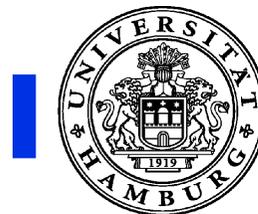


Allgemeines Lineares Modell General Linear Model

Tobias Sommer-Blöchl,
NeuroImage Nord,
Institut für Systemische Neurowissenschaften



Universitätsklinikum
Hamburg-Eppendorf

General linear model (GLM)

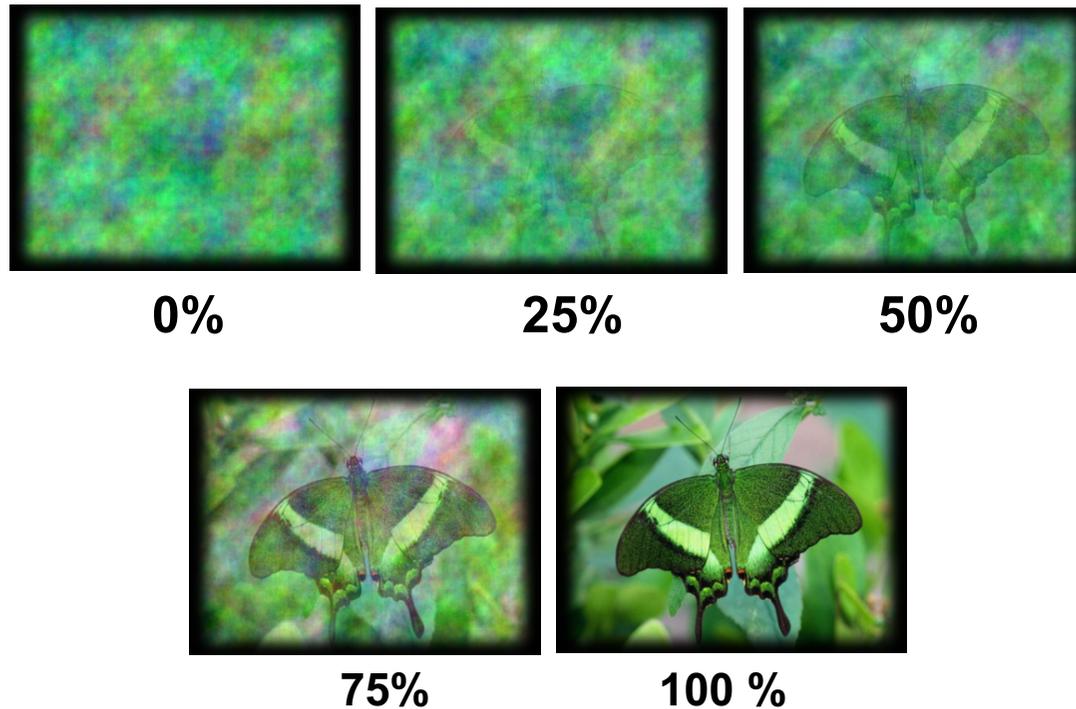
- vereinigende Alternative zur klassischen Statistik
- in den späten 60ern eingeführt basierend auf der multiplen Regressionsanalyse
- T-tests, ANOVAs, ANCOVAs, und multiple Regressionen “übersetzt” in multiple Regressionsprobleme
- gelöst mit den selben Formeln und basierend auf derselben Logik
- leicht erweiterbar für nicht-lineare Fragen
- SPM, andere fMRI Analyse Softwares, allgemeine statistische Software Packages

Übersicht über den Vortrag

- sehr kurze allgemeine Einführung in das GLM
- Mini Einführung in relevante Aspekte der Matrix Algebra
- detaillierte Einführung in das GLM
 - mittels eines behaviouralen (multiplen) Regressionsbeispiels
- Erweiterung auf ANOVAs im GLM
- das GLM in SPM (Vorschau auf morgigen Vortrag ‚Das ALM in der fMRT‘)
 - 1st Level Analysen: multiple Regressionen
 - meisten 2nd Level Models: t-tests oder ANOVAs

Beispielstudie (Rose et al., Cereb Cortex, 2005)

- Aufgabe im Scanner:
 - Bilder (1 Sekunde) in **5 unterschiedlichen Sichtbarkeitsstufen**
 - jeweils Blöcke von je 10 Bildern einer Sichtbarkeitsstufe (20 Sekunden)



Beispielstudie (Rose et al., Cereb Cortex, 2005)

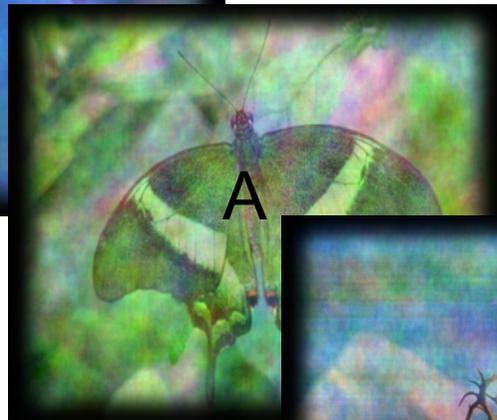
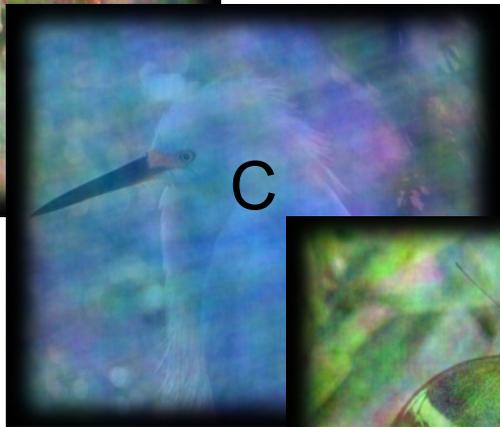
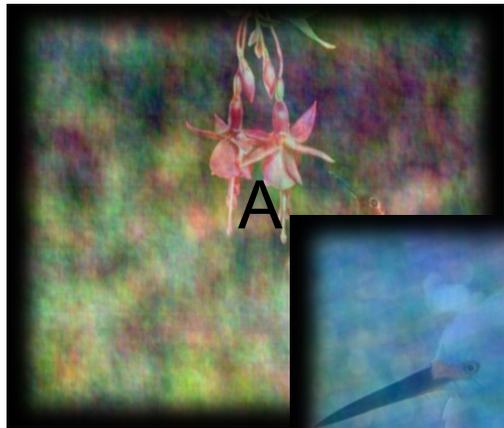
Beispielstudie

- Aufgabe im Scanner:
 - Bilder (1 Sekunde) in **5 unterschiedlichen Sichtbarkeitsstufen**
 - jeweils Blöcke von je 10 Bildern einer Sichtbarkeitsstufe (20 Sekunden)
 - jeweils einer der Buchstaben A, B, C, D, E, F auf einem Bild

⇒ **Arbeitsgedächtnisaufgabe**: 1-back vs. 2-back

⇒ 5 (Sichtbarkeit) × 2 (n-back) faktorielles Design

- jede dieser 10 Bedingungen 2 mal in jeder der 3 Sessions im Scanner



2-back target

1-back target

Beispielstudie (Rose et al., Cereb Cortex, 2005)

- Überraschungs-Gedächtnistest nach dem Scan:
 - alte und neue Bilder
 - alle Bilder 100% sichtbar
 - Aufgabe: möglichst schnell alt/neu-Entscheidung



neu



neu



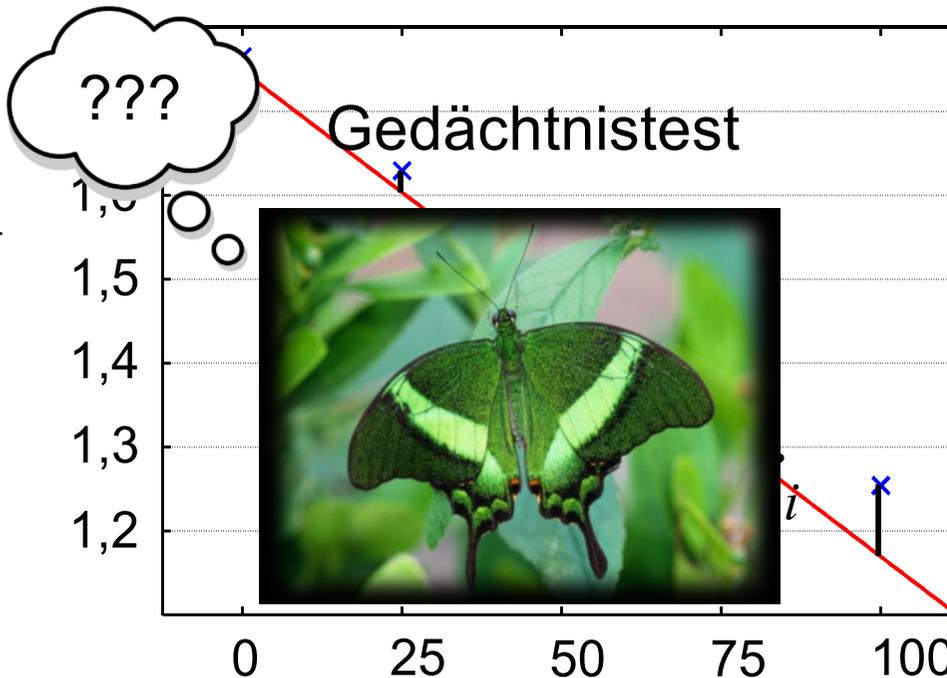
alt



neu

- GLM: (multiple) Regression – ähnlich einer Gradengleichung $y = ax + b + Fehler$
- abhängige Variable (y) und unabhängige Variable(n)/**Regressoren** (x's)
- a = Steigungsmaß/Regressionskoeffizient/**Parameter** (im GLM: β - betas)
- b = Achsenabschnitt/**Konstante**
- Fehler = **Residuen** (im GLM: ϵ)

Sichtbarkeit	Reaktionszeit
x	y
0	1,77
25	1,63
50	1,44
75	1,20
100	1,25



Ziel: \Rightarrow Beschreibung des Zusammenhangs zwischen x und y

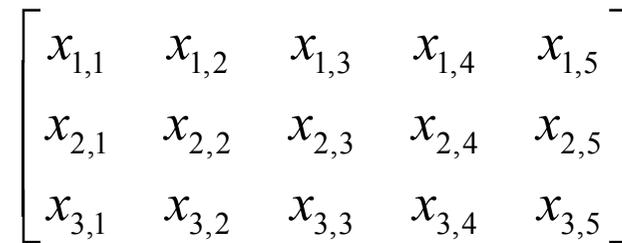
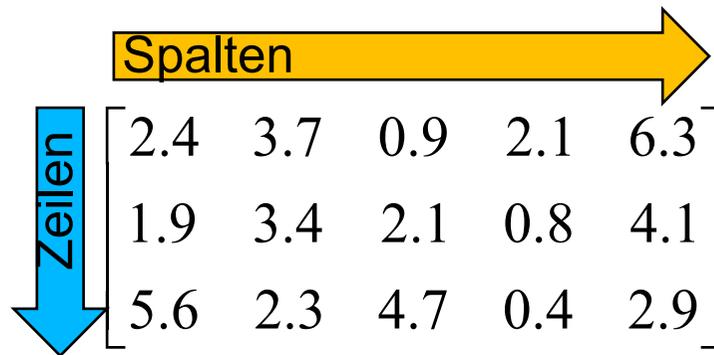
– bei mehreren Regressoren x_j : $y = a_1x_1 + a_2x_2 + \dots + a_mx_m + b + \epsilon$

\Rightarrow **Ziel des GLM:** y als gewichtete Linearkombination von x_j

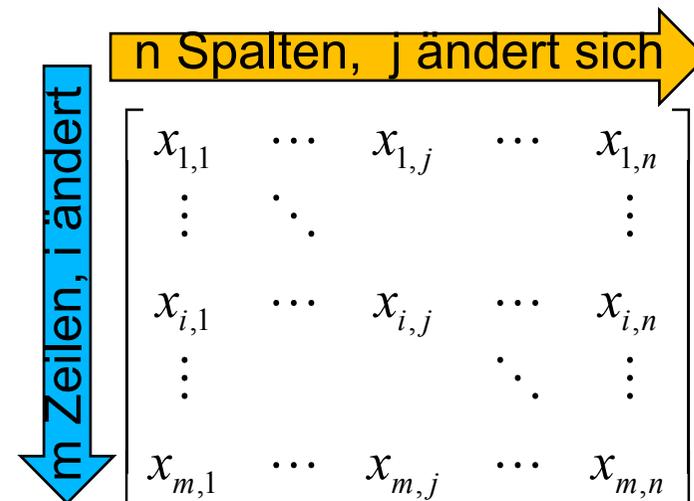
- GLM ist in Matrizen und Matrix-Algebra formuliert

Matrizen

- rechteckiges Feld/Tabelle von Elementen angeordnet in Zeilen und Spalten



- Elemente von Matrizen werden adressiert durch 1. Zeile und 2. Spalte



Spezialfälle von Matrizen

- *Vektor*: nur eine Zeile oder Spalte

$$\text{Zeilen-Vektor } x = [x_{1,1} \quad x_{1,2} \quad x_{1,3} \quad x_{1,4} \quad x_{1,5}]$$

$$\text{Spalten-Vektor } x = \begin{bmatrix} x_{1,1} \\ x_{2,1} \\ x_{3,1} \\ x_{4,1} \\ x_{5,1} \end{bmatrix}$$

- *Skalar*: nur ein Element $[x_{1,1}]$
- *Identitäts-Matrix* (immer eine *quadratische Matrix*)
 - analoge zur Zahl 1

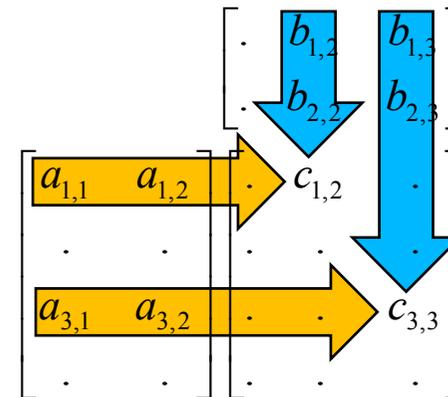
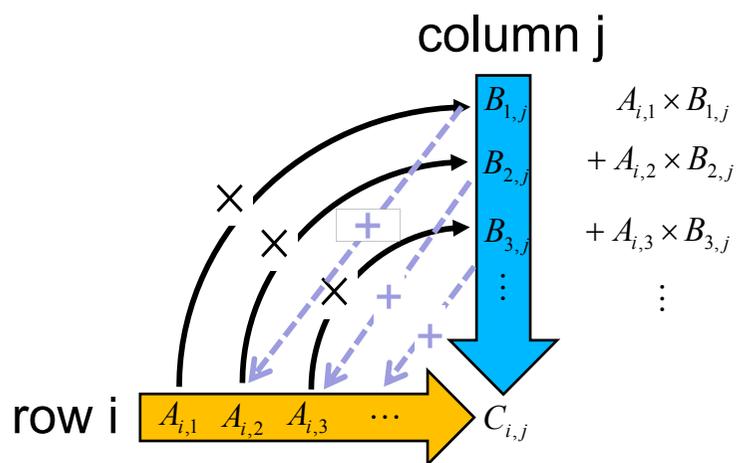
$$I_5 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

- Matrizen: Großbuchstaben; Vektoren und Skalare: Kleinbuchstaben

$$X = \begin{bmatrix} x_{1,1} & \cdots & x_{1,j} & \cdots & x_{1,n} \\ \vdots & \ddots & & & \vdots \\ x_{i,1} & \cdots & x_{i,j} & \cdots & x_{i,n} \\ \vdots & & & \ddots & \vdots \\ x_{m,1} & \cdots & x_{m,j} & \cdots & x_{m,n} \end{bmatrix}$$

Matrizen-Rechnung

- Addition, Subtraktion und Punkt Multiplikation von zwei Matrizen:
 - beide Matrizen müssen gleiche Dimensionen haben
 - Element-weise addiert, subtrahiert oder multipliziert
- Multiplikation mit Skalar: jedes Element wird mit dem Skalar multipliziert
- Multiplikation mit einer anderen Matrix oder einem Vektor
 - Anzahl der Spalten der linken Matrix muss genauso groß sein wie Anzahl der Zeilen der rechten Matrix
 - Summe der Punkt-Produkte der Elemente einer gegebenen Zeile in **A** und einer gegebenen Spalte in **B**



$$a_{1,1} \times b_{1,2} + a_{1,2} \times b_{2,2} = c_{1,2}$$

$$a_{3,1} \times b_{1,3} + a_{3,2} \times b_{2,3} = c_{3,3}$$

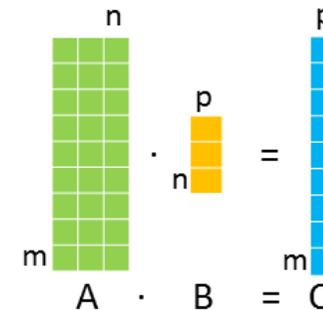
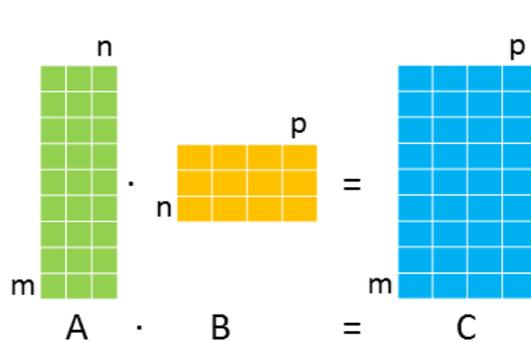
Matrizen-Rechnung

- Multiplikation mit einer anderen Matrix oder einem Vektor
 - Anzahl der Spalten der linken Matrix muss genauso groß sein wie Anzahl der Zeilen der rechten Matrix
 - Summe der Punkt-Produkte der Elemente einer gegebenen Spalte in A und einer gegebenen Spalte in B

- m -mal- n Matrix **A** · n -mal- p Matrix **B** = m -mal- p Matrix *Produkt* **AB**

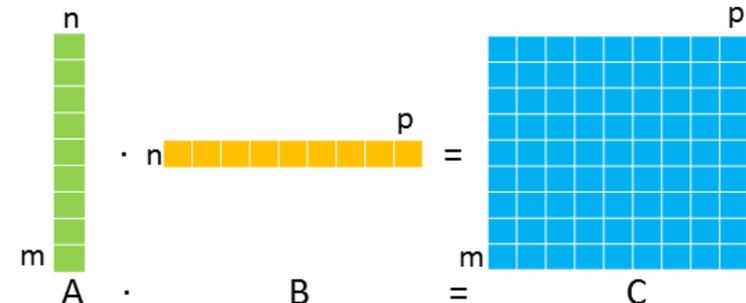
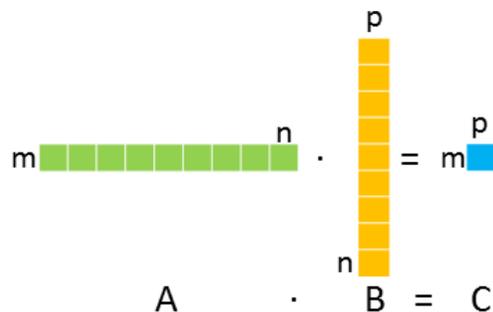
- **Beispiele:** Matrix · Matrix = Matrix

Matrix · Spalten-Vektor = Spalten-Vektor



Zeilen-Vektor · Spalten-Vektor = Skalar

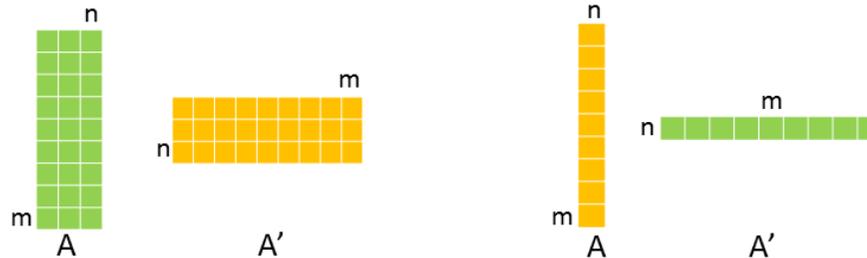
Spalten Vektor · Zeilen-Vektor = Matrix



Matrizen-Rechnung

- transponierte Matrix

- *transponierte* einer m -mal- n Matrix \mathbf{A} ist die n -mal- m Matrix \mathbf{A}' (auch als \mathbf{A}^T notiert), die man erhält durch das Drehen von Zeilen in Spalten und umgekehrt



- die Inverse einer quadratischen Matrix

- $\mathbf{AB} = \mathbf{BA} = \mathbf{I}_n$ (Identitäts-Matrix, analog zu $a \times \frac{1}{a} = 1$)
- wenn \mathbf{B} existiert, ist sie eindeutig und wird \mathbf{A}^{-1} genannt, die inverse Matrix von \mathbf{A}
- \mathbf{A} ist dann invertierbar, regulär, nicht-singulär oder nicht degeneriert

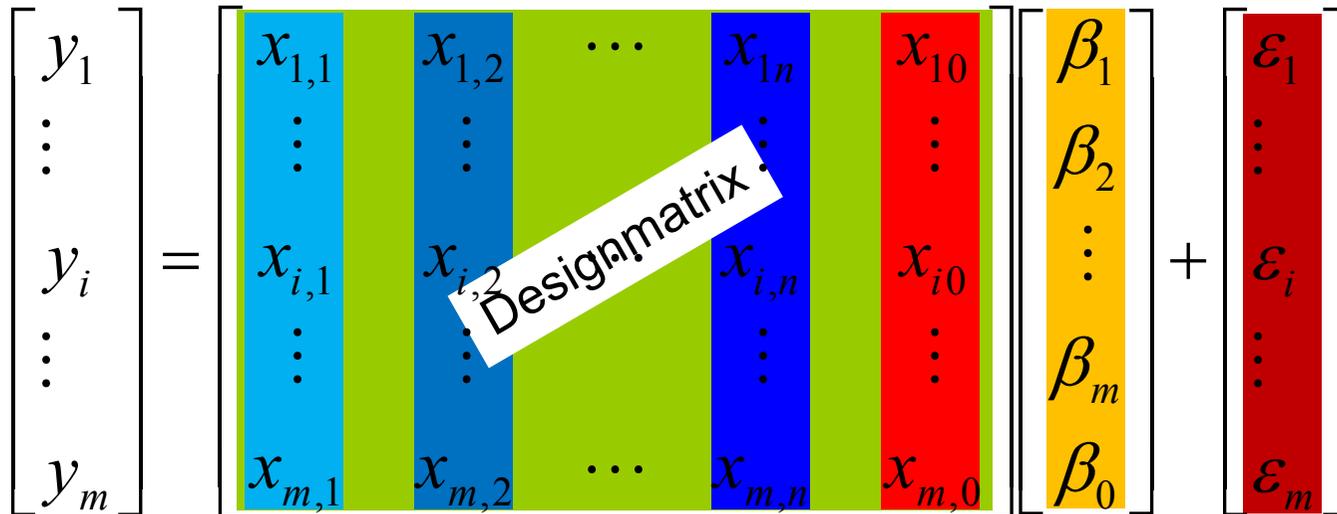
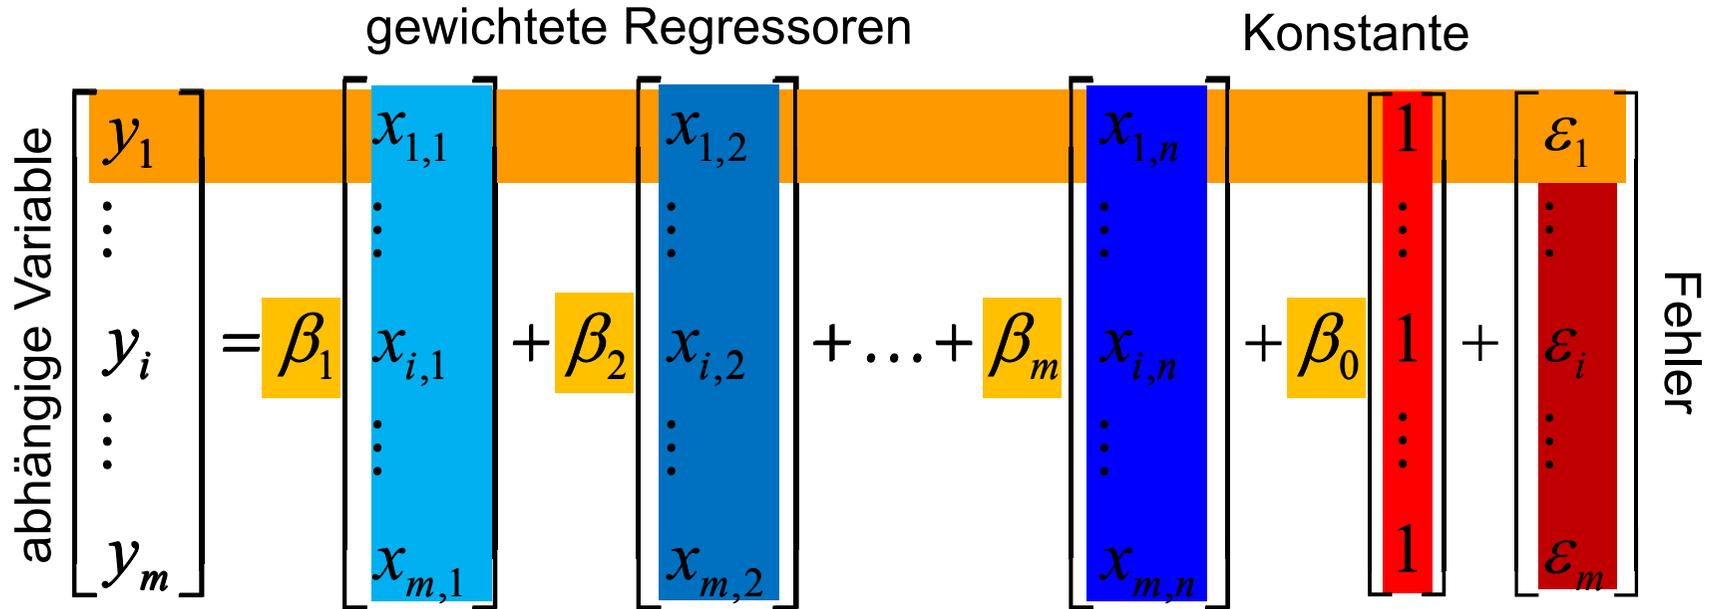
$$I_5 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

- (Moore–Penrose) pseudoinverse Matrizen

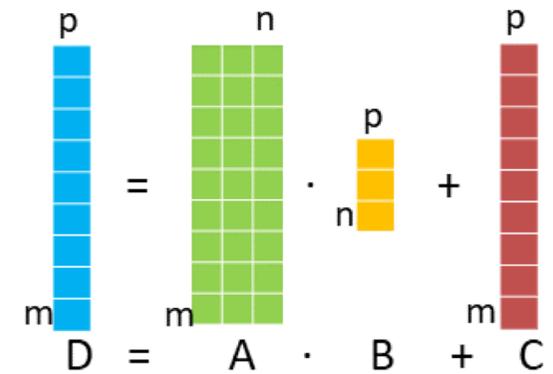
- \mathbf{A}^+ ist eine Verallgemeinerung der inversen Matrix
- wenn die Inverse nicht berechnet werden kann, z.B. bei nicht quadratischen oder Rang defizient Matrizen (später mehr weil SPM relevant)

- GLM ist in Matrizen und Matrix-Algebra formuliert

$$y = a_1x_1 + a_2x_2 + \dots + a_nx_n + 1b + \varepsilon$$



$$\begin{bmatrix} y_1 \\ \vdots \\ y_i \\ \vdots \\ y_m \end{bmatrix} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,n} & x_{1,0} \\ \vdots & \vdots & & \vdots & \vdots \\ x_{i,1} & x_{i,2} & \cdots & x_{i,n} & x_{i,0} \\ \vdots & \vdots & & \vdots & \vdots \\ x_{m,1} & x_{m,2} & \cdots & x_{m,n} & x_{m,0} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_m \end{bmatrix}$$



$$y = X\beta + \varepsilon$$

Regressionsanalyse

- Regressionsanalysen im GLM intuitiver
- SPM 1st Level Analysen sind multiple Regressionen

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

1. **Modellauswahl/-spezifikation**
2. **Parameterschätzung**
3. **Beurteilung der Modellgüte**
4. **Inferenz/Signifikanztestung**

Modellauswahl/-spezifikation

- Wie viele und welche Regressoren werden in das Model aufgenommen?
- Welche Art von Zusammenhang zwischen y und x 's ist erwartet?
 - erweiterbar zu nichtlinearen Zusammenhängen, z.B. ein logarithmischer Einfluss der unabhängigen Variablen $y_i = \beta_1 \log(z_i) + \beta_0 + \varepsilon_i$
 - mit $x_i = \log(z_i)$ ein lineares Model $y_i = \beta_1 x_i + \beta_0 + \varepsilon_i$

Beispielstudie:

⇒ abhängige Variable:

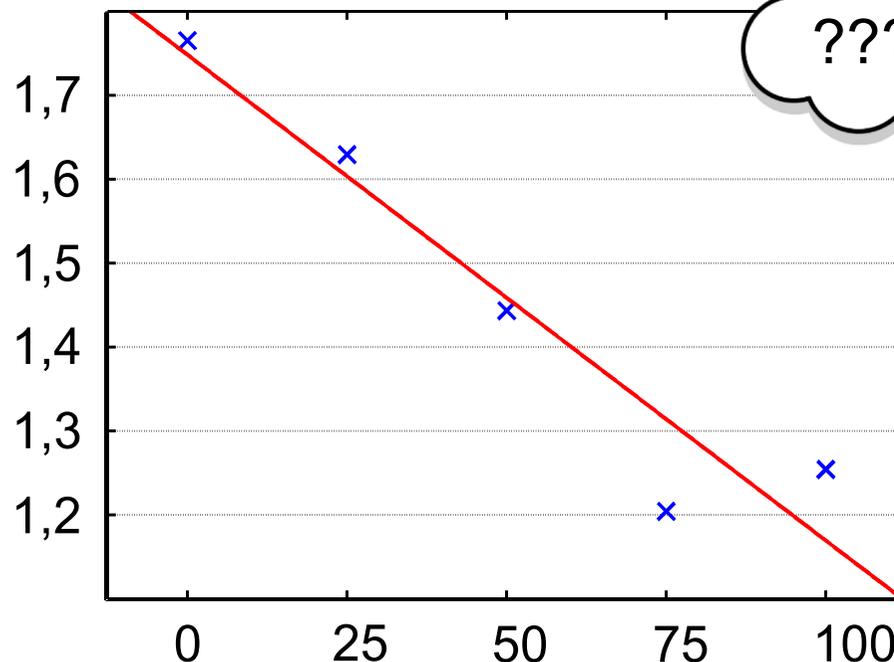
- mittlere Reaktionszeit (RT) im Gedächtnistest
- $RT \approx$ Gedächtnisstärke

⇒ 1 unabhängige Variable/Regressor (+ 1 Konstante)

- Sichtbarkeit der Bilder während der Enkodierung in %

⇒ Hypothese: linearer Zusammenhang zwischen Sichtbarkeit während der Enkodierung und RT beim Wiedererkennen

Reakt. y	Sichtb. x
1.77	0
1.63	25
1.44	50
1.20	75
1.25	100



$$y = X\beta + \varepsilon$$

y	x
1,77	0
1,63	25
1,44	50
1,20	75
1,25	100

x_1 :Sichtbarkeit

$$\begin{matrix} \text{Reaktionszeiten} \\ \left[\begin{array}{c} 1,77 \\ 1,63 \\ 1,44 \\ 1,20 \\ 1,25 \end{array} \right] = \begin{matrix} \underbrace{\begin{bmatrix} 0 & 1 \\ 25 & 1 \\ 50 & 1 \\ 75 & 1 \\ 100 & 1 \end{bmatrix}}_{\text{Designmatrix}} \begin{bmatrix} \beta_1 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix} \end{matrix}$$

β_0 : y-Achsenabschnitt/Konstante

β_1 : Steigung

Parameterschätzung

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

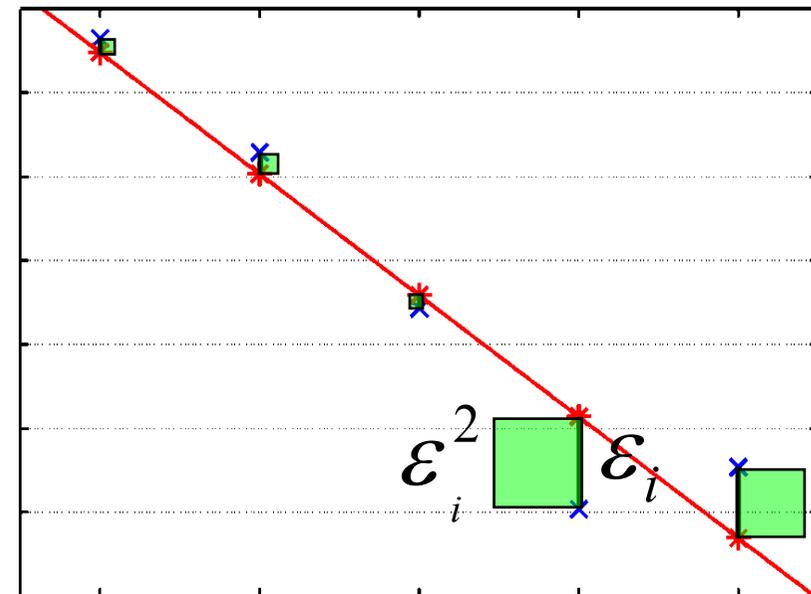
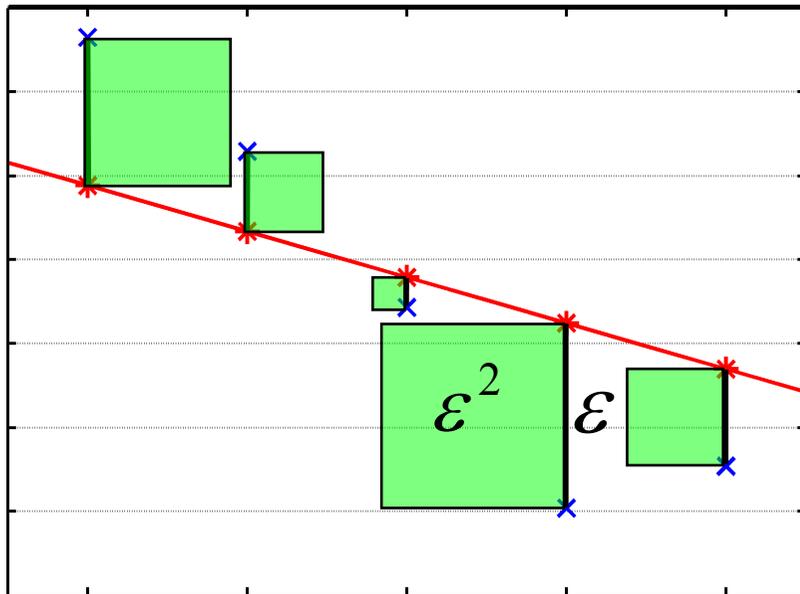
Inferenz

Ziel:

- Regressionsgewichte bestimmen, so dass die abhängig Variable möglichst genau vorhergesagt wird
- Fehler soll minimiert werden

⇒ **Kriterium der kleinsten Abweichungsquadrate:**

- **SSE (Sum of Squared Errors)** soll minimiert werden



Beispielstudie:

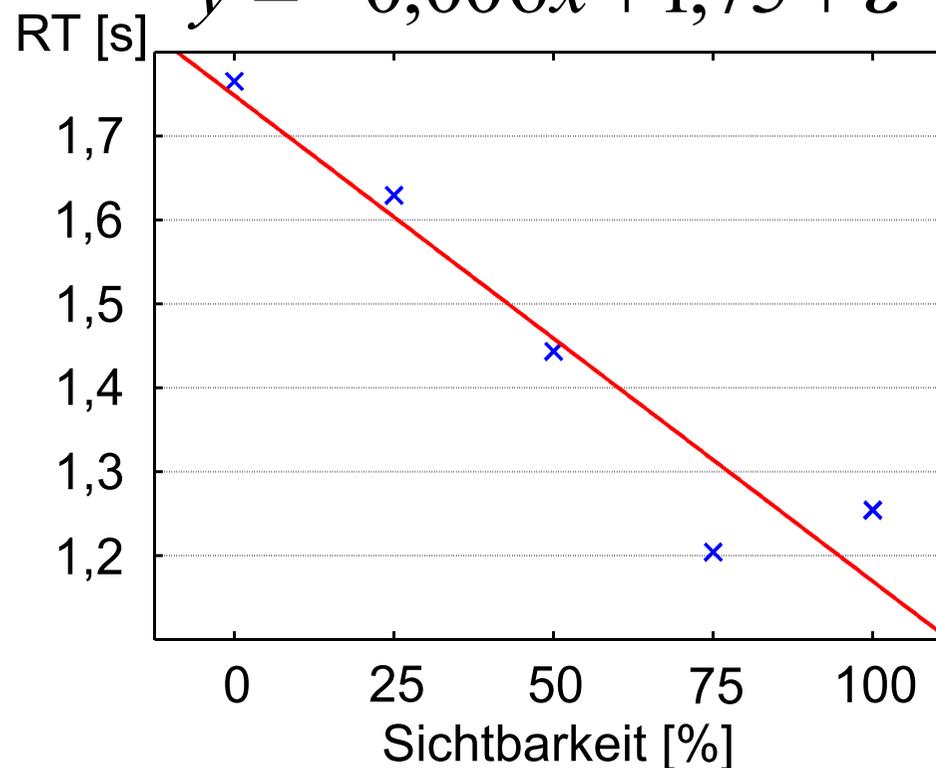
- 1 Regressor + 1 Konstante

⇒ 2 Regressionsgewichte/Parameter zu schätzen

⇒ im GLM eine Formel für das *ordinary least square* Verfahren für alle statistischen Anwendungen

$$\beta = (X'X)^{-1}X'y = \begin{bmatrix} -0,006 \\ 1,752 \end{bmatrix}$$

$$y = -0,006x + 1,75 + \varepsilon$$



Regressionsanalyse

Modellauswahl

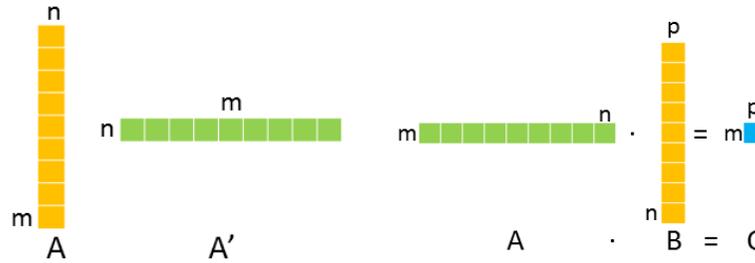
Parameterschätzung

Modellgüte

Inferenz

⇒ SSE soll minimiert werden

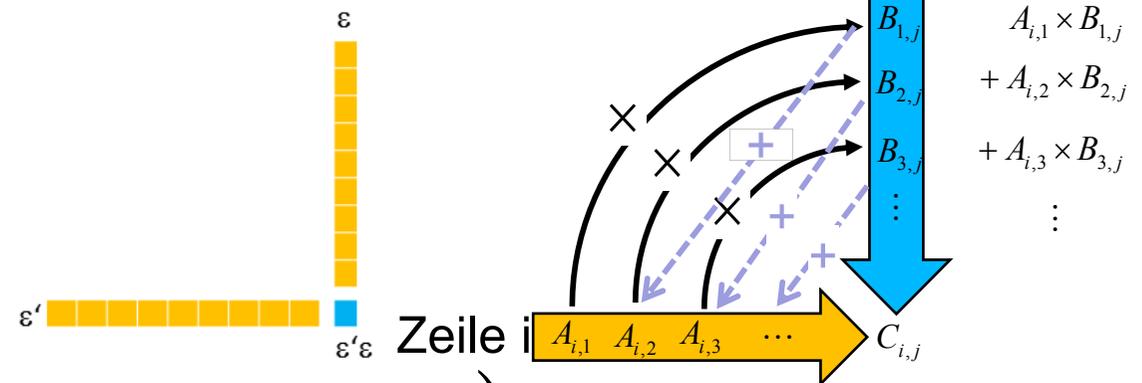
$$SSE = \sum_{i=1}^n \varepsilon_i^2 = \varepsilon' \varepsilon$$



- Fehler ε : Spalten-Vektor
- ε' : Zeilen-Vektor
- Multiplikation eines Zeilen- mit einem Spalten-Vektor ergibt ein Skalar
- insbesondere, Multiplikation eines transponierten Spalten-Vektors (ε') mit sich selbst (ε) ergibt die Summe der Quadrate der Elemente des Vektors, also die SSE

$$y = X\beta + \varepsilon$$

$$\varepsilon = y - X\beta$$



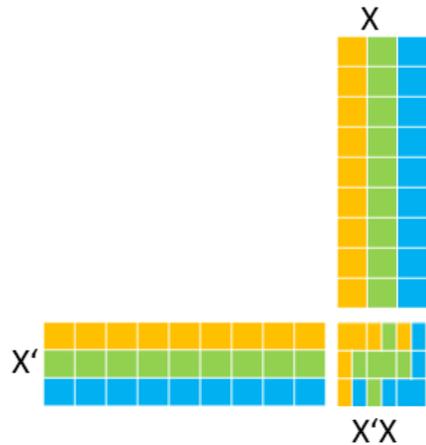
$$SSE = \varepsilon' \varepsilon = (y - X\beta) (y - X\beta)$$

$$SSE = y'y - 2\beta'X'y + \beta'X'X\beta$$

$$SSE = y'y - 2\beta'X'y + \beta'X'X\beta$$

⇒ Multiplikation eines transponierten **Spalten-Vektors** (ε') mit sich selbst (ε) ergibt die **Summe der Quadrate der Elemente** des Vektors, also die SSE

⇒ Multiplikation einer transponierten **Matrix** mit sich selbst ergibt die “Produkt-Summen-Matrix”



- auf der Hauptdiagonalen die **Summe der Quadrate der Elemente** der Spalten

- auf den anderen Diagonalen zeilenweise die Produkt-Summen der Spalte und der anderen Spalten

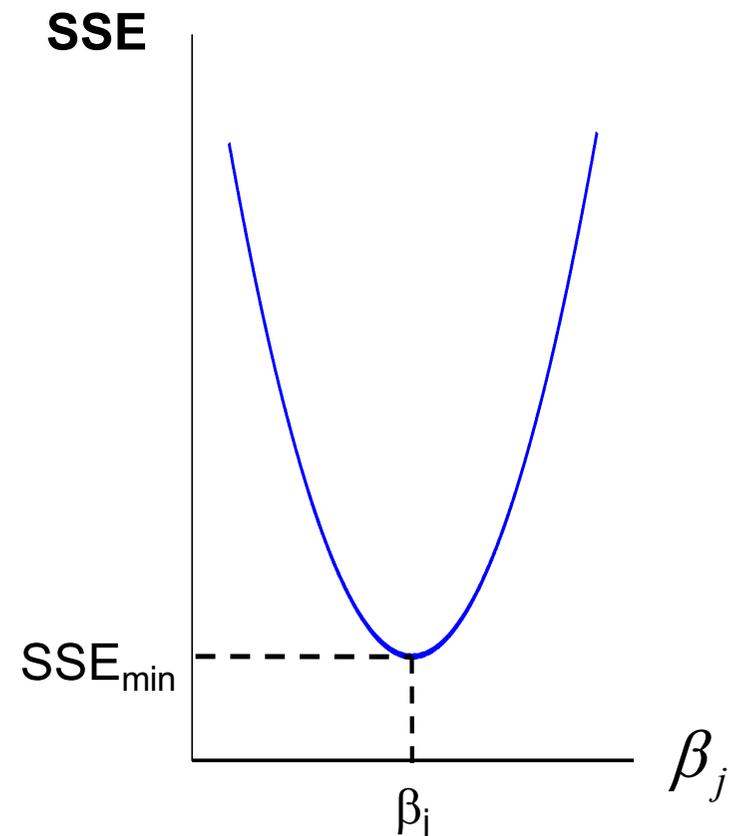
⇒ $SSE = \dots + \beta'X'X\beta$ ist eine quadratische Gleichung wie $y = x^2$

$$SSE = y'y - 2\beta'X'y + \beta'X'X\beta$$

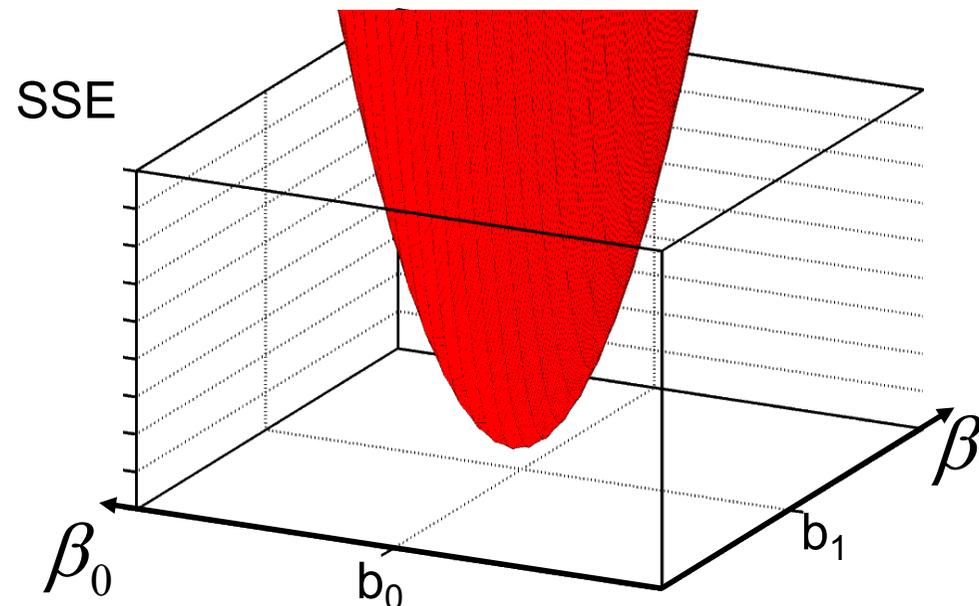
- bei einem Parameter formen die SSE eine Parabel als Funktion von β
- die partielle Ableitung der SSE nach 0 ergibt das β , für das die SSE minimal sind

$$\frac{\partial SSE}{\partial \beta'} = -2X'y + 2X'X\beta = 0$$

$$\hat{\beta} = (X'X)^{-1} X'y$$



- bei zwei Parameters (z.B. 1 Regressor und Konstante), formen die SSEs als Funktion der β s einen 3-dimensionalen Kegel mit genau einem Minimum
- die partielle Ableitung nach 0 ergibt die Kombination von zwei β s bei denen die SSE minimal sind
- **Implikationen**
 - eine eindeutige Lösung
 - Schätzung aller Parameter beim OLS Verfahren simultan in einem Schritt



Beurteilung der Modellgüte

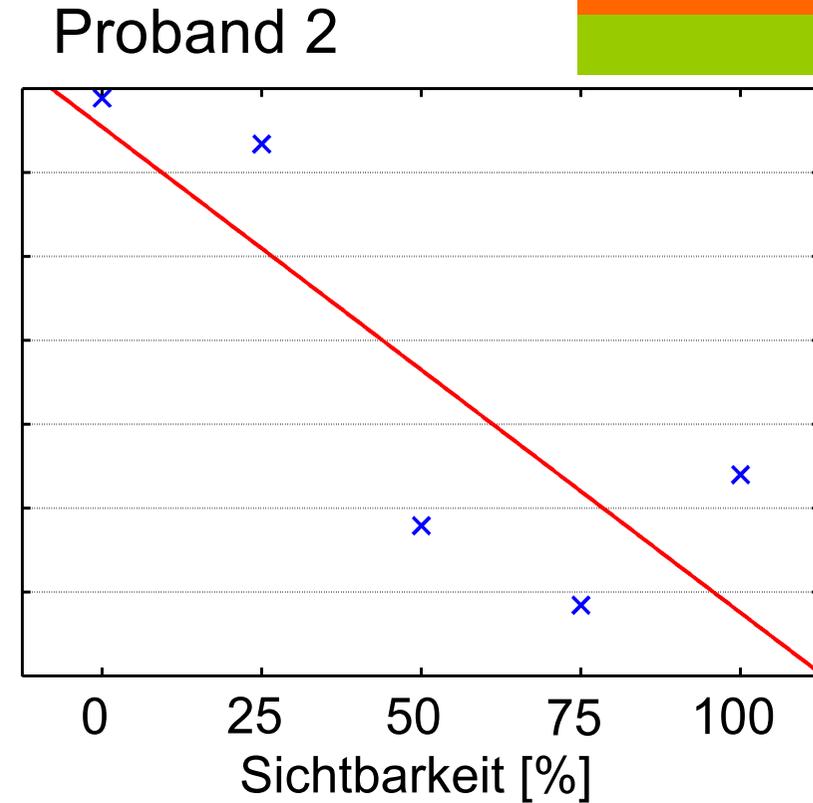
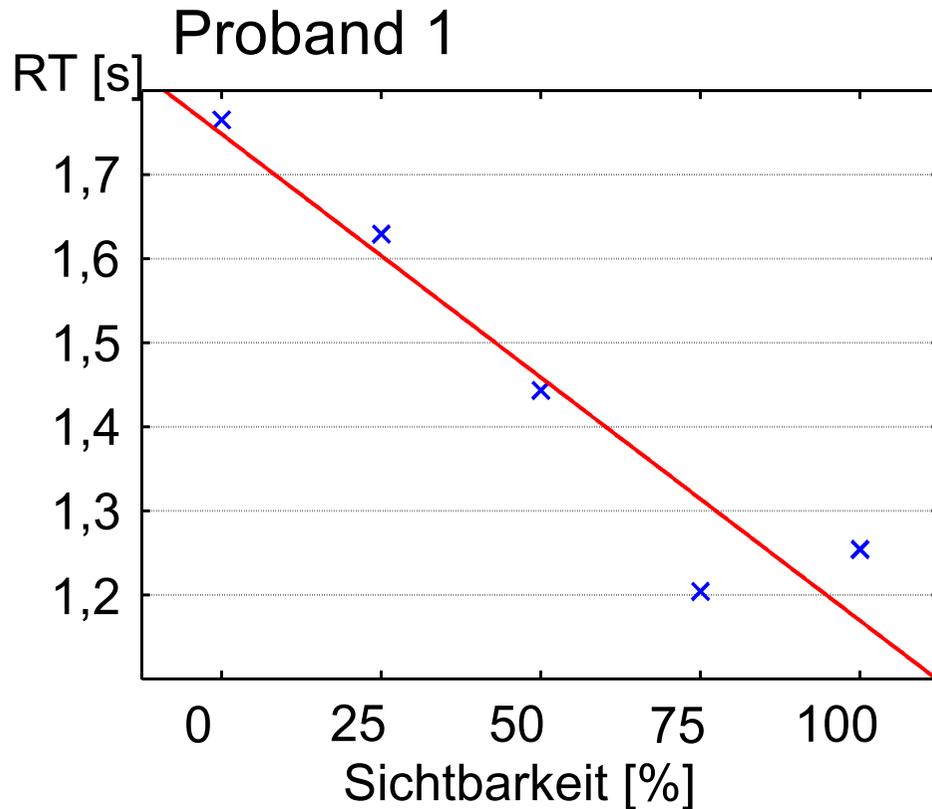
Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz



$$y = -0,006x + 1,75 + \varepsilon$$

Welchen Anteil der beobachteten Varianz erklärt das Modell?

Definitionen:

i) uneingeschränktes oder ‚full‘ Modell:

- Model mit allen Regressoren
- Im Beispiel 1 regressors und die Konstante

$$y = \beta_1 x_1 + \beta_0 1 + \varepsilon$$

$$\begin{bmatrix} 1.77 \\ 1.63 \\ 1.44 \\ 1.20 \\ 1.25 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 25 & 1 \\ 50 & 1 \\ 75 & 1 \\ 100 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}$$

ii) eingeschränktes oder ‚reduced‘ Modell

- reduziert um mindestens einen Regressor verglichen zum ‚full‘ Modell
- max. reduziert um alle Regressoren bis auf die Konstante

$$y = \beta_0 1 + \varepsilon$$

$$\begin{bmatrix} 1.77 \\ 1.63 \\ 1.44 \\ 1.20 \\ 1.25 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \beta_0 + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}$$

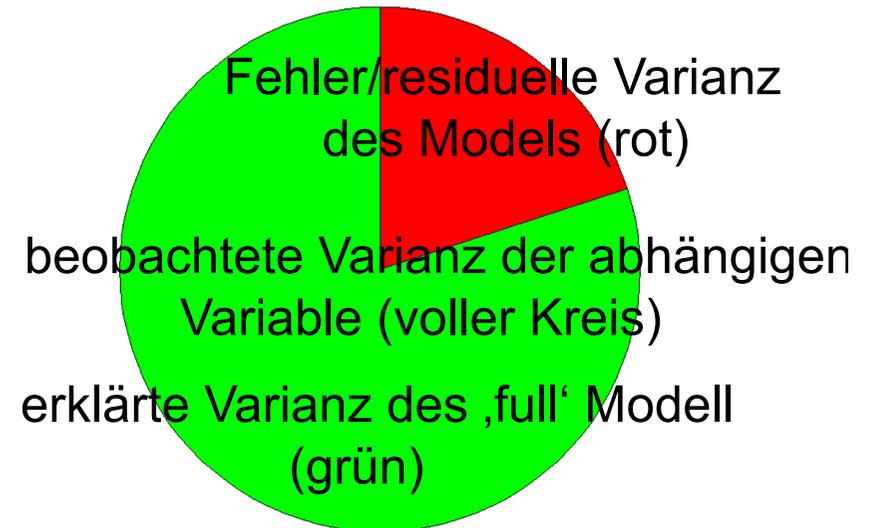
Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz



Berechnung der relevanten Varianzen

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

- beobachtete Varianz der abhängigen Variable

$$s_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2$$

- **Sum of Squares Total** der abhängigen Variable

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

- geschätzte Parameter

$$\hat{\beta} = (X'X)^{-1} X'y$$

- durch das Modell vorhergesagte Werte

$$\hat{y} = X\hat{\beta}$$

- **Sum of Squares Model**, die durch das Modell erklärte Varianz

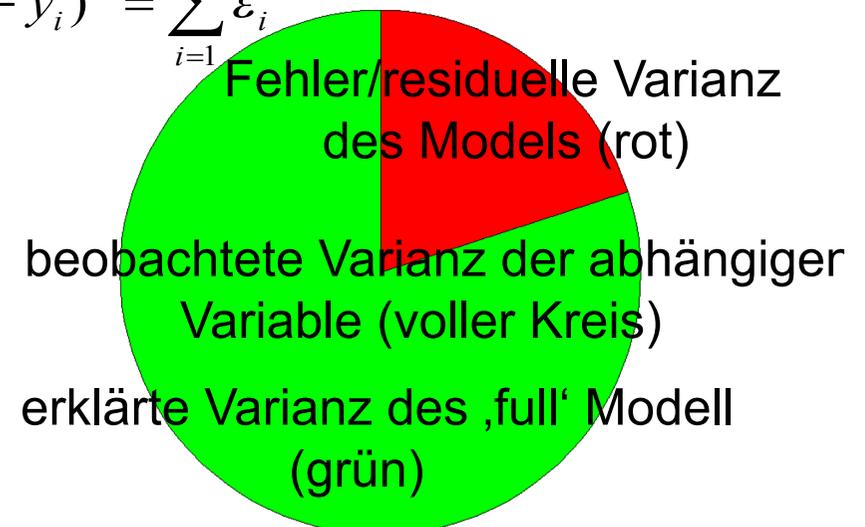
$$SSM = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

- **Sum of Squares Errors**, residuale oder Fehler Varianz des Modells

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n \varepsilon_i^2$$

$$SST = SSM + SSE$$

- Berechnung der relevanten Varianzen des 'full' und 'reduced' Modells durch entsprechende Modifikation der Designmatrix X.



Welchen Anteil der beobachteten

Varianz erklärt das Modell?

$$R^2 = \frac{\text{erklärte Varianz}}{\text{beobachtete Varianz}} = \frac{\text{[Pie chart: 3/4 green, 1/4 white]}}{\text{[Pie chart: 3/4 green, 1/4 red]}}$$

Beispiel

Regressionsanalyse

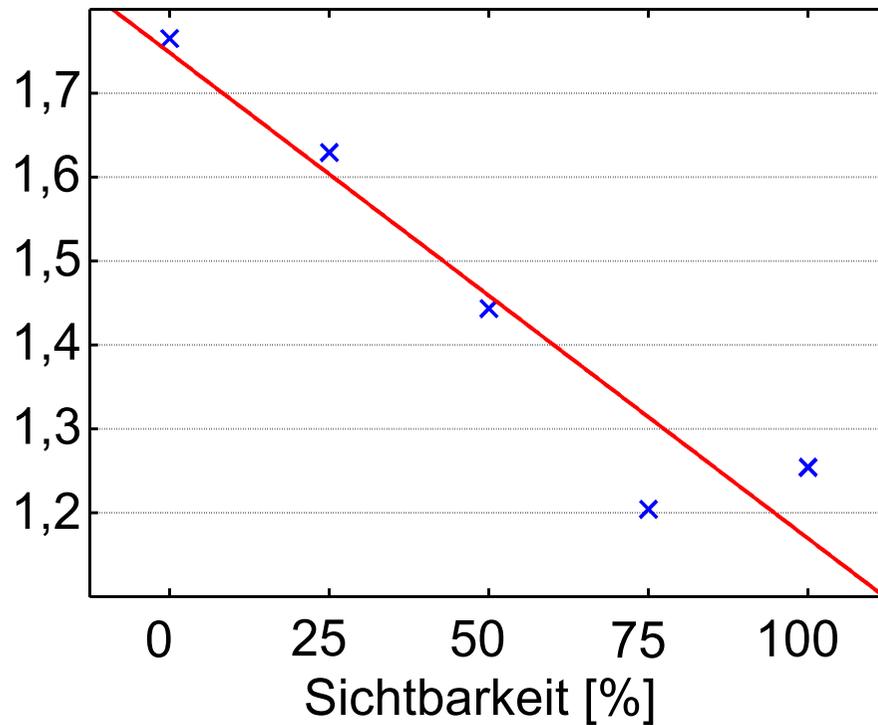
Modellauswahl

Parameterschätzung

Modellgüte

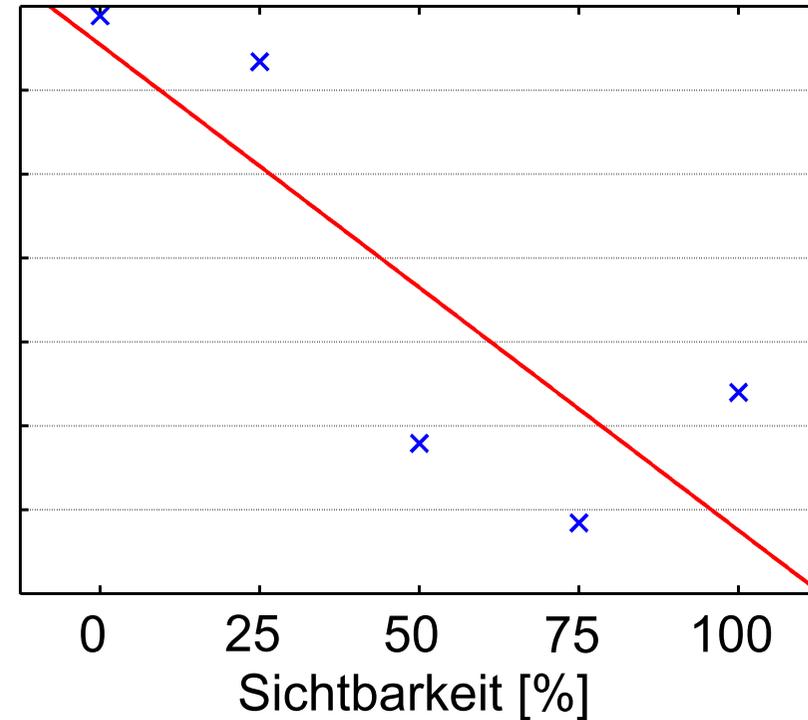
Inferenz

Proband 1



$$R^2 = 0,91$$

Proband 2

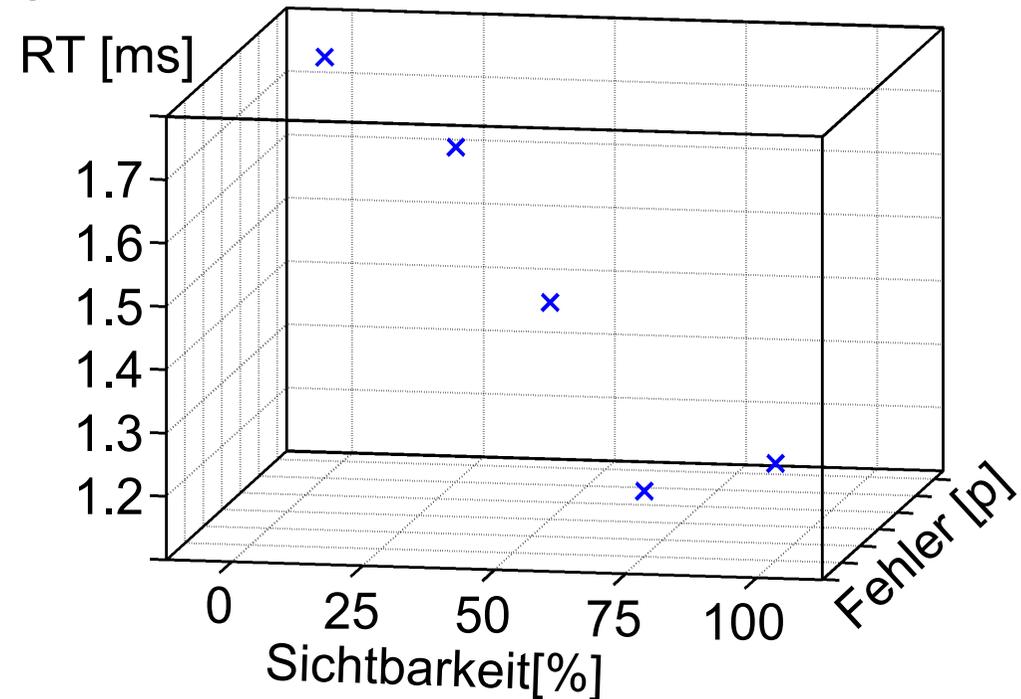


$$R^2 = 0,39$$

Erweiterung/Verbesserung des Modells

- zweiter Regressor:
 - Fehlerrate im Gedächtnistest um die unabhängige Variable RT zu erklären
 - RTs von falschen Antworten sind langsamer

y	x ₁	x ₂
1.77	0	0.5
1.63	25	0.5
1.44	50	0.3
1.20	75	0.1
1.25	100	0.1



$$y = \beta_1 x_1 + \beta_2 x_2 + \beta_0 1 + \varepsilon$$

	Sichtbarkeit	Fehlerrate		
	x_1	x_2		
Reaktionszeit	1.765	0	0.5	1
	1.629	25	0.5	1
	1.443	50	0.1	1
	1.204	75	0.1	1
	1.254	100	0.1	1

$$= \begin{bmatrix} 0 & 0.5 & 1 \\ 25 & 0.5 & 1 \\ 50 & 0.1 & 1 \\ 75 & 0.1 & 1 \\ 100 & 0.1 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}$$

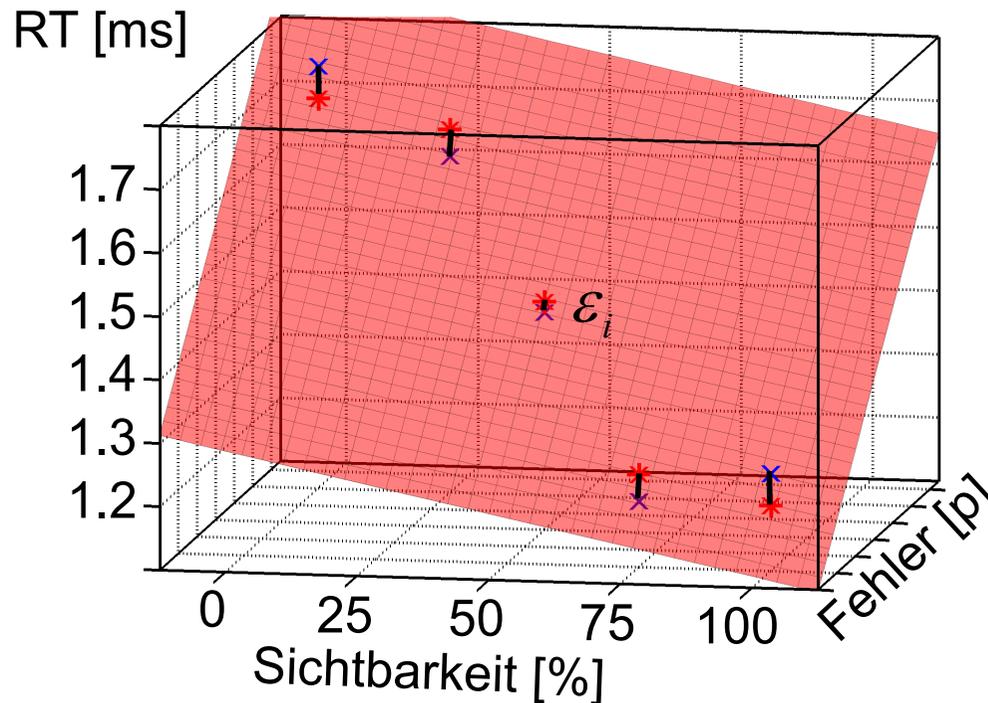
Designmatrix

$$b = (X'X)^{-1} X'y = \begin{bmatrix} -0.002 \\ 0.85 \\ 1.3 \end{bmatrix}$$

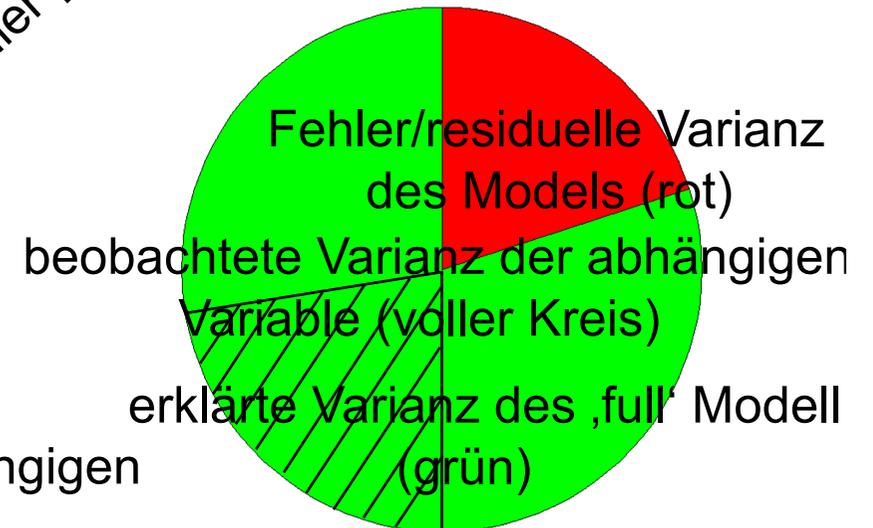
$$y = -0.002x_1 + 0.85x_2 + 1.3 + \varepsilon$$

Beispiel Regressionsanalyse

Modellauswahl
Parameterschätzung
Modellgüte
Inferenz



- Determinationskoeffizient: $R^2 = 0.96$
 - **Inkrement**: 5% zusätzlich erklärte Varianz
 - **aber** beide Regressoren sind hoch korreliert
 - erklären teilweise dieselbe Varianz der abhängigen Variable (straffierte Fläche)
- ⇒ **werden weniger reliabel geschätzt**
- nachteilig für die Statistik



⇒ **dieser Effekt der Korrelation von Regressoren** wichtig in fMRT Designs und Analysen (Mumford et al., 2015, PLOS ONE)

Inferenz

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

Ziel statistischer Inferenz

- Formulieren und Testen von Hypothesen bzgl. einer Population basierend auf einer Zufallsstichprobe aus dieser Population

I) Übersetzung der Forschungsfrage in statistische Hypothese

- i) Null-Hypothese H_0 : die Hypothese, die man zurückweisen möchte
- ii) Alternativhypothese H_1 : die Hypothese, die man akzeptieren möchte

II) Wahl des Signifikanzniveaus α

- Wahrscheinlichkeit, fälschlich die Alternativhypothese zu akzeptieren (Typ I Fehler)

III) F-Test oder t-Test?

- hängt von der Hypothese ab
 - **F-Tests:** - Erklärt ein Regressionsmodell die Varianz in den beobachteten Daten gut?
 - Ist ein bestimmter Parameter ungleich Null? (ungerichtet)
 - **t-Tests:** - Ist ein bestimmter Regressionsgewicht/Parameter größer als Null?
 - Ist ein Parameter größer als ein anderer? (gerichtet)

F-Test

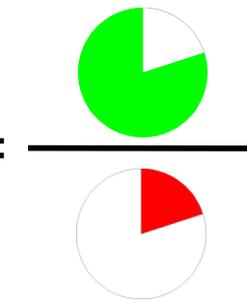
- **F-Tests:** Erklärt ein Regressionsmodell die die Varianz in den beobachteten Daten gut?
 - Erklärt das Modell einen signifikanten Anteil der beobachteten Varianz?
 - Erklärt das uneingeschränkte Modell signifikant mehr Varianz als das maximal reduzierte Modell?
- **F-Wert:** Verhältnis zweier Varianzen (geteilt durch Freiheitsgrade)

$$F = \frac{\text{erklärte Varianz ,full' Modell}}{\text{Fehler-Varianz ,full' Modell}} = \frac{\text{erklärte Varianz ,full' Modell}}{(\text{Fehler-Varianz ,red.' Modell}) - (\text{Fehler-Varianz ,full' Modell})}$$

Fehler-Varianz ,full' Modell

Freiheitsgrade/degrees of freedom (df)

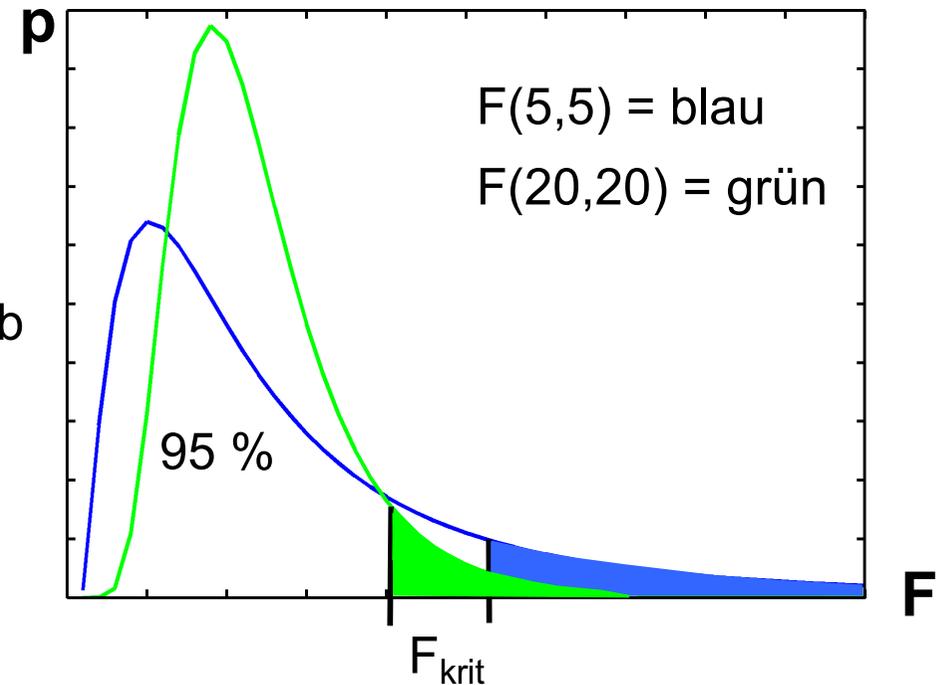
- F-Wert : Verhältnis zweier Varianzen
- geteilt durch dfs

$$F = \frac{\left[\begin{array}{l} \text{Varianz 1} \\ \text{df}_{\text{Zähler}} \end{array} \right]}{\left[\begin{array}{l} \text{Varianz 2} \\ \text{df}_{\text{Nenner}} \end{array} \right]}$$


- $df_{\text{Varianz des 'full' Modell (Zähler)}}$ = Anzahl der Regressoren
- $df_{\text{Fehler Varianz (Nenner)}}$ = Anzahl der Beobachtungen – Anzahl der Regressoren

F- Verteilung

- Wahrscheinlichkeitsverteilung
- Form hängt von Anzahl der Freiheitsgrade ab
- $F > F_{\text{krit}}$: H_0 kann zurückgewiesen werden mit 95% Sicherheit



Beispielstudie

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

- Alternativhypothese

- das Modell erklärt signifikanten Anteil der beobachteten Varianz
- Modell 1: 1 Regressor + Konstante

- $F(1,4) = 40.4 > F_{\text{krit}} = 21.2 \Rightarrow H_0$ wird zurückgewiesen $R^2 = 0.91$

- Model 2: 2 Regressoren + Konstante

- $F(2,3) = 36.9 > F_{\text{krit}} = 30.8 \Rightarrow H_0$ wird zurückgewiesen $R^2 = 0.96$

- Ergebnisse der F-Tests

- beide Modelle erklären einen signifikanten Anteil der Varianz in den beobachteten Daten:

- d.h. signifikanter Zusammenhang zwischen Sichtbarkeit der Bilder sowie der Fehlerrate beim Abruf (Modell 2) und der Reaktionszeit beim Gedächtnistest

- erklärte Varianz des Modell 2 größer
- aber F-Wert von Modell 1 größer und F_{krit} kleiner
- der zweite Regressor und die zusätzlich erklärte Varianz des Modell 2 kommen mit 'Kosten' (darüber hinaus, dass sie hier auch noch hochkorreliert sind!)

(nicht getestet, ob das zweite Modell signifikant mehr Varianz erklärt!)

Beispielstudie

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

- Alternativhypothese

- das Modell erklärt signifikanten Anteil der beobachteten Varianz

- Modell 1: 1 Regressor + Konstante

- $F(1,4) = 40.4 > F_{\text{krit}} = 21.2 \Rightarrow H_0$ wird zurückgewiesen $R^2 = 0.91$

- Model 2: 2 Regressoren + Konstante

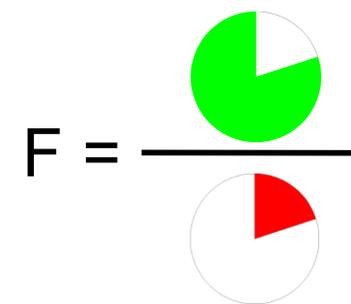
- $F(2,3) = 36.9 > F_{\text{krit}} = 30.8 \Rightarrow H_0$ wird zurückgewiesen $R^2 = 0.96$

- Zusammenhang zwischen der Anzahl der Regressoren und Signifikanz

- $df_{\text{Varianz des 'full' Modell (Zähler)}} = \text{Anzahl der Regressoren}$

- $df_{\text{Fehler Varianz (Nenner)}} = \text{Anzahl der Beobachtungen} - \text{Anzahl der Regressoren}$

$$F = \frac{\left[\begin{array}{l} \text{Varianz 1} \\ \text{df}_{\text{Zähler}} \end{array} \right]}{\left[\begin{array}{l} \text{Varianz 2} \\ \text{df}_{\text{Nenner}} \end{array} \right]}$$



- Anzahl der Regressoren $\uparrow \Rightarrow$ F-Wert \downarrow

- Anzahl der Beobachtungen $\uparrow \Rightarrow$ F-Wert \uparrow

\Rightarrow mehr Regressoren erklären evtl. zusätzliche Varianz aber kosten Freiheitsgrade

t-Test

- **t-Tests:**
 - Ist ein Parameter größer als Null?
 - Ist ein Parameter größer als ein anderer?
- **Kontrast-Vektor:** Welcher Parameter/Regressor soll getestet werden?
 - gleiche Anzahl an Elementen wie der β -Vektor
 - jedes Element des Kontrast-Vektors korrespondiert mit einem β (und Regressor)
 - Kontrastgewichte: Elemente eines Kontrast-Vektors
- **Beispielstudie:** Korreliert Sichtbarkeit signifikant positiv mit Reaktionszeit?

Ist das β des ersten regressors signifikant größer als 0?

Kontrast-Vektor $c' = [1 \quad 0 \quad 0]$

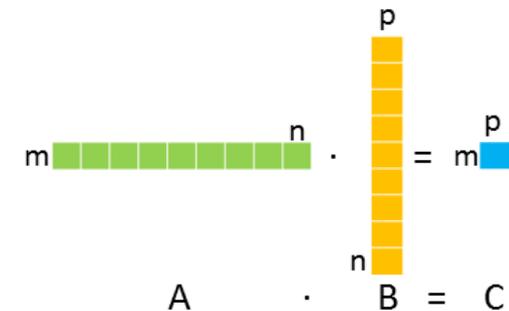
$$\begin{bmatrix} 1.765 \\ 1.629 \\ 1.443 \\ 1.204 \\ 1.254 \end{bmatrix} = \begin{bmatrix} 0 & 0.5 & 1 \\ 25 & 0.5 & 1 \\ 50 & 0.3 & 1 \\ 75 & 0.1 & 1 \\ 100 & 0.1 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}$$

t-Test

- **t-Tests:**
 - Ist ein Parameter größer als Null?
 - Ist ein Parameter größer als ein anderer?
- **Kontrast-Vektor:** Welcher Parameter/Regressor soll getestet werden?
 - gleiche Anzahl an Elementen wie der β -Vektor
 - jedes Element des Kontrast-Vektors korrespondiert mit einem β (und Regressor)
 - Kontrastgewichte: Elemente eines Kontrast-Vektors
- **Beispielstudie:** Korreliert Sichtbarkeit signifikant positiv mit Reaktionszeit?
Ist das β des ersten regressors signifikant größer als 0?

Kontrast-Vektor $c' = [1 \quad 0 \quad 0]$

$$c' = [1 \quad 0 \quad 0] * \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_0 \end{bmatrix}$$



- **Beispielstudie:** Korreliert Sichtbarkeit signifikant stärker mit RT als die Fehlerrate?

$$c' = [1 \quad -1 \quad 0]$$

$$\begin{bmatrix} 1.765 \\ 1.629 \\ 1.443 \\ 1.204 \\ 1.254 \end{bmatrix} = \begin{bmatrix} 0 & 0.5 & 1 \\ 25 & 0.5 & 1 \\ 50 & 0.3 & 1 \\ 75 & 0.1 & 1 \\ 100 & 0.1 & 1 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \end{bmatrix}$$

Regressionsanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

- **Beispielstudie:** Korreliert Sichtbarkeit signifikant stärker mit Reaktionszeit als die Fehlerrate? $c' = [1 \quad -1 \quad 0]$

- Ist das β des ersten Regressors minus das β des zweiten Regressors signifikant größer als 0?

$$c' = [1 \quad -1 \quad 0] * \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_0 \end{bmatrix}$$

t-Wert: Verhältnis von (Kontrasten von) geschätzten Parametern und geschätzter Fehler-Varianz

$$t = \frac{c' \beta}{\sqrt{\frac{SSE}{df} c' (X' X)^{-1} c}} \quad \frac{c' \beta = 1\beta_1 + (-1\beta_2) + 0\beta_0 = \beta_1 - \beta_2}{- \text{geschätzte Fehler-Varianz der full models}}$$

- **Vergleich des empirischen mit dem kritischen t_{krit} der t-Verteilung**

-die Nullhypothese H_0 wird zurückgewiesen wenn $t > t_{\text{krit}}$

F-Test

- F-Wert: Verhältnis zweier Varianzen, kann berechnet werden z.B.

$$F = \frac{\text{Pie chart 1} - \text{Pie chart 2}}{\text{Pie chart 3}}$$

The diagram illustrates the F-test formula using pie charts. The numerator consists of two pie charts: the first is a large red circle with a small black sector removed, and the second is a white circle with a small red sector removed. A minus sign is between them. The denominator is a single white circle with a small red sector removed.

- alternative Berechnung über die **Sum of Squares Hypothesis SSH**

- Kontrast-Vektor oder Matrix

- um die Regressors zu spezifizieren, deren erklärte Varianz getestet werden soll

- gleiche Anzahl von Spalten wie Designmatrix

- Anzahl der Zeilen hängt von der Hypothese ab

- Beispiel:

- um zu testen, ob min. einer von drei Regressoren eines Modells Varianz

erklärt

$$c = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

- analog zum “effect of interest” or “Omnibus F-Test”: Erklärt das ‘full’ Modell signifikant mehr Varianz als das max. reduzierte Modell?

F-Test

- Sum of Square of the Hypothesis SSH

$$c = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

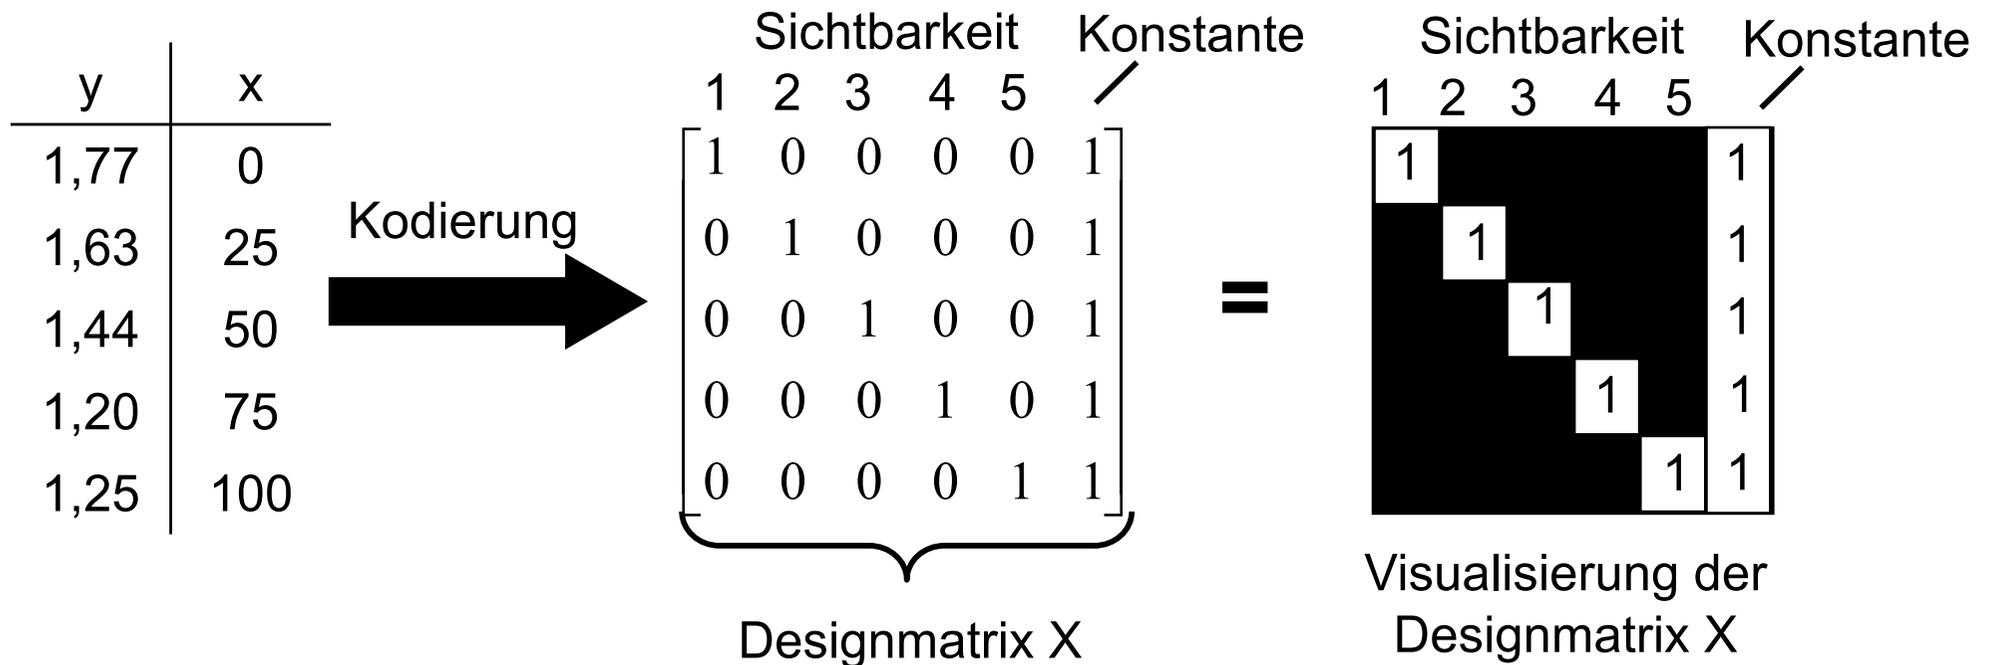
$$SSH = c\beta^{-1} [c(X'X)^{-1}c']^{-1} c\beta$$

$$F = \frac{\left[\begin{array}{l} SSH \\ \text{df}_{\text{Nenner}} \end{array} \right]}{\left[\begin{array}{l} SSE \\ \text{df}_{\text{Zähler}} \end{array} \right]}$$

- mehr (und praktischer) über Kontrast Spezifikation, t- und F-Tests in SPM im Vortrag von Philipp Taesler und Julia Jablonowski über 1st and 2nd Level fMRT Analysen

Beispielstudie:

- gleiches Model und Daten wie in der Regressionsanalyse:
 - Kriteriumsvariable: Reaktionszeit im Gedächtnistest
 - Regressoren: Sichtbarkeit der Bilder kodiert als 5 Faktorstufen



⇒ Grenzen des Beispielmmodels:

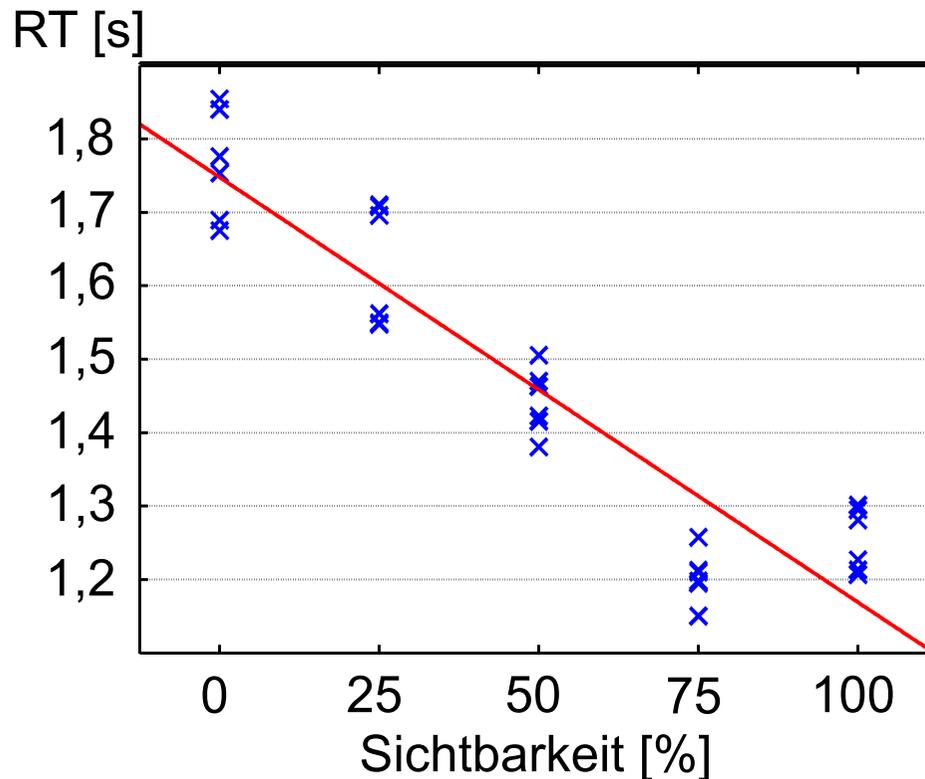
- keine Varianz in den einzelnen Faktorstufen
- Varianzanalyse nicht möglich

Modell:

- bisher: Mittelwerte der Reaktionszeit einer Person
- jetzt: einzelne Trials (n=30) im Gedächtnistest

⇒ Regressionsanalyse

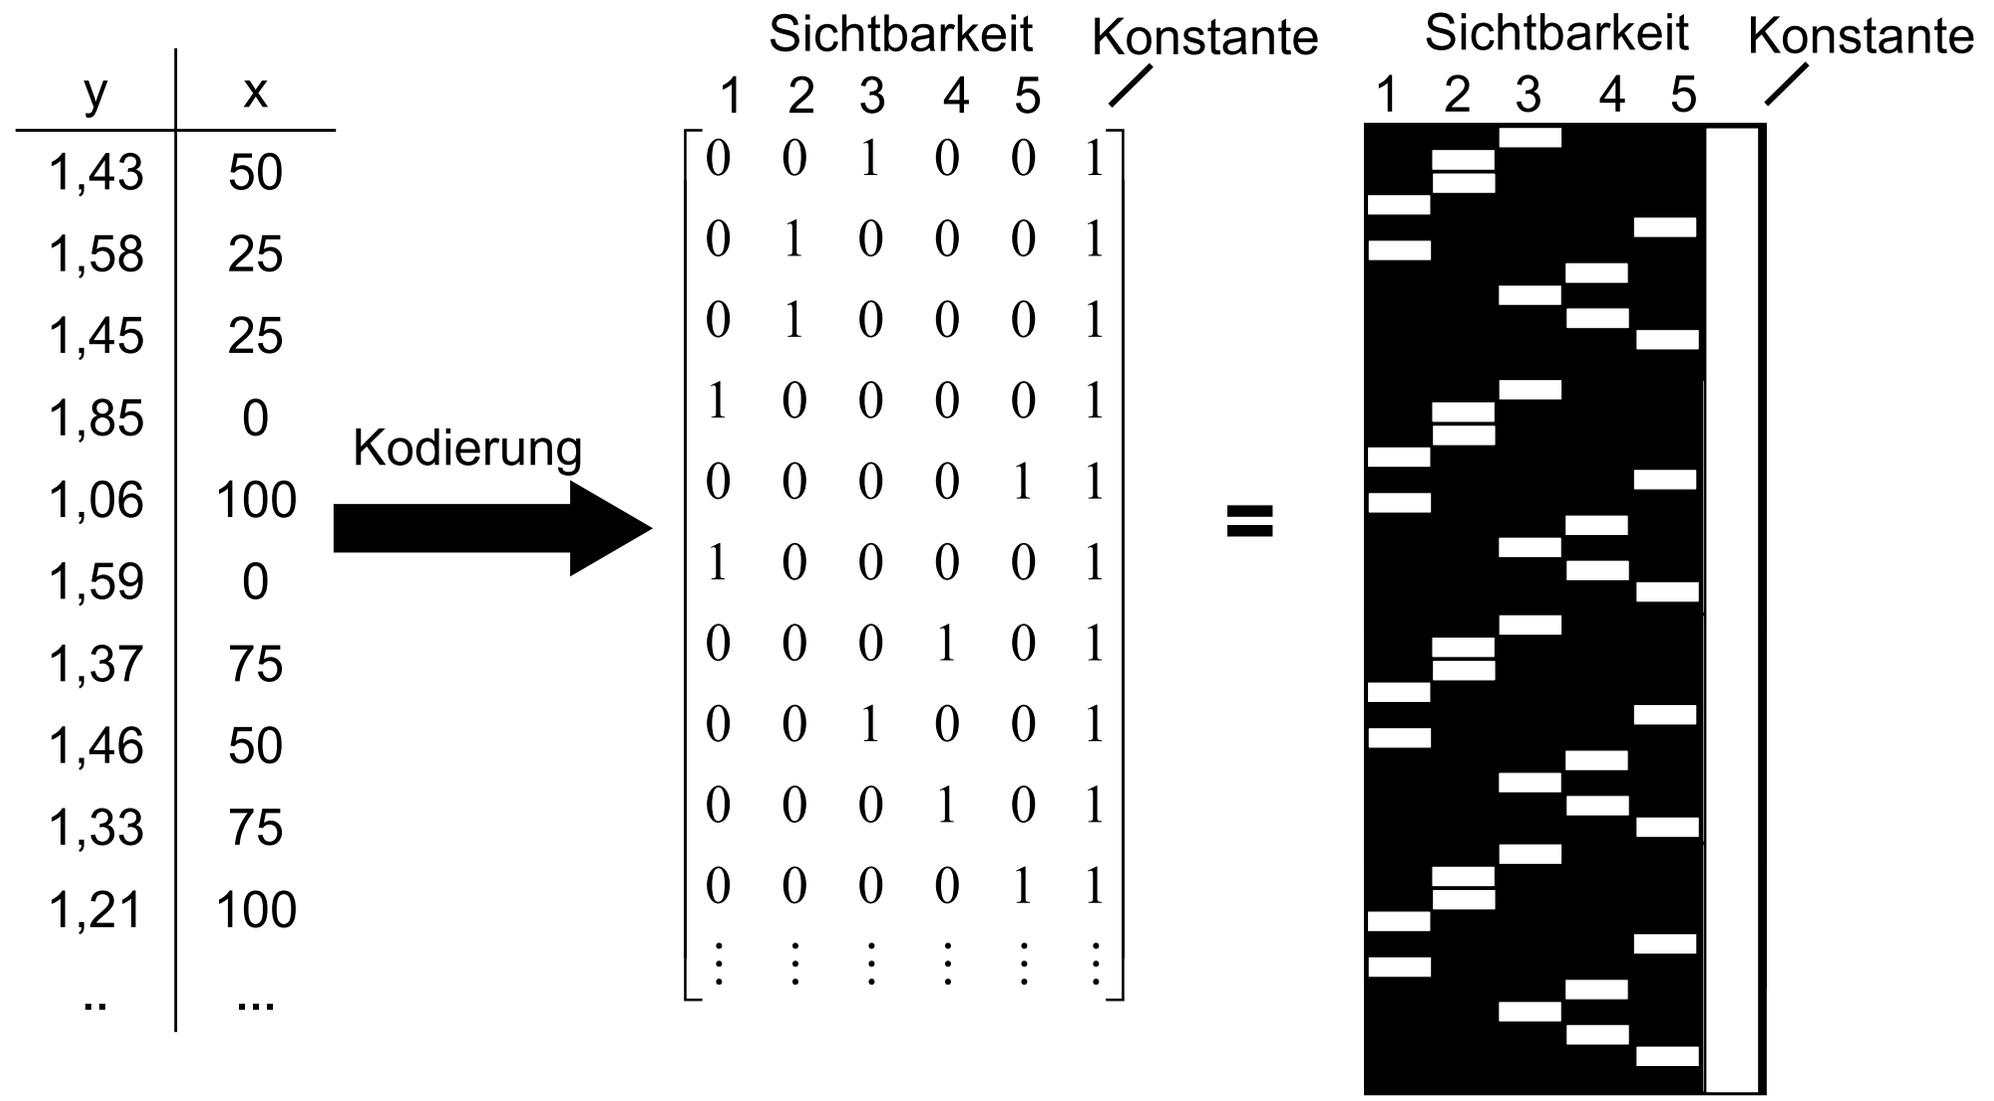
y	x
1,43	50
1,58	25
1,45	25
1,85	0
1,06	100
1,59	0
1,37	75
1,46	50
1,33	75
1,21	100
..	...



$$b = (X'X)^{-1} X'y = \begin{bmatrix} -0,0006 \\ 1,75 \end{bmatrix}$$

$$\begin{bmatrix} 1,43 \\ 1,58 \\ 1,45 \\ 1,85 \\ 1,06 \\ 1,59 \\ 1,37 \\ 1,46 \\ 1,33 \\ 1,21 \\ \vdots \end{bmatrix} = \begin{bmatrix} 50 & 1 \\ 25 & 1 \\ 25 & 1 \\ 0 & 1 \\ 100 & 1 \\ 0 & 1 \\ 75 & 1 \\ 50 & 1 \\ 75 & 1 \\ 100 & 1 \\ \vdots & \vdots \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_i \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

⇒ **Varianzanalyse**



- Parameterschätzung

$$b = (X'X)^{-1} X'y =$$

$$\begin{bmatrix} 0.55 \\ 0.41 \\ 0.23 \\ -0.01 \\ 0.03 \\ 1.25 \end{bmatrix}$$

100% Sichtbarkeit

75% Sichtbarkeit

50% Sichtbarkeit

25% Sichtbarkeit

0% Sichtbarkeit

Konstante

Beispiel

Varianzanalyse

Modellauswahl

Parameterschätzung

Modellgüte

Inferenz

- Modellgüte

$$R^2 = 0.99$$

(aber nicht direkt vergleichbar zum ersten Regressionsmodell, da mehr Beobachtungen und mehr Regressoren!)

- Inferenz

- ANOVA: Vergleich einzelner Faktorstufen via t-Tests oder post hoc Tests möglich
- z.B.: H_1 : RT bei 50% Sichtbarkeit größer als bei 25% Sichtbarkeit?
- Kontrast-Vektor $c = [0 \ 0 \ 1 \ -1 \ 0 \ 0]$
- Kontrast: $c' * b = 0 * \beta_1 + 0 * \beta_2 + 1 * \beta_3 + (-1 * \beta_4) + 0 * \beta_5 + 0 * \beta_6 = \beta_3 - \beta_4$

-mass univariate approach:

- Aktivität wird in jedem Voxel unabhängig von allen anderen Voxeln analysiert (im Gegensatz zu multivariaten Verfahren, z.B. multivariate Mustererkennung)
- nur am Ende der Analyse werden die Ergebnisse in den übrigen Voxeln berücksichtigt \Rightarrow Korrektur der Statistik für multiple Vergleiche (Lena Tiedemanns Vortrag über multiple Vergleiche)

-abhängige Variable 'y' and unabhängige Variablen/Regressoren 'x':

- unterschiedlich in 1st und 2nd Level Analysen

1st level oder single subject Analysen

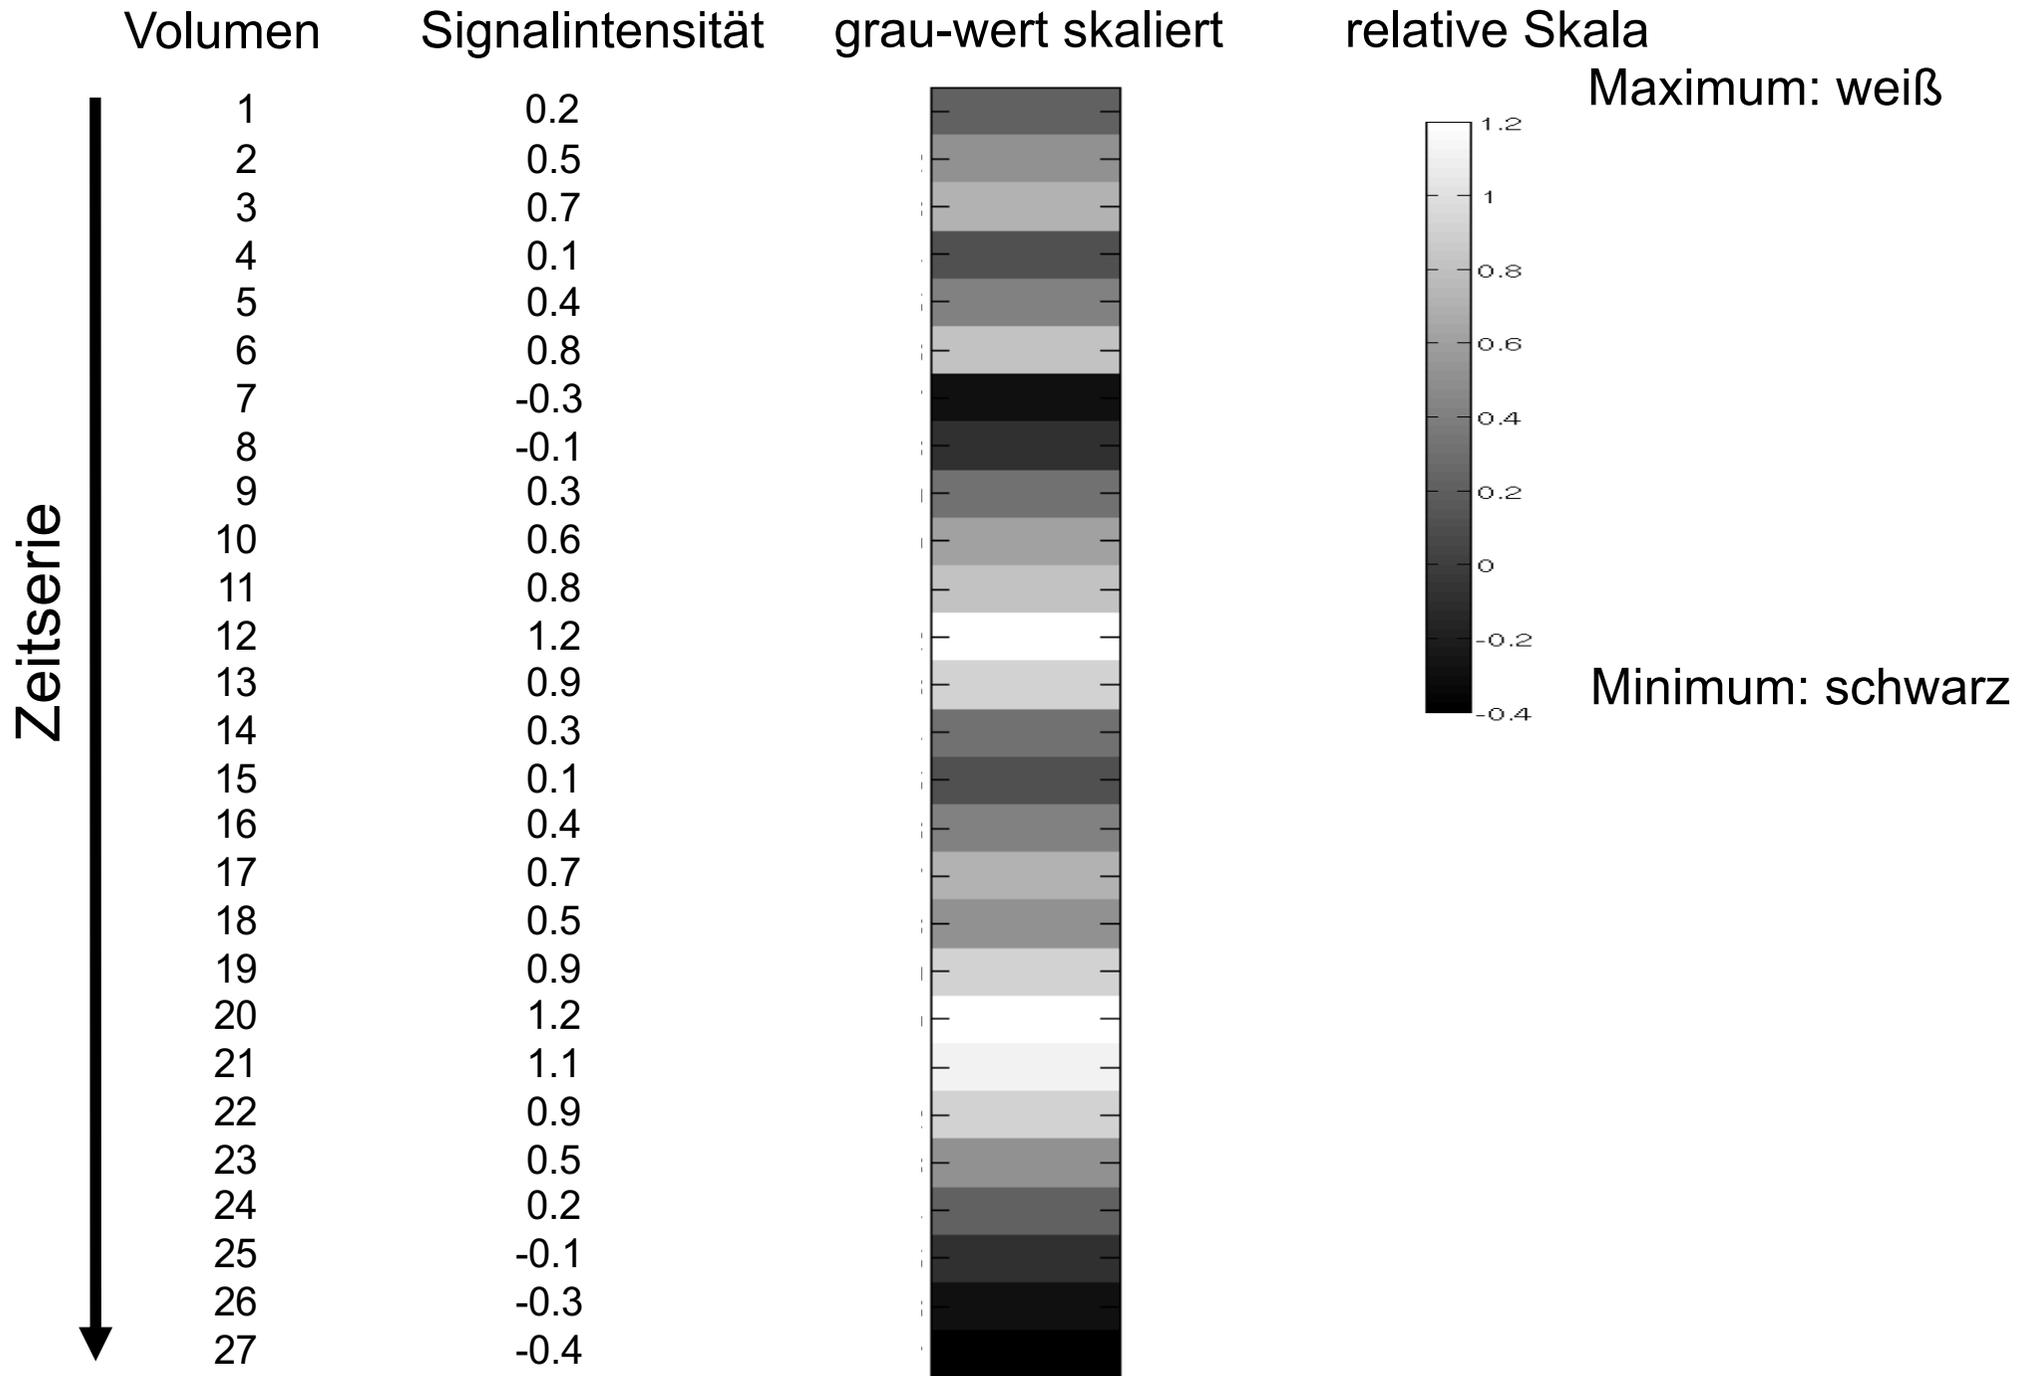
- first Level fMRT: **multiple Regressionsanalyse**

- abhängige Variable y:

- Veränderungen der BOLD-Signalintensität in einem Voxel über die Zeit, also in jedem Volumen/Scan des Experimentes
- in SPM wird Signalintensität Grau-Wert skaliert visualisiert: je dunkler, desto geringer, je heller desto höher

⇒ y = **BOLD-Signalintensität** in einem **Voxel** über die **Zeit**

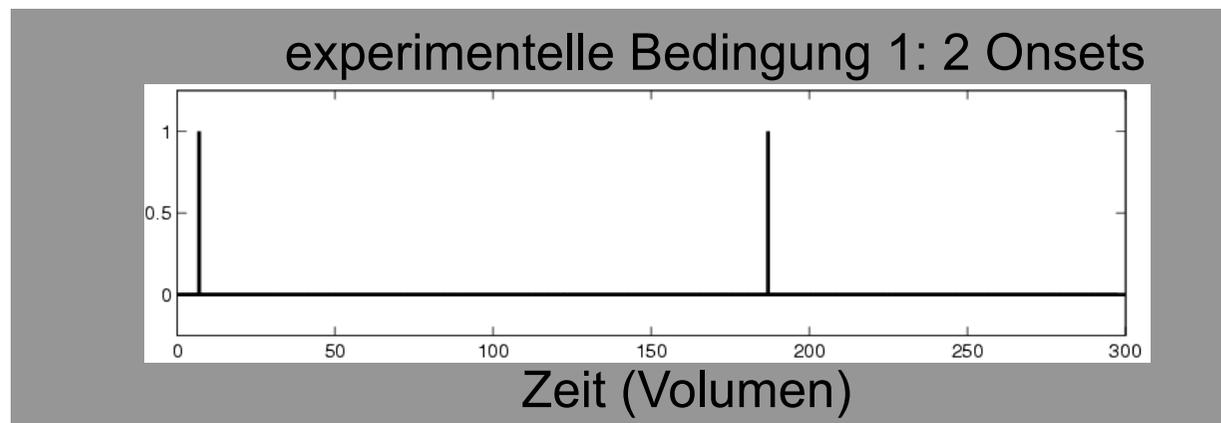
GLM in fMRI – 1st Level
Regression Analyse



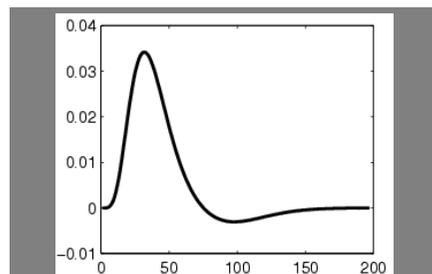
1st Level Regressoren

Regressoren = unabhängige Variablen

- unabhängig – basierend auf dem Timing der experimentellen Bedingungen
- Neurone, die in die Verarbeitung/Reaktion auf Stimuli einer experimentellen Bedingung involviert sind, zeigen zu dessen Onset erhöhte Aktivität
- elektrochemische neuronale Aktivität = sehr kurzes Ereignis
- δ -Funktion (stick-Funktion; 0 und 1) zum Onset der experimentellen Bedingung

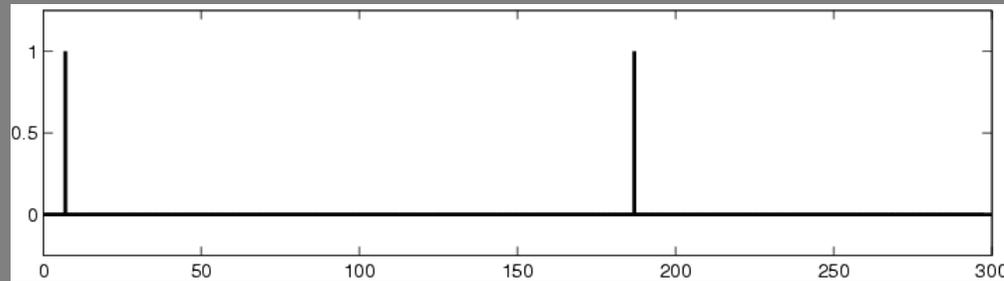


- neuronal Aktivität kann nicht direkt mittel fMRT gemessen werden
- erhöhte neuronale Aktivität triggert eine *hemodynamic response function* (hrf)

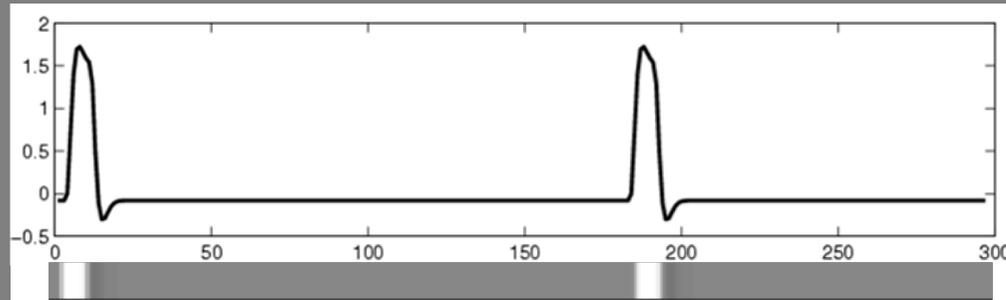


1st Level Regressoren

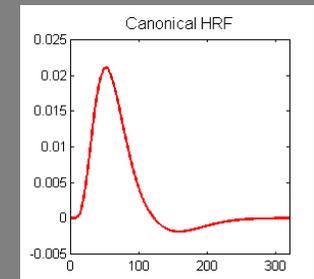
- δ -Funktion zum Onset der experimentellen Bedingung
- neuronale Aktivität triggert hrf



hypothetischer hämodynamischer Verlauf
der experimentellen Bedingung 1



Convolution

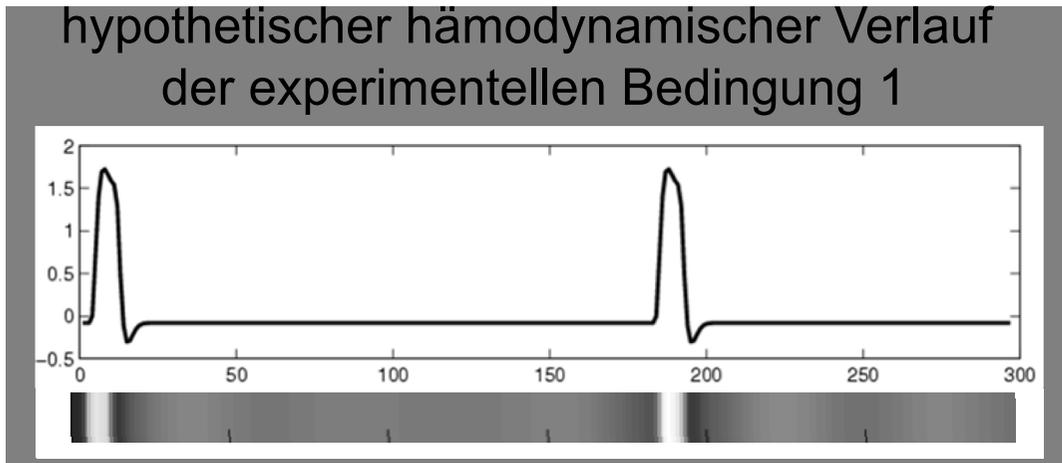


- Neurone involviert in die Prozessierung der Stimuli von Bedingung 1 sollten diese hypothetische hämodynamische Antwortfunktion zeigen \approx BOLD Signal Veränderungen

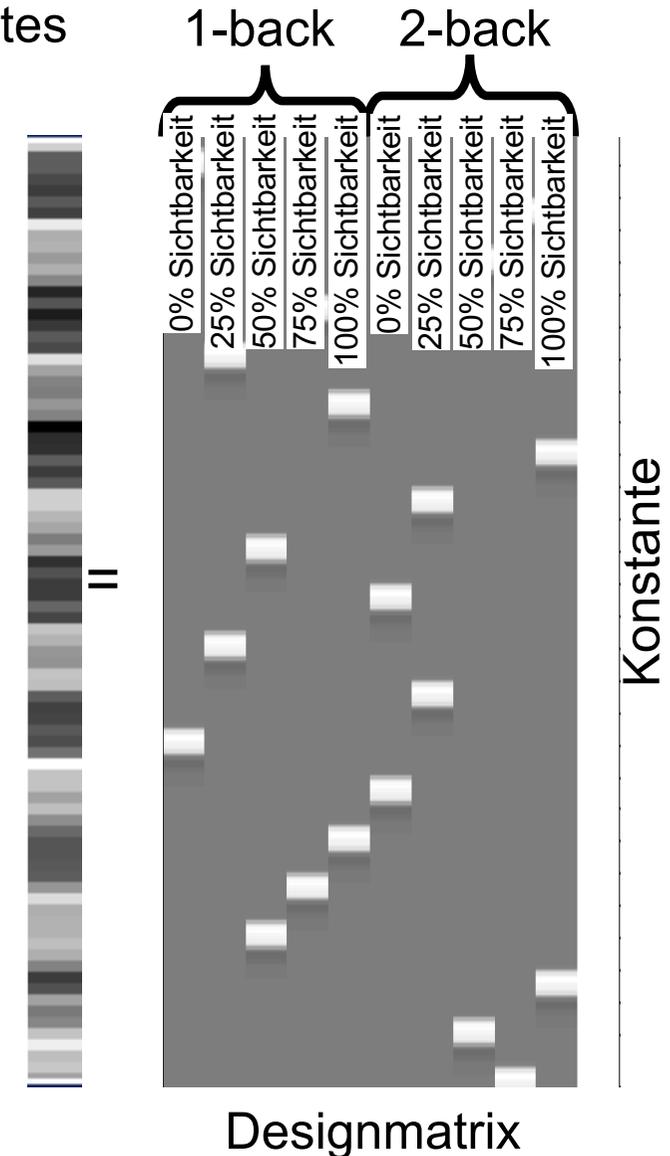
1st Level Designmatrix

- meist mehr als eine experimentelle Bedingung in Design Matrix
- Beispielstudie: 5 Sichtbarkeits- x 2 n-back Stufen = 10 Bedingungen
- Unabhängige Variable y:

Signalintensität in jedem Volumen des Experimentes



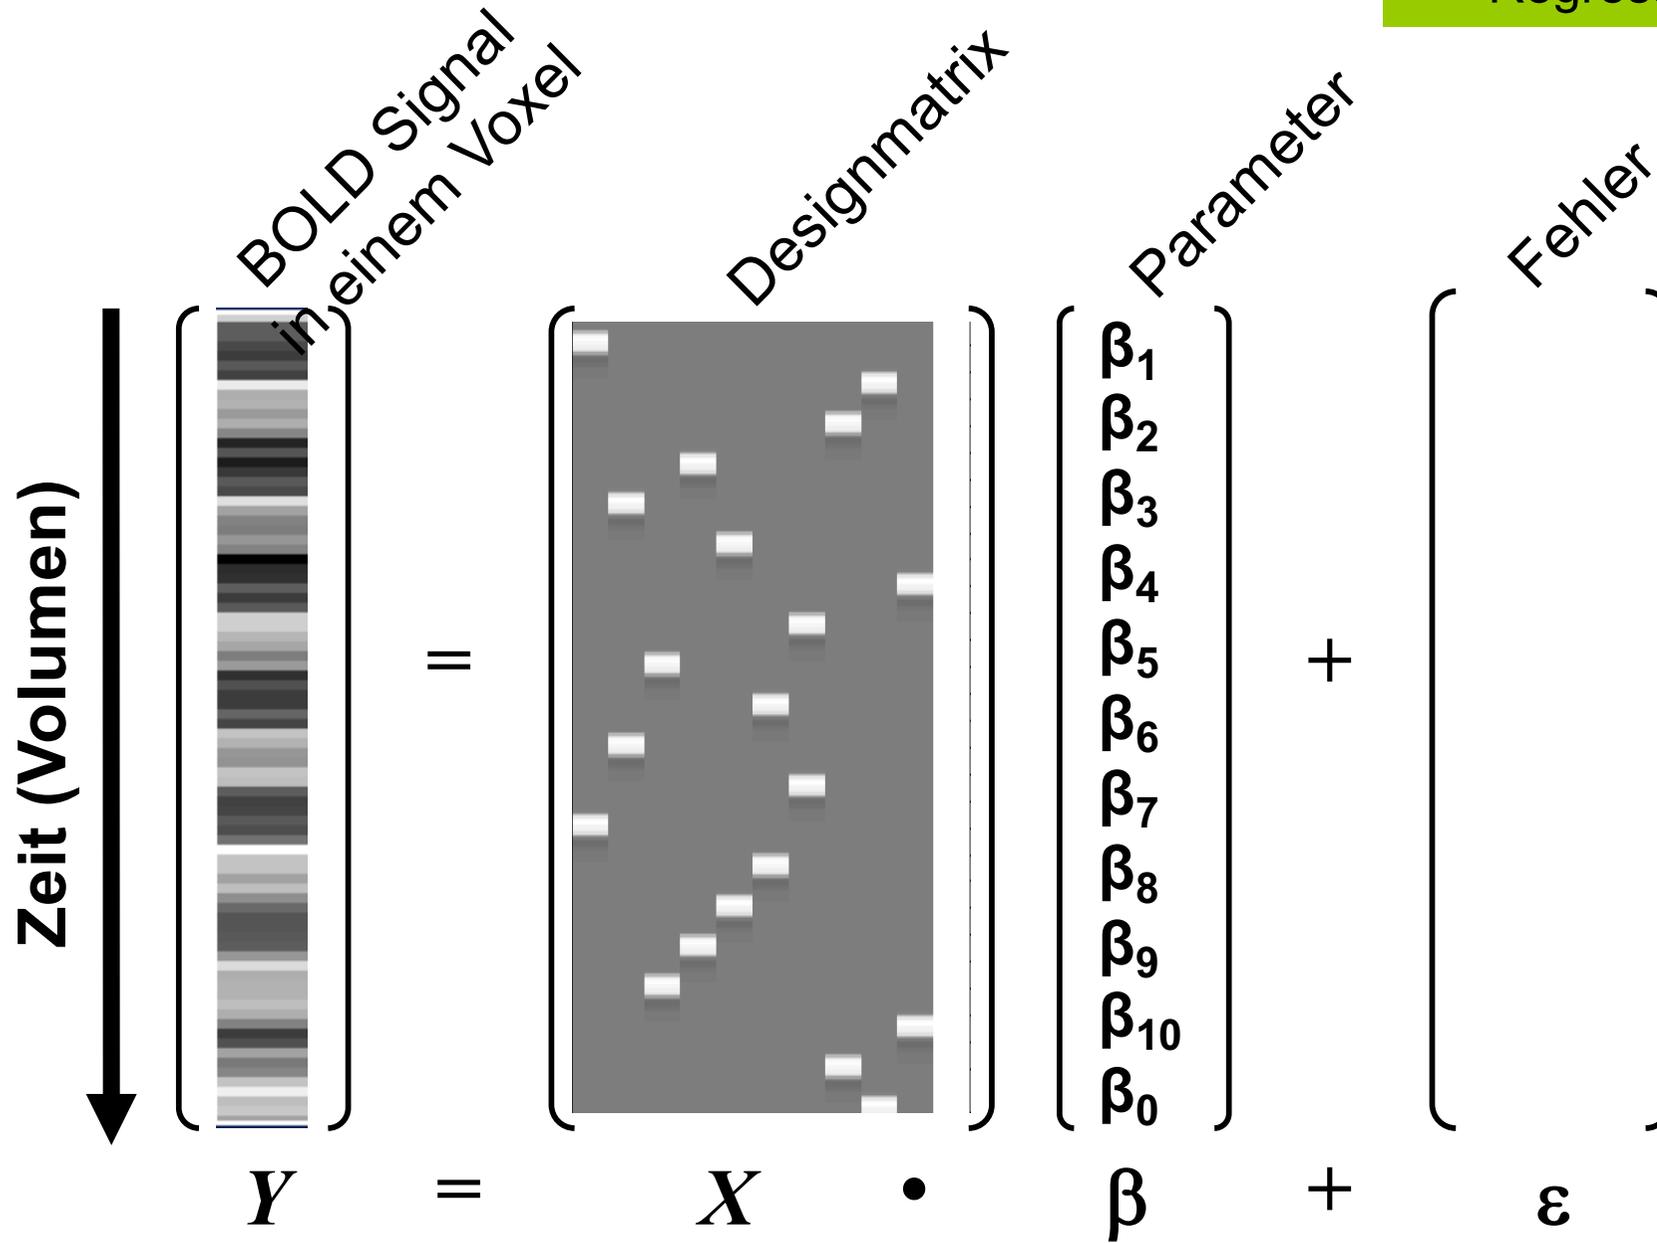
mehr dazu morgen im Vortrag Model Spezifikation
und Schätzung von Jan Gläscher



Designmatrix

GLM in 1st Level-fMRI

GLM in fMRI – 1st Level
Regression Analysis

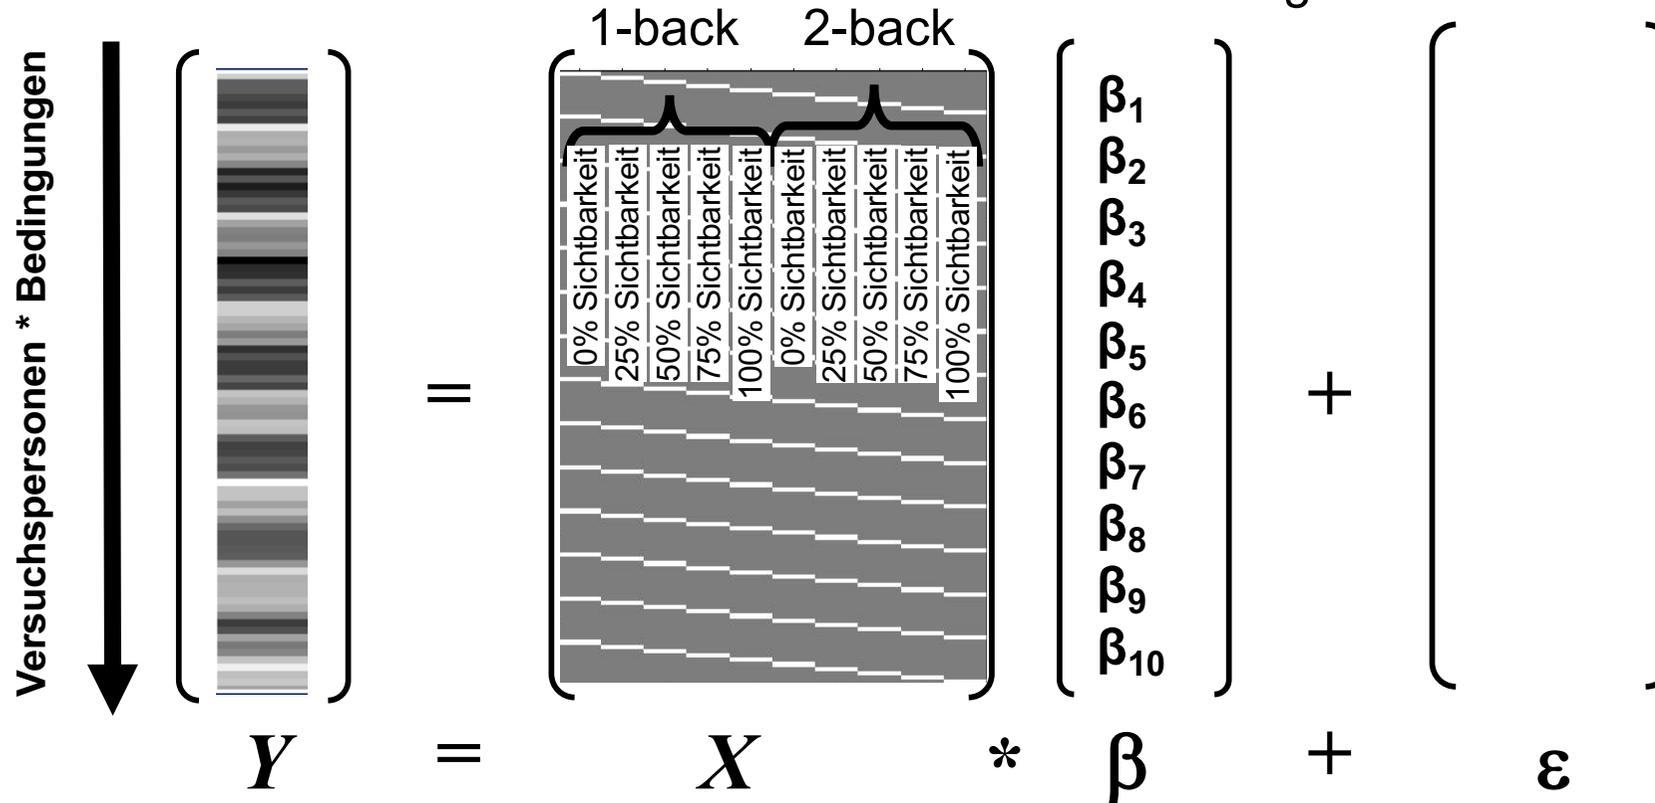


abhängige Variable

- Ergebnis der 1st-Level Analyse ein einem gegebenen Voxel über die Versuchspersonen (Werte in den con-images)

Regressoren

- 0 und 1 Dummy-codierte Zuordnung dieser Ergebnisse (also der con-images) zu den Bedingungen oder Faktorstufen
- diese werden auf dem 2nd-Level über Kontrast-Vektoren verglichen werden



- mehr über 1st und 2nd Level Modelle und Inferenz in SPM in Michael Roses Vorträgen

Unterschiede von Design-Matrizen

„full-rank“

$$\begin{bmatrix} 0 & 0,5 & 1 \\ 25 & 0,5 & 1 \\ 50 & 0,3 & 1 \\ 75 & 0,1 & 1 \\ 100 & 0,1 & 1 \end{bmatrix}$$

„rank-deficient“

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix}$$

⇒ Regressor als Linearkombination der anderen
Regressoren

$$1 * x_1 + 1 * x_2 + 1 * x_3 + 1 * x_4 + 1 * x_5 = x_6$$

⇒ nicht alle Parameter können nicht eindeutig
geschätzt werden

⇒ nicht alle Kontraste können geschätzt werden
(Kontrastgewichte müssen in der Summe 0 ergeben)

Unterschiede von Design-Matrizen

„full-rank“

$$\begin{bmatrix} 0 & 0,5 & 1 \\ 25 & 0,5 & 1 \\ 50 & 0,3 & 1 \\ 75 & 0,1 & 1 \\ 100 & 0,1 & 1 \end{bmatrix}$$

„rank-deficient“

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix}$$

$$b = (X'X)^{-1} X'y$$

Inverse von X

$$\beta = X^+ y$$

Pseudoinverse von X
(in SPM)