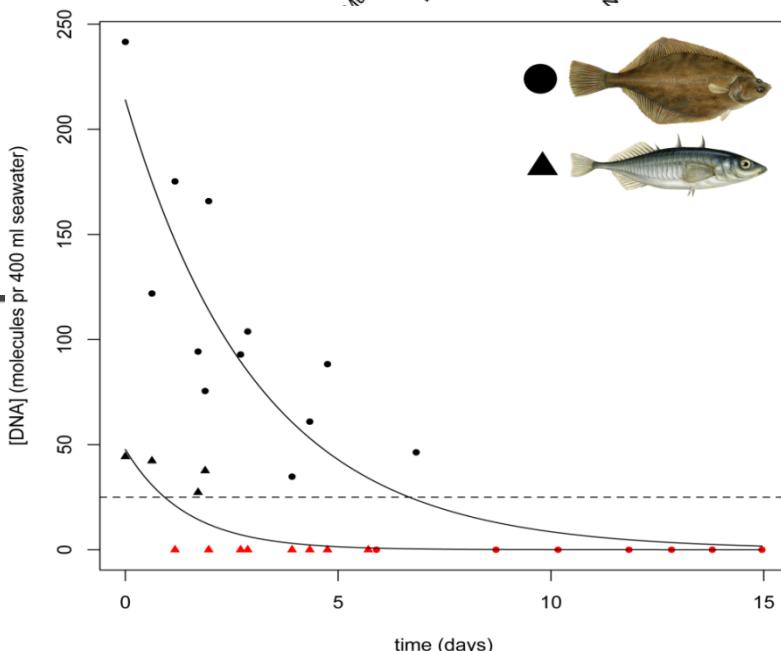
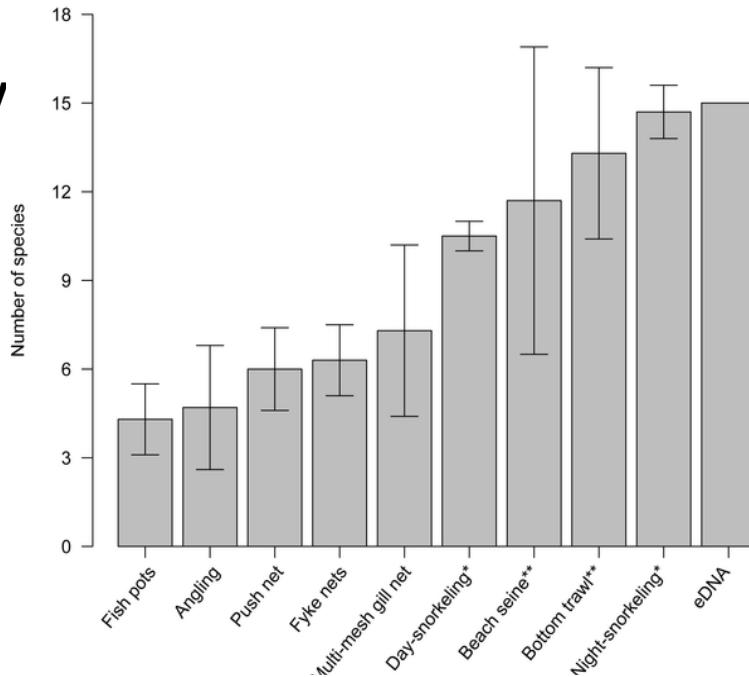
OPEN ACCESS Freely available online

PLOS ONE

## Detection of a Diverse Marine Fish Fauna Using Environmental DNA from Seawater Samples

Philip Francis Thomsen<sup>1\*</sup>, Jos Kielgast<sup>1</sup>, Lars Lønsmann Iversen<sup>2</sup>, Peter Rask Møller<sup>3</sup>, Morten Rasmussen<sup>1</sup>, Eske Willerslev<sup>1\*</sup>

<sup>1</sup> Centre for GeoGenetics, Natural History Museum of Denmark, University of Copenhagen, Øster Voldgade, Copenhagen, Denmark, <sup>2</sup> Freshwater Biology Section, Department of Biology, University of Copenhagen, Helsingørsgade, Hillerød, Denmark, <sup>3</sup> Vertebrate Department, Natural History Museum of Denmark, University of Copenhagen, Universitetsparken, Copenhagen, Denmark



# Metabarcoding – příklady využití

## Analýza potravy

Podíl hospodářských zvířat v potravě irbise je minimální



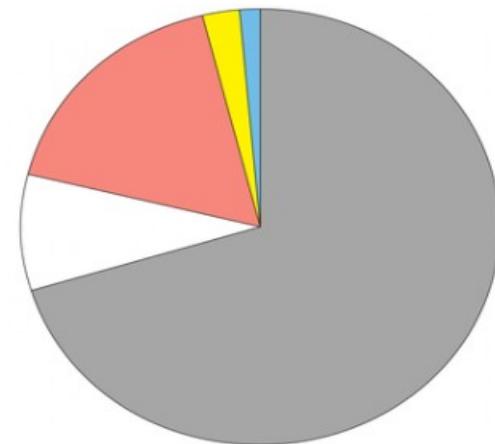
OPEN ACCESS Freely available online

PLOS one

### Prey Preference of Snow Leopard (*Panthera uncia*) in South Gobi, Mongolia

Wasim Shehzad<sup>1</sup>, Thomas Michael McCarthy<sup>2</sup>, Francois Pompanon<sup>1</sup>, Lkhagvajav Purevjav<sup>3</sup>, Eric Coissac<sup>1</sup>, Tiayba Riaz<sup>1</sup>, Pierre Taberlet<sup>1\*</sup>

<sup>1</sup> Laboratoire d'Ecologie Alpine, Centre National de la Recherche Scientifique, Unité Mixte de Recherche 5553, Université Joseph Fourier, Grenoble, France, <sup>2</sup> Snow Leopard Program, Panthera, New York, New York, United States of America, <sup>3</sup> Snow Leopard Conservation Fund, Ulaanbaatar, Mongolia



Siberian ibex  
(*Capra sibirica*)

Domestic sheep  
(*Ovis aries*)

Argali sheep  
(*Ovis ammon*)

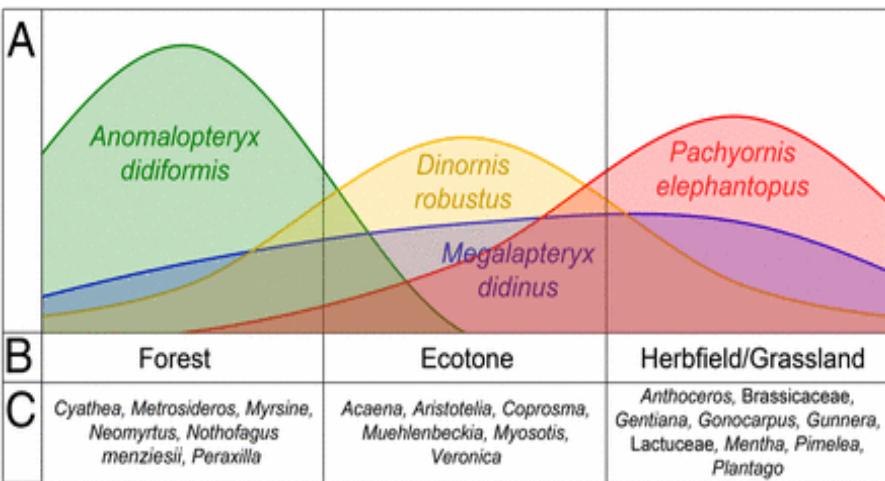
Chukar partridge  
(*Alectoris chukar*)

Domestic goat  
(*Capra hircus*)

# Metabarcoding – příklady využití

## Analýza složení společenstva na základě ancient DNA z koprolitů moa (Nový Zéland)

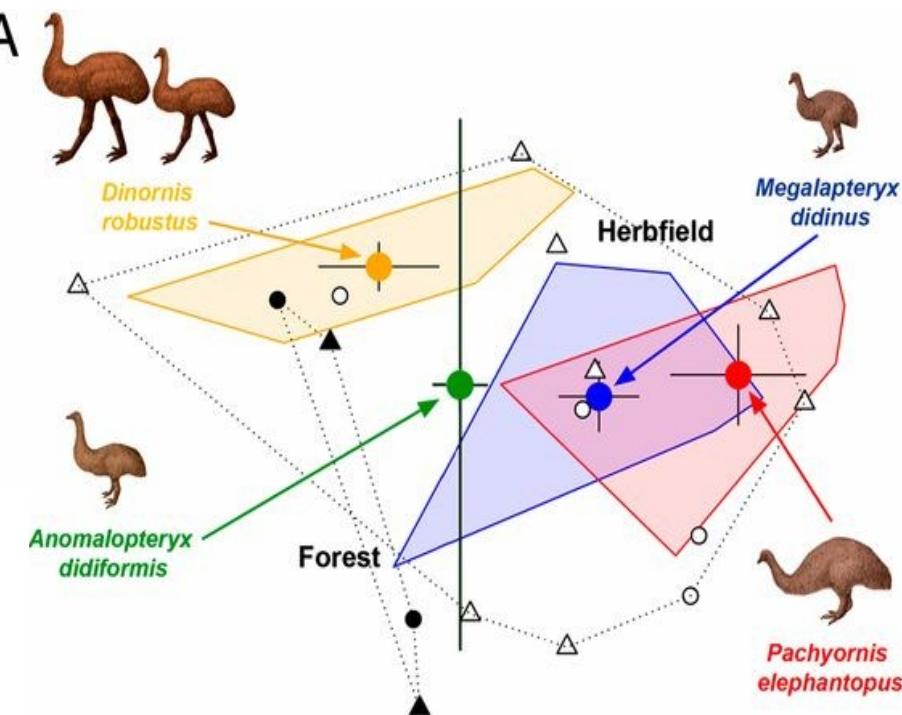
Umožňuje odhadnout typ prostředí které jednotlivé druhy obývaly a separaci ekologických nich



### Resolving lost herbivore community structure using coprolites of four sympatric moa species (Aves: Dinornithiformes)

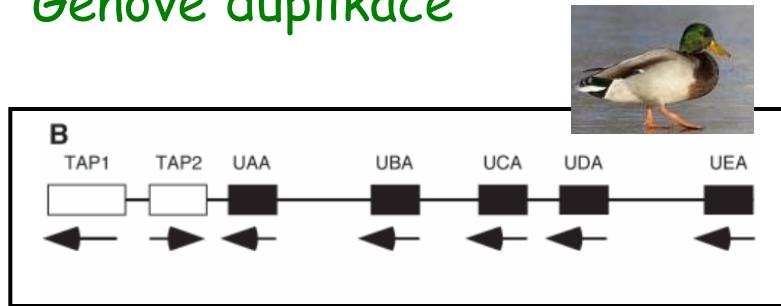
Jamie R. Wood<sup>a,1</sup>, Janet M. Wilmshurst<sup>b</sup>, Sarah J. Richardson<sup>a</sup>, Nicolas J. Rawlence<sup>b,2</sup>, Steven J. Wagstaff<sup>a</sup>, Trevor H. Worthy<sup>c,3</sup>, and Alan Cooper<sup>b</sup>

<sup>a</sup>Landcare Research, Lincoln, Canterbury 7640, New Zealand; <sup>b</sup>Australian Centre for Ancient DNA, University of Adelaide, Adelaide, SA 5005, Australia;



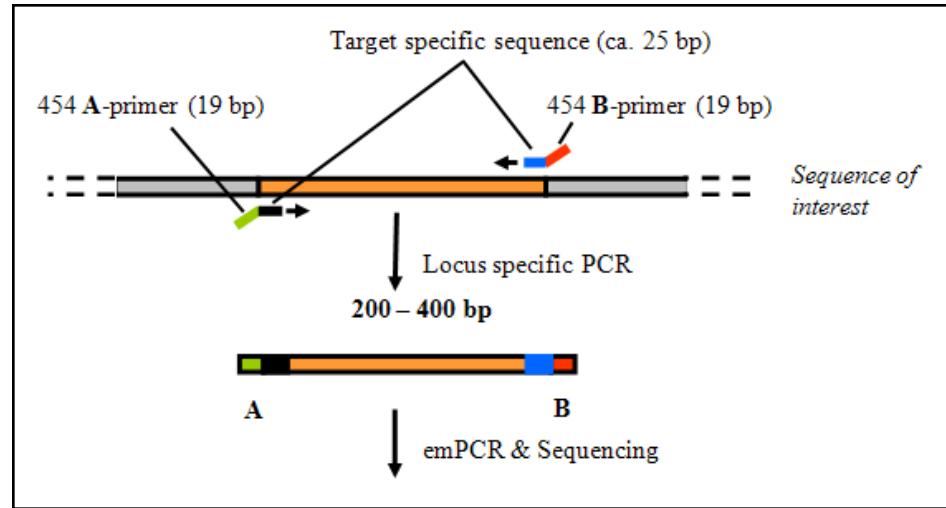
### 3. Sekvenování amplikonů (PCR produktů)

#### Genové duplikace



A-adaptor      MID      Target specific

Označí jedince  
Amplifikuje všechny kopie MHC genů  
Potřeba k emPCR, sekvenování..

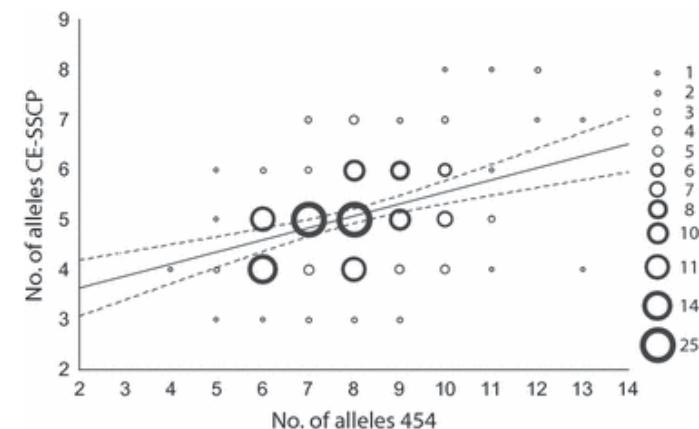
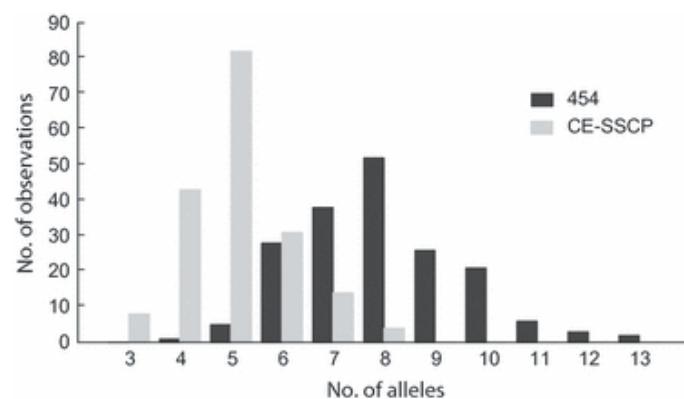


192 jedinců u 454 pyrosekvenování

# Amplikonové sekvenování

## MHC u hýla rudého

- 454 má větší rozlišovací schopnost než SSCP + klonování



MOLECULAR ECOLOGY  
RESOURCES

Molecular Ecology Resources (2012) 12, 285–292

doi: 10.1111/j.1755-0998.2011.03082.x

Evaluation of two approaches to genotyping major histocompatibility complex class I in a passerine—CE-SSCP and 454 pyrosequencing

MARTA PROMEROVÁ,\* WIESŁAW BABIK,† JOSEF BRYJA,\* TOMÁŠ ALBRECHT,\*‡ MICHAŁ STUGLIK†  
and JACEK RADWAN§

## 4. Další aplikace - hledání nových genetických markerů

### Mikrosatelity

- sekvenování obohacených knihoven

### SNPs

- kompletní genomické sekvence pro hledání diagnostických SNPs
- např. RAD-sequencing

# Hledání nových genetických markerů - mikrosateliity

## Obvyklý postup:

- Obohacení genomické knihovy o mikrosateliteové motivy – sequence capture
- Sekvenování obohacených knihoven
- Detekce mikrosateliitů a navržení vhodných primerů

MOLECULAR ECOLOGY  
RESOURCES

Molecular Ecology Resources (2011) 11, 638–644 doi: 10.1111/j.1755-0998.2011.0295

### High-throughput microsatellite isolation through 454 GS-FLX Titanium pyrosequencing of enriched DNA libraries

THIBAUT MALAUSA,\* ANDRÉ GILLES,† EMESE MEGLÉCZ,‡ HÉLÈNE BLANQUART,‡ STÉPHANIE DUTHOY,‡ CAROLINE COSTEODOAT,‡ VINCENT DUBUT,‡ NICOLAS PECH,‡ PHILIPPE CASTAGNONE-SERENO,\* CHRISTOPHE DÉLYE,§ NICOLAS FEAU,¶ PASCAL FREY,\*\* PHILIPPE GAUTHIER,‡ THOMAS GUILLEMAUD,\* LAURENT HAZARD,‡ VALÉRIE LE CORRE,§ BRIGITTE LUNG-ESCARMANT,¶ PIERRE-JEAN G. MALÉ,§§ STÉPHANIE FERREIRA,‡ and JEAN-FRANÇOIS MARTIN‡

\*INRA, UMR 1301 IBSV INRA/UNSA/CNRS, 400 Route des Chappes, BP 167, 06903 Sophia-Antipolis Cedex, France, †Aix-Marseille Université, CNRS, IRD, UMR 6116 – IMEP, Equipe Evolution Génome Environnement, Centre Saint-Charles, Case 36 3 Place Victor Hugo, 13331 Marseille Cedex 3, France, ‡Genoscreen, Genomic Platform and R&D, Campus de l’Institut Pasteur, rue du Professeur Calmette, Bâtiment Guérin, 59000 Lille, France, §INRA, UMR 1210 Biologie et Gestion des Adventices, 17 rue Sully, 21000 Dijon, France, ¶INRA, UMR 1202 BIOGECO, Equipe de Pathologie Forestière, Domaine de Pierrotton, 69 route d’Arcachon, 33612 Cestas Cedex, France, \*\*INRA, Nancy-Université, UMR 1136, Interactions Arbres – Microorganismes, IFR 11 54280 Champenoux, France, ††UMR CBGP (INRA/IRD/Cirad/Montpellier SupAgro), Campus International de Baillarguet, CS 30016, 34988 Montferrier-sur-Lez Cedex, France, ‡‡INRA – UMR 1248 AGIR, BP 52627, 31326 Castanet-Tolosan Cedex, France §§UMR Evolution et Diversité Biologique (Université Toulouse III; CNRS), 118 Route de Narbonne, 31062 Toulouse, France



allgenetics

HOME COMPANY SERVICES ▾

HOME » SERVICES » Microsatellite Development

#### Experts in Microsatellite Development

Microsatellites (also known as short tandem repeats) are repetitive DNA elements usually found in non-coding regions of the genome. They have high mutation rates, and therefore are frequently highly polymorphic. Variations in the number of repetitions generate different alleles. This makes them appropriate molecular markers for population genetics and molecular ecology projects.

#### We develop microsatellite markers for your study species

At AllGenetics, we use next-generation sequencing to obtain primer pairs which amplify polymorphic microsatellite loci in your study species. Genomic DNA is used to generate genomic libraries. We usually enrich these libraries with 4 to 6 different microsatellite motifs. However, we can customise the number of motifs to your needs. We obtain thousands of microsatellite-containing reads by using high-throughput sequencing. Our bioinformaticians analyse these reads for primer design. The primers obtained are multiplexed and tested for polymorphism in a number of individuals from different populations.

#### How we work

High quality DNA at a concentration of 100 ng/ $\mu$ L in a minimum volume of 50  $\mu$ L from a number of individuals is required. Alternatively, we can isolate DNA from your samples. These samples should be adequately preserved to ensure DNA integrity. We will deliver tested primer pairs which amplify polymorphic loci for your study species. A detailed methodological report and all sequencing reads generated will also be provided.

Our microsatellite development projects are divided into four steps. For your convenience, we can carry out the entire project or only the parts you need.

OPEN ACCESS Freely available online

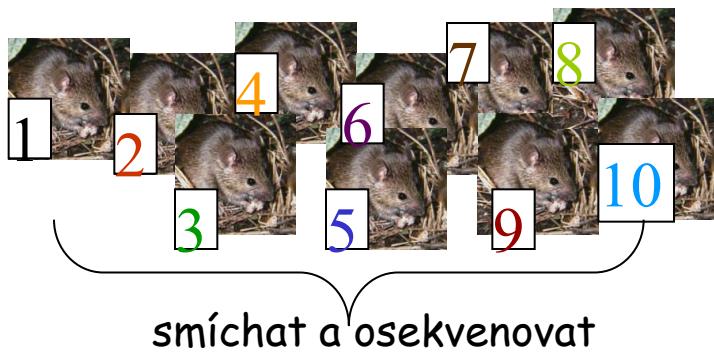
PLOS ONE

### 32 species validation of a new Illumina paired-end approach for the development of microsatellites

Stacey L. Lance<sup>1</sup>, Cara N. Love<sup>1</sup>, Schyler O. Nunziata<sup>1</sup>, Jason R. O'Bryhim<sup>1</sup>, David E. Scott<sup>1</sup>, R. Wesley Flynn<sup>1</sup>, Kenneth L. Jones<sup>2</sup>

<sup>1</sup> Savannah River Ecology Laboratory, University of Georgia, Aiken, South Carolina, United States of America, <sup>2</sup> Department of Biochemistry and Molecular Genetics, University of Colorado School of Medicine, Aurora, Colorado, United States of America

## Hledání diagnostických SNP (např. pro studium hybridizace)



G  
G  
T  
T  
C  
G  
G  
T  
G



10 jedinců

G  
GG  
GGG  
GGG  
GG  
G  
G



10 jedinců

T  
T  
T  
T  
T  
T  
T  
T

# Hledání nových SNPs - RAD-sequencing

Sekvenování podél restrikčních míst

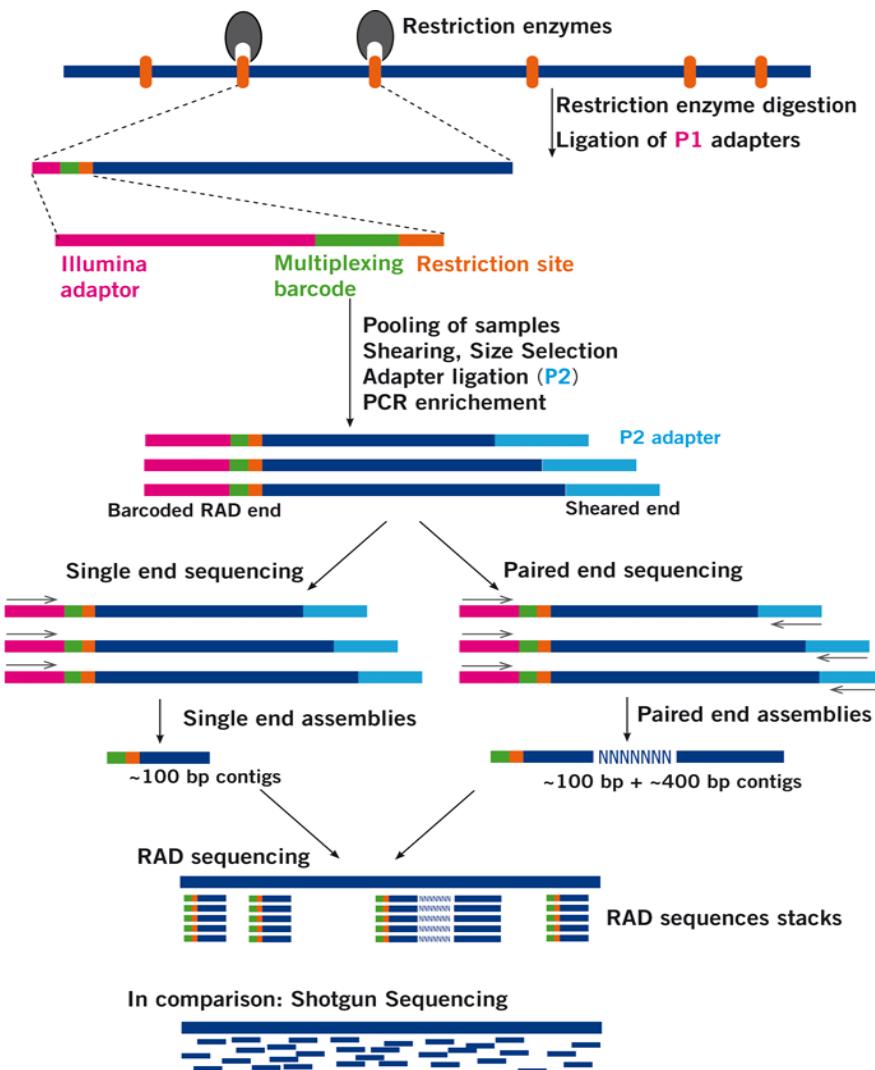
Fragmetace gelogenomové DNA po mocí restrikčních enzymů

Ligace sekvenačních adaptorů na výsledné fragmenty

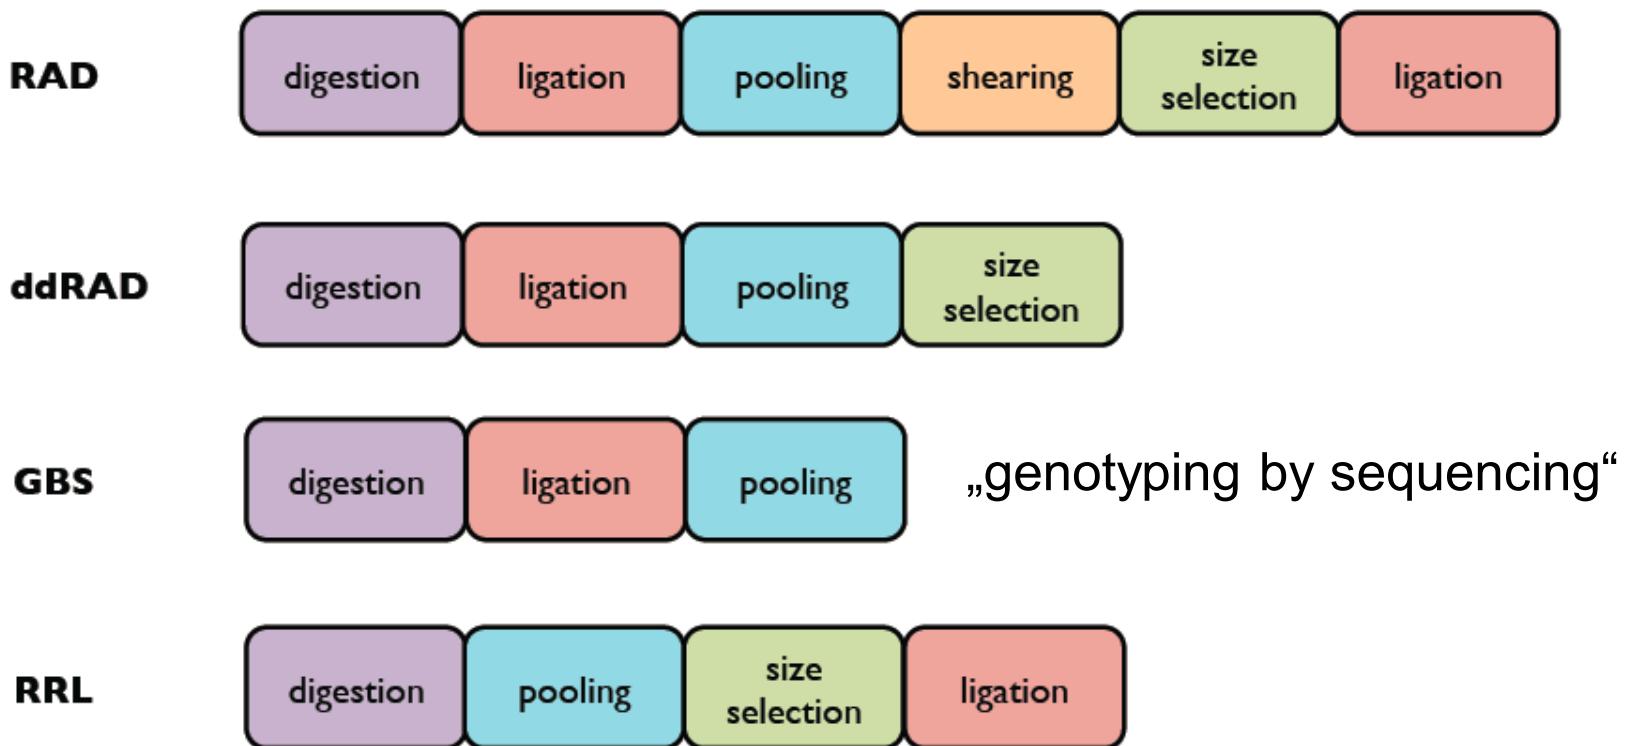
Následná sekvenace podél restrikčních míst

Celogenomové scany genetické variabilnosti

*Hledání SNPs, populační genomika (např. RAD-SEQ) apod.*



# Sekvenování podél restrikčních míst



# RAD vs. ddRAD

A

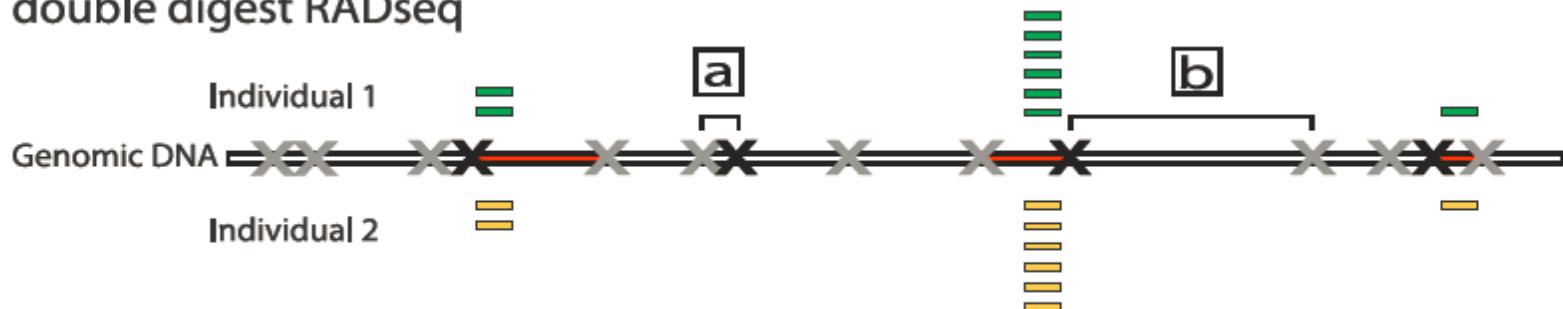
RAD sequencing

X Rare cut site  
X Common cut site  
— Genomic interval present in library  
— Sequence reads

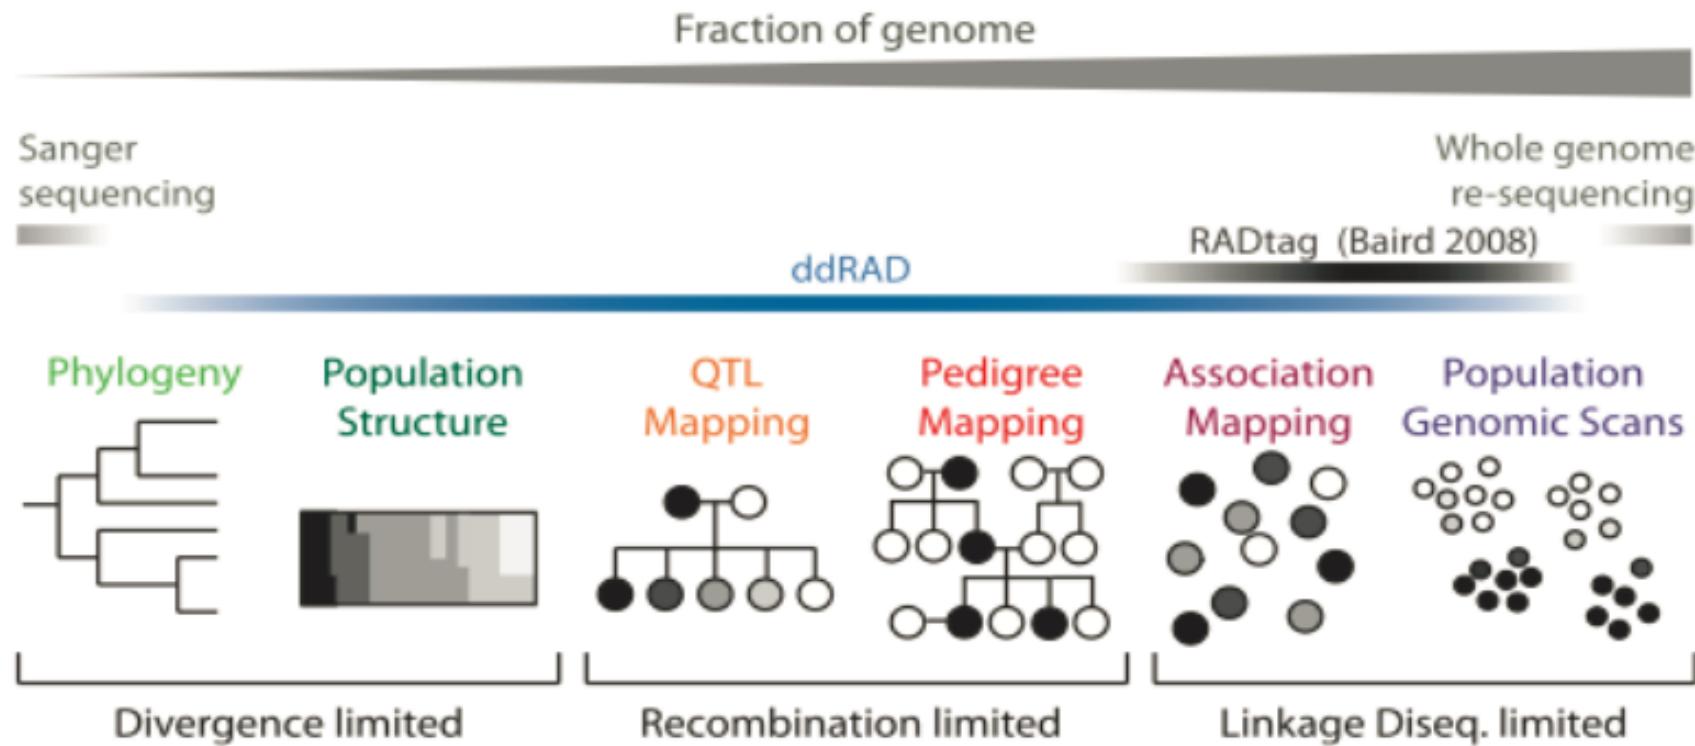


B

double digest RADseq



# Sekvenování podél restrikčních míst



# Review a příklady

STUDY DESIGNS

## Genome-wide genetic marker discovery and genotyping using next-generation sequencing

John W. Davey\*, Paul A. Hohenlohe†, Paul D. Etter§, Jason Q. Boone||,  
Julian M. Catchen† and Mark L. Blaxter\*†



RESEARCH ARTICLE

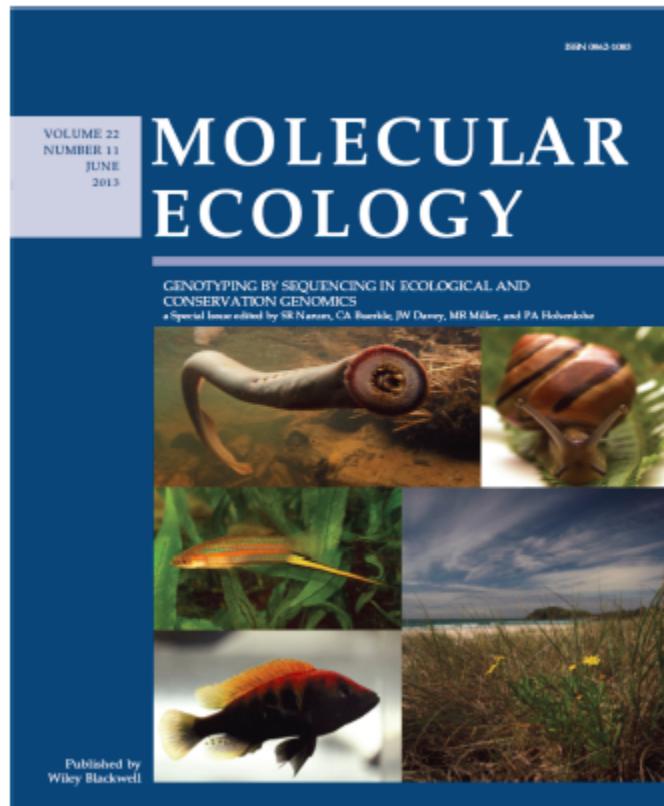
Open Access

## Genome wide SNP discovery, analysis and evaluation in mallard (*Anas platyrhynchos*)

Robert HS Kraus<sup>1\*†</sup>, Hindrik HD Kerstens<sup>2†</sup>, Pim Van Hooft<sup>1</sup>, Richard PMA Crooijmans<sup>2</sup>, Jan J Van Der Poel<sup>2</sup>,  
Johan Elmberg<sup>3</sup>, Alain Vignal<sup>4</sup>, Yinhua Huang<sup>5</sup>, Ning Li<sup>5</sup>, Herbert HT Prins<sup>1</sup>, Martien AM Groenen<sup>2</sup>



# Review a příklady



## MOLECULAR ECOLOGY

Molecular Ecology (2012)

doi: 10.1111/mec.12084

### Special features of RAD Sequencing data: implications for genotyping

JOHN W. DAVEY,\* TIMOTHÉE CEZARD,† PABLO FUENTES-UTRILLA,\* CATHLENE ELAND,† KARIM GHARBI† and MARK L. BLAXTER\*†

\*Institute of Evolutionary Biology, School of Biological Sciences, University of Edinburgh, West Mains Road, Edinburgh, EH9 3JT, UK, †The GenePool, Ashworth Laboratories, University of Edinburgh, West Mains Road, Edinburgh, EH9 3JT, UK

#### Abstract

Restriction site-associated DNA Sequencing (RAD-Seq) is an economical and efficient method for SNP discovery and genotyping. As with other sequencing-by-synthesis methods, RAD-Seq produces stochastic count data and requires sensitive analysis to develop or genotype markers accurately. We show that there are several sources of bias specific to RAD-Seq that are not explicitly addressed by current genotyping tools, namely restriction fragment bias, restriction site heterozygosity and PCR GC content bias. We explore the performance of existing analysis tools given these biases and discuss approaches to limiting or handling biases in RAD-Seq data. While these biases need to be taken seriously, we believe RAD loci affected by them can be excluded or processed with relative ease in most cases and that most RAD loci will be accurately genotyped by existing tools.

**Keywords:** contig assembly, genotyping by sequencing, population genetics, RAD Sequencing, restriction enzymes

Received 29 June 2012; revision received 7 September 2012; accepted 12 September 2012

Příště: Analýza genové exprese