



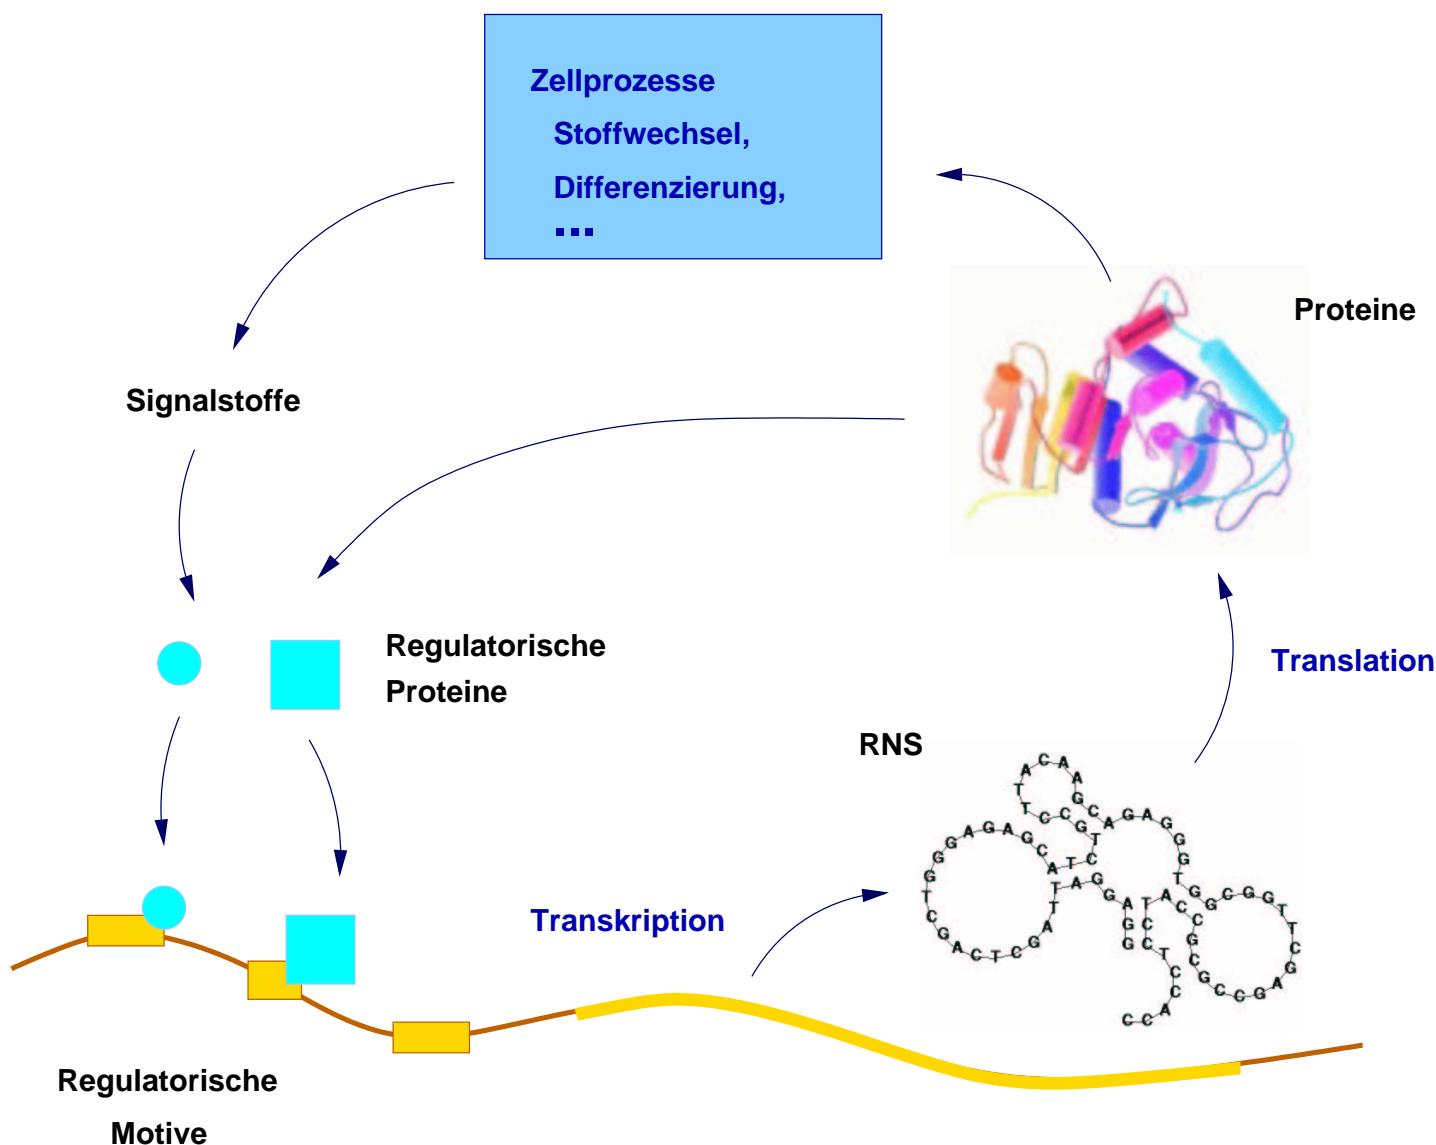
# Analyse der optimalen differentiellen Genexpression

Wolfram Liebermeister

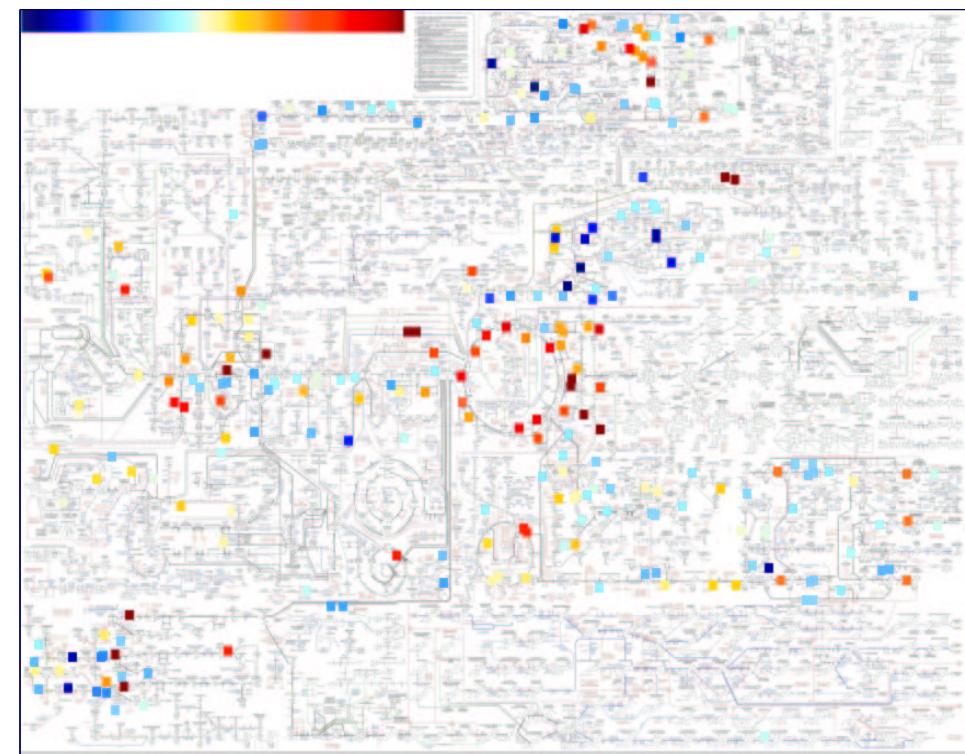
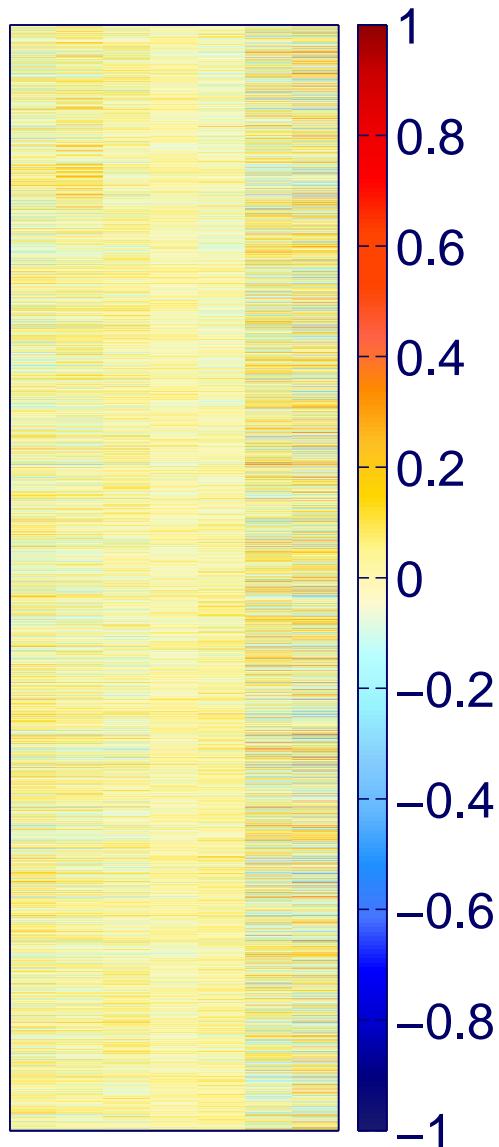
13. Januar 2004

Humboldt-Universität zu Berlin  
Theoretische Biophysik

# Genexpression



## Microarraydaten



$\log_2$  diff. Expression **-Glukose/+Glukose**

**Daten aus**

J.L. DeRisi et al. (1997), *Exploring the metabolic and genetic control of gene expression on a genomic scale*, Science 278

---

## Zielstellung meiner Arbeit

- **Datenanalyse mit statistischen Modellen**

Globale Moden in Microarraydaten als additive Faktoren

Koexpression z.B. bei Proteinkomplexen und im Stoffwechsel

- **Problem:**

Theoretische Erklärung für die Beziehung zwischen Expression und Funktion?

- **Vorhersage von Expressionsprofilen**

Expression dient der Steuerung der Proteinmenge

Komplexe Steuerung: viele Gene, viele Zellprozesse

Welche Korrelationen sind in Expressionsdaten zu erwarten?

**Ziel:** Allgemeine Beziehungen für große Zellmodelle

---

# Ein Modell für optimale Genexpressionsmuster

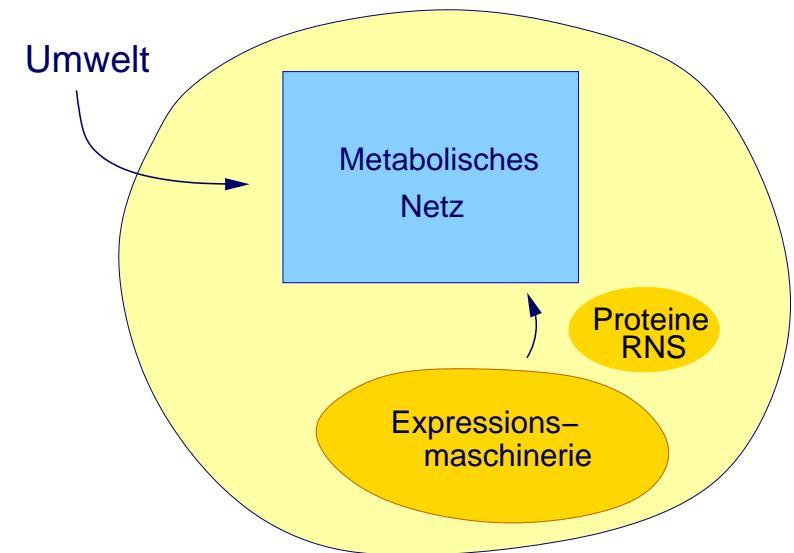
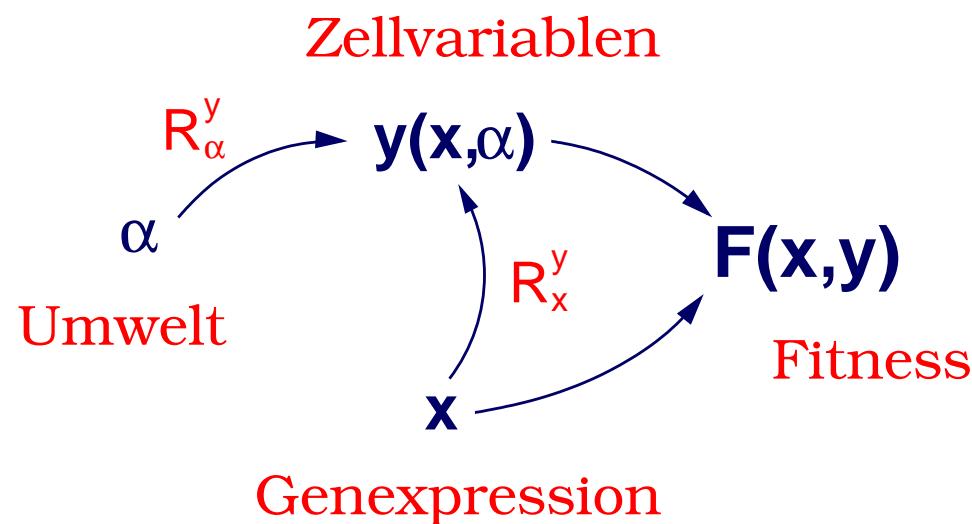
## Das Modell soll

1. optimale differentielle Expression vorhersagen
2. die koordinierte Expression vieler Gene beschreiben
3. die korrelierte Expression im Stoffwechsel erklären

## Modellannahmen

1. Differentielle Expression dient der optimalen Kontrolle von Zellprozessen
2. Modell der Zellprozesse mit stabilem stationären Zustand
3. Optimalität bedeutet: Maximierung einer Zielfunktion ("Zellfitness")
4. Gene mit komplexen Effekten:  
Kompromiss zwischen Nutzen und Kosten für alle Gene
5. Differentielle Störungen  $\Rightarrow$  lokale Näherung

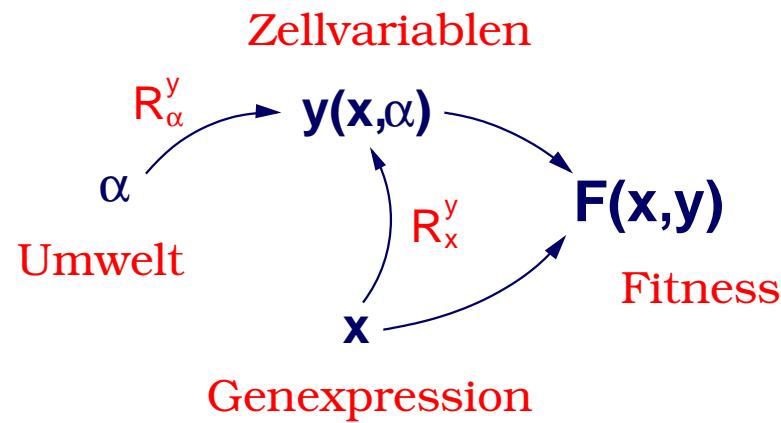
# Das Modell



**Das Optimalitätsprinzip:**

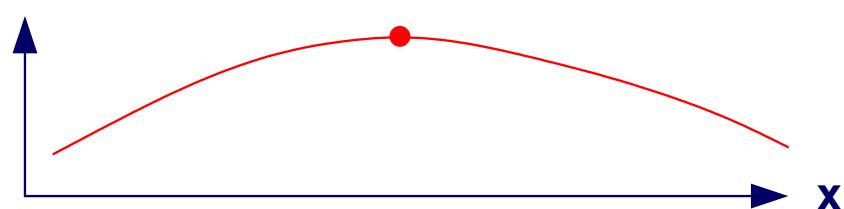
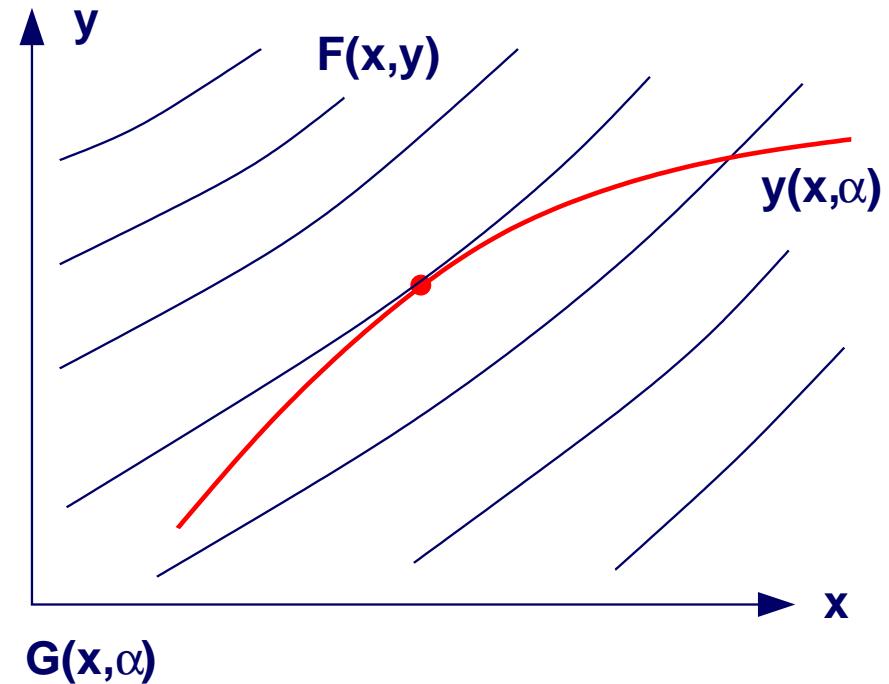
Die Expressionswerte  $x_i$  maximieren die Fitness  $F(x, y(x, \alpha))$

# Das Modell

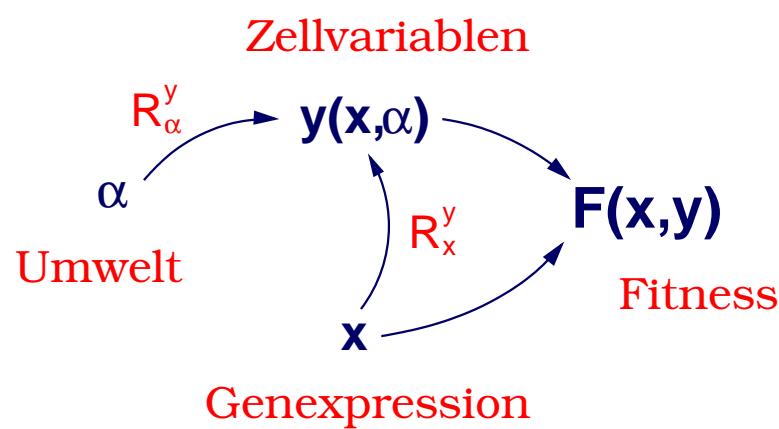


Effektive Fitness

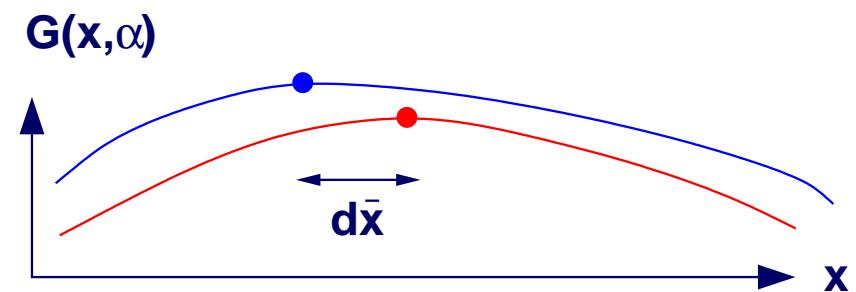
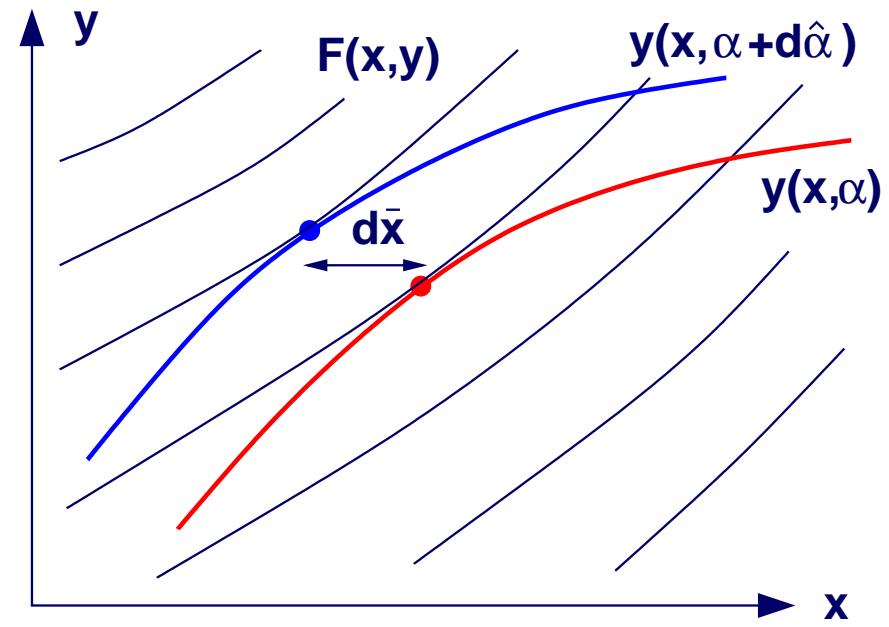
$$G(x, \alpha) = F(x, y(x, \alpha))$$



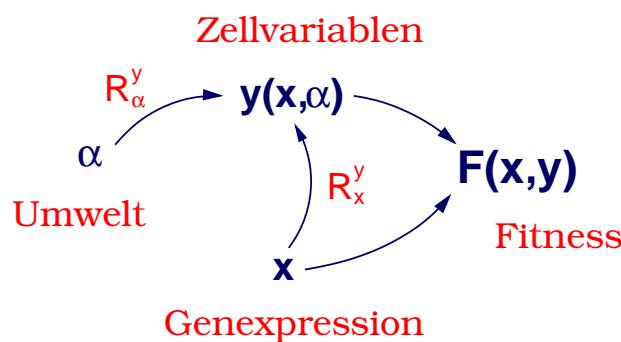
# Das Modell



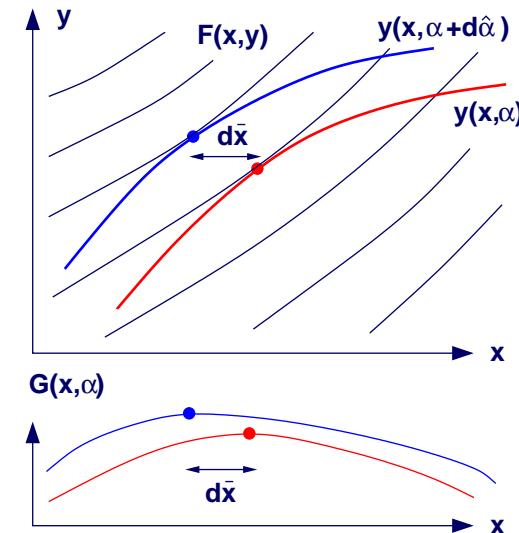
Differentielle Störung  $d\hat{\alpha} \rightarrow$   
Differentielle Expression  $d\bar{x}$



# Optimale differentielle Expression



Differentielle Störung  $d\hat{\alpha} \rightarrow d\hat{y}, d\hat{R}_x^y$



Responsekoeffizienten

$$R_x^y = \frac{\partial y}{\partial x}, \quad R_\alpha^y = \frac{\partial y}{\partial \alpha}$$

Ableitungen der Fitness

$$F_x, F_{xx}, F_{yy}, G_x, G_{xx}, G_{x\alpha}$$

Optimalitätsbedingung

$$d\bar{G}_x = 0$$

Differentielles Expressionsprofil

$$d\bar{x} = -G_{xx}^{-1} G_{x\alpha} d\hat{\alpha}$$

Vereinfachende Annahme

$$F(x, y) = V(y) + U_1(x_1) + U_2(x_2) + \dots$$

Expression als Reaktion auf  $d\hat{y}$  und  $d\hat{R}_x^y$

$$d\bar{x} = -(G_{xx}^{-1} R_x^y)^T F_{yy} d\hat{y} - (G_{xx}^{-1} F_y^T) d\hat{R}_x^y$$

---

## Drei Anwendungen

### 1. Optimale Feedbacksteuerung

Wie müssen Gene auf Zellvariablen reagieren,  
damit optimale Expressionsmuster entstehen?

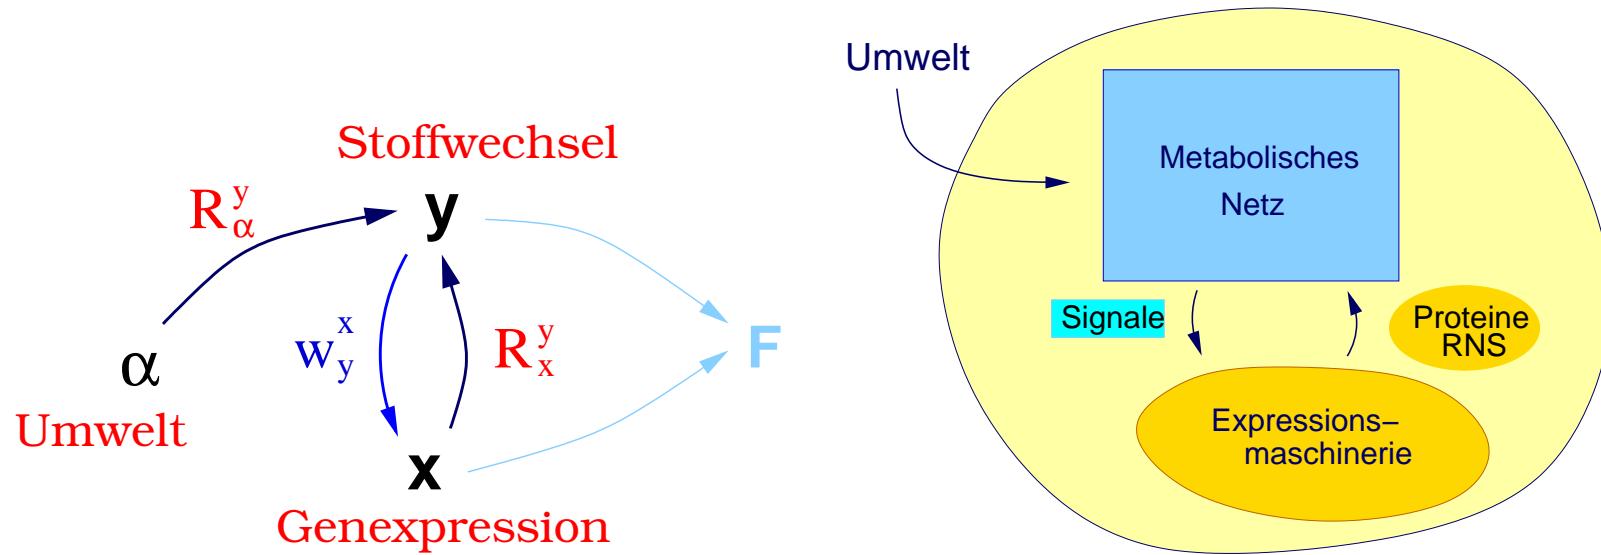
### 2. Expressionsmuster und Responsekoeffizienten

Wie lässt sich die korrelierte Expression im  
Stoffwechsel erklären?

### 3. Kompensation von Gendeletionen

Wie sollen die Expressionsmuster nach der Deletion  
einzelner Gene aussehen?

# (1) Optimale Feedbacksteuerung



Lineare Beziehung

$$dx = w_y^x dy$$

Optimalitätsbedingung

$$d\bar{G}_x = 0$$

Annahme

$$d\hat{R}_x^y = 0$$

Optimale Einflüsse

$$w_y^x = -F_{xx}^{-1} R_x^y {}^T F_{yy}$$

---

## (2) Expression im Stoffwechsel

- **Stoffwechsel: Topologie vs. Funktion**

Topologische Beschreibung durch Stoffwechselwege?

Responsekoeffizienten  $\Rightarrow$  globale Wirkung eines Enzyms

Responsekoeffizienten spiegeln die Netzstruktur wider

- **Optimalität führt zu Koregulation**

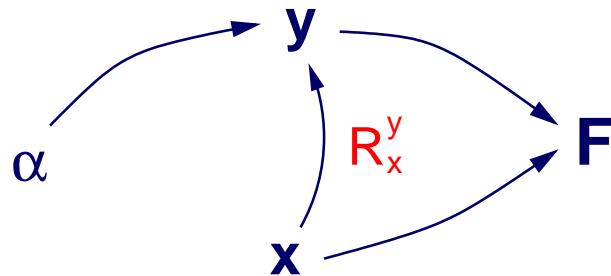
**Teilprobleme:**

1. Genexpression  $\Leftarrow$  Responsekoeffizienten

2. Responsekoeffizienten  $\Leftrightarrow$  Stoffwechselnetz

$\Rightarrow$  **Summenregeln** für korrelierte Expression von benachbarten Reaktionen und auf stationären Flussmoden

## (2) Lineare Überlagerung von Responsekoeffizienten



**Optimales Expressionsprofil**  
für gegebene Änderung  $dy$ :

$$d\bar{x} = F_{xx}^{-1} R_x^{y^T} (R_x^y F_{xx}^{-1} R_x^{y^T})^{-1} dy$$

$$\begin{matrix} dx \\ \vdots \\ \vdots \end{matrix} = \begin{matrix} R_x^{y^T} \\ \vdots \\ \vdots \end{matrix} \times \begin{matrix} dm \\ \vdots \\ \vdots \end{matrix}$$

**Annahme**  
Fitnesskrümmungen aller Gene gleich

**Optimales Expressionsprofil**

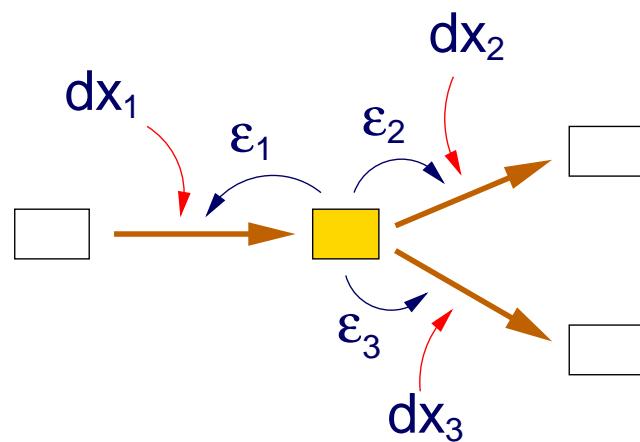
$$\begin{aligned} d\bar{x} &= R_x^{y^T} dM \\ &= R_x^{y_1^T} dm_1 + R_x^{y_2^T} dm_2 + \dots \end{aligned}$$

⇒ Strukturen in Responsekoeffizienten  
können sich auf Expressionsprofile  
übertragen

## (2) Summenregel 1: Benachbarte Reaktionen

### Annahmen:

- Nur Reaktionsgeschwindigkeiten werden reguliert
- Keine Erhaltungsbeziehung zwischen Metaboliten



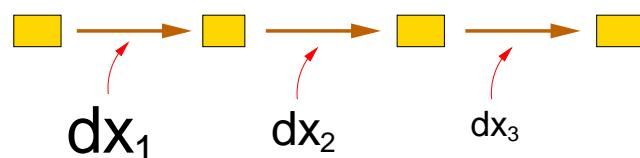
### Summenregel

$$d\bar{x}^T \epsilon L = 0$$

aus dem Konnektivitätstheorem

### Rings um einen Metaboliten gilt

$$\epsilon_1 d\bar{x}_1 + \epsilon_2 d\bar{x}_2 + \epsilon_3 d\bar{x}_3 + \dots = 0$$



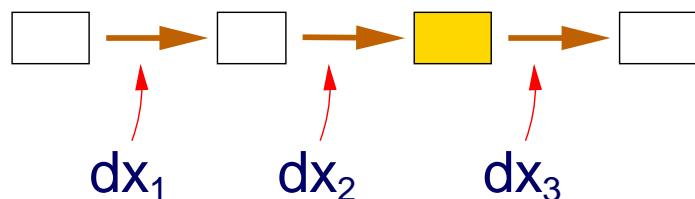
### Lineare Reaktionskette:

Differentielle Expressionswerte  
sind proportional

## (2) Summenregel 2: Reaktionen entlang Flußmoden

### Annahmen:

- Nur Stoffkonzentrationen werden reguliert



### Summenregel

$$d\bar{x}^T K = 0$$

aus dem Summationstheorem

### Auf stationärem Flussmodus gilt

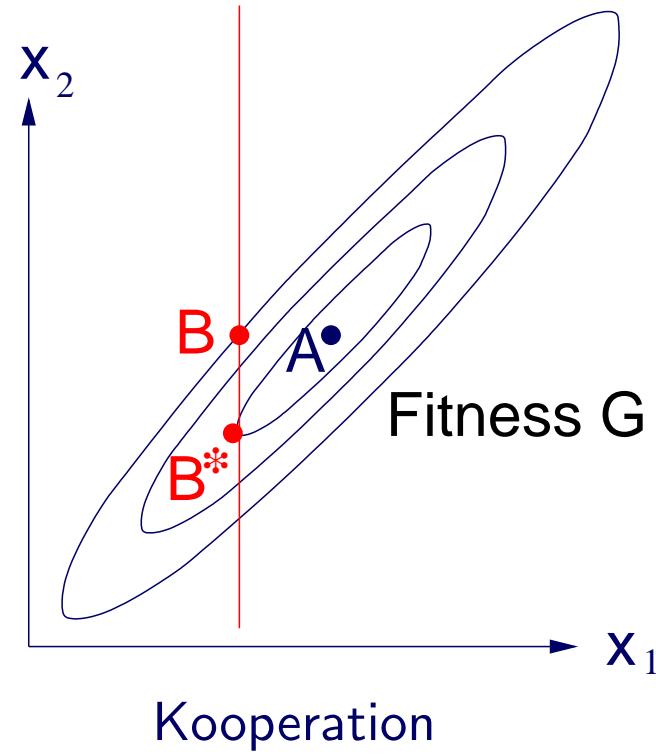
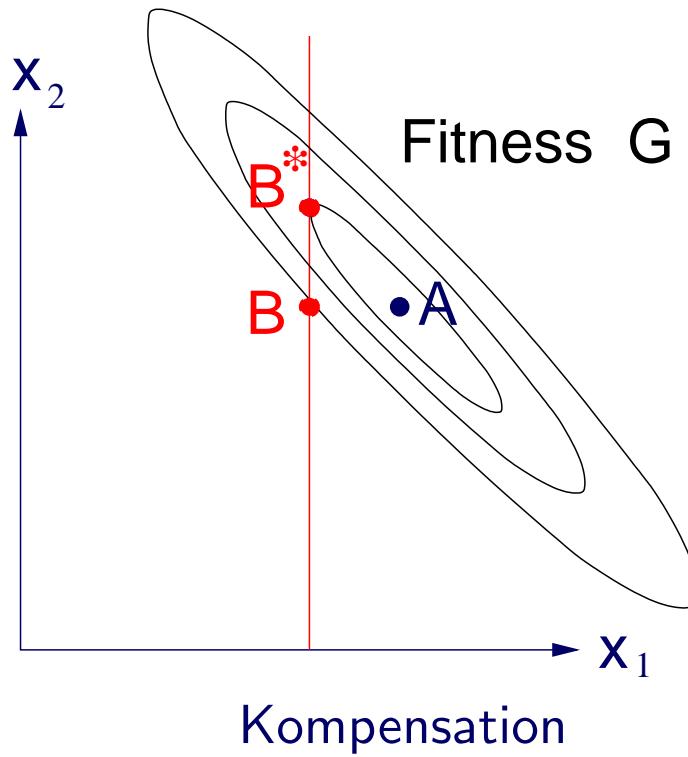
$$d\bar{x}_1 + d\bar{x}_2 + d\bar{x}_3 + \dots = 0$$

### Lineare Reaktionskette:

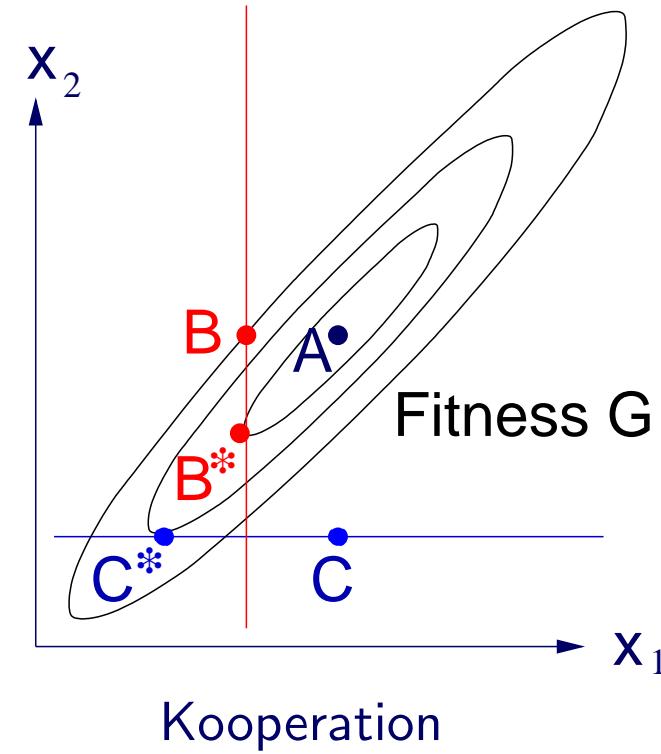
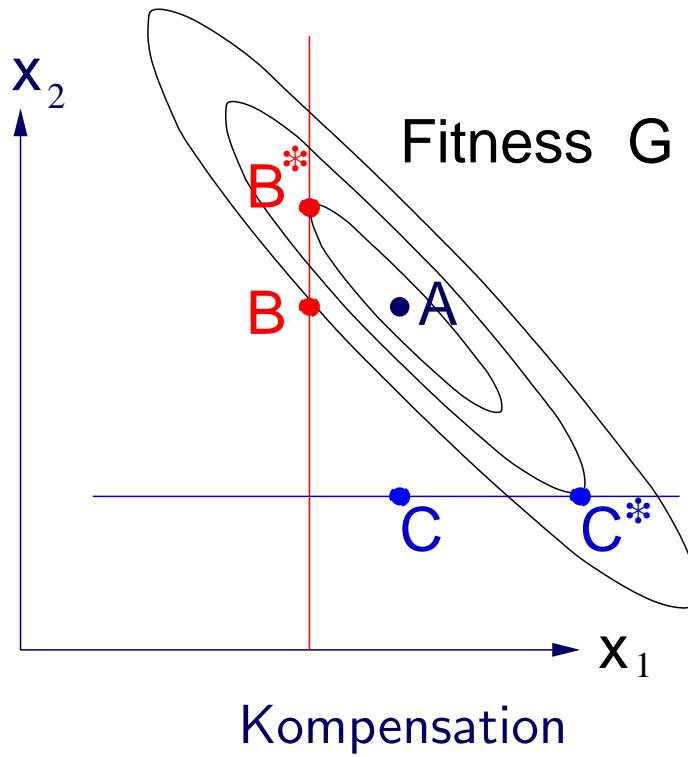
Gegenläufige Steuerung

Zur Erhöhung einer Konzentration wird die Enzymaktivität oberhalb des Metaboliten erhöht, unterhalb gehemmt.

### (3) Kompensation von Gendeletionen

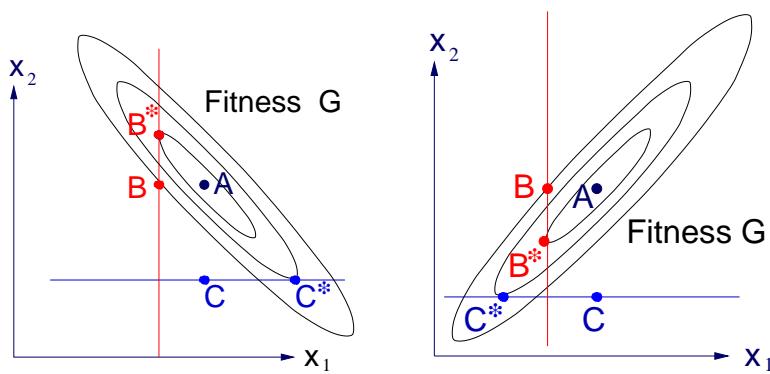


### (3) Kompensation von Gendeletionen



In beiden Fällen: Symmetrisches Verhalten der Gene

### (3) Kompensation von Gendeletionen

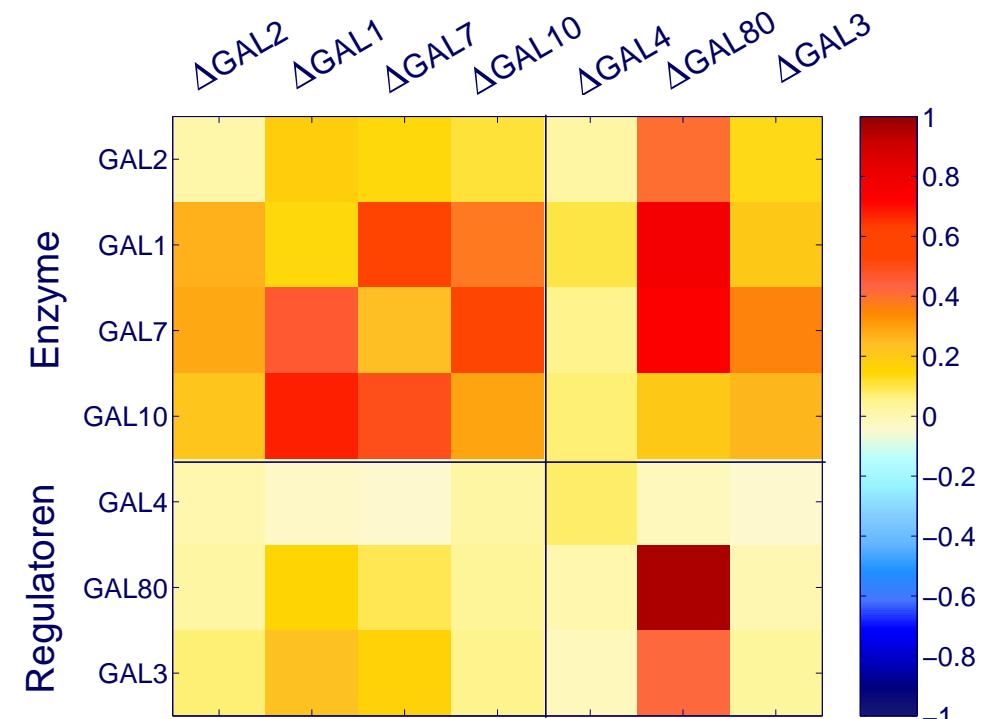


#### Modellvorhersage

für Expressionsmatrix  $X$  nach  
Deletionen

$$X = G_{xx}^{-1} D$$

$G_{xx}^{-1}$  ist symmetrisch,  $D$  ist diagonal.



Daten: + Galaktose/ - Galaktose

T. Ideker et al. (1997), *Integrated Genomic and proteomic analyses of a systematically perturbed metabolic network*, Science 292

---

# Zusammenfassung

## Ansatz

- Optimalitätsannahme  $\Rightarrow$  differentielle Expressionsprofile
- Koordination vieler Gene mit komplexen Wirkungen
- lokale Näherung  $\Rightarrow$  allgemeine Vorhersagen

## Ergebnisse

- Optimale differentielle Expressionsmuster
- Regulation von Genen repräsentiert u.A. deren Funktion
- Korrelierte Expression von Stoffwechselenzymen
- Symmetrische Antwort auf Deletionen



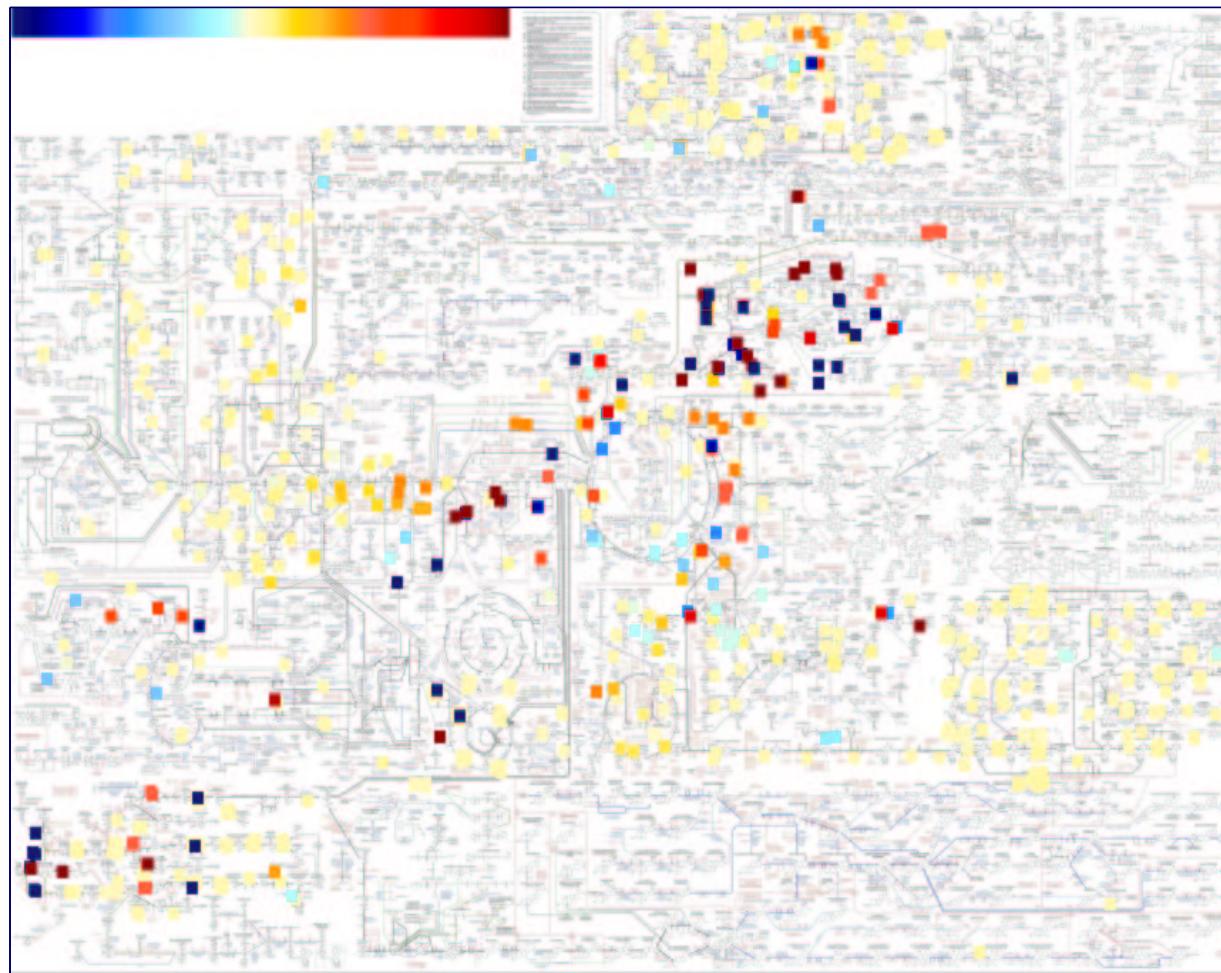
# Analyse der optimalen differentiellen Genexpression

Wolfram Liebermeister

13. Januar 2004

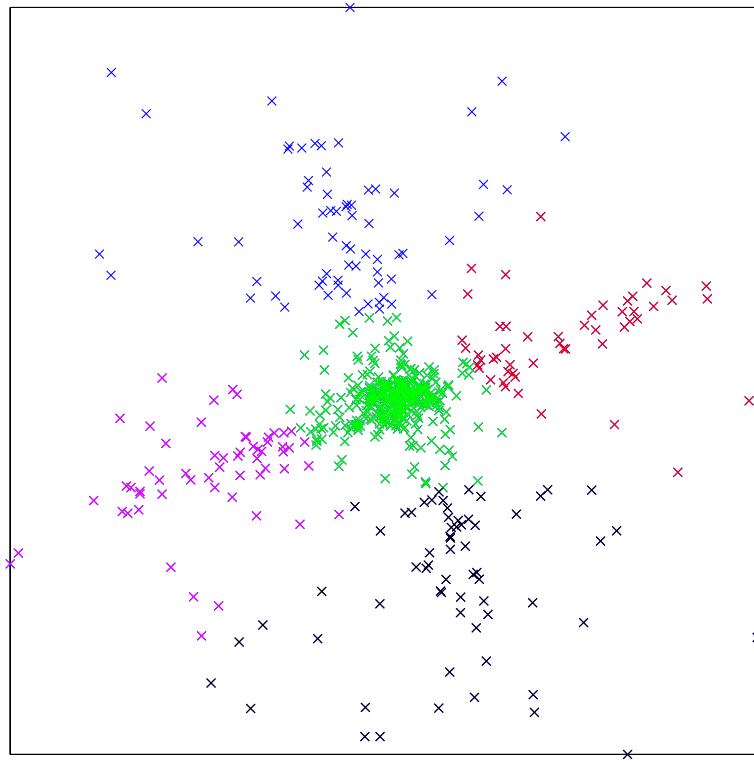
Humboldt-Universität zu Berlin  
Theoretische Biophysik

## Metabolische Kontrollkoeffizienten

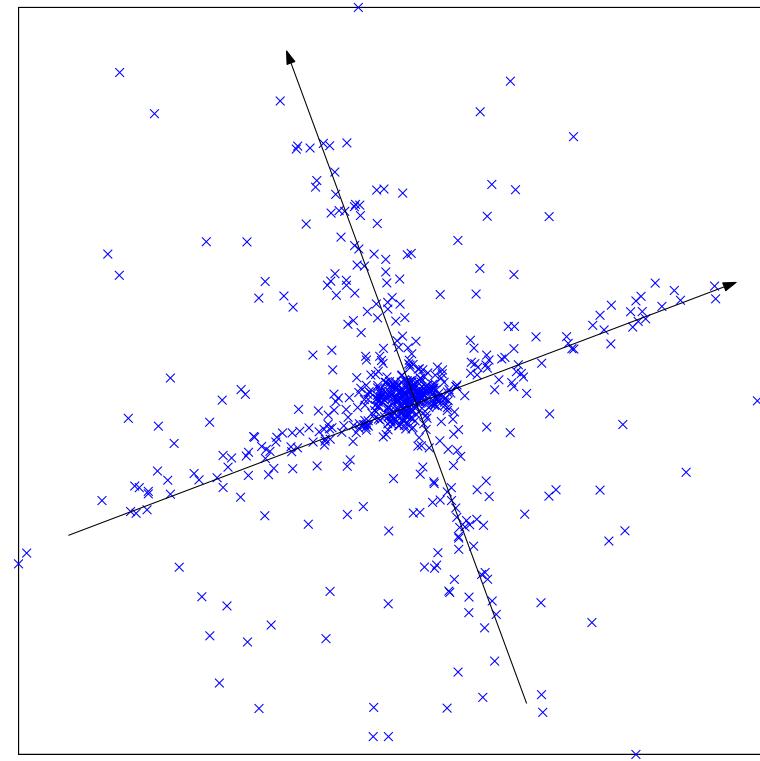


$R_i^{Ethanol}$  für Ethanol, basierend auf Hefe-Netz aus KEGG

# Analyse von multivariaten Expressionsdaten

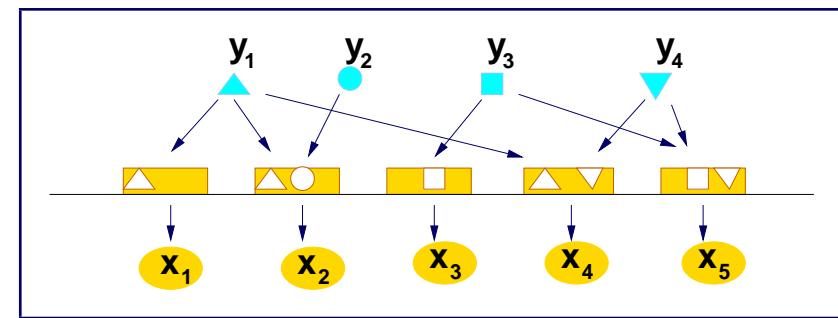
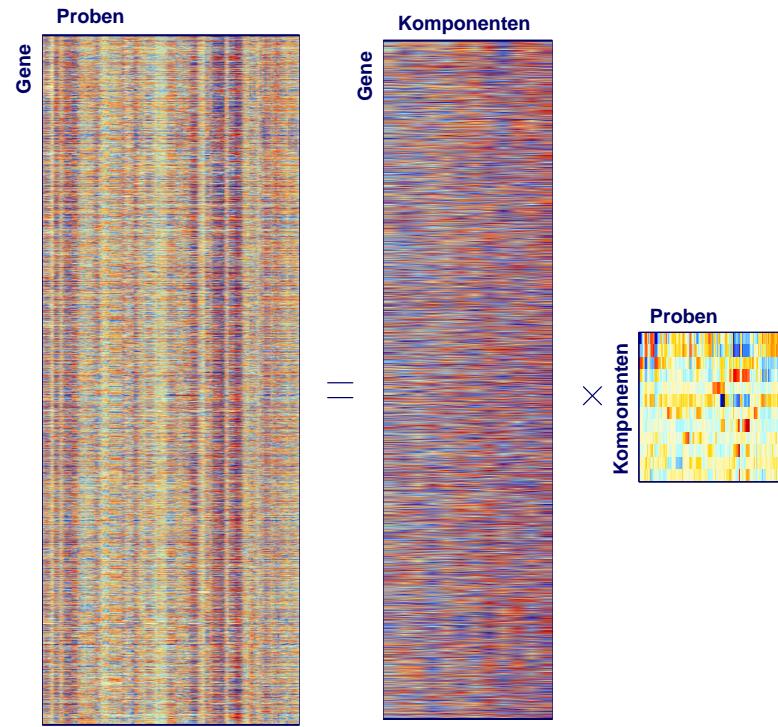


Clustering



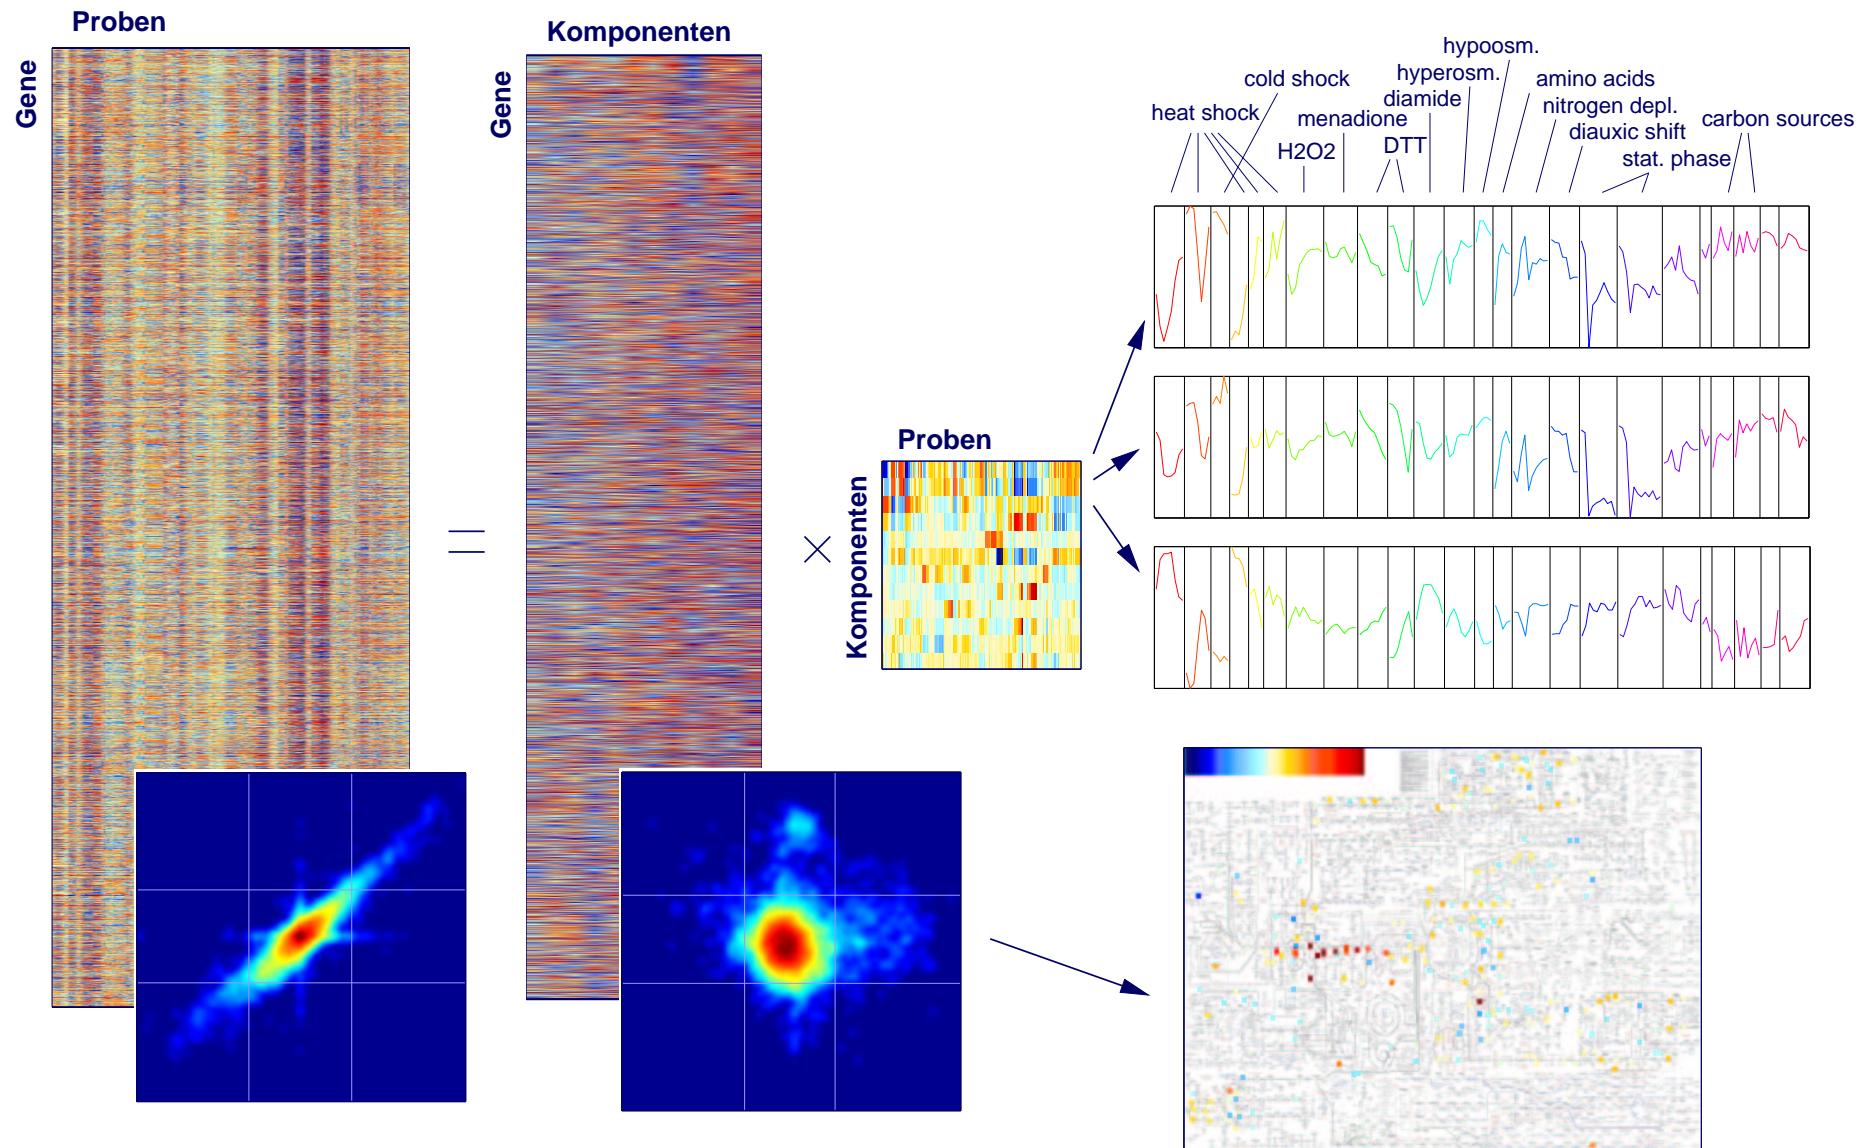
Lineares Modell (ICA)

# Lineare Modelle

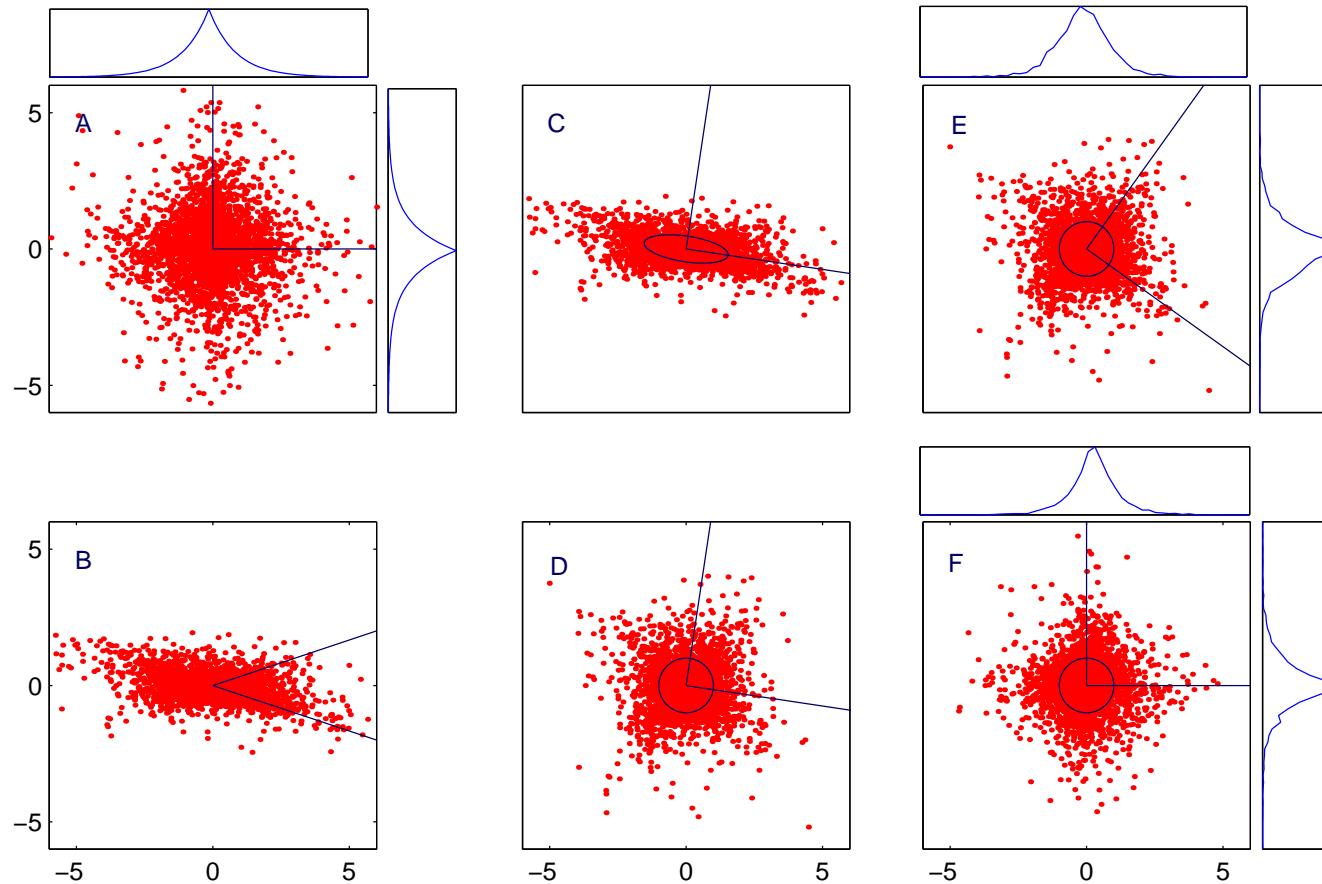


$$X = S \times Y + \eta$$

# Independent component analysis (ICA)



# ICA



A. Wahre Komponenten

B. Künstliche Daten

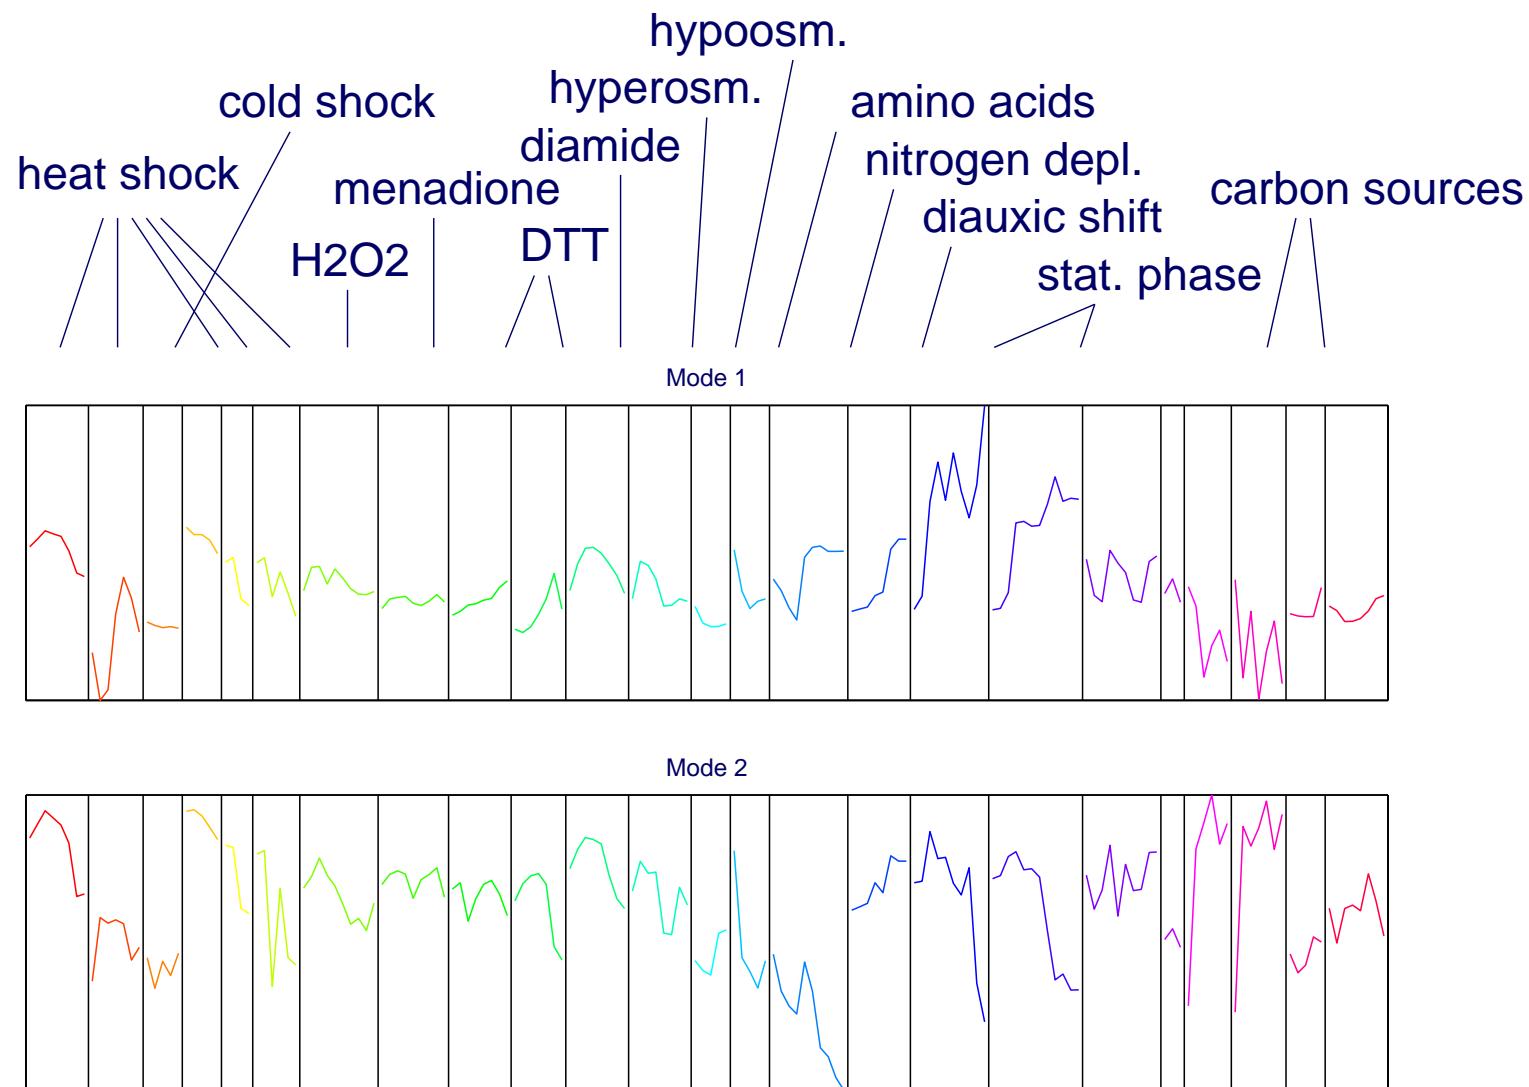
C. Kovarianz

D. Entkorrelieren

E. Auffällige Randverteilungen

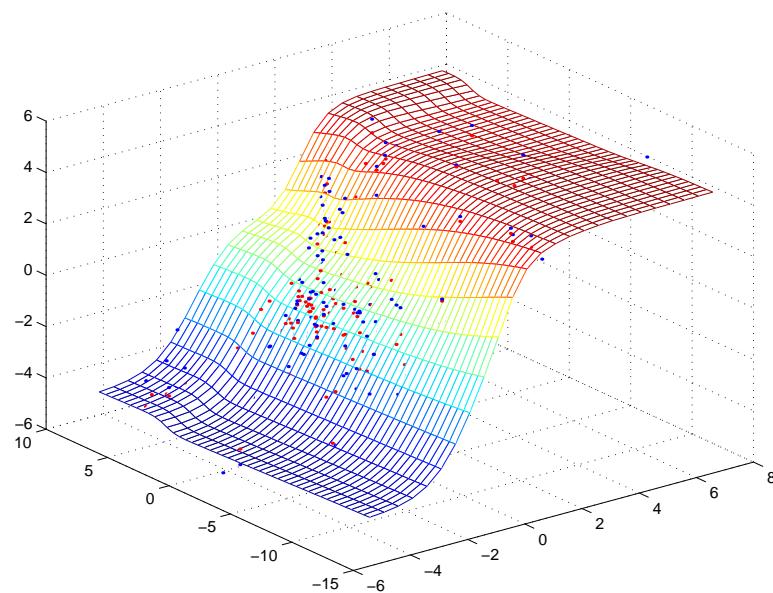
F. Rekonstruierte Komponenten

# Nichtlineare ICA (Zellstress-Daten)

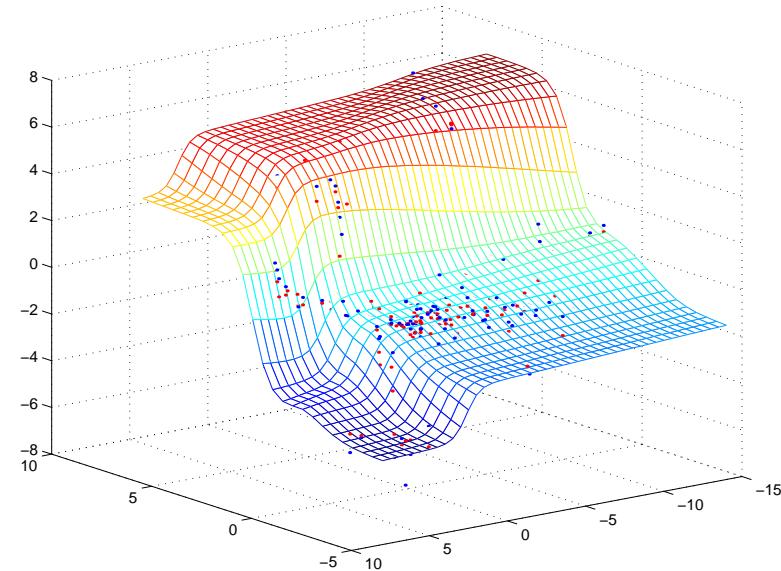


Nichtlineare Komponenten in Zellstress-Daten Gasch et al.

## Nichtlineare ICA (Zellstress-Daten)



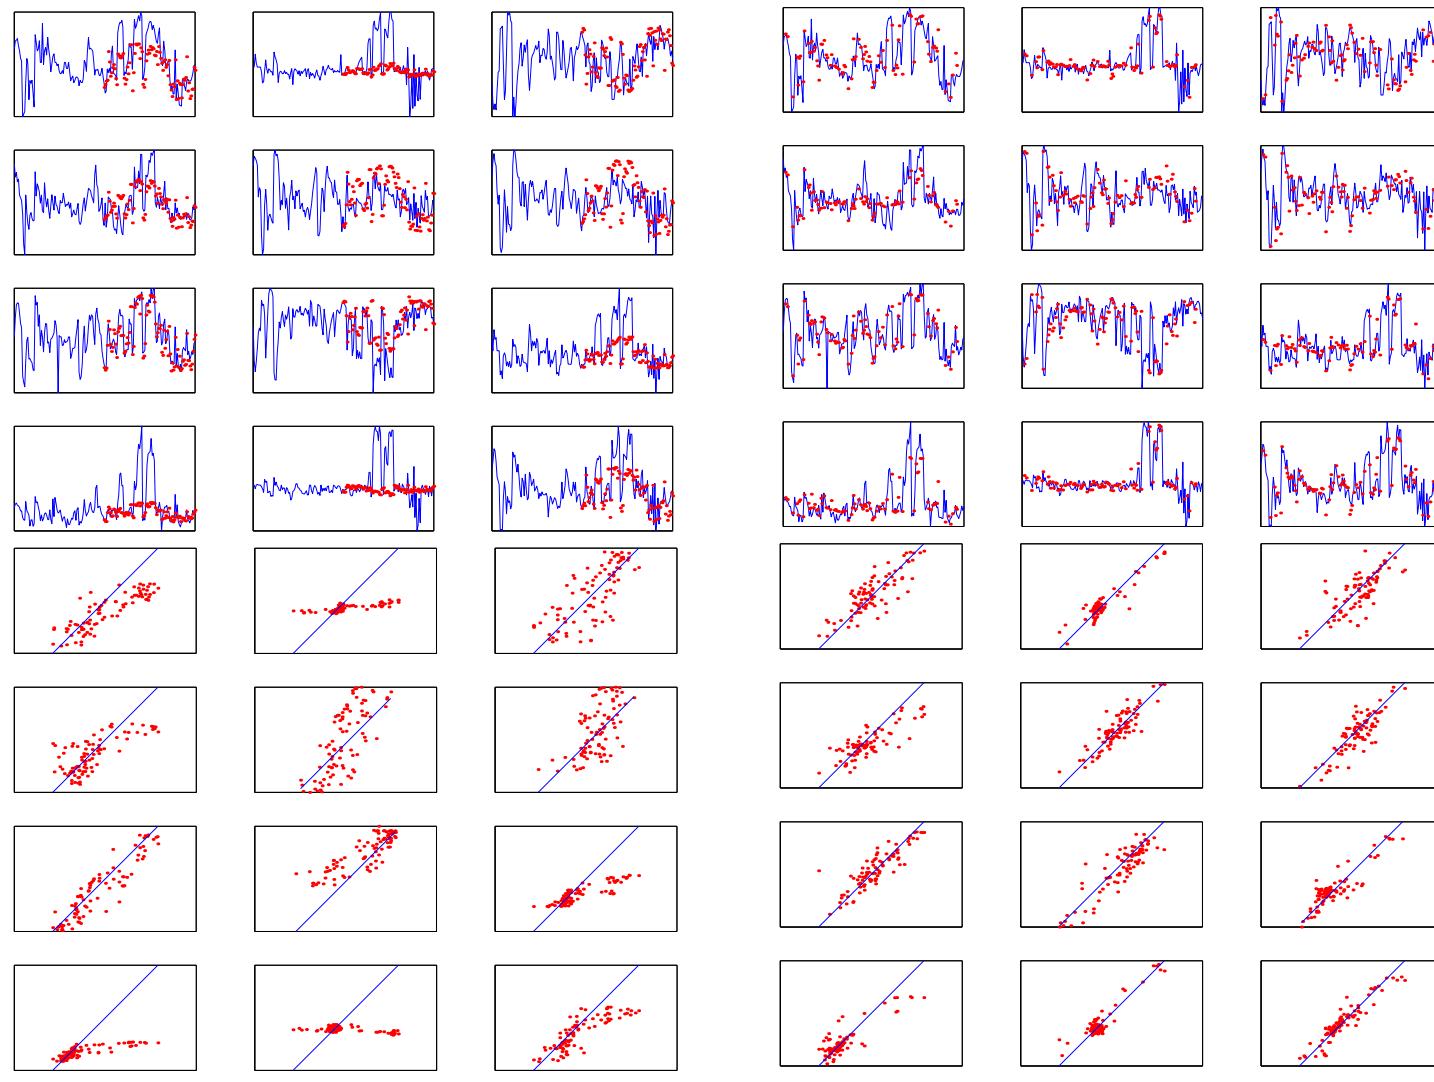
HSP26



JEN

Zellstress-Daten Gasch et al.

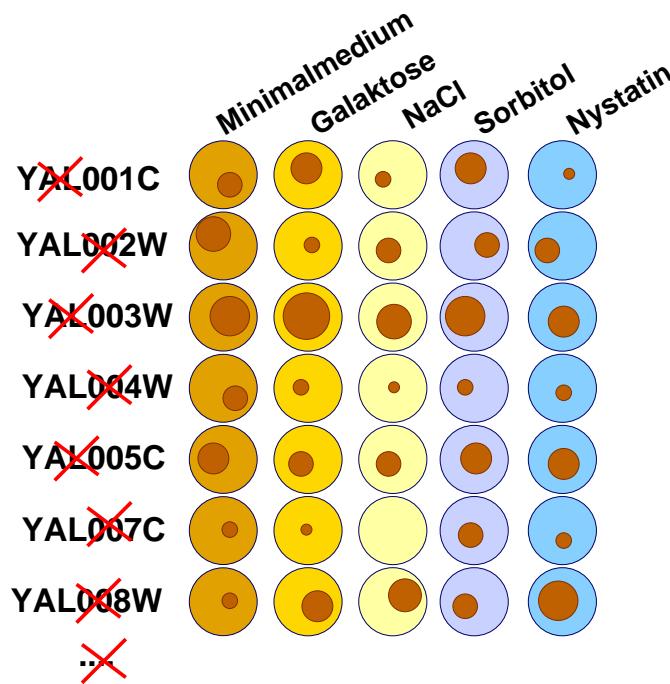
## Nichtlineare ICA (Zellstress-Daten)



Blau: Genprofile

Rot: Vorhersage mit nichtlin. ICA

# Expression und Fitnessverlust nach Deletionen



G. Giaever et al. (2002),  
*Functional profiling of the *Saccharomyces cerevisiae* genome*, Nature 418

“The fact that such a small percentage of the genes that exhibit a significant increase in expression also exhibit a significant fitness defect was unexpected and warrants closer inspection.”

## Interaktion Deletion/Medium

$$dx^T G_{x\alpha} d\alpha = \frac{\mathbf{d}\hat{x}_i^T}{(G_{xx}^{-1})_{ii}} G_{xx}^{-1} G_{x\alpha} d\alpha$$

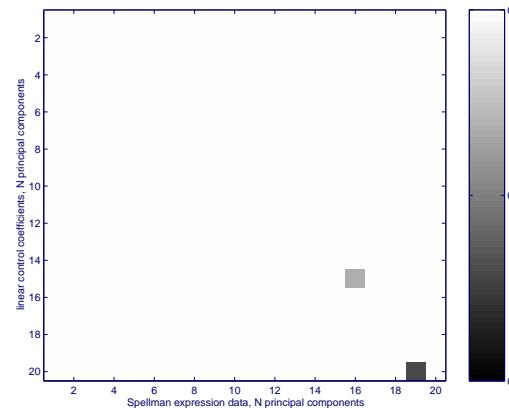
## Diff. Expression ohne Deletion

$$d\bar{x} = -G_{xx}^{-1} G_{x\alpha} d\alpha$$

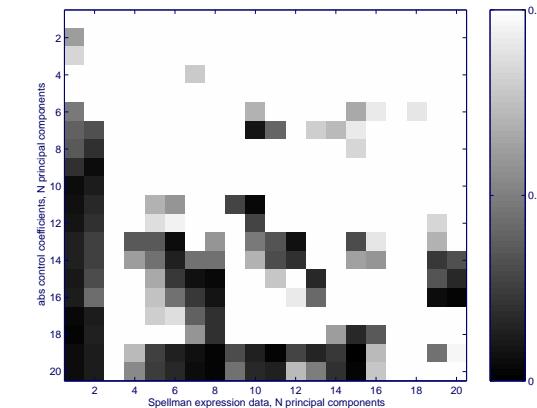
# Expression und Kontrollkoeffizienten

- Vergleich von Expressionsdaten und Kontrollkoeffizienten
- Maß für Ähnlichkeit:  
Winkel zwischen den Räumen der ersten Hauptkomponenten
- p-Werte aus Permutationstest

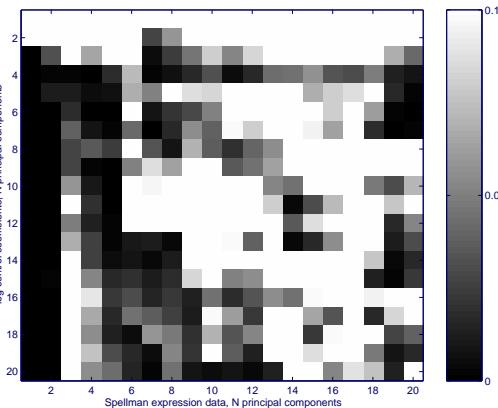
Kontrollkoeffizienten  $C^J$



$|C^J|$



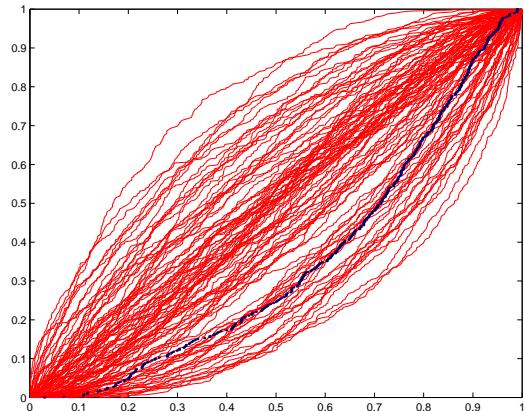
$\log|C^J|$



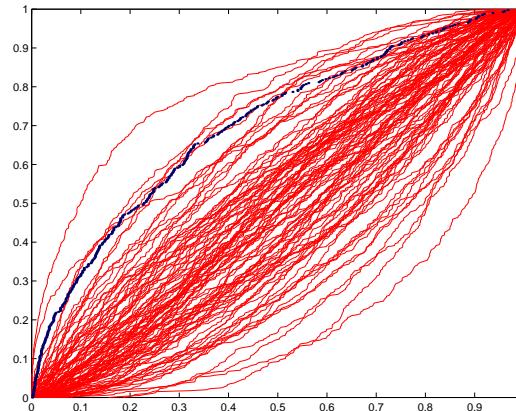
# Expression und Kontrollkoeffizienten

## Verteilung der p-Werte

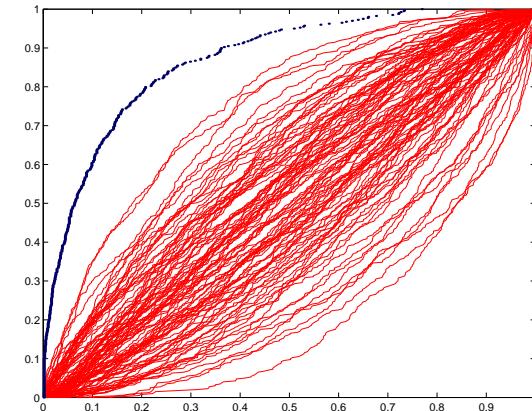
Kontrollkoeffizienten  $C^J$



$|C^J|$



$\log|C^J|$

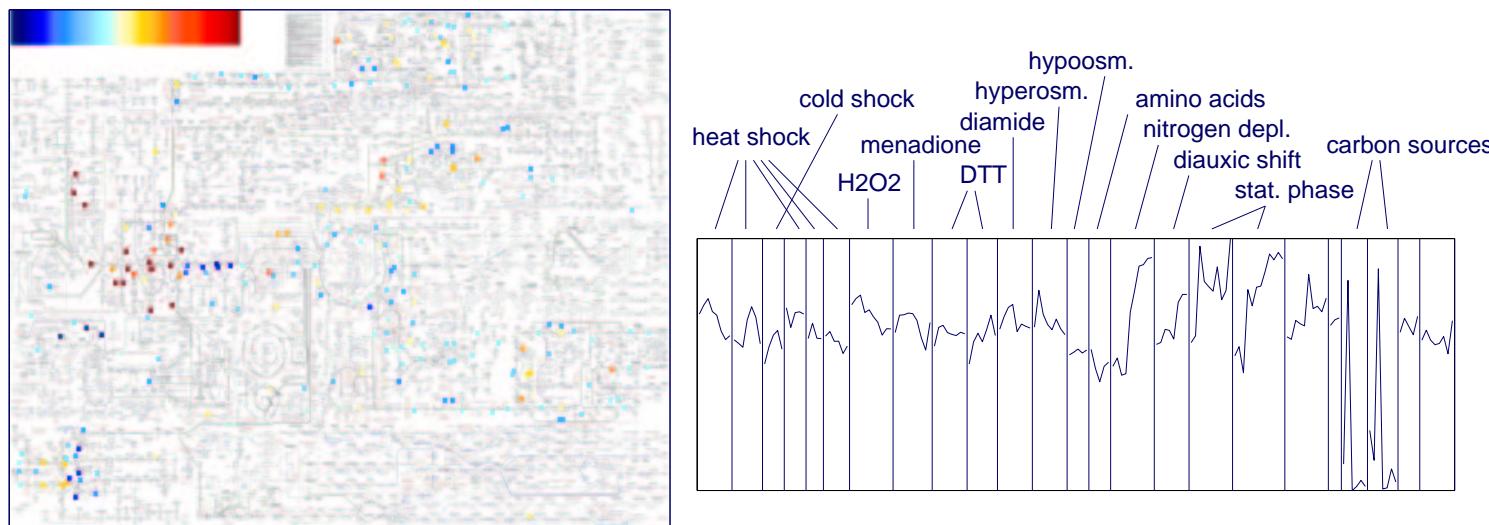


Schwarz: Kumulative Verteilungen der p-Werte

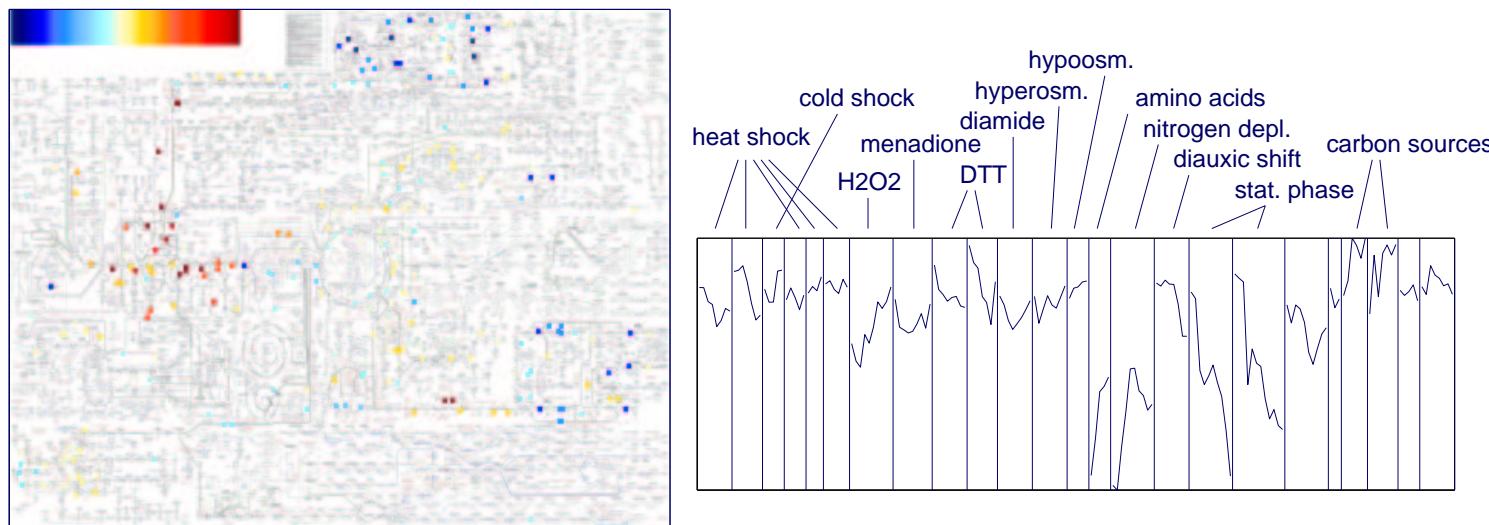
Rot: Ergebnis unter Nullhypothese (Permutationstest)

Daten: Hefe-Zellzyklus, Spellman et al. 1998

# Expression und Kontrollkoeffizienten: ICA

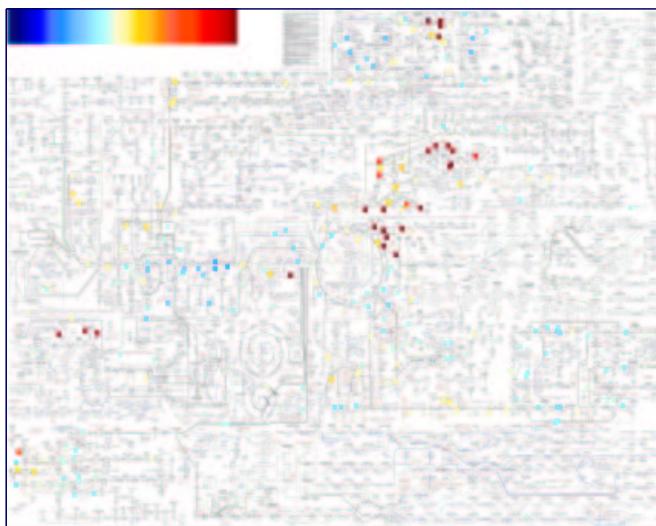


Galaktoseabau und obere Glycolyse (Wachstum auf Galaktose)

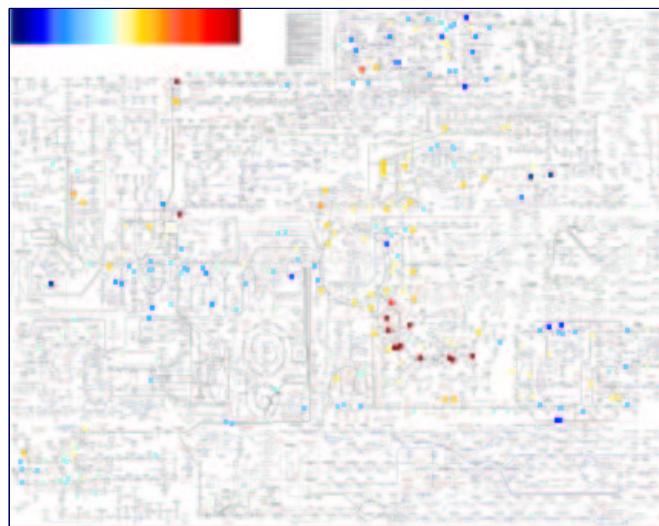
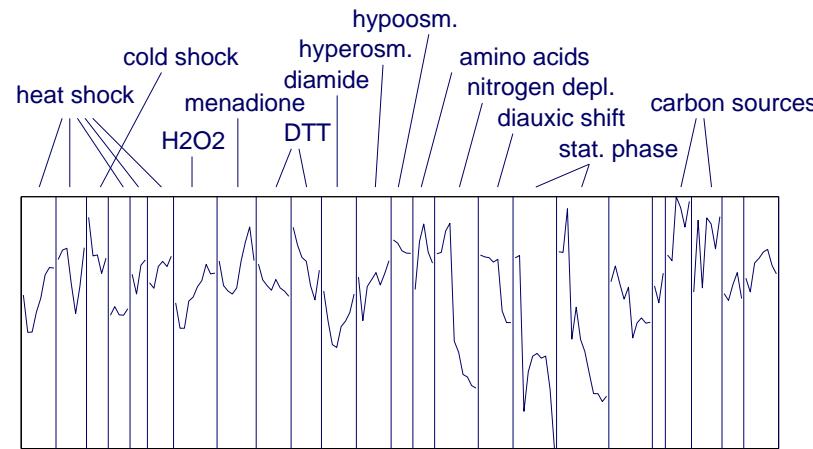


+ Glykolyse, - Nukleotidsynthese

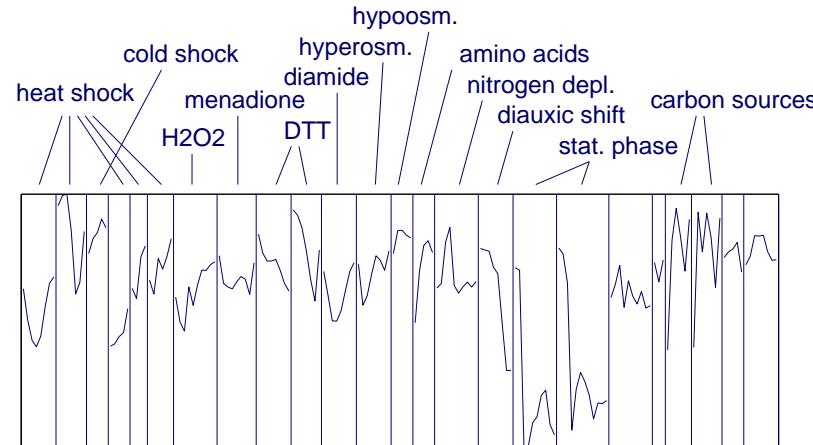
# Expression und Kontrollkoeffizienten: ICA



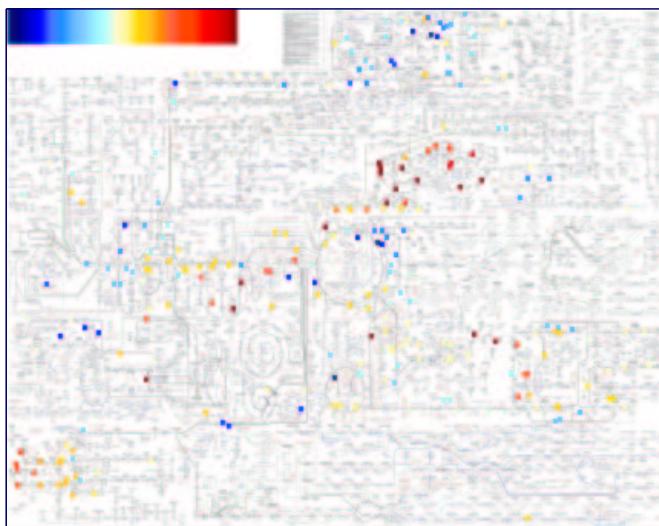
Aminosäuresynthese



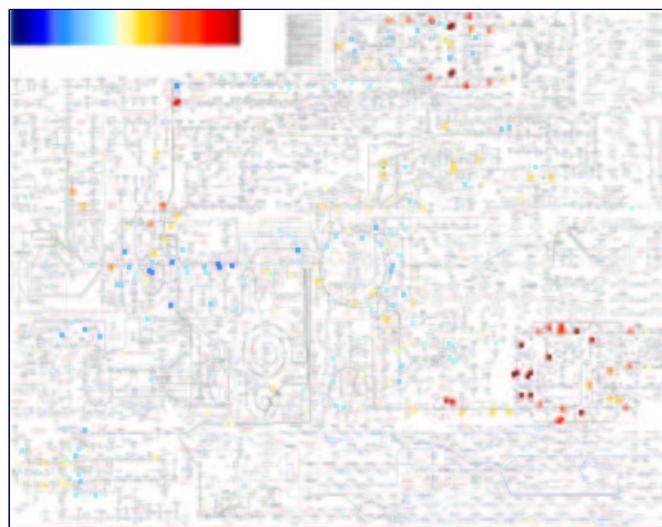
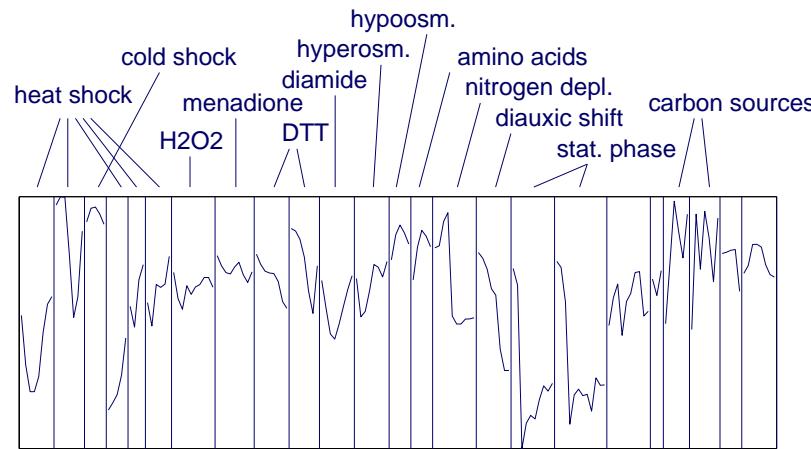
Prolinweg



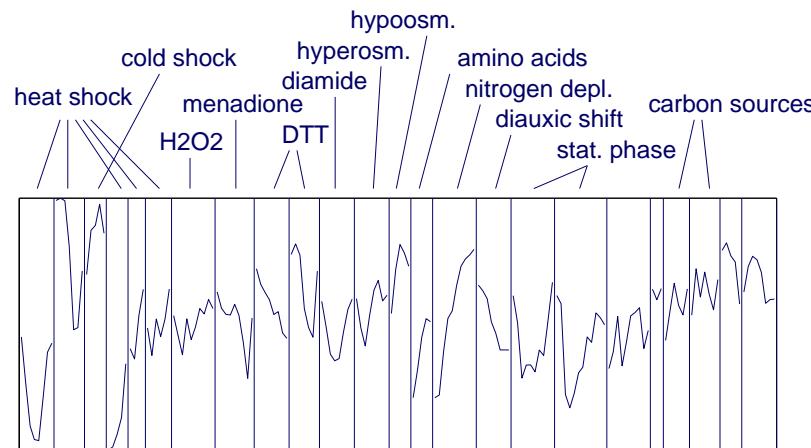
# Expression und Kontrollkoeffizienten: ICA



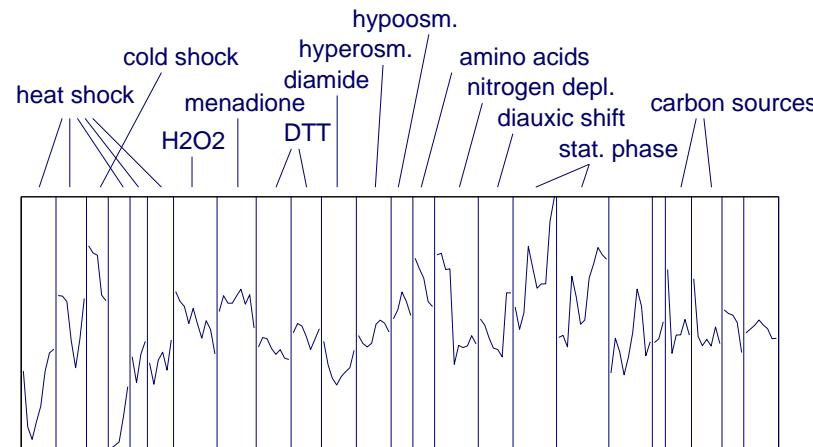
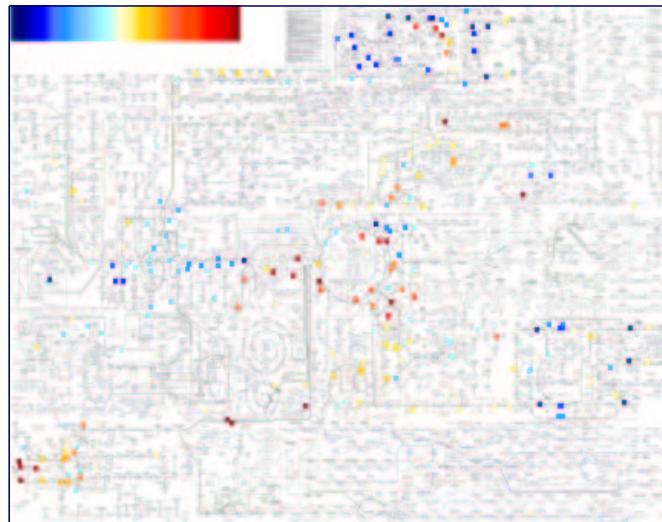
Aminosäuresynthese



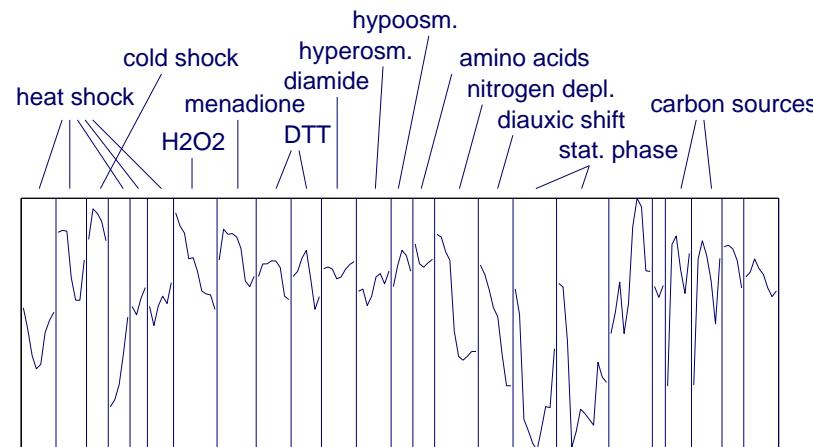
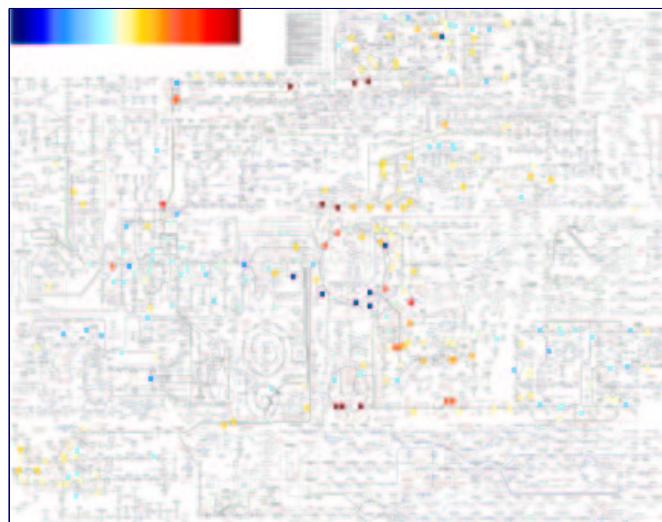
Nukleotidsynthese



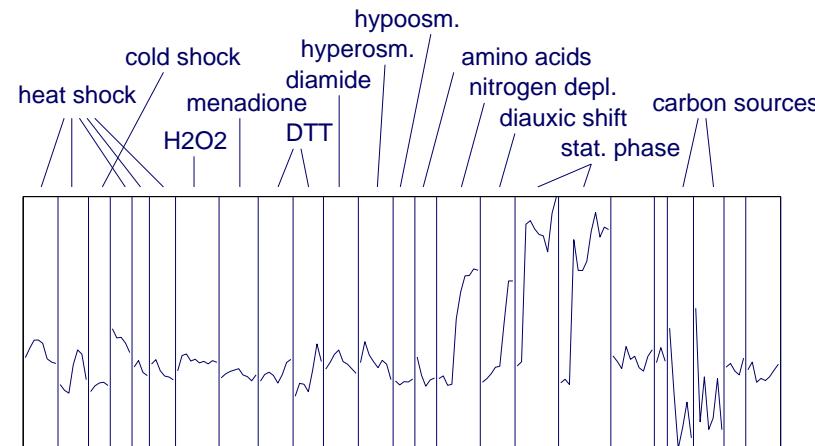
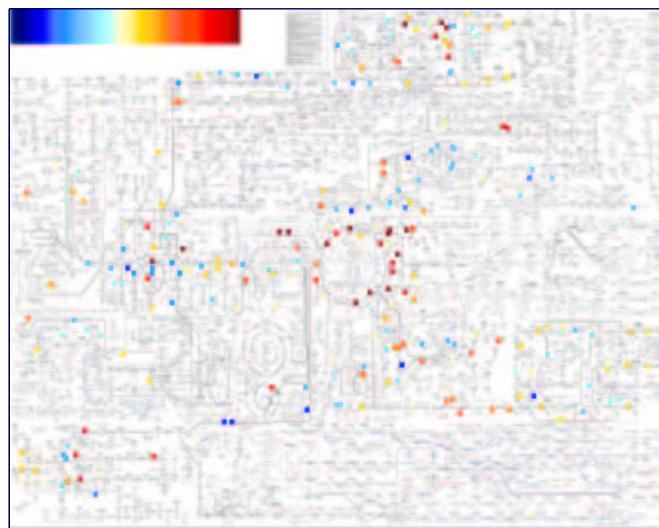
# Expression und Kontrollkoeffizienten: ICA



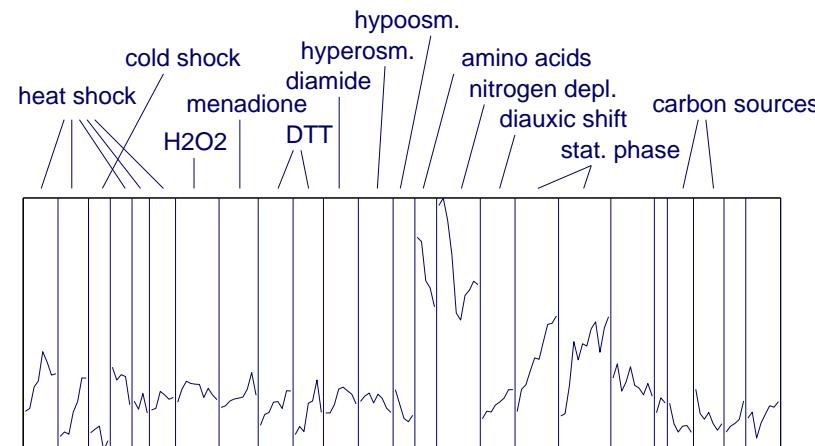
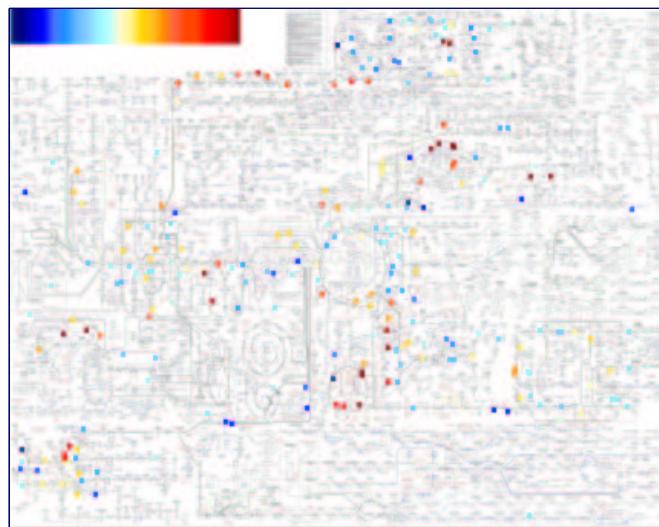
+ Zitratzyklus, - Glykolyse -Nukleotidsynthese



# Expression und Kontrollkoeffizienten: ICA

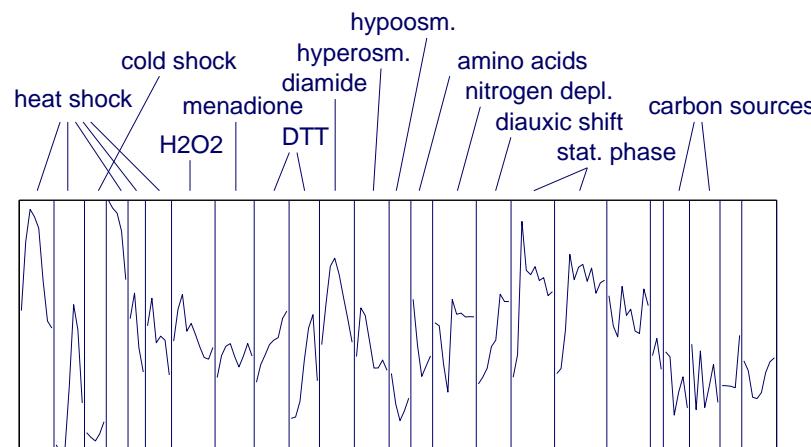
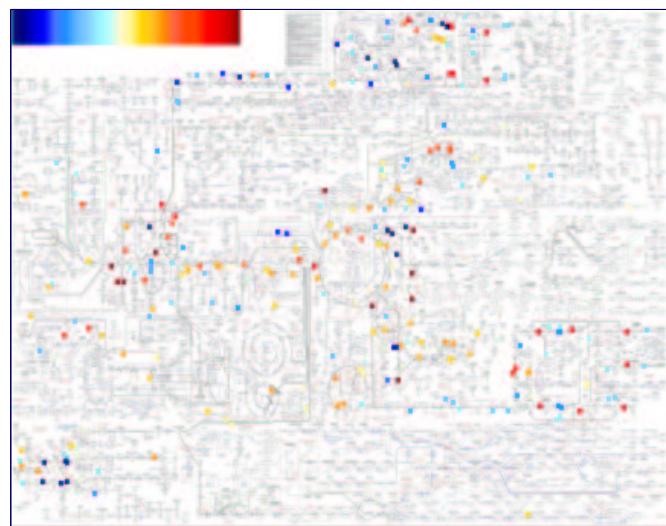
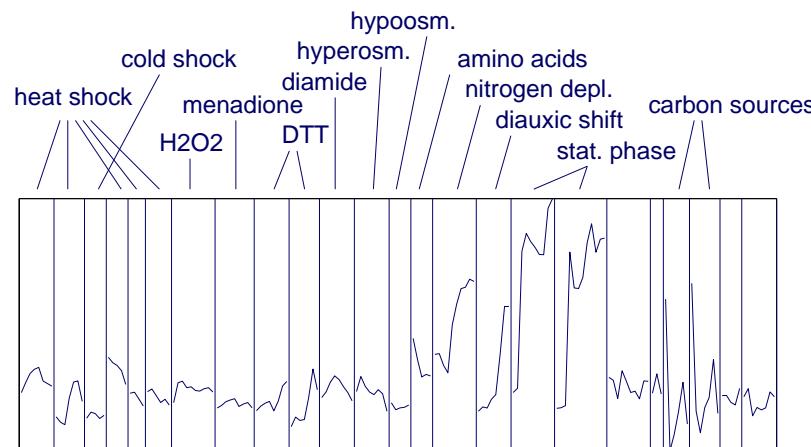
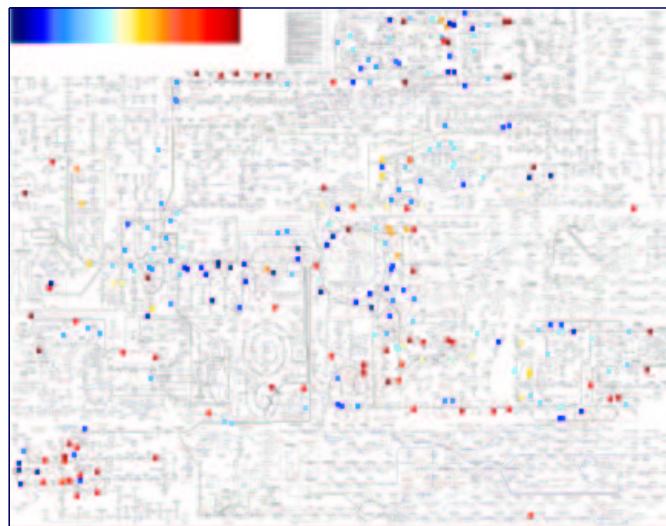


Zitratzyklus



Reaktion auf Minimalmedium (- Aminosäuren,- Stickstoff)

# Expression und Kontrollkoeffizienten: ICA



Ähnlich dem environmental stress response cluster (Gasch et al., 2000)