

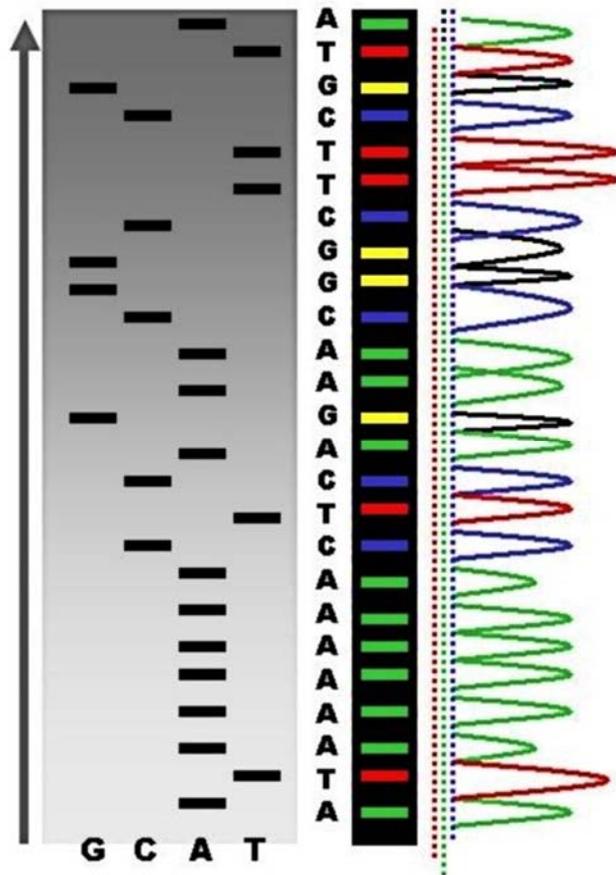
Archivierung von NGS-Daten – Artefaktsammlung oder Datenschatz?



Michael Nothnagel

Christian-Albrechts-Universität zu Kiel

Next-Generation Sequencing (NGS)



<http://www.wikipedia.de/>

- Nach Sanger Sequencing (1977) zweite Generation von Hochdurchsatz-Sequenzierungstechniken
- Entwicklung seit den 1990er Jahren
- Seit 2005 verbreitete Anwendung, wiederholte Veränderungen und Verbesserungen
- Durchbruch in der Bestimmung genomischer Sequenzen

⇒ immer noch **relativ neue Technik**

NGS als Hoffnungsträger

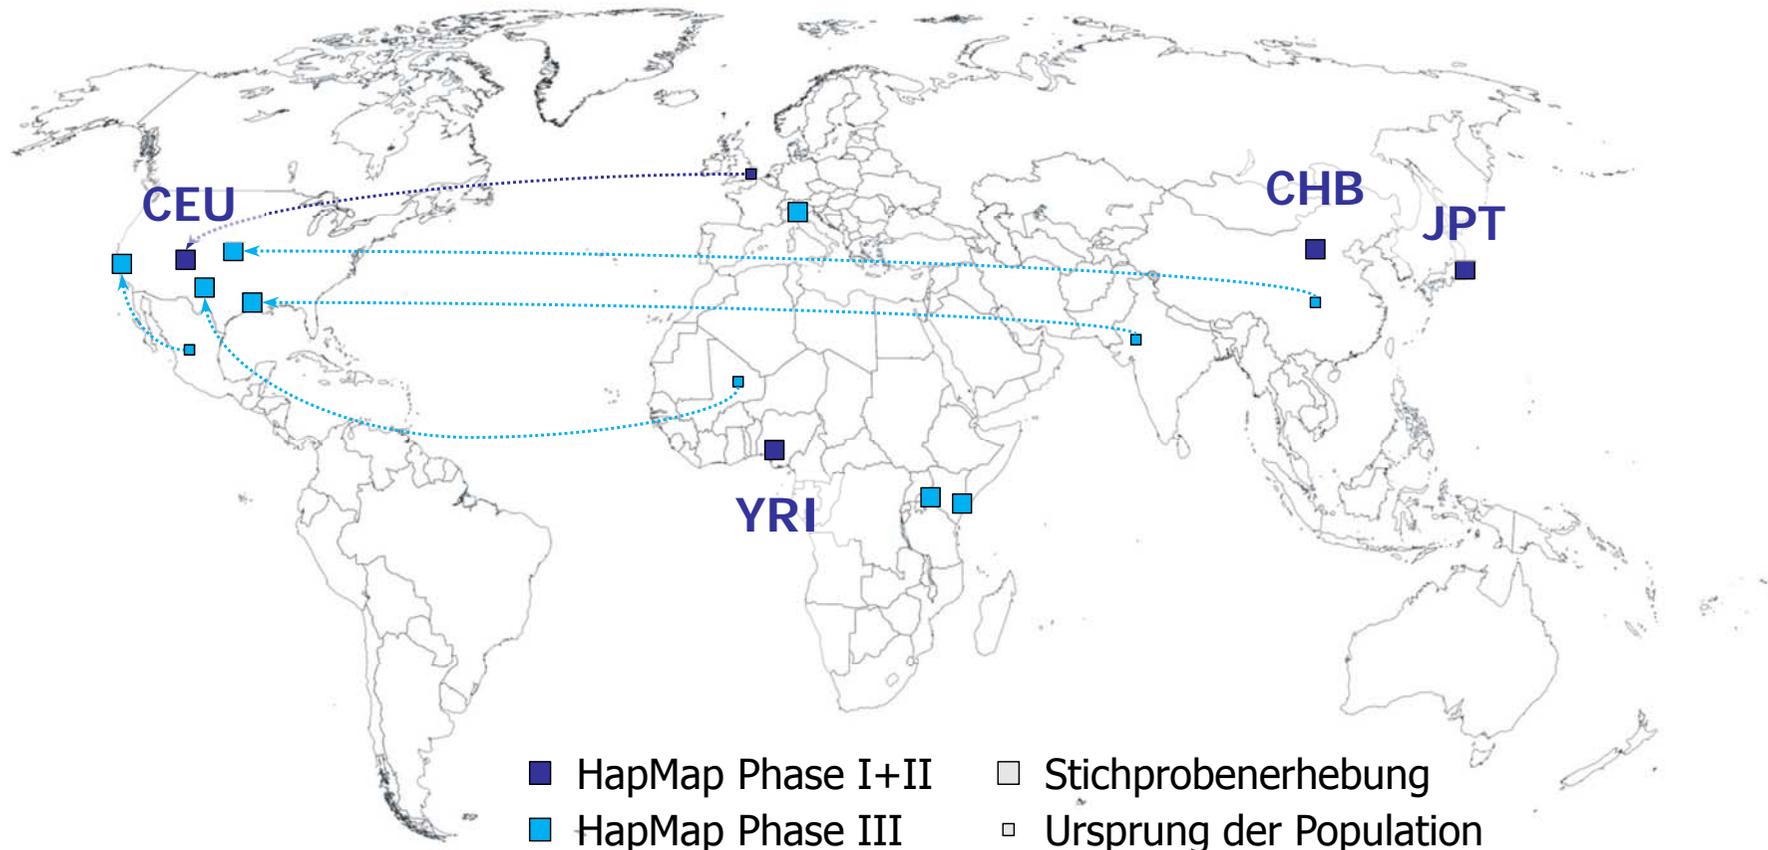
- **Direkte Untersuchung** kausaler Varianten; mögliche Ablösung des Ansatzes indirekter Assoziationsstudien
- Teilweise Aufklärung der ‚missing heritability‘ in häufigen Erkrankungen durch **Identifizierung seltener genetischer Varianten**
- Gezieltere Tumorthherapie mit Hilfe **somatischer Mutationsprofile**
- **Umfassendere Analyse genetischer Information**, u.a. durch Quantifizierung epigenetischer Modifikationen (Epigenomics) und intermediärer Genprodukte (Transcriptomics)
- und mehr...

Neue Daten – Neue Fehler

- NGS-Daten sind fehlerbehaftet
- Natur der Fehler
 - im Vornherein häufig unbekannt („learning by doing“, Erfahrungssammlung)
- Fehlerquellen für NGS-Daten (Auswahl):
 - Probleme beim Alignment von Reads (kurze Sequenzen teilweise unklaren genomischen Ursprungs)
 - einige Regionen sind nicht erreichbar (z.B. Pseudoautosomale Region der X/Y-Chromosomen, Repeats, Duplications etc.)
 - unterschiedlich hohe Abdeckung genomischer Regionen

Das HapMap-Referenz-Projekt

Ziel: Katalog häufiger genetischer Varianten in humanen Populationen
(basierend auf Genotypisierung, Frequenz $\geq 5\%$; 3.1 Mill. SNPs in Phase I+II)

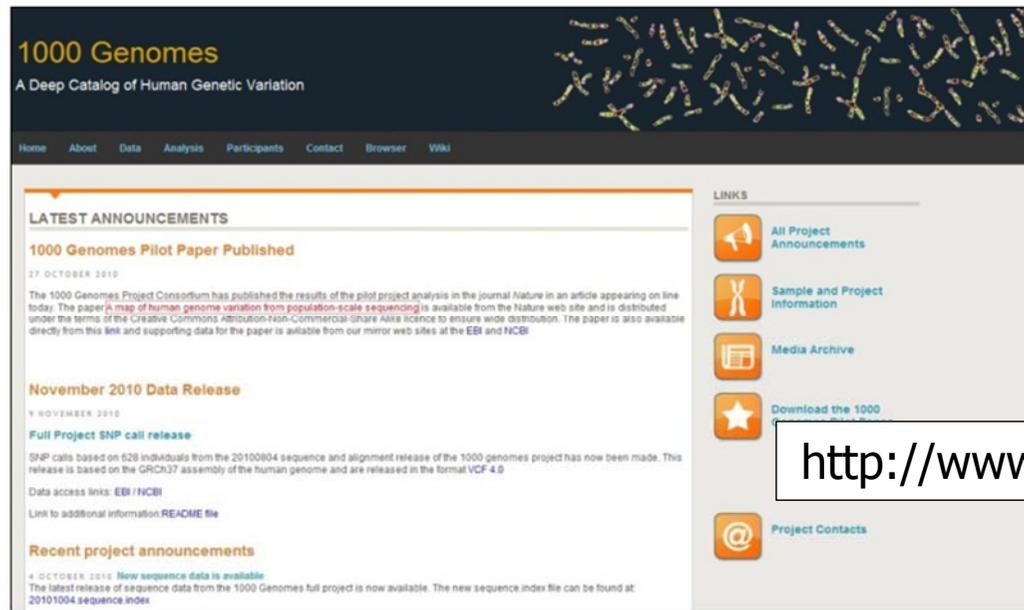


Referenz für: tagSNP-Auswahl, Genotyp-Imputation, Qualitätskontrolle, etc.

The International HapMap Consortium (2003,2005,2007) Nature

Das 1000-Genome-Projekt

Ziel: Katalog der meisten genetischen Varianten mit einer Frequenz $\geq 1\%$ in den untersuchten Populationen (basierend auf Next-Gen-Sequenzierung)



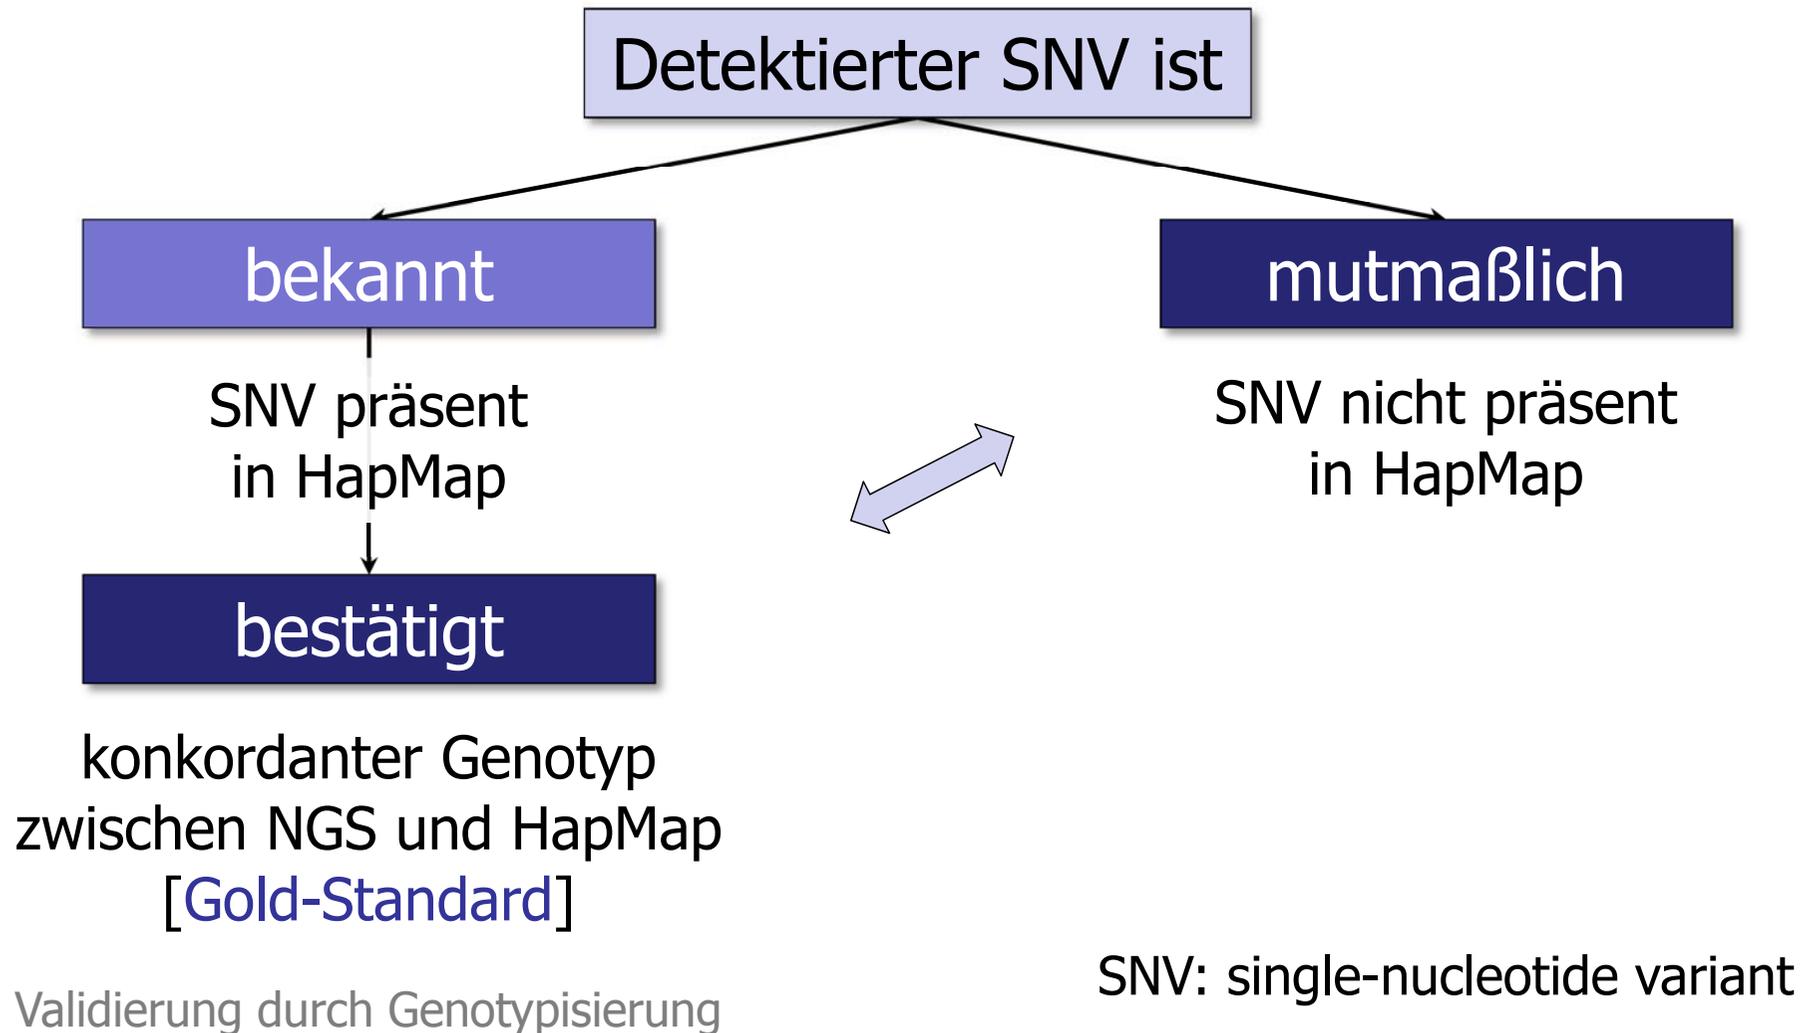
Pilot 2 Projekt:

Gesamtes Genom in 2 Trio-Familien (CEU, YRI) @ 20-60x Abdeckung

The 1000 Genomes Project Consortium (2010) Nature

Fehler in NGS-basierter SNV-Detektion

Frage: Wie hoch ist der Anteil Falsch-Positiver unter neu detektierten (heterozygoten) SNVs?

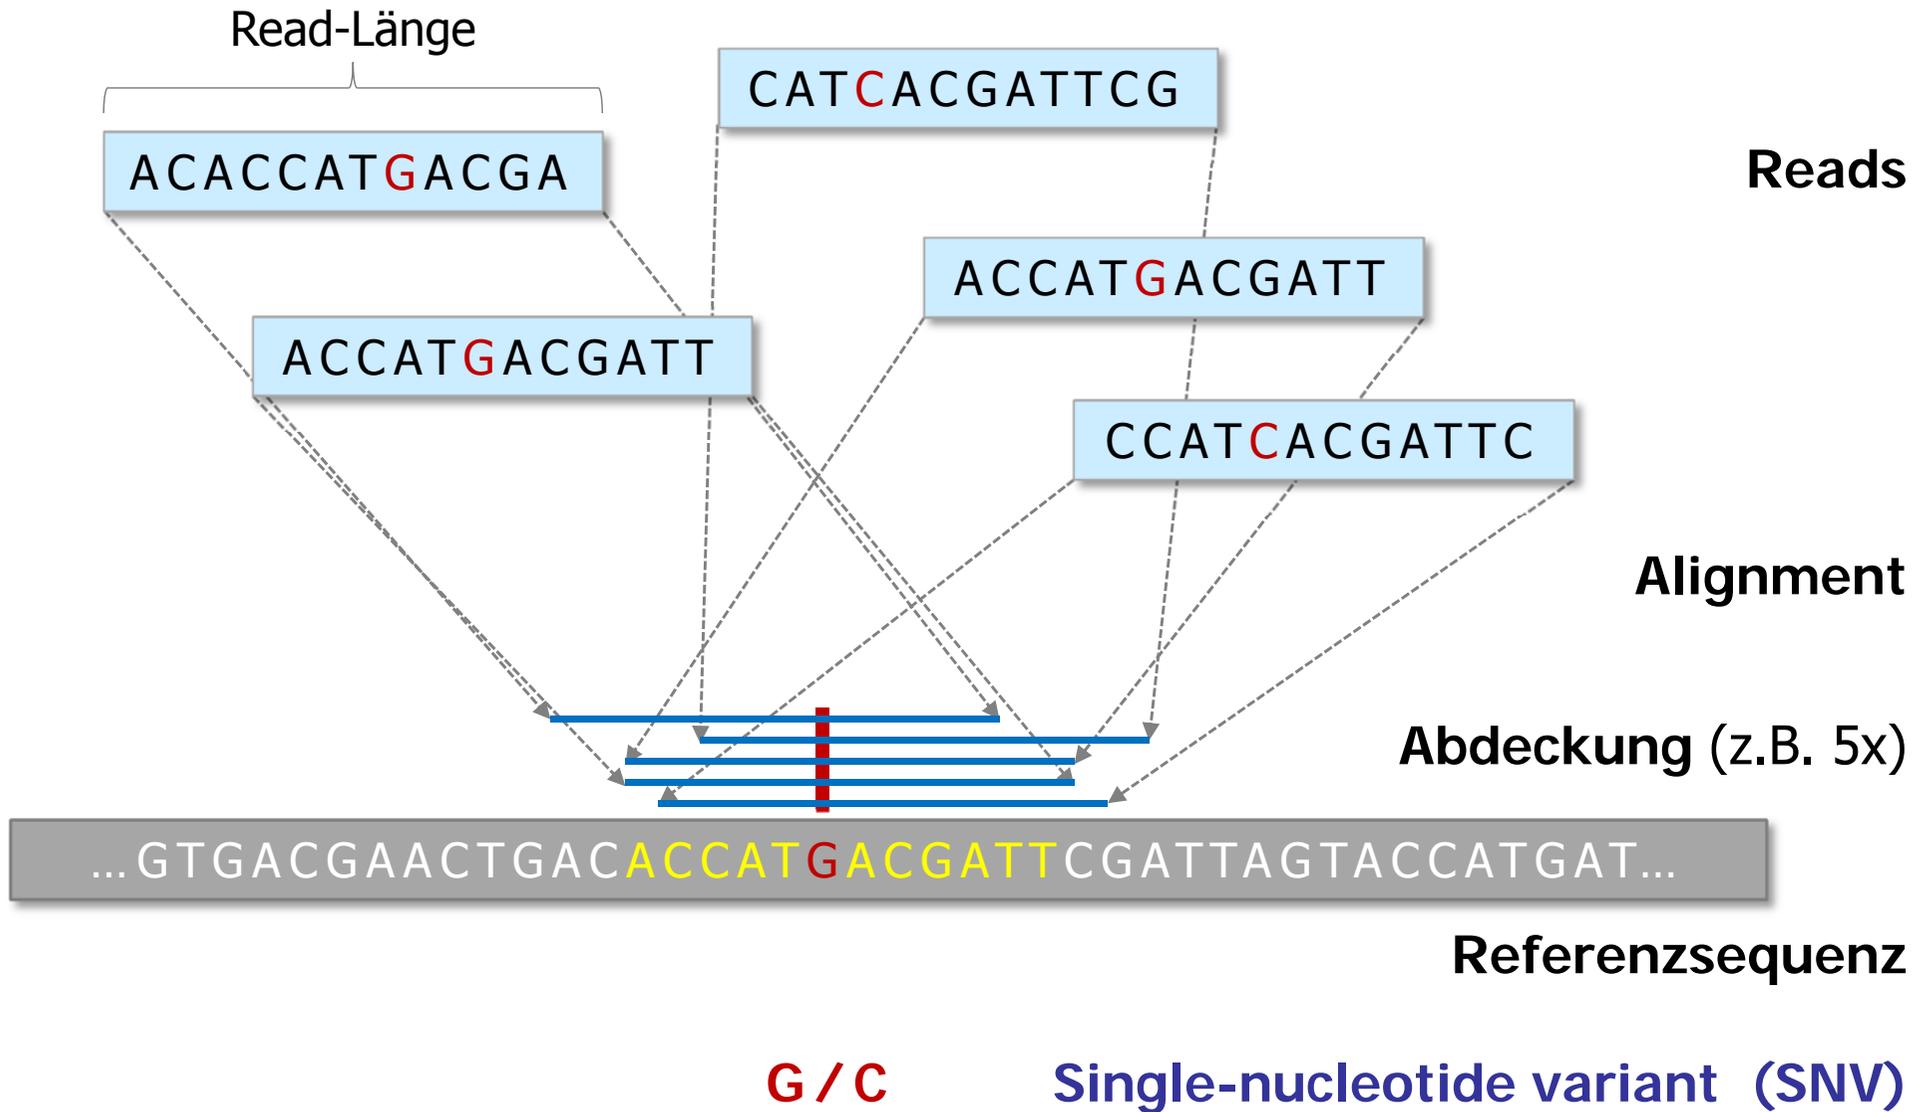


Analysierte Proben und Sequenzen



- Proben NA12878 and NA19240 wurden sequenziert mit je drei Technologien: 454 FLX™, GA IIX™ and SOLiD™
[zu verschiedenen Zeiten, verschiedene Algorithmen und QC-Ansätze]
- Download der Daten aligner Sequence-Reads von der 1000 Genome Projekt-Webseite (Pilot 2 data set, Mai 2010)

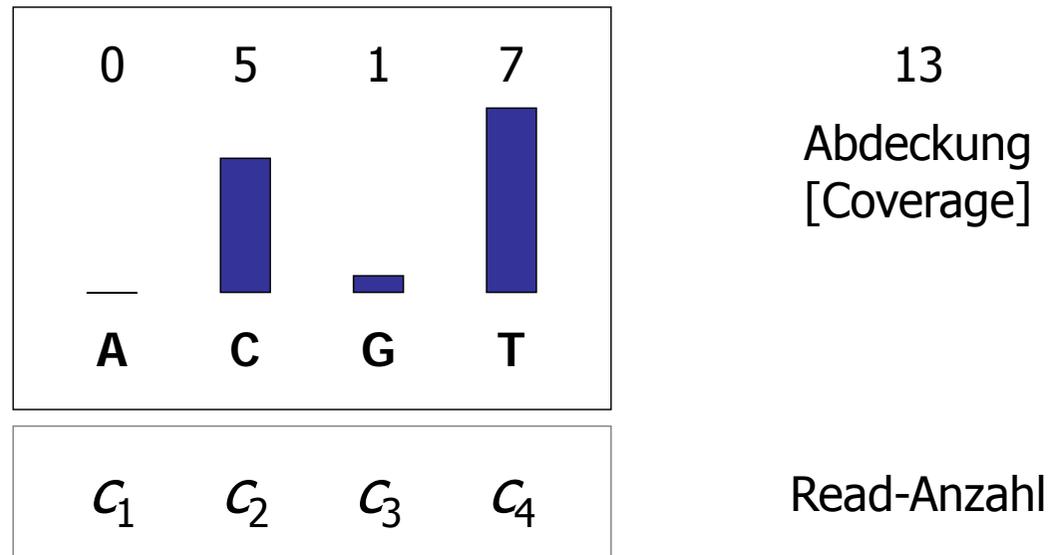
NGS: SNV-Inferenz



Software: SAMtools, GATK, diBayes, CASAVA, etc.

Verteilung allelspezifischer Reads

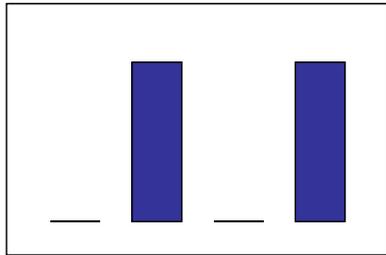
Allelspezifische Reads aus dem NGS



Entropie: $H = -\sum p_i \log_2(p_i)$ $p_i = c_i / \sum_j c_j$

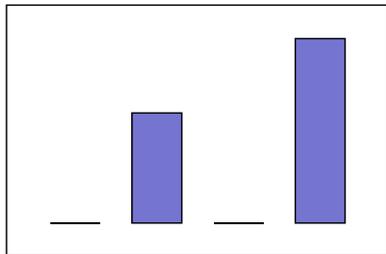
Entropie der allelspezifischen Reads

Anzahl allelischer Reads



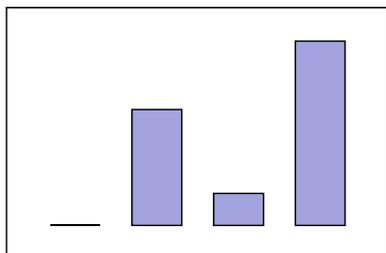
Gleichhäufige Reads für zwei Allele:

$$H = 1$$



Ungleichhäufige Reads für zwei Allele:

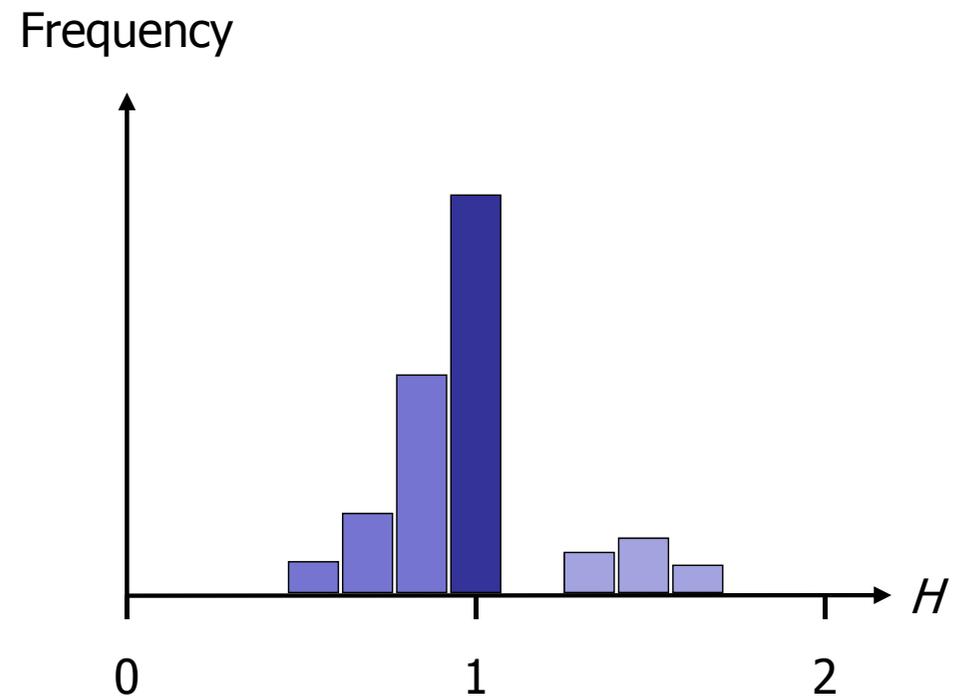
$$H < 1$$



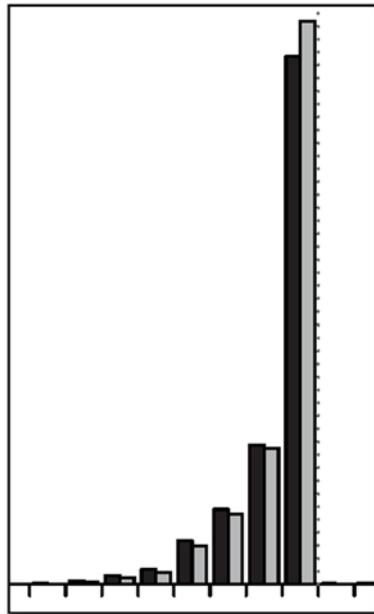
Präsenz von Reads für dritte / vierte Allele:

$$H > 1$$

Entropie-Histogramm (Beispiel)



Schätzung des Anteils falsch-positiver SNVs



- Mutmaßliche SNVs
- Bestätigte SNVs

Beobachtete Dichte von H für mutmaßliche SNVs
 Mischung der Dichten heterozygoter und homozygoter
 (**falsch-positiver**) Genotypen

$$f_{\text{putative}} = (1 - \alpha) \cdot f_{\text{het}} + \alpha \cdot f_{\text{hom}}$$

approximiert
 durch Gold-
 Standard!

normaler-
 weise nicht
 verfügbar

Schätzung für den Anteil falsch-positiver SNV-Detektionen:

$$\hat{\alpha} = \min \{ \alpha : f_{\text{putative}}(x) \geq (1 - \alpha) \cdot f_{\text{het}}(x), \forall x \in [0, 1] \}$$

Bestätigte SNVs

Benutzung von Bins für
 die Schätzung

Übersicht über inferierte SNVs

1000-Genome-Projekt, Pilot 2, Chromosomen 1-22

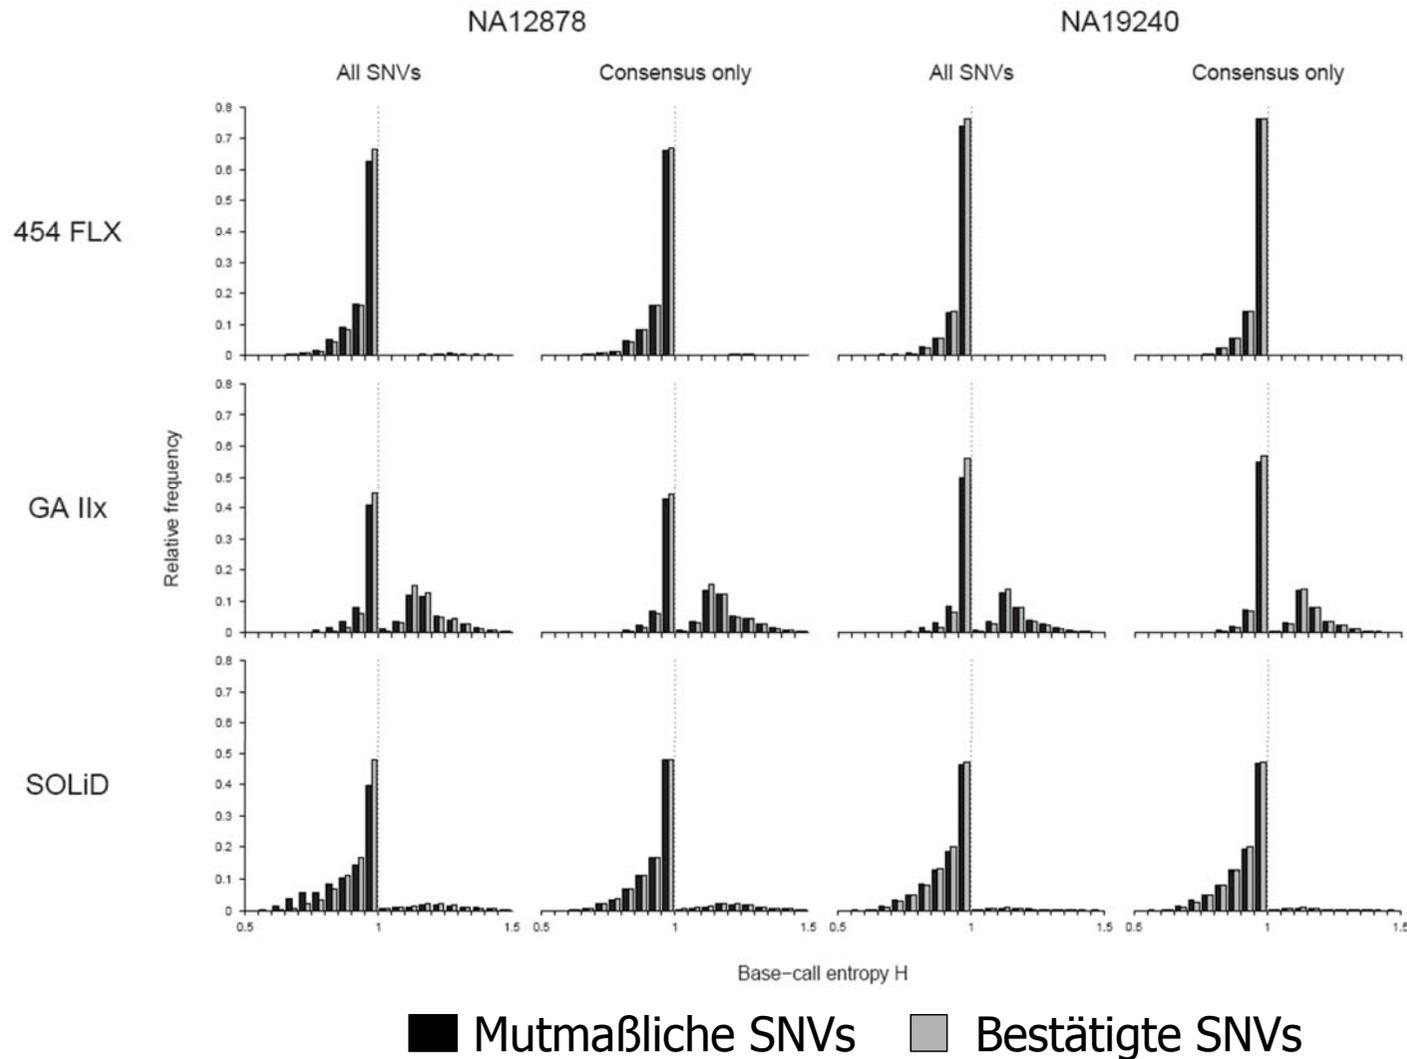
	NA12878 (CEU)		NA19240 (YRI)	
	Bekannte (Bestätigte) SNVs	Mutmaßliche SNVs	Bekannte (Bestätigte) SNVs	Mutmaßliche SNVs
454 FLX™	760,693 (724,548)	1,330,000	336,432 (319,106)	659,605
GA IIX™	821,017 (786,131)	1,126,727	892,372 (851,842)	1,816,994
SOLID™	686,686 (651,873)	1,219,584	812,710 (777,840)	1,544,714
Konsens	609,429 (587,348)	631,533	300,237 (288,818)	420,570

- **SNV-Inferenz:** SAMtools (Li et al. 2009) mit Standard-Optionen
- **SNV-Filter:** quality score ≥ 20 , read coverage ≤ 100
- **Consensus:** SNVs, die konkordant durch alle drei Plattformen gecallt wurden

Nothnagel et al. (2011) Hum Genet

Read-Entropie pro SNV

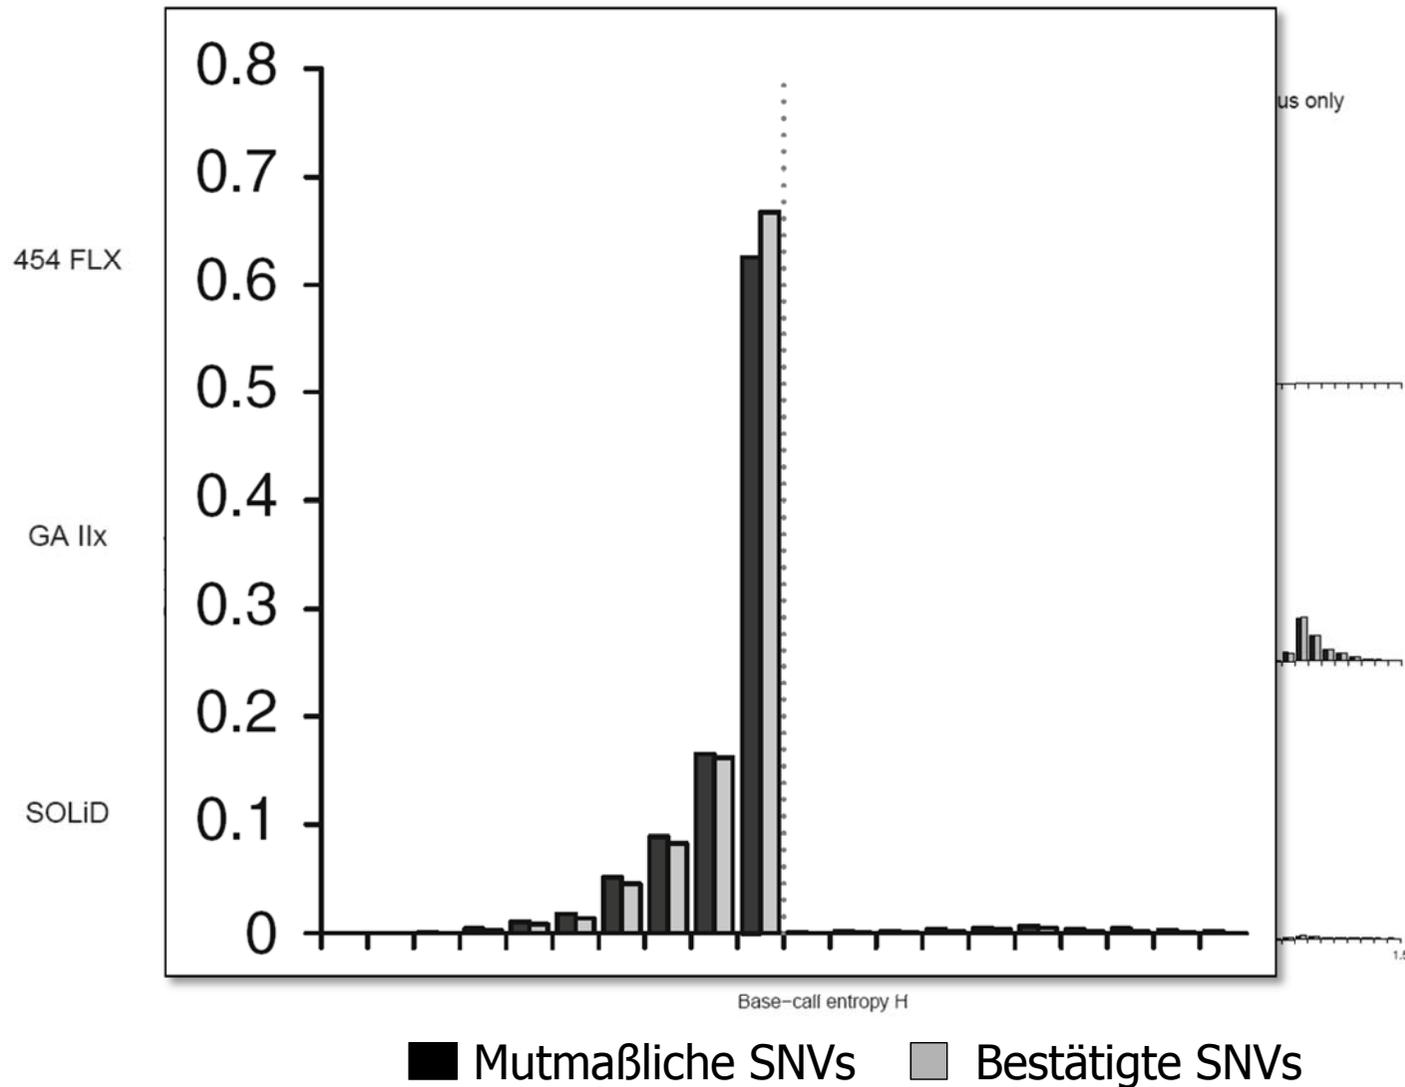
1000-Genome-Projekt, Pilot 2, Chromosomen 1-22



Nothnagel et al. (2011) Hum Genet

Read-Entropie pro SNV

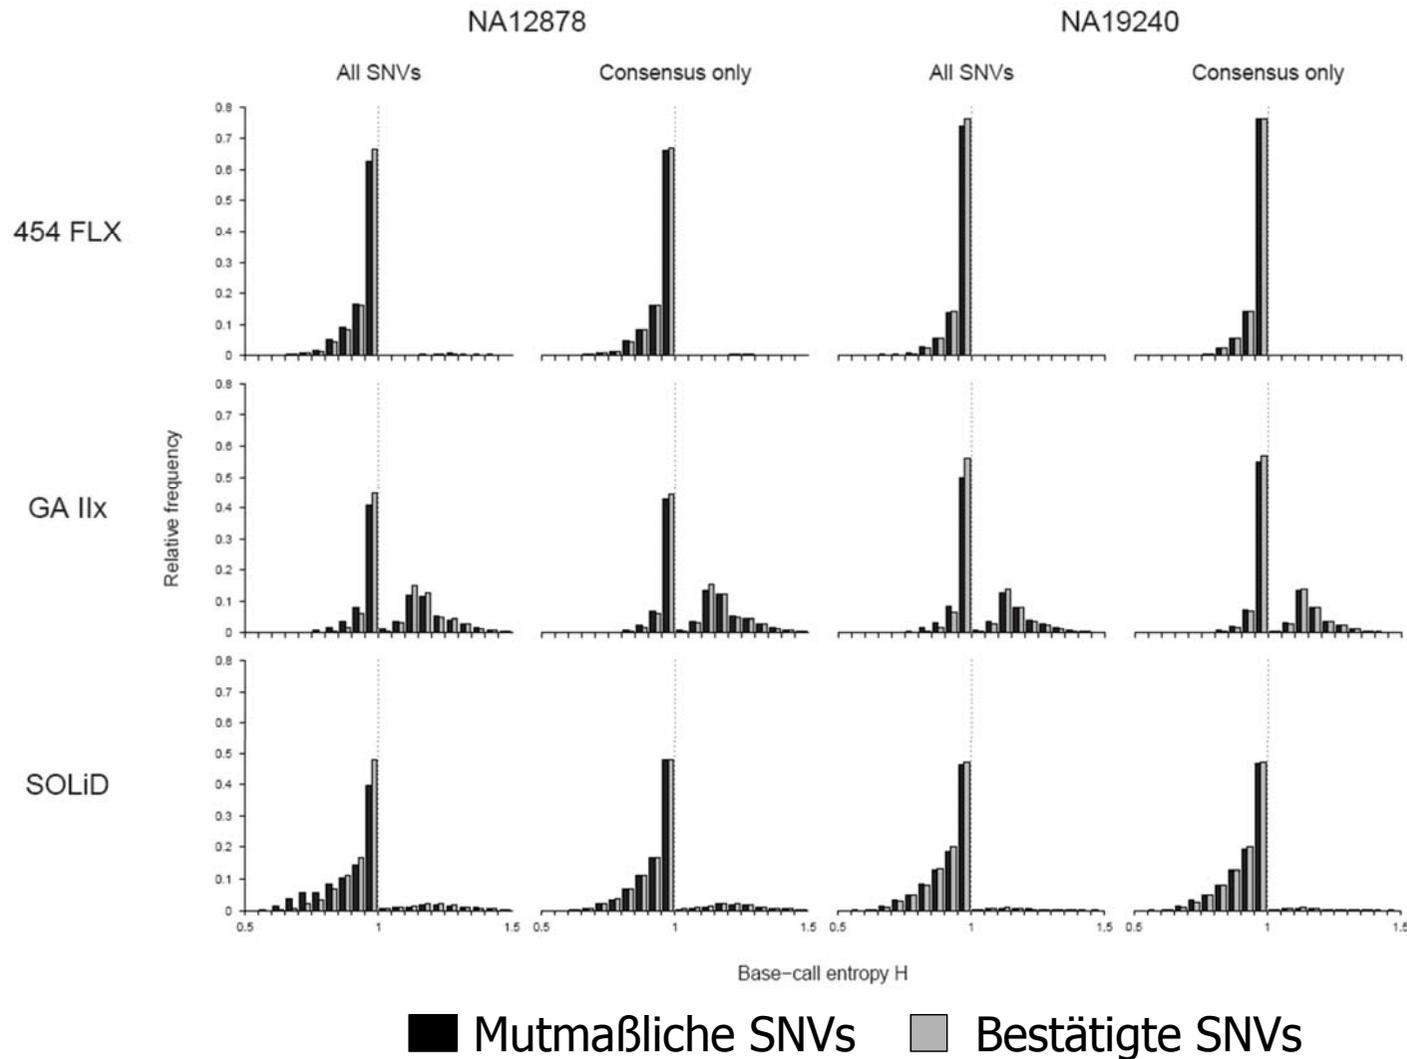
1000-Genome-Projekt, Pilot 2, Chromosomen 1-22



Nothnagel et al. (2011) Hum Genet

Read-Entropie pro SNV

1000-Genome-Projekt, Pilot 2, Chromosomen 1-22



Nothnagel et al. (2011) Hum Genet

Schätzungen des Anteils falsch inferierter SNVs

1000-Genome-Projekt, Pilot 2, Chromosomen 1-22

[%]	NA12878 (CEU)			NA19240 (YRI)		
	Alle SNVs	Konsens	P	Alle SNVs	Konsens	P
454 FLX™	6.3 (6.1-6.5)	0.7 (0.5-3.6)	<10 ⁻⁴	2.9 (2.7-3.2)	2.6 (1.2-4.7)	0.08
GA IIx™	8.4 (8.0-8.7)	3.5 (3.1-3.9)	<10 ⁻⁴	11.1 (10.9-11.3)	3.9 (3.5-4.3)	<10 ⁻⁴
SOLiD™	17.1 (16.9-17.4)	0.8 (0.1-2.6)	<10 ⁻⁴	7.3 (6.8-7.8)	4.0 (3.1-4.8)	<10 ⁻⁴

P-Werte aus einem Permutationstest.

Fragen

- I. Hilft **Qualitätskontrolle (QC)**?
- Minimaler Schwellenwert für die Abdeckung 
 - Minimaler Schwellenwert für den Quality-Score 
- II. Sind HapMap-Varianten **„einfacher“ zu sequenzieren**? 
- Untersuchung möglicher Unterschiede in der flankierenden Sequenz zwischen bestätigten und mutmaßlichen SNVs
- III. Sind die Ergebnisse **spezifisch für den Datensatz**? 
- Analyse der July 2010 Release des 1000-Genome-Projekts
- IV. Sind die Ergebnisse **spezifisch für den SNV-Calling-Algorithmus**? 
- Analyse von SNVs, die mit einem alternativen Algorithmus gecalled wurden: GATK

Fazit

- Unterschiedliche Fehlerprofile der Plattformen [spezifische Fehler und Anfälligkeiten]
- Risiko der Verfälschung von Analysen
- Konsens-Calls können Anteil irrtümlicher SNV-Detektionen reduzieren
- Public July 2010 Release erscheint in Teilen von schlechterer Qualität als Pilot2 Release (unklare QC?)
- NGS ist eine sich noch entwickelnde Technologie
 - mit Fehlern (bekannter und unbekannter Form)
 - ohne validierten Konsens über die Qualitätskontrolle der Daten
 - ohne Konsens über die ‚richtige‘ Form der Datenanalyse
 - ‚work in progress‘

Datensicherung? Sicher!

- Datenarchivierung bietet **Möglichkeiten zur Re-Analyse**
 - Post-hoc-Überprüfung nach Berichten über Fehlerquellen
 - Erneute Analyse unterschiedlich gereinigter und analysierter Daten zur Herstellung von Vergleichbarkeit
 - Erneute Analyse der ursprünglichen Daten (Read-Daten) mittels korrigierter, neuer und verbesserter Verfahren
 - Detektion von Fälschungen
- Archivierung bis zu einem **Konsens über Qualitätskontrolle und Analyseform** notwendig (bei Standard-Analysen)
- Archivierung daher in den meisten Fällen **wünschenswert und notwendig** (in den nächsten 5 Jahren)

Danksagungen

Hum Genet
DOI 10.1007/s00439-011-0971-3

ORIGINAL INVESTIGATION

Technology-specific error signatures in the 1000 Genomes Project data

Michael Nothnagel · Alexander Herrmann · Andreas Wolf · Stefan Schreiber ·
Matthias Platzer · Reiner Siebert · Michael Krawczak · Jochen Hampe

M. Nothnagel and A. Herrmann contributed equally to this work.

<http://www.ncbi.nlm.nih.gov/pubmed/21344269>

- **Andreas Wolf, Michael Krawczak**
(Christian-Albrechts-Universität zu Kiel)
- **Alexander Herrmann, Stefan Schreiber, Rainer Siebert, Jochen Hampe**
(Universitätsklinikum Schleswig-Holstein, Campus Kiel)
- **Mathias Platzer**
(Leibniz-Institut für Altersforschung, Jena)