# Informationsveranstaltung <br> Qualitätsmanagement für Hochdurchsatz-Genotypisierung 

## Statistische Qualitätssicherung von Affymetrix- Daten

Berlin, 21.06.2010
Arne Schillert \& Andreas Ziegler
Institut für Medizinische Biometrie und Statistik, Universität zu Lübeck

## Hochdurchsatz-Genotypisierung

- Ergebnis einer genomweiten Assoziationsstudie:


Samani, NEJM 2007, 357:443-453

## Schematischer Aufbau eines Microarrays



- Oligonukleotide auf Glasträger fixiert
- komplementär zur Sequenz des SNPs
- vollständig komplementär: perfect match (PM)
Base des SNPs nicht komplementär: mismatch (MM)
- pro SNP mehrere Oligonukleotide


## Ablauf eines Microarray-Experimentes

- DNA fragmentieren und markieren
- DNA-Fragmente auf Array hybridisieren lassen
- Abwaschen nicht gebundener Fragmente
- Farbstoff anhängen und anregen
- Scannen und Bild an Raster ausrichten $\rightarrow$ CEL-Datei


## Falschfarbenbild der Intensitätswerte



Lipshutz, Nat Genet 1999, 21:20-24

- Intensitätswerte eines

Quadranten zusammengefasst

- Verhältnis von Intensität des A-Allels $\left(I_{A}\right)$ zu Intensität des B-Allels $\left(I_{B}\right)$ bestimmt Genotyp:
$I_{A} \gg I_{B} \rightarrow A / A$
$I_{A} \approx I_{B} \rightarrow A / B$
$I_{A} \ll I_{B} \rightarrow B / B$


## Cluster-Plots


theoretisch

## Cluster-Plots


theoretisch

praktisch

## Cluster-Plots



## Cluster-Plots von Realdaten



## Einleitung

# Genotypisierung mit Microarrays <br> Beurteilung der Genotypisierung 

Calling-Algorithmen<br>Übersicht<br>Calling<br>Vergleich

## Beurteilung von Cluster-Plots

## Zusammenfassung

SPORSOARD BYTHE

## Identifizierte Algorithmen

## Birdseed

BRLMM Bayesian robust linear model with Mahalanobis distance classifier
CHIAMO ital. "lch rufe"
CRLMM Corrected robust linear model with Mahalanobis distance classifier
GEL Genotype calling using empirical likelihood
JAPL lautmalerisch frz. "Ich rufe"
MAMS Multi-array multi-SNP genotype calling
PLASQ Probe-level allele-specific quantification procedure
SNiPer-HD SNiPer High Density

## Identifizierte Algorithmen

## Birdseed

BRLMM Bayesian robust linear model with Mahalanobis distance classifier
CHIAMO ital. "lch rufe"
CRLMM Corrected robust linear model with Mahalanobis distance classifier
GEL Genotype calling using empirical likelihood
JAPL lautmalerisch frz. "Ich rufe"
MAMS Multi-array multi-SNP genotype calling
PLASQ Probe-level allele-specific quantification procedure
SNiPer-HD SNiPer High Density

## Flow chart - CRLMM



## Flow chart - JAPL



## Confidence Scores - CRLMM

crlmm-calls.txt

|  | ID1 | ID2 | ID3 |
| :---: | :---: | :---: | :---: |
| SNP-1 | 3 | 2 | 1 |
| SNP-2 | 2 | 2 | 1 |

crlmm-conf.txt

|  | ID1 | ID2 | ID3 |
| :---: | :---: | :---: | :---: |
| SNP-1 | 0.999 | 0.950 | 0.990 |
| SNP-2 | 0.990 | 0.800 | 0.999 |

- Annotationsinformation: SNP-1: A/C; SNP-2: G/T
- Grenzwert für Confidence Scores: 0.99
tped Genotypen:

$$
\begin{array}{lllll} 
& \text { ID1 } & \text { ID2 } & \text { ID3 } \\
\text { SNP-1 } & \text { C } & \text { C } & 0 & 0 \\
\text { A } & \text { A } \\
\text { SNP-2 } & \text { G } & \text { T } & 0 & 0 \\
\text { G } & \text { G }
\end{array}
$$

## Confidence Scores - JAPL

SNP-1.gen

| SNP | chipScan | P1 | P2 | P3 |
| :---: | :---: | ---: | ---: | ---: |
| SNP-1 | ID1 | $5.5 \mathrm{e}-05$ | 0 | 0.999 |
| SNP-1 | ID2 | 0.05 | 0.95 | 0 |
| SNP-1 | ID3 | 0 | 0.001 | 0.999 |

- Annotationsinformation: SNP-1: A/C
- Grenzwert für A-posteriori Wahrscheinlichkeit: 0.99


## tped Genotypen:

$$
\begin{array}{lllll} 
& \text { ID1 } & \text { ID2 } & \text { ID3 } \\
\text { SNP-1 } & \text { C } \mathrm{C} & 0 & 0 & \text { A }
\end{array}
$$

## HapMap-Daten

- Genotypdaten und CEL-Dateien für das Affymetrix Human Mapping 500k Array Set und den Genome-Wide Human SNP Array 6.0
- Goldstandard
- Daten von 270 Individuen
- nur die der 30 CEU trios verwendet
- CEL-Dateien direkt (www.hapmap.org) oder als Bioconductor Paket verfügbar
- Genotypen von der PLINK Website verwendet


## Berechnung der Konkordanz

- PLINKs merge-mode 7 verwendet, d.h. fehlende Genotypen nicht berücksichtigt
- mit HapMap-Daten verglichen
- Bewertung der Güte mittels ADPs:
- Accuracy vs. Drop rate Plots (Lin, Genome Biol 2008, 9:R63)
- für verschiedene Grenzwerte des Confidence Scores Konkordanz und Anteil fehlender Werte bestimmt


## Accuracy vs drop rate plot - alle SNPs



## ADP - Häufige SNPs



- MAF $\geq 10 \%$
- 321,883 SNPs


## ADP - Seltene SNPs



## ADP - Homozygote Genotypen



## ADP - Heterozygote Genotypen



## Ergebnisse der Qualitätskontrolle

Kriterien:

- Anteil fehlender Werte (MiF) < 2\%
- Häufigkeit des seltenen Allels (MAF) > 1\%
- Abweichungen vom HWE (HWE) p > 0.0001

Anzahl der ausgeschlossenen SNPs:

| Algorithmus | MiF | MAF | HWE | Summe |
| :--- | ---: | :---: | :---: | ---: |
| BRLMM | 153656 | 77349 | 67727 | 213373 |
| Birdseed | 111111 | 77026 | 65970 | 166750 |
| CHIAMO | 166683 | 87709 | 91074 | 233785 |
| CRLMM | 21794 | 82027 | 80411 | 98013 |
| JAPL | 66046 | 69697 | 70107 | 136456 |

SNPs: 482,203

## Konkordanz vor/nach der QC

Accuracy [\%]


Einleitung

# Genotypisierung mit Microarrays Beurteilung der Genotypisierung 

Calling-Algorithmen
Übersicht
Calling
Vergleich

## Beurteilung von Cluster-Plots

Zusammenfassung

SPORSOARD BYTHE

## Clustervaliditätsmaße

- Beurteilung von Cluster-Plots = interne Validität eines Clusterings in Cluster-Analysen
- Kriterien für die Validität:

A Kompaktheit
B Verbundenheit
C Trennbarkeit
D Kombinationen von A-C


B


- Alternative Idee: Pertubations- Analyse (Teo, Ann Hum Genet 2008, 72: 368-374)


## A: Kompaktheit

- gemessen durch Cluster-spezifische Intra-Cluster-Varianz $\mathbb{V a r}\left(\mathrm{IC}_{k}\right)$ und die Gesamt-Intra-Cluster-Varianz $\mathbb{V} \operatorname{ar}(\mathrm{IC})$

$$
\begin{aligned}
\mathbb{V} \operatorname{ar}\left(\mathrm{IC}_{k}\right) & =\frac{1}{n_{k}} \sum_{i=1}^{n_{k}} d_{k}^{2}\left(i, \mu_{k}\right) \\
\mathbb{V} \operatorname{ar}(\mathrm{IC}) & =\frac{1}{n} \sum_{k=1}^{3} \sum_{i=1}^{n_{k}} d_{k}^{2}\left(i, \mu_{k}\right)
\end{aligned}
$$

- In der Praxis jedoch root mean square distance (RMSD):

$$
\mathrm{RMSD}=\sqrt{\mathbb{V} \operatorname{ar}(\mathrm{IC})}
$$

## B: Verbundenheit - Connectivity

- Bestimmung mittels „Nächster Nachbar"-Methoden
- Für Probe $i$ des Clusters $k$ wird der $j$-te nächste Nachbar $n n_{i(j)}$ bestimmt

$$
C_{i, \mathrm{nn}_{i(j)}}=\left\{\begin{array}{ll}
0 & \text { falls } i \text { und } \mathrm{nn}_{i(j)} \text { denselben Genotyp, } \\
\frac{1}{j} & \text { falls } i \text { und } \mathrm{nn}_{i(j)}
\end{array}\right. \text { verschiedene Genotypen }
$$

- Kennzahl für die Verbundenheit für die $J$ nächsten Nachbarn:

$$
\text { Conn }=\sum_{i=1}^{n} \sum_{j=1}^{J} C_{i, \mathrm{nn}_{i(j)}}
$$

- Conn groß $\Rightarrow$ Cluster zweier Genotypgruppen liegen sehr dicht beieinander


## C: Trennbarkeit

- Vielzahl von Maßen vorgeschlagen
- für Intensitätsdaten minimaler Abstand zwischen Clustern sinnvoll
- alternativ durchschnittlicher Abstand zum Heterozygoten-Cluster
- werden jeweils Abstände der Clusterzentren betrachtet: $d\left(\boldsymbol{\mu}_{\boldsymbol{k}}, \boldsymbol{\mu}_{k^{\prime}}\right)$
- minimaler Inter-Cluster-Abstand (minD)

$$
\min D=\min _{k \neq k^{\prime}} d\left(\boldsymbol{\mu}_{k}, \mu_{k^{\prime}}\right)
$$

- durchschnittlicher Inter-Cluster-Abstand (meanD)

$$
\text { mean } D=\frac{d\left(\mu_{1}, \mu_{2}\right)+d\left(\mu_{2}, \mu_{3}\right)}{2}
$$

## D: Cluster-Separation-Criterion



- nur Cluster-spezifische Kontrast-Mittelwerte $\bar{c}_{k}$ und -Streuungen berücksichtigt

$$
C S C=\min \left\{\frac{\bar{c}_{2}-\bar{c}_{1}}{\sigma_{1}+\sigma_{2}}, \frac{\bar{c}_{3}-\bar{c}_{2}}{\sigma_{2}+\sigma_{3}}\right\}
$$

## Praktische Evaluation

- Daten der Gutenberg-Herz-Studie Mainz (3194 Individuen, 649.491 qualitätskontrollierte SNPs)
- 5000 SNPs zufällig ausgewählt
- Bewertung der Güte durch zwei erfahrene Beurteiler $\Rightarrow$ Goldstandard
- Vergleich mit ausgewählten Clustermaßen


## ROC-Kurven

- Vergleich der Clustermaße mit Goldstandard:


Kontrastdarstellung


## Zusammenfassung

- Unsere Empfehlung: CRLMM
- Hohe Konkordanz bei geringem Anteil fehlender Werte
- Einfach zu benutzen (Bioconductor-Pakete)
- Schnell
- Beschränkungen dieser Analyse:
- HapMap-Daten für Trainung und Evaluation der Modelle verwendet
- Stichprobengröße sehr gering, aktuelle GWA-Studien > 2000 Individuen
- Betrachtung der Cluster-Plots notwendig
- Clustervaliditätsmaße ermöglichen objektive Bewertung
- Automatisierung wird als R-Paket implementiert


## Danke für die Aufmerksamkeit!

## Affymetrix Genotyping Microarrays

Name Kurzbeschreibung

> Human Mapping 10K 10.204 SNPs, PM+MM
> 2.0 Array

Human Mapping 100K 116.204 SNPs, 2 Arrays, PM+MM Set

Human Mapping 500K 500.568 SNPs, 2 Arrays, PM+MM Array Set

Genome-Wide Human 500.568 SNPs und 420.000 CNVSNP Array 5.0 Sonden, nur PM

Genome-Wide Human 906.600 SNPs und 946.00 CNV-Sonden, SNP Array 6.0 nur PM

Axiom Genotyping So- 567.096 SNPs, komplettes Neudesign lution der Plattform

