

Statistik

für Betriebswirtschaft, Internationales Management,
Wirtschaftsinformatik und Informatik

Sommersemester 2017

HSA Statistik SS 2017 Sessionlist		
Datum	Statistik für BW/IM/I/Winf	Nr.
15.03.2017	Einführung Statistik	1
22.03.2017	Differentialrechnung, 2-dim Diff.Rechnung	2
29.03.2017	univ. deskr. Stat., Quantile, Plots	3
05.04.2017	Streuung, Konzentrationsmaße	4
12.04.2017	Kontingenztabellen, Mosaikplots, Korrelation	5
19.04.2017	Preisindizes, lineare Regression	6
26.04.2017	Wahrscheinlichkeitsbegriff	7
03.05.2017	Bedingte Wahrscheinlichkeit, Bayes	8
10.05.2017	diskrete Zufallsvariablen	9
17.05.2017	Stetige ZV, Gleichverteilung	10
24.05.2017	Pyramid	
31.05.2017	Normalverteilung, Verteilungsparameter	11
07.06.2017	Schätzfunktionen und Punktschätzer	12
14.06.2017	Konfidenzintervalle	13
21.06.2017	Wiederholung, Besprechung Probeklausur	14
28.06.2017	Prüfungswoche	15

- 1 Statistik: Einführung
- 2 Differenzieren 2
- 3 Deskriptive Statistik
- 4 Wahrscheinlichkeitstheorie
- 5 Induktive Statistik



- 2 Differenzieren 2
Partielle Ableitung
Kurvendiskussion
Optimierung mit Nebenbedingungen



Betrachtet werden

- ▶ Funktionen $f : D \rightarrow \mathbb{R}$, $D \in \mathbb{R}^n$
- ▶ mit $x = (x_1, \dots, x_n) \mapsto f(x) = f(x_1, \dots, x_n) = z$
- ▶ außerdem: i -ter Einheitsvektor $e_i = (0, \dots, 0, 1, 0, \dots, 0)$
- ▶ und: $x + h \cdot e_i \in D$ mit $h > 0$

Definition

- ▶ f heißt im Punkt x **partiell differenzierbar** bei Existenz des Grenzwerts:

$$\lim_{h \rightarrow 0} \frac{f(x + h \cdot e_i) - f(x)}{h}$$

- ▶ In diesem Fall heißt dieser Grenzwert $f_{x_i}(x)$ die **erste partielle Ableitung** von f nach x_i im Punkt x . Schreibweisen:

$$f^i(x) = f_{x_i}(x) = \frac{\partial f(x)}{\partial x_i}$$

1. Einführung

2. Differenzieren 2

- 2.1. Partielle Ableitung
- 2.2. Kurvendiskussion
- 2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen

Partielle Ableitung: Idee: Bestimme Steigung in Richtung der Koordinatenachsen, dazu: Betrachte eine Variable und setze alle anderen Variablen konstant

$$\frac{\partial f}{\partial x_i}(x_1, x_2, \dots, x_i, \dots, x_n) = f_{x_i}$$

„partielle Ableitung nach x_i “

Achtung: Bei Funktionen mehrerer Variablen gibt es kein f' ! Nie!

Beispiel: $f(x, y) = x^2 - 2x^2y + 3y$

$$\frac{\partial f}{\partial x}(x, y) = 2x - 6x^2y$$

$$\frac{\partial f}{\partial y}(x, y) = -2x^2 + 3$$

$f(x, y) = x \cdot e^{-x^2 - y^2}$

$$(g(x) \cdot h(x))' = g' \cdot h + g \cdot h'$$

partielle Ableitungen:

nach x

$$f_x = 1 \cdot e^{-x^2 - y^2} + x \cdot e^{-x^2 - y^2} \cdot (-2x)$$

$$= e^{-x^2 - y^2} \cdot (1 - 2x^2)$$

$$f_y = x \cdot e^{-x^2 - y^2} \cdot (-2y) = -2xy \cdot e^{-x^2 - y^2}$$

$$f(x,y) = x e^{-x^2 - y^2}, \quad \begin{aligned} f_x &= e^{-x^2 - y^2} \cdot (1 - 2x^2) \\ f_y &= e^{-x^2 - y^2} \cdot (-2xy) \end{aligned}$$

$$f_x(0.4, 0.55) \approx 0.428$$

$$f_y(0.4, 0.55) \approx -0.177$$


Gradient $\hat{=}$ Vektor der partiellen Ableitungen

↗ Nabla-Operator

$$\text{grad } f = \nabla f = \begin{pmatrix} f_x(x,y) \\ f_y(x,y) \end{pmatrix}$$

Beispiel: $f(x,y) = x \cdot e^{-x^2 - y^2}$

$$\Rightarrow \text{grad } f = \begin{pmatrix} e^{-x^2 - y^2} \cdot (1 - 2x^2) \\ e^{-x^2 - y^2} \cdot (-2xy) \end{pmatrix}$$





Eigenschaften des Gradienten:

- ▶ ∇f zeigt in Richtung des stärksten Anstiegs von f
- ▶ 90° von ∇f „weggedreht“: Richtung einer Höhenlinie
- ▶ $-\nabla f$: in Richtung des stärksten Abfalls von f
- ▶ (x,y) ist Extremwert von $f \Rightarrow \nabla f(x,y) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$

plot $x \exp(-x^2 - y^2)$


$x = -2$ to 2
 $y = -2$ to 2

3D plot



2. partielle Ableitungen und Hessematrix

Beispiel: $f(x,y) = x^3 + x^2y - 2xy^2$




$$\frac{\partial}{\partial x} \left(\frac{\partial f}{\partial x} \right) = \frac{\partial^2 f}{\partial x^2} = f_{xx}$$
$$\frac{\partial}{\partial y} \left(\frac{\partial f}{\partial x} \right) = \frac{\partial^2 f}{\partial y \partial x} = f_{yx}$$
$$\frac{\partial}{\partial x} \left(\frac{\partial f}{\partial y} \right) = \frac{\partial^2 f}{\partial x \partial y} = f_{yx}$$
$$\frac{\partial}{\partial y} \left(\frac{\partial f}{\partial y} \right) = \frac{\partial^2 f}{\partial y^2} = f_{yy}$$

2. partiellen Ableitungen von f

Hessematrix

$$H_f(x,y) = \begin{pmatrix} f_{xx} & f_{xy} \\ f_{yx} & f_{yy} \end{pmatrix}$$



Satz von Schwarz
Bei „fast allen“ Funktionen $f(x,y)$ gilt:
 $f_{xy} = f_{yx}$

Rezept zur Extremwertbestimmung von $f(x,y)$

1. Setze $\nabla f = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Rightarrow (x_1, y_1), (x_2, y_2), \dots$
sind Kandidaten für Extremwerte
2. Bestimme $H_f(x,y)$ und setze Kandidaten jeweils ein, z. B.
 $H_f(x_1, y_1) = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$
3. $ad - bc > 0$ und $\begin{cases} a > 0 \Rightarrow \text{Minimum} \\ a < 0 \Rightarrow \text{Maximum} \end{cases}$
 $ad - bc < 0 \Rightarrow$ Sattelpunkt
 $ad - bc = 0 \Rightarrow$ (für uns) keine Aussage möglich

Beispiel (Extremwerte von $f(x,y)$)

$$f(x,y) = -x^4 + 2x^2 + y^2$$

ges: Extrema

$$\textcircled{1} \nabla f = \begin{pmatrix} f_x \\ f_y \end{pmatrix} = \begin{pmatrix} -4x^3 + 4x \\ 2y \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$\Leftrightarrow y = 0 \text{ und } -4x(x^2 - 1) = 0$$

$$y = 0 \text{ und } x = 0, -1, +1$$

\Leftrightarrow 3 Kandidaten

$$(0,0), (-1,0), (+1,0)$$



$$\textcircled{2} H_f(x,y) = \begin{pmatrix} f_{xx} & f_{xy} \\ f_{yx} & f_{yy} \end{pmatrix} = \begin{pmatrix} -12x^2 + 4 & 0 \\ 0 & 2 \end{pmatrix}$$

$\textcircled{3}$ Einsetzen der Kandidaten in H_f

$$H_f(0,0) = \begin{pmatrix} a & b \\ c & d \end{pmatrix} = \begin{pmatrix} 4 & 0 \\ 0 & 2 \end{pmatrix} \Rightarrow \begin{matrix} a \cdot d - b \cdot c \\ 4 \cdot 2 - 0 \cdot 0 = 8 > 0 \text{ und } 4 > 0 \end{matrix} \Rightarrow \text{Minimum bei } (0,0)$$

$$H_f(-1,0) = \begin{pmatrix} -8 & 0 \\ 0 & 2 \end{pmatrix} \Rightarrow -8 \cdot 2 - 0 \cdot 0 = -16 < 0 \Rightarrow \text{Sattel bei } (-1,0)$$

$$H_f(+1,0) = \begin{pmatrix} -8 & 0 \\ 0 & 2 \end{pmatrix} \Rightarrow \dots \Rightarrow \text{Sattel bei } (+1,0)$$



Beispiel: Suche Extrema von $f(x,y) = 2x^2 + y^4 - 16xy$

$$\textcircled{1} \quad \nabla f = \begin{pmatrix} f_x \\ f_y \end{pmatrix} = \begin{pmatrix} 4x - 16y \\ 4y^3 - 16x \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \quad \begin{matrix} \text{I} \\ \text{II} \end{matrix}$$

$$\Leftrightarrow x = y \quad \text{(I)} \quad \text{und} \quad 4y^3 - 16y = 0 \quad \text{(II)} \quad (\text{I in II eingesetzt})$$

$$\Leftrightarrow x = y \quad \text{und} \quad 4y(y^2 - 4) = 0$$


$$\Leftrightarrow x = y \quad \text{und} \quad y = 0, -2, 2$$

\Rightarrow Kandidaten: $(-2, -2)$, $(0, 0)$, $(2, 2)$

$$\textcircled{2} \quad H_f(x,y) = \begin{pmatrix} f_{xx} & f_{xy} \\ f_{yx} & f_{yy} \end{pmatrix} = \begin{pmatrix} 4 & -16 \\ -16 & 12y^2 \end{pmatrix}$$

$$\textcircled{3} \quad H_f(0,0) = \begin{pmatrix} 4 & -16 \\ -16 & 0 \end{pmatrix} \Rightarrow 4 \cdot 0 - (-16) \cdot (-16) < 0 \\ \Rightarrow \text{Sattel bei } (0,0)$$

$$H_f(-2,-2) = \begin{pmatrix} 4 & -16 \\ -16 & 48 \end{pmatrix} \Rightarrow 4 \cdot 48 - (-16) \cdot (-16) > 0 \\ 48 > 0 \Rightarrow \text{Minimum bei } (-2,-2)$$



Minimum $(2,2)$

Sattel

min. $(-2,-2)$



Differenzierbarkeit auf $D_1 \subseteq D$

- ▶ Die Funktion $f : D \supset \mathbb{R}^n \rightarrow \mathbb{R}$
- ▶ heißt in $D_1 \subseteq D$ **partiell differenzierbar**
- ▶ wenn f für alle $x \in D_1$ partiell differenzierbar ist

Gradient

- ▶ Ist die Funktion $f : D \supset \mathbb{R}^n \rightarrow \mathbb{R}$ im Punkt x
- ▶ nach allen Variablen x_1, \dots, x_n differenzierbar, dann heißt

$$\text{grad } f(x) = \nabla f(x) = \begin{pmatrix} \frac{\partial f(x)}{\partial x_1} \\ \vdots \\ \frac{\partial f(x)}{\partial x_n} \end{pmatrix}$$

- ▶ **Gradient** von f im Punkt $x \in D$

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen

Tangentialebene

- ▶ Gegeben: $f : D \subset \mathbb{R}^2 \rightarrow \mathbb{R}$ und ein Punkt $\tilde{x} = (\tilde{x}_1, \tilde{x}_2)$
- ▶ Gesucht: Ebene, die f in \tilde{x} berührt

- ▶ **Tangentialebene:**

$$T(x_1, x_2) = f(\tilde{x}) + \frac{\partial f}{\partial x_1}(\tilde{x}) \cdot (x_1 - \tilde{x}_1) + \frac{\partial f}{\partial x_2}(\tilde{x}) \cdot (x_2 - \tilde{x}_2)$$

Tangentialhyperebene


- ▶ Gegeben: $f : D \subset \mathbb{R}^n \rightarrow \mathbb{R}$ und ein Punkt \tilde{x}
- ▶ Gesucht: Ebene, die f in \tilde{x} berührt

- ▶ **Tangentialhyperebene:**

$$H(x) = f(\tilde{x}) + (\nabla f(\tilde{x}))^T \cdot (x - \tilde{x})$$



- ▶ Gegeben: $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ mit $f(x, y) = 4x^3y^2 + 2y$
- ▶ Gesucht: Tangentialebene im Punkt $(1, -2, f(1, -2))$



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Voraussetzungen

- ▶ $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$ und ein Punkt $x \in D$
- ▶ mit stetig partiellen Ableitungen in D und
- ▶ ein Punkt $x \in D$
- ▶ und ein Richtungsvektor $r \in D$ mit $\|r\| = 1$.
- ▶ Außerdem: Es existiert sowohl ein $\epsilon > 0$ mit $[x - \epsilon r; x + \epsilon r] \in D$
- ▶ als auch der Grenzwert


$$\lim_{t \rightarrow 0} \frac{f(x + t \cdot r) - f(x)}{t}$$

Richtungsableitung

- ▶ Dann heißt

$$(\nabla f(x))^T \cdot r$$

Richtungsableitung von f an der Stelle x in Richtung r



1. Einführung

2. Differenzieren 2

- 2.1. Partielle Ableitung
- 2.2. Kurvendiskussion
- 2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik


4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen

- ▶ Gegeben: $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ mit $f(x, y) = x e^y + \cos(xy)$
- ▶ Gesucht: Ableitung im Punkt $(2, 0)$ in Richtung des Vektors $\begin{pmatrix} 3 \\ -4 \end{pmatrix}$





Voraussetzungen

- ▶ Funktion $f : D \rightarrow \mathbb{R}$, $D \subseteq \mathbb{R}^n$
- ▶ in D nach allen Variablen x_1, \dots, x_n partiell differenzierbar,
- ▶ auch partiell differenzierbar: alle partiellen Ableitungen f_{x_1}, \dots, f_{x_n} .

Dann heißt

- ▶ f **zweimal partiell** nach allen Variablen **differenzierbar**.
- ▶ **Partielle Ableitungen zweiter Ordnung** für $i, j = 1, \dots, n$:

$$f^{ij}(x) = f_{x_i x_j}(x) = \frac{\partial}{\partial x_j} \left(\frac{\partial}{\partial x_i} f(x) \right) = \frac{\partial^2 f(x)}{\partial x_j \partial x_i}$$

- ▶ Achtung: Zuerst nach x_i , dann nach x_j differenzieren

1. Einführung

2. Differenzieren 2

- 2.1. Partielle Ableitung
- 2.2. Kurvendiskussion
- 2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen

Voraussetzungen

- ▶ $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$ ist zweimal stetig partiell differenzierbar in D
- ▶ 2. partielle Ableitungen:

$$\frac{\partial^2 f(x)}{\partial x_i \partial x_j}$$

- ▶ mit $i, j \in \{1, \dots, n\}$

Dann gilt für alle $x \in D$

$$\frac{\partial^2 f(x)}{\partial x_i \partial x_j} = \frac{\partial^2 f(x)}{\partial x_j \partial x_i}$$



Hermann Schwarz (1843-1921)

Gegeben

- ▶ Zweimal stetig partiell differenzierbare Funktion $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$

Definition

- ▶ Die symmetrische Matrix



$$H_f(x) = \left(\frac{\partial^2 f}{\partial x_i \partial x_j} \right) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_n} \end{pmatrix}$$

heißt **Hessematrix**



1. Einführung

2. Differenzieren 2

- 2.1. Partielle Ableitung
- 2.2. Kurvendiskussion
- 2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen




Notwendige Bedingung für lokale Extrema

- ▶ Gegeben: Funktion $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$ stetig partiell nach allen Variablen differenzierbar
- ▶ f hat im Punkt \tilde{x} ein lokales Minimum oder Maximum
- ▶ Dann gilt: $\nabla f(\tilde{x}) = 0$

Beispiel

- ▶ $f : \mathbb{R}^2 \rightarrow \mathbb{R}$
- ▶ $f(x, y) = \sin^2(x) \cdot \cos(4y)$



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Am Punkt \tilde{x} heißt die Hessematrix $H_f(\tilde{x})$

- ▶ **positiv definit**, wenn $x^T H_f(\tilde{x}) x > 0$,
- ▶ **positiv semidefinit**, wenn $x^T H_f(\tilde{x}) x \geq 0$,
- ▶ **negativ definit**, wenn $x^T H_f(\tilde{x}) x < 0$,
- ▶ **negativ semidefinit**, wenn $x^T H_f(\tilde{x}) x \leq 0$
- ▶ jeweils für alle x gilt.
- ▶ Andernfalls heißt $H_f(\tilde{x})$ **indefinit**.

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Hauptunterdeterminanten

- ▶ Gegeben: Symmetrische $n \times n$ -Matrix A
- ▶ Dann heißt

$$\det H_i = \det \begin{pmatrix} a_{11} & \cdots & a_{1i} \\ \vdots & & \vdots \\ a_{i1} & \cdots & a_{ii} \end{pmatrix}$$

die i -te **Hauptunterdeterminante** ($i = 1, \dots, n$) von A .

Satz

- ▶ Matrix A positiv definit $\Leftrightarrow \det H_i > 0$
 \Leftrightarrow alle Eigenwerte von A sind positiv
- ▶ Matrix A negativ definit $\Leftrightarrow (-1)^i \det H_i > 0$
 \Leftrightarrow alle Eigenwerte von A sind negativ

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Voraussetzungen

- ▶ $D \subseteq \mathbb{R}^n$ konvex und offen
- ▶ Funktion $f : D \rightarrow \mathbb{R}$ zweimal stetig partiell differenzierbar
- ▶ Es gibt ein \tilde{x} , für das $\nabla f(\tilde{x}) = 0$

Satz

- ▶ $H_f(\tilde{x})$ ist negativ definit $\Rightarrow \tilde{x}$ ist lokale Maximalstelle von f
- ▶ $H_f(\tilde{x})$ ist positiv definit $\Rightarrow \tilde{x}$ ist lokale Minimalstelle von f
- ▶ $H_f(\tilde{x})$ ist indefinit $\Rightarrow \tilde{x}$ ist keine lokale Extremalstelle von f

- ▶ $H_f(x)$ ist positiv definit für alle $x \in D$
 $\Rightarrow \tilde{x}$ ist einziges globales Minimum von f
- ▶ $H_f(x)$ ist negativ definit für alle $x \in D$
 $\Rightarrow \tilde{x}$ ist globales Maximum von f

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Voraussetzungen

- ▶ $D \subseteq \mathbb{R}^n$ konvex und offen
- ▶ Funktion $f : D \rightarrow \mathbb{R}$ zweimal stetig partiell differenzierbar

Satz

- ▶ $H_f(x)$ ist positiv definit für alle $x \in D$
 $\Rightarrow f$ ist streng konvex in D
- ▶ $H_f(x)$ ist negativ definit für alle $x \in D$
 $\Rightarrow f$ ist streng konkav in D

- ▶ $H_f(x)$ ist positiv semidefinit für alle $x \in D$
 $\Rightarrow f$ ist konvex in D
- ▶ $H_f(x)$ ist negativ semidefinit für alle $x \in D$
 $\Rightarrow f$ ist konkav in D

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

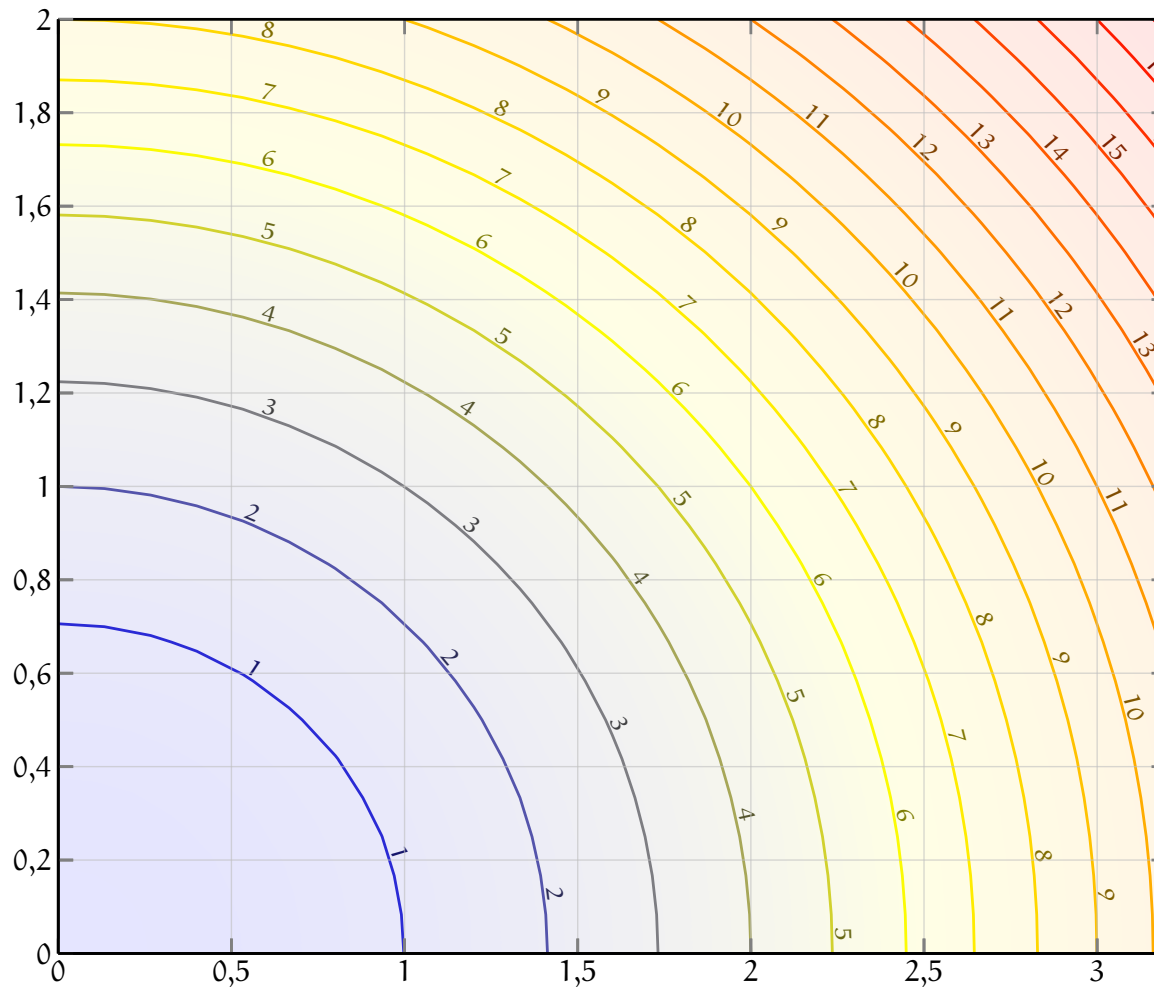
5. Induktive Statistik

Quellen

Tabellen

Problem

- ▶ Betrachte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$ mit $f(x, y) = x^2 + 2y^2$
- ▶ Gesucht: Punkt in \mathbb{R}^2 mit kleinstem Wert von f
- ▶ auf der Geraden $2y + x - 3 = 0$



1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Aufgabe

- ▶ Maximiere (oder minimiere) Funktion $f : \mathbb{R}^n \rightarrow \mathbb{R}$
- ▶ in Abhängigkeit von $x = (x_1, \dots, x_n)$,
- ▶ so dass die Nebenbedingungen $g^i(x) = 0$ mit $g^i : \mathbb{R}^n \rightarrow \mathbb{R}$ und $i = 1, \dots, m$ erfüllt sind
- ▶ Kurz:

$$f(x) \rightarrow \max \quad (\min)$$

$$\text{NB: } g^1(x) = 0$$

$$\vdots$$

$$g^m(x) = 0$$

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit
Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik


Quellen

Tabellen



Idee von Lagrange

- ▶ Gut wäre: Transformation des Optimierungsproblems mit Nebenbedingungen in eines ohne NB.
- ▶ Im Optimum: Gradient der zu optimierenden Funktion und Gradient der NB sind parallel



Lagrangefunktion

- ▶ Gegeben: Optimierungsproblem (O) mit $f(x) \rightarrow \max(\min)$ unter den Nebenbedingungen $g^j(x) = 0$ für $j = 1, \dots, m$
- ▶ Dazu wird definiert: **Lagrangefunktion** $L : \mathbb{R}^{n+m} \rightarrow \mathbb{R}$

$$L(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) = L(x, \lambda) = f(x) + \sum_{j=1}^m \lambda_j g^j(x)$$

1. Einführung

2. Differenzieren 2

- 2.1. Partielle Ableitung
- 2.2. Kurvendiskussion
- 2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Voraussetzungen

- ▶ $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$, zweimal stetig partiell differenzierbar
- ▶ Optimierungsproblem (O) mit $f(x) \rightarrow \max$ (min) unter den Nebenbedingungen $g^j(x) = 0$ für $j = 1, \dots, m$
- ▶ Hessematrix der Lagrangefunktion:

$$\hat{H}_L(x, \lambda) = \begin{pmatrix} \frac{\partial^2 L(x, \lambda)}{\partial x_1 \partial x_1} & \dots & \frac{\partial^2 L(x, \lambda)}{\partial x_1 \partial x_n} \\ \vdots & & \vdots \\ \frac{\partial^2 L(x, \lambda)}{\partial x_n \partial x_1} & \dots & \frac{\partial^2 L(x, \lambda)}{\partial x_n \partial x_n} \end{pmatrix}$$

- ▶ Eine Lösung $(\tilde{x}, \tilde{\lambda})$ des Systems $\nabla L(x, \lambda) = 0$

Dann gilt:

- ▶ $\hat{H}_L(\tilde{x}, \tilde{\lambda})$ negativ definit $\Rightarrow \tilde{x}$ ist lokales Maximum von (O)
- ▶ $\hat{H}_L(\tilde{x}, \tilde{\lambda})$ positiv definit $\Rightarrow \tilde{x}$ ist lokales Minimum von (O)
- ▶ $\hat{H}_L(x, \tilde{\lambda})$ negativ definit für alle x $\Rightarrow \tilde{x}$ ist globales Maximum von (O)
- ▶ $\hat{H}_L(x, \tilde{\lambda})$ positiv definit für alle x $\Rightarrow \tilde{x}$ ist globales Minimum von (O)

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen



Voraussetzungen

- ▶ $f : \mathbb{R}^n \supset D \rightarrow \mathbb{R}$, zweimal stetig partiell differenzierbar
- ▶ Optimierungsproblem (O) mit $f(x) \rightarrow \max$ (min) unter den Nebenbedingungen $g^j(x) = 0$ für $j = 1, \dots, m$
- ▶ Lagrangefunktion

$$\hat{L}(x) = f(x) + \sum_{j=1}^m \lambda(x) g^j(x)$$

Dann gilt:

- ▶ Ist \tilde{x} eine Maximalstelle bzw. Minimalstelle von \hat{L}
- ▶ mit $g^j(\tilde{x}) = 0$ für alle $j = 1, \dots, m$
- ▶ dann ist \tilde{x} auch Maximalstelle bzw. Minimalstelle von (O)

1. Einführung

2. Differenzieren 2

2.1. Partielle Ableitung

2.2. Kurvendiskussion

2.3. Optimierung mit Nebenbedingungen

3. Deskriptive Statistik

4. W-Theorie

5. Induktive Statistik

Quellen

Tabellen