




# Archivierungserfordernisse und Datenstrukturen in genetischen High Throughput-Analysen

A. Herrmann  
Arbeitsgruppe J.Hampe, UKSH Kiel


# Einleitung

- Genome Sequenzierung
- Aktuelle Hochdurchsatz-Technologien
  - 454
  - SLX
  - SOLiD
- Datenaufkommen
- Datenmanagement
- Sequenzierzentrum Kiel

# Genom Sequenzierung



- Sequenzierung des menschlichen Genoms:  
HGP 1990-2003
- Hochdurchsatz-Sequenziermethoden:  
Individual Genome



# Sequenzierungsmethoden

1990-2003

2005-jetzt

In wenigen Jahren

<b>Sequenzierung</b>	Sanger	„Next Generation“	EinzelIn Molekül
<b>Datenmenge / Run</b>	100 Reads	10M Reads	1G Reads
<b>Probenanzahl / Run</b>	einige	einige	hunderte
<b>Sequenzqualität</b>	analog	analog	digital
<b>Kosten pro menschlichen Genom</b>	1000000\$	10000\$	1000\$



# „Next-Generation“ Sequenzierungstechnologien

- Solexa
  - Firma Illumina, Gerät ca. 500T€
  - ~30-70 nt/read, 30GB/run, 5-10T€/Run, 3-10Tage/Run
- SOLiD
  - Firma Applied Biosystems, Gerät ca. 500T€
  - ~20-70 nt/read, 25GB/Run, 5-10T€/Run, 3-10Tage/Run
- 454
  - Firma 454 Life Sciences von Roche
  - ~400 nt/read, 400-500 MB/Run, ca. 2T€/Run, 1Tag/Run

# Sequenzierungsprojekte

- 1000 Genome Projekt
  - Start 2008
  - Ein Individuum
    - ~ 200Gb Sequenzen und ca. 300Gb Alignments
- Cancer Genome Projekt
- Größtes Europäisches Sequenzierzentrum:
  - Sanger Institut, Hinxton UK
    - 37 Solexa
    - theoretisch 5000 Humangenome pro Jahr



# Sequenzierungspipeline

Archivierung durch Sequenzierzentren



Gerätedaten  
(Bilder)



Gerätehersteller  
Software

Sequenzen  
Format: FASTQ



Sekundäre  
Analysen

Alignment  
Format: SAM



Archivierung durch Anwender

# Sicht der Anwender

- Sicherung der Sequenzen:
  - Format:
    - FASTQ
    - Proprietäre Formate der Gerätehersteller
  - Aufbewahrung  
10 Jahre / 30 Jahre - medizinische Daten
- Analysedaten  
Alignmentformat: SAM
- Sicherheitsaspekt



# Sequenzierzentrum Kiel

- Universitätsklinikum Schleswig-Holstein
  - 3 SOLiD Maschinen und Sanger-Sequenziergerät
  - 30 Runs/Gerät/Jahr
  - Archiv (komplettes Pipeline) ca. 500GB-1TB/Run
- Kooperation mit Rechenzentrum Kiel
  - Rechencluster mit 100 Knoten
  - Festplattenkapazität ca. 90TB RAID
- Lokale Speicherung auf USB-Platten
  - Vollständige Pipeline Archivierung
  - Notlösung ca. 50 1TB USB Platten

# Sequenzierzentrum Jena

- Fritz Lipmann Institute
  - 2 Solexa Geräte
  - Durchsatz ca. 40 Runs/Gerät/Jahr
  - Archiv (Sequenzen + Alignment) ca. 50GB/Run
- Datenmanagement
  - 80 TB Raid System,  
zur Zeit 5 TB mit Archiven belegt
  - Parallele Speicherung auf Band
  - Keine Archivierung der Bilderdaten

# Ausblick

- stetiger Wachstum der Sequenzdatenmengen
- Langzeitarchivierung
  - Wird nicht ausreichend beachtet
  - Keine eindeutige Regelung
  - Sicherstellung der 10 oder 30 Jahre Speicherung
  - Spätestens mit „Einzel-Molekül“ Sequenzierung ein akutes Problem