

**Einführung in die Angewandte Bioinformatik:
Analyse und Design von DNA Microarrays
08.07.2010**

Prof. Dr. Sven Rahmann

Transcript – Omics (Genexpressionsanalyse)

Zum Verständnis von lebenden Organismen untersucht man u.a. ihr

- Genom
- Transkriptom
- Proteom
- Metabolom,

sowie Wechselwirkungen zwischen diesen Ebenen.

Das Genom wird durch DNA-Sequenzierung in Genomprojekten bestimmt.
Das Proteom und Metabolom z.B. mit Massenspektrometrie.

Transcript – Omics (Genexpressionsanalyse)

Das Transkriptom (Gesamtheit der in RNA transkribierten DNA) wird bestimmt mittels


- aktuell: DNA-Microarrays,
- Zukunft: Hochdurchsatz-Sequenzierung von mRNA.

Transkription variiert

- von Gewebe zu Gewebe,
- abhängig von äußeren und inneren Einflüssen,
- als Antwort auf Signale anderer Zellen, ...

Genexpressionsanalyse: Motivation Beispiel Bronchialkarzinom


Phänotyp „gesund“



Proteinexpression



Genexpression



Differenzielle
Proteinexpression




Differenzielle
Genexpression

Phänotyp „Bronchialkarzinom“

Kandidaten-Gen: differenziell exprimiert in Tumorzellen.
Identifikation wichtig für Diagnostik und Therapie.

(Alte) cDNA-Array-Technologie

2. Vorbereitung der Proben (samples)




mRNA-Extraktion & Amplifikation



Markierung mit Fluoreszenz-Farbstoffen

3. Hybridisierung



1. Vorbereitung des Microarrays

PCR-Amplifikation der zu untersuchenden Gene (pro Gen ein Arbeitsschritt)



Spotten der cDNA auf definierten Plätzen



4. Bild- und Datenanalyse


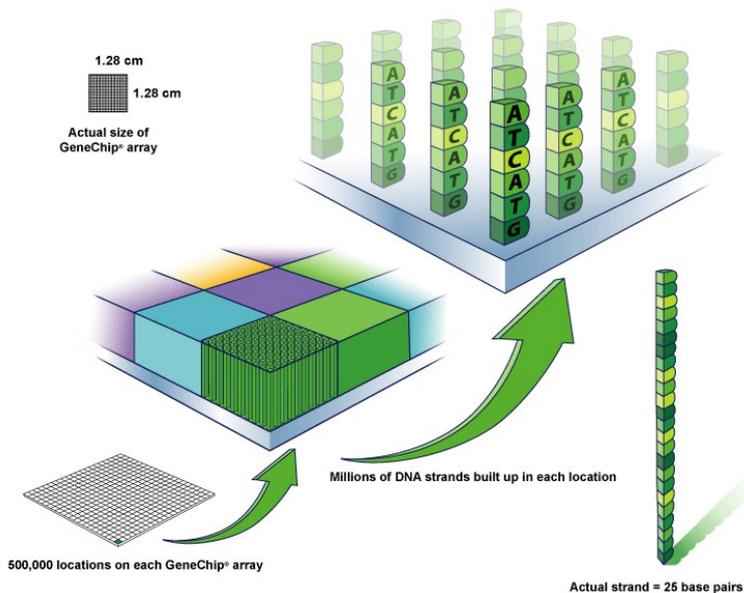
Rot/Grün-Verhältnis
Hintergrundkorrektur

(Aktuelle) Oligonukleotid-Array-Technologie


Oligonukleotid-Microarrays bestehen aus Mio. **spots** oder **features**.

- Spot enthält Mio. Kopien eines bestimmten Oligonukleotids.
- Oligonukleotid hybridisiert (spezifisch) an mRNA / cDNA (Watson-Crick-Paarung).
- mRNA/cDNA ist fluoreszierend markiert.
- Ungebundene RNA wird abgewaschen.
- Fluoreszenz-Signal auf Spot erlaubt Rückschluss auf Genexpression.



Wichtig: Oligonukleotid-Sonden **gen-spezifisch**.





Ablauf eines einzelnen Microarray-Experiments






Extraktion der poly-A-RNA




Amplifikation und Markierung der RNA




Fragmentierung
Hybridisierung



Schritte einer Microarray-Studie



Resultate einer Microarray-Studie



Ergebnisse aus Daten-Sicht:

- Rohdaten (Bild-Dateien).
- „Halbgare“ Daten (Roh-Farb-Intensitäten).
- Normalisierte Expressionswerte pro Gen.

Ergebnisse aus Wissens-Sicht:

- Unterstützung oder Falsifikation der initialen Hypothese; neue Hypothese(n).
- wenn keine Hypothese vorlag: Generierung von Hypothesen.

Auswertung einer Microarray-Studie

Typische Visualisierung einer Microarray-Studie:

hierarchisches (Bi-)Clustering

- Zeilen: Gene
- Spalten: Experimente (z.B. Zeitpunkte)

Rot: Gen unterexprimiert gegenüber Standard.


Grün: Gen überexprimiert gegenüber Standard.

Gene, die sich über viele Experimente gleich verhalten, bilden Gen-Cluster
Experimente, in denen sich viele Gene gleich verhalten, bilden Experiment-Cluster.

Anordnung der Gene und Experimente:

Ähnliche möglichst nebeneinander.

Berechnung wie bei phylogenetischen Bäumen (UPGMA).



Die einzelnen Analyseschritte

Low-Level-Analyse:

- Bildanalyse
- Hintergrundkorrektur
- Normalisierung (Herausrechnen von systematischen Fehlern)
- Schätzung der absoluten oder relativen Genexpression pro Gen

High-Level-Analyse:

- Identifizierung differenziell exprimierter Gene
- Clustering und Klassifikation von Genen und Experimenten

Low-Level: Bildanalyse und Hintergrundkorrektur

Eingabe:


- fotografierte Bilddaten (ein Intensitätswert pro Bildpunkt)

Vorgehen:

- Identifikation der Lage der Spots
- Berechnung einer Gesamtintensität pro Spot aus Bildpunkten, die Spot bilden
- Abzug des „Hintergrunds“
- Transformation (z.B. Logarithmierung)

Ausgabe:

- ein Intensitätswert pro Spot/Feature



Low-Level: Normalisierung

Problem:

- Intensitätswerte pro Spot nicht direkt vergleichbar für mehrere Arrays
- Grund z.B.: mehr Farbstoff; längere Belichtung auf zweitem Array
- Daher z.B. alle Werte auf Array 2 doppelt so groß wie auf Array 1, aber Gene nicht doppelt so aktiv.

Grundannahme der Normalisierung:

Zwischen zwei Experimenten (Arrays)

- ändert sich die Expression einzelner Gene
- ändern sich nicht globale Eigenschaften der Verteilung der Expressionswerte

Daher:


Angleichung der Histogramme möglich und sinnvoll.

Beispiel zur Normalisierung

Zwei „Mini“-Microarrays mit nur 10 Spots:

Array 1 in blau: (13, 15, 27, 19, 33, 11, 21, 22, 12, 17)

Array 2 in grün: (20, 23, 34, 30, 50, 11, 31, 40, 18, 25)



Alle Werte in Array 2 scheinen höher.

Widerspricht Grundannahme, also: angleichen = normalisieren.

Affin-Lineare Normalisierung


Annahme:

Es gilt ein affiner Zusammenhang $y = ax + b$

mit x : Wert aus Array 1, y : entsprechender Wert aus Array 2.

Scatterplot von x gegen y (blau) und

Berechnung einer Ausgleichsgeraden (grün): $y = 1.53394x - 0.94480$.



Affin-Lineare Normalisierung

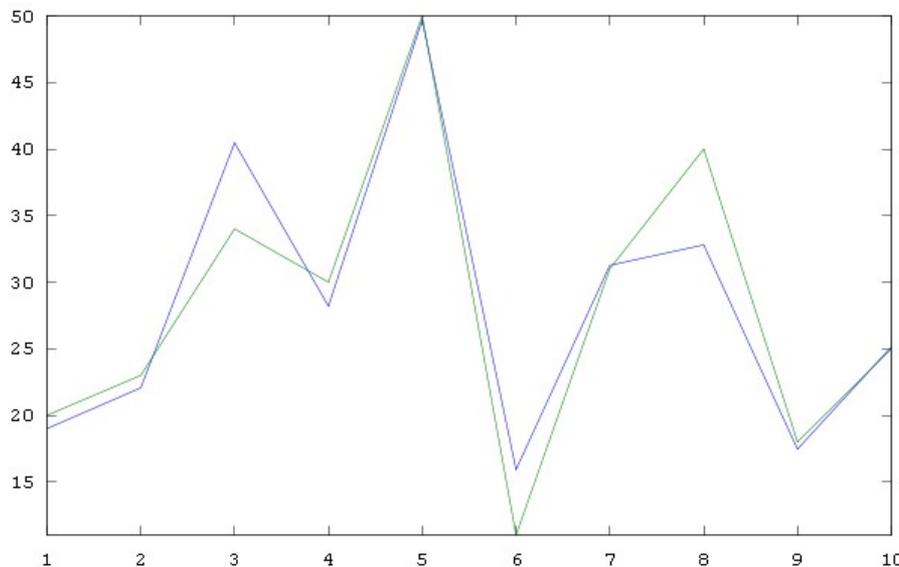
Zwei „Mini“-Microarrays mit nur 10 Spots:

Array 1: (13, 15, 27, 19, 33, 11, 21, 22, 12, 17)

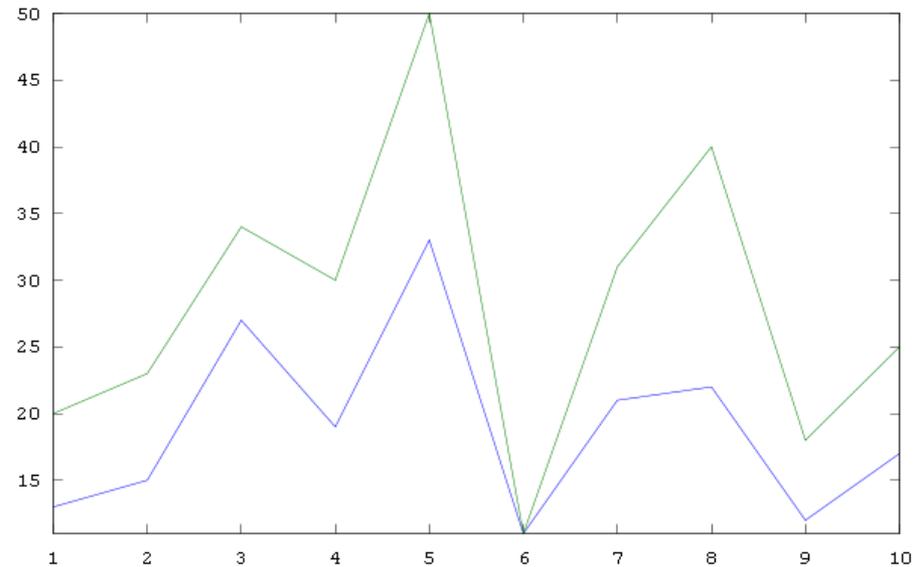
angleichen mittels $y = 1.53394x - 0.94480$.

Array 1' in blau: (19.0, 22.0, 40.5, 28.2, 49.7, 15.9, 31.3, 32.8, 17.5, 25.1)

Array 2 in grün: (20, 23, 34, 30, 50, 11, 31, 40, 18, 25)



(nach Normalisierung)



(vor Normalisierung)

Quantil-Normalisierung (RMA-Verfahren)

Annahme: Sortiert man die Intensitäten beider Arrays, sind die Werte gleich.
D.h. Alle Quantile der Intensitätsverteilungen sind gleich (und gleich Referenz).


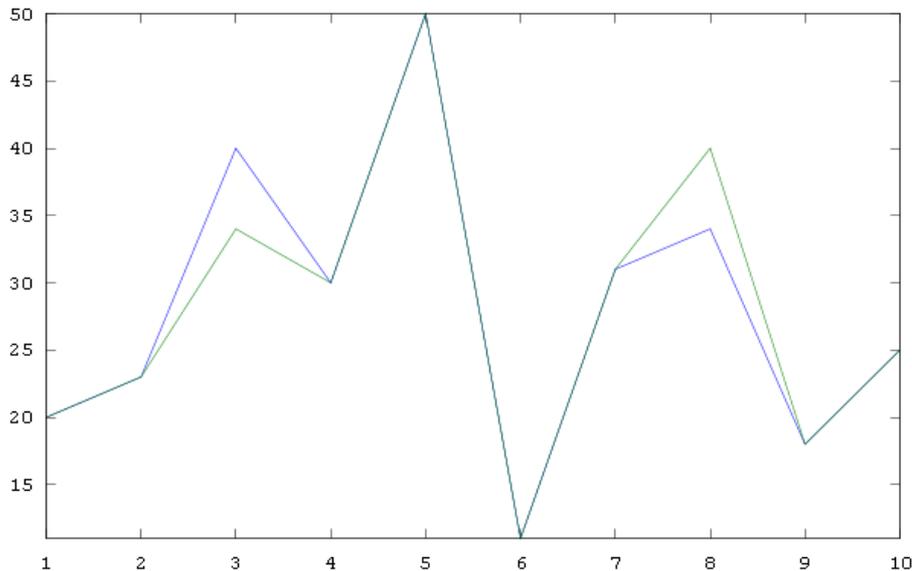
Array 1: (13, 15, 27, 19, 33, 11, 21, 22, 12, 17) # x

Array 2: (20, 23, 34, 30, 50, 11, 31, 40, 18, 25) # y

Array 1': (20, 23, 40, 30, 50, 11, 31, 34, 18, 25) # x normalisiert

Array 1' enthält die Werte aus Array 2, aber Sortierung aus Array 1.

in R: `x[order(x)] = referenz # referenz: sortierte y-Werte`



Schätzung eines Expressionswerts pro Gen

Jedes Gen wird durch mehrere (z.B. 11) Sonden / Spots gemessen.
Idealerweise liefern alle nach Normalisierung denselben Wert.

Das ist aber in der Praxis nicht so.

Die 11 Intensitätswerte werden zu einem Expressionswert zusammengefasst.


Methoden:

- Mittelwert
- Median
- Modelle, die die Hybridisierungsstärke der Sonden berücksichtigen.

Identifikation differenziell exprimierter Gene (Kandidaten-Gene)

MA-Plot („Minus gegen Average“):

Differenz gegen Durchschnitt aller Genexpressionswerte in zwei Experimenten.



MIAME - Standard

MIAME: Minimal Information About a Microarray Experiment

Richtlinien der MGED (Microarray and Gene Expression Data) Society

URL: http://www.mged.org/Workgroups/MIAME/miame_2.0.html

Ziel: Informationen zu Microarray Studien in Datenbanken sollen langfristig nutzbar und interpretierbar bleiben.

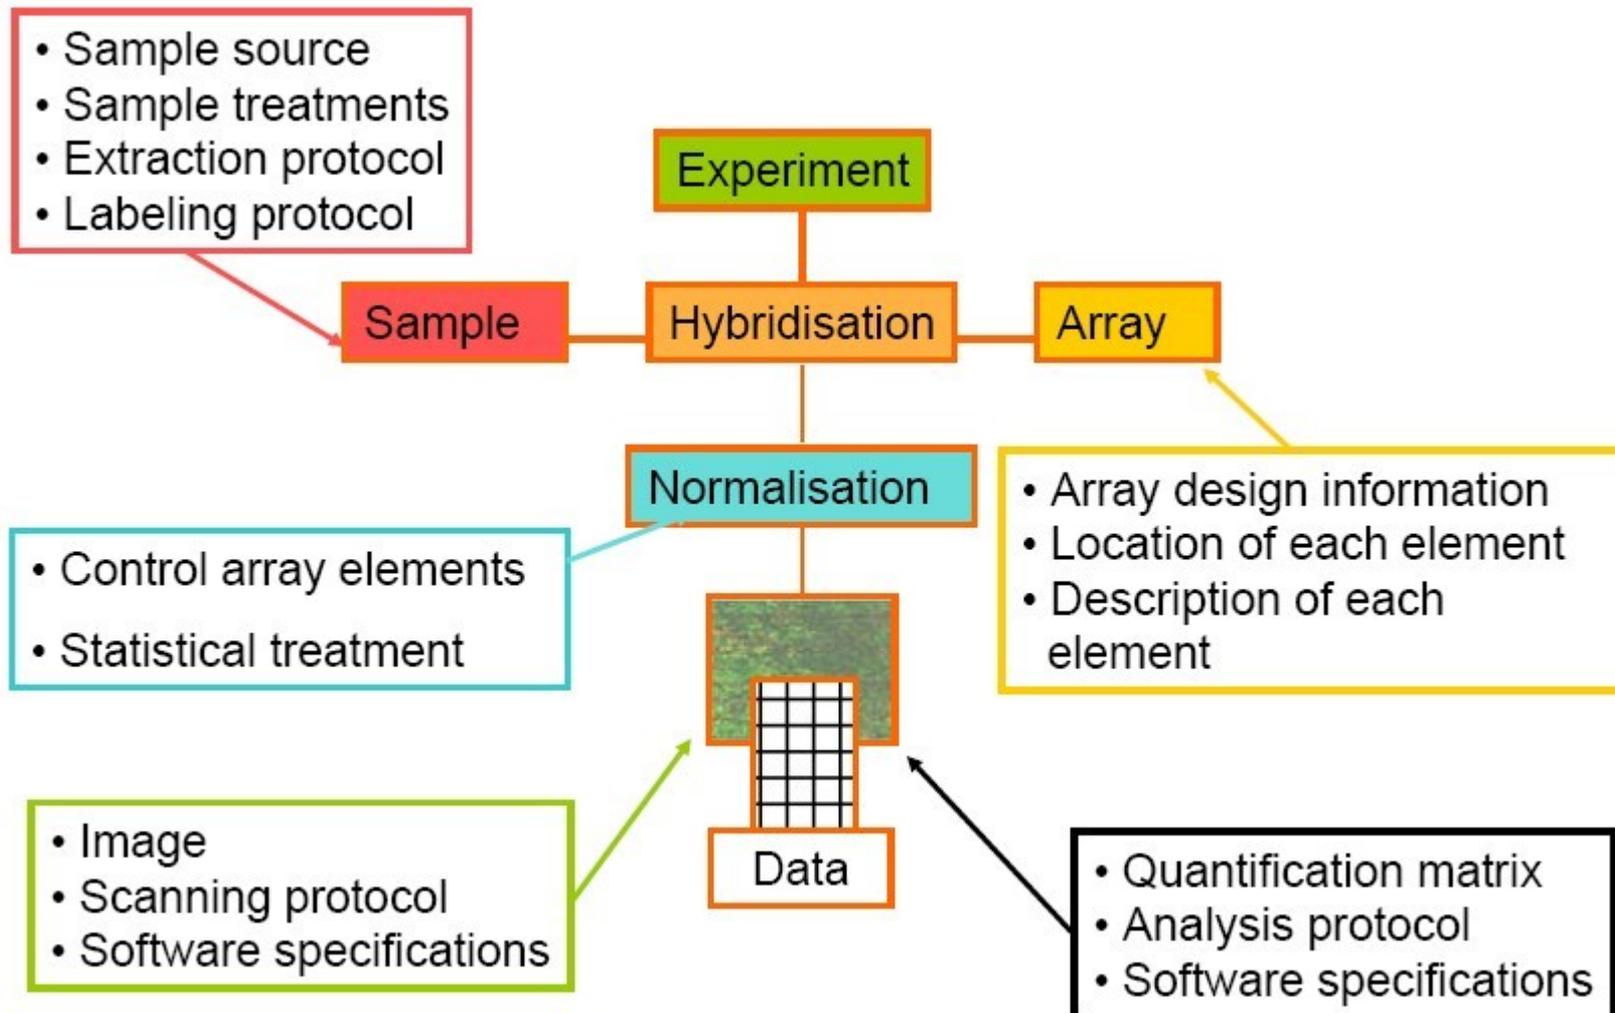
Verlangt werden Informationen zu 6 Bereichen.

Nach MIAME verlangte Informationen

6 Bereiche:

1. Rohdaten (Bild-Daten, unbearbeitet).
2. Prozessierte Daten (Matrix mit Expressionswerten pro Gen und Experiment).
3. Daten zu den Proben (samples):
Woher stammen die Proben (z.B. Tumorgewebe / gesundes Gewebe);
wie wurden in jedem Experiment die Proben behandelt?
4. Daten zum experimentellen Design:
Welche Beziehungen bestehen zwischen den Experimenten einer Studie,
zwischen verschiedenen samples ?
Welche Rohdaten gehören zu welchem sample?
5. Daten zum Array-Design:
Entweder welches Array von welchem Hersteller,
oder bei Eigenentwicklungen Liste der DNA-Sequenzen aller Sonden.
6. Protokolle, sowohl experimentell, als auch zur Datenanalyse.

Nach MIAME verlangte Informationen



GEO

Gene Expression Omnibus

- MIAME-konforme Microarray-Datenbank
- am NCBI
- <http://www.ncbi.nlm.nih.gov/geo/>

The screenshot shows the NCBI GEO website interface. At the top, there is the NCBI logo and the GEO logo (Gene Expression Omnibus). Navigation links include HOME, SEARCH, SITE MAP, Handout, NAR 2006 Paper, NAR 2002 Paper, FAQ, MIAME, and Email GEO. The current page is identified as NCBI > GEO. A user status bar indicates 'Not logged in | Login'. The main content area features a description of the Gene Expression Omnibus as a repository for MIAME-compliant data. Below this is a 'GEO navigation' section with 'QUERY' and 'BROWSE' options. The 'QUERY' section includes links for DataSets, Gene profiles, GEO accession, and GEO BLAST, each with a search input field and a 'GO' button. The 'BROWSE' section includes links for DataSets, GEO accessions, Platforms, Samples, and Series. A 'SUBMIT' section offers 'Direct deposit / update', 'Web deposit / update', and 'Create new account' options. On the right side, there are two summary boxes: 'Public data' showing counts for GPL Platforms (4754), GSM Samples (231841), GSE Series (8901), and a Total of 245496; and 'Site contents' with links for Documentation, Query & Browse, and Deposit & Update. At the bottom, there is a search bar for 'Get GEO accession' with dropdowns for Scope (Self), Format (HTML), and Amount (Quick), and a 'GO' button. Below the search bar is a 'Depositors only' section with fields for User and Password, a 'LOGIN' button, and a link to 'Recover a password'. The footer contains links for NLM, NIH, GEO Help, Disclaimer, and Section 508.

ArrayExpress

- MIAME-konforme Microarray-Datenbank
- am EBI
- <http://www.ebi.ac.uk/microarray/>

Microarray Informatics at the EBI

ArrayExpress - a public resource for transcriptomics and related data

Query ArrayExpress:	Profiles ▾	<input type="text" value="nfkbia"/>	Gene	
Browse ArrayExpress		<input type="text" value="leukemia"/>	Keyword	
		All ▾	Species	
				<input type="button" value="Query"/>

[Submit data to ArrayExpress](#)

[Analyse data in Expression Profiler](#)

New [ArrayExpress Atlas Beta](#)

[Documentation](#)

[Defined MGED Standards:](#) [MIAME](#) [MAGE-TAB](#) [MAGE-ML](#) [MGED Ontology](#)

Ein GEO-Beispiel

Accession Number GSM120719

URL: <http://www.ncbi.nlm.nih.gov/geo/query/acc.cgi?acc=GSM120719>

Standard Affymetrix Experiment; Homo sapiens; Muskelgewebe.

Prozessierte Daten, ein Intensitätswert pro Transkript: einfache Textdatei.

3 Spalten: Transkript-ID; Intensitätswert; Present/Absent - Entscheidung

ID_REF	VALUE	ABS_CALL
200000_s_at	7844.43408203125	P
200001_at	31178.318359375	P
200002_at	65324.34375	P
200003_s_at	60674.9921875	P
200004_at	28636.283203125	P
200005_at	16733.904296875	P
200006_at	39892.4765625	P
200007_at	23791.220703125	P
200008_s_at	10948.0546875	P
200009_at	18589.80078125	P
200010_at	48697.41015625	P
200011_s_at	3656.510009765625	P

...

Software für die Analyse von Microarray-Experimenten

Anbieter von Analyse-Software

- Gerätehersteller
- Kommerzielle Anbieter (spezialisierte Firmen)
- Forschergruppen, oft freie Software

Was ist Freie Software?

- „free as in speech“
- „free as in beer“

Bioconductor für R: Paketsammlung, Freie Software.

- URL: <http://www.bioconductor.org/>
- u.a. Funktionen für Microarrays



Erinnerung zu R: Test auf Normalität

Gegeben: Daten (Vektor) x

Frage: Stammt x aus einer Normalverteilung?

Kann Folgendes tun:

```
y=rnorm(10000)
qqplot(x, y) # Gerade?
```

Einfacher:

keine Zufallszahlen ziehen, sondern mit theoretischen Quantilen vergleichen



```
qqnorm(x) # Gerade ??
qqline(x) # Beste Gerade dazu einzeichnen!
```

Beispiel:

Sequenzierdaten; Qualitätswerte an Position 29 normalverteilt?

Test auf Normalität mit qqnorm()

```
qqnorm(q$V29) # Gerade??  
qqline(q$V29) # beste Gerade dazu
```



Warum nicht Histogramm
mit Dichte `dnorm()` vergleichen?

- qqplot zeigt Abweichungen besser;
invariant bei Verschiebung, Skalierung

Tests: Vergleich von normalverteilten Stichproben (Vektoren)

Fragestellung:

Gegeben zwei Datensätze (Vektoren),
haben die Verteilungen, aus denen sie stammen, gleichen Mittelwert?

Erste Idee und Problem:

Vergleiche empirische Mittelwerte (Durchschnitte) der beiden Vektoren.
Aber Durchschnitte sind nie exakt gleich!
(Auch nicht, wenn aus exakt der gleichen Verteilung gezogen wurde.)

Experiment:

Ziehe zweimal je 10 Werte aus Standard-Normalverteilung (`rnorm(10)`).
Berechne Durchschnitt (`mean`). Differenz der Durchschnitte ungleich Null!

Also:

Gewisse (kleine) Unterschiede des Mittelwerts zwischen Stichproben
aus derselben Verteilung sind kein Indiz für verschiedene Mittelwerte!

Test auf gleichen Mittelwert (bei Normalverteilung)

Nullhypothese:

Stichproben stammen aus Normalverteilungen mit gleichem Mittelwert.

Alternative:

Stichproben stammen aus Normalverteilungen mit verschiedenen Mittelwerten.

Frage, die die Statistik beantworten kann:

Angenommen, die Nullhypothese trifft zu.

Wie wahrscheinlich ist es, dass sich die beobachteten Mittelwerte um mindestens so viel wie die beobachtete Differenz unterscheiden?

Diese Wahrscheinlichkeit nennt man p-value (p-Wert).

(Für nicht normalverteilte Daten wird hier nichts ausgesagt!)

Anwendung:

Man gibt eine Grenze (Signifikanzniveau) vor (z.B. 0.05 oder 0.01).

Ist der p-Wert ≤ 0.05 , sagt man: „Der Unterschied ist signifikant“.

Ist der p-Wert ≤ 0.01 , sagt man: „Der Unterschied ist hoch signifikant“.

(Wahrscheinlichkeit für einen so großen Unterschied ist bei Nullhypothese klein!)

Der t-Test

Vergleich von zwei normalverteilten Stichproben x, y heißt
Zwei-Stichproben-t-Test.

Man „darf“ diesen Test nur auf (approximativ) normalverteilte Daten anwenden.
(Wenn man das nicht beachtet, ist das Ergebnis bedeutungslos.)

In R:

Zuerst x, y auf Normalverteilung prüfen (z.B. mit `qqnorm`).

Dann: `t.test(x, y)`

... liefert viele Informationen; wichtig ist der p-value.

(Aufgabe der mathematischen Statistik und Wahrscheinlichkeitsrechnung
ist Erfinden solcher Tests und exakte Berechnung der p-values.)

Der t-Test bei Microarrays

Situation:

Microarray-Experimente von 10 Tumor-Proben und 100 Kontroll-Proben von ca. 25,000 Genen liegen vor.

Betrachte Genexpression in beiden Klassen (10 und 100 Werte).

Gibt es einen signifikanten Unterschied zwischen den Klassen?

Lösung:

t-Test für jedes Gen (sofern die 10 und 100 Werte normalverteilt sind).

Aber:

Wahrscheinlichkeit, dass ein Gen-p-Wert $\leq x$ ist, obwohl kein Unterschied besteht, ist x (nach Definition des p-Werts).

Wir testen viele Gene ($\sim 25,000$).

Da ist „durch Zufall“ schon ein p-Wert $\leq 1/25000$.

Das bedeutet noch nichts.

Korrektur für multiples Testen

Wahrscheinlichkeit, dass ein Gen-p-Wert $\leq x$ ist,
obwohl kein Unterschied besteht, ist x (nach Definition des p-Werts).

Wir testen viele Gene ($\sim 25,000$).

Da ist „durch Zufall“ schon ein p-Wert $\leq 1 / 25000$.

Das bedeutet noch nichts.

Bonferroni-Korrektur:

Multipliziere p-Werte mit Anzahl der Gene.

Betrachte dann p-Werte ≤ 0.05 (signifikant) bzw. 0.01 (hoch signifikant).