

**Bachelorstudiengänge Wirtschaftswissenschaften und Informatik**

**Mathematik II**

**Prof. Dr. D. Klatte**

**Universität Zürich**

**Vorlesungsmaterialien Frühjahrssemester 2009**

**Version 22.05.09**

# Inhaltsverzeichnis

<b>Integralrechnung</b> .....	[1]
7. Integralrechnung .....	[1]
7.1. Das bestimmte Integral .....	[3]
7.2. Das unbestimmte Integral .....	[13]
7.3. Integrationstabelle .....	[19]
7.4. Integrationsregeln .....	[21]
7.5. Doppelintegrale .....	[28]
7.6. Uneigentliche Integrale .....	[33]
7.7. Abschliessende Bemerkungen zur Integralrechnung .....	[40]
<b>Lineare Algebra</b> .....	1
8. Lineare Gleichungssysteme (LGS) .....	3
8.1. Grundbegriffe: Vektoren und Matrizen .....	3
8.2. Einführung LGS .....	7
8.3. LGS in expliziter Form .....	13
8.4. Auflösen von LGS .....	18
9. Vektoren .....	37
9.1. Vektorraum .....	37
9.2. Norm, Skalarprodukt .....	40
9.3. Lineare Unabhängigkeit und Basis .....	53
9.4. Rang einer Matrix und theoretische Aussagen zu LGS .....	73

10. Matrizen– und Determinantenkalkül .....	83
10.1. Matrizentypen .....	83
10.2. Rechnen mit Matrizen .....	86
10.3. Inverse einer Matrix .....	101
10.4. Determinanten .....	107
11. Lineare Abbildungen .....	121
12. Spezielle Kapitel der linearen Algebra .....	133
12.1. Verbrauchsmatrizen (Input-Output-Modell) .....	133
12.2. Lineare Algebra und Differentialrechnung im $\mathbb{R}^n$ .....	141
12.2.1. Optimierung unter linearen Restriktionen .....	141
12.2.2. Semi-definite Matrizen und Optimalitätsbedingungen 2. Ordnung bei freien Extremalaufgaben .....	151
12.2.3. Hinreichende Bedingungen 2. Ordnung der Optimierung unter einer Gleichungsnebenbedingung (optional) .....	161
12.3. Matrizenrechnung und Regressionsanalyse (optional) .....	178

Die Kapitel 1-6 wurden im Fach **Mathematik I** behandelt.

Die Kapitel 7-11 sind als Skript im Studentenladen zu beziehen.

## 12. Spezielle Kapitel der linearen Algebra

### 12.1. Verbrauchsmatrizen (Input-Output-Modell) [SH §16.9]

Wir betrachten eine Volkswirtschaft mit  $n$  Produktionszweigen, in der der Output jedes Zweiges als Produktionsfaktor (Input) im eigenen wie in den anderen Zweigen eingesetzt und verbraucht werden kann.

**Beispiel:** Volkswirtschaft mit  $n = 3$  Produktionszweigen

En    Energieproduktion,  
Ch    Chemieproduktion,  
Ba    Bauwesen

und einer *Verbrauchsmatrix*  $A$

$$\begin{pmatrix} \text{En-Verbrauch} \\ \text{Ch-Verbrauch} \\ \text{Ba-Verbrauch} \end{pmatrix} = \underbrace{\begin{pmatrix} 0.2 & 0.4 & 0.3 \\ 0.3 & 0.4 & 0.2 \\ 0.4 & 0.3 & 0.1 \end{pmatrix}}_{=: A} \begin{pmatrix} \text{Input für En} \\ \text{Input für Ch} \\ \text{Input für Ba} \end{pmatrix}.$$

Z.B. betrifft die erste Zeile den Energieverbrauch: Der **Verbrauch**

zur Produktion von 1 Einheit in En beträgt 0.2 En-Einheiten  
zur Produktion von 1 Einheit in Ch beträgt 0.4 En-Einheiten  
zur Produktion von 1 Einheit in Ba beträgt 0.3 En-Einheiten.

Nennen wir den *Produktionsvektor (Inputvektor)*

$$\underline{p} = \begin{pmatrix} p_1 \\ p_2 \\ p_3 \end{pmatrix} \quad \begin{array}{l} \textit{Energie} \\ \textit{Chemieprodukte} \\ \textit{Produkte des Bauwesens} \end{array}$$

so berechnet sich der *verfügbare Output*  $\pi_1$  an Energie durch

$$\pi_1 = p_1 - (0.2p_1 + 0.4p_2 + 0.3p_3),$$

analog die verfügbaren Outputs  $\pi_2$ ,  $\pi_3$  aus Chemie und Bauwesen, insgesamt

$$\begin{pmatrix} \pi_1 \\ \pi_2 \\ \pi_3 \end{pmatrix} = \begin{pmatrix} p_1 \\ p_2 \\ p_3 \end{pmatrix} - \begin{pmatrix} 0.2 & 0.4 & 0.3 \\ 0.3 & 0.4 & 0.2 \\ 0.4 & 0.3 & 0.1 \end{pmatrix} \begin{pmatrix} p_1 \\ p_2 \\ p_3 \end{pmatrix}$$

das heisst

$$\underline{\pi} = \underline{p} - A\underline{p}.$$

In diesem Modell wird berücksichtigt, dass ein Teil des Inputs  $\underline{p}$ , nämlich  $A\underline{p}$ , während der Produktion verbraucht wird.

Mit  $I$  bezeichnen wir wieder die Einheitsmatrix (hier: vom Typ  $(3, 3)$ ).

Sei nun ein Nachfragevektor

$$\underline{y} = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} \quad \begin{array}{l} \text{Energie} \\ \text{Chemieprodukte} \\ \text{Produkte des Bauwesens} \end{array}$$

gegeben mit  $\underline{y} \geq \underline{0}$ . Gesucht ist in dem Modell

$$\underline{p} - A\underline{p} = \underline{y}, \quad \text{d.h., } (I - A)\underline{p} = \underline{y}, \quad (1)$$

ein geeigneter Input  $\underline{p} \geq \underline{0}$ , so dass die Nachfrage  $\underline{y}$  befriedigt werden kann ("produktive Volkswirtschaft").

Literaturhinweis: Simon-Blume *Mathematics for Economists* §8.5

Mathematisch ergibt sich also ein lineares Gleichungssystem

$$(I - A)\underline{p} = \underline{y} \quad (2)$$

mit bekannter rechter Seite  $\underline{y}$  und gesuchtem Vektor  $\underline{p}$ .

Weiss man, dass  $I - A$  invertierbar ist, dann folgt sofort, dass

$$\underline{p} = (I - A)^{-1}\underline{y}$$

zu jedem  $\underline{y}$  die eindeutige Lösung des LGS (2) ist.

Wann ist in diesem Falle bei nichtnegativem Nachfragevektor  $\underline{y}$  auch der Lösungsvektor  $\underline{p}$  nichtnegativ?

Antwort: Sicher ist das so, wenn die Matrix  $(I - A)^{-1}$  nur nichtnegative Elemente enthält.

Mathematica liefert als Inverse von  $I - A$  in unserem Beispiel die Matrix (sie enthält nur positive Elemente!)

$$(I - A)^{-1} = \frac{1}{29} \begin{pmatrix} 96 & 90 & 52 \\ 70 & 120 & 50 \\ 66 & 80 & 72 \end{pmatrix}.$$

Also ist in unserem Beispiel erfüllt, dass die Lösungsvektoren

$$\underline{p} = (I - A)^{-1} \underline{y} \quad \text{des LGS } (I - A)\underline{p} = \underline{y}$$

nichtnegativ sind, wenn die Nachfragevektoren  $\underline{y}$  nichtnegativ sind.

Gibt es da eine allgemeine Gesetzmässigkeit? **Ja!**

**Satz:** Sei  $A$  eine  $(n, n)$ -Matrix mit nichtnegativen Elementen  $a_{ij}$ , so dass alle Zeilensummen  $s_i$  die Eigenschaft

$$s_i := \sum_{j=1}^n a_{ij} < 1 \quad (i = 1, \dots, n)$$

haben. Dann existiert  $(I - A)^{-1}$  (wobei  $I$  die  $(n, n)$ -Einheitmatrix ist), und es gilt

$$(I - A)^{-1} = I + A + A^2 + \dots + A^m + \dots$$

Folglich hat auch  $(I - A)^{-1}$  nur nichtnegative Elemente.

Wegen der Analogie zur Summenformel der geometrischen Reihe

$$1/(1 - q) = 1 + q + q^2 + \dots + q^m + \dots \quad \text{für } -1 < q < 1.$$

spricht deshalb auch von der **geometrischen Reihe für Matrizen** (auch *Neumannsche Reihe* genannt).

## Beweis:

Wir betrachten die Partialsummen  $S_m$  und das Produkt  $AS_m$

$$\begin{aligned} S_m &= I + A + A^2 + \dots + A^m \\ AS_m &= A + A^2 + \dots + A^m + A^{m+1} \end{aligned}$$

und bilden die Differenz  $S_m - AS_m$ . Als Ergebnis erhalten wir

$$(I - A)S_m = I - A^{m+1}. \quad (3)$$

Man sagt, dass eine Folge von  $(n, n)$ -Matrizen  $\{S_m = (s_{ij}^{(m)})\}$  gegen die  $(n, n)$ -Matrix  $S = (s_{ij})$  **konvergiert**, geschrieben  $S := \lim_{m \rightarrow \infty} S_m$ , wenn für jedes Indexpaar  $(i, j)$

$$\lim_{m \rightarrow \infty} s_{ij}^{(m)} = s_{ij}$$

gilt. Analog versteht man die Konvergenz der Folge  $\{A, A^2, \dots, A^m, \dots\}$ .

Da alle Zeilensummen kleiner als 1 sind, konvergiert die Folge der Matrizen

$$\{A, A^2, \dots, A^m, A^{m+1}, \dots\} \quad \text{für } m \rightarrow \infty$$

gegen die Nullmatrix.

**Machen Sie sich das in unserem Beispiel klar! (Computorexperiment oder Nachdenken!) Zusatzfrage: Was passiert, wenn nicht  $s_i < 1$  gilt?**

Damit gilt aber nach (3) und den Rechengesetzen für Limes

$$I = \lim_{m \rightarrow \infty} (I - A^{m+1}) = \lim_{m \rightarrow \infty} (I - A)S_m = (I - A)S,$$

wobei  $S := \lim_{m \rightarrow \infty} S_m$  ist (die Existenz des Limes ist gesichert \*).

Nach Definition der Inversen folgt damit, dass  $S$  die Inverse zu  $(I - A)$  und folglich gleich  $I + A + A^2 + \dots + A^m + \dots$  ist!!! q.e.d.

\*Beweis unter Ausnutzung der Konvergenz der geometrischen (Zahlen-) Reihe

## 12.2. Lineare Algebra und Differentialrechnung im $\mathbb{R}^n$

### 12.2.1. Optimierung unter linearen Restriktionen

[Ro II §7.3], [SH §14.5]\*

#### **Beispiel 12.1:** *Abstand eines Punktes von einer Geraden im Raum*

Gegeben sei eine Gerade  $G$ , definiert durch

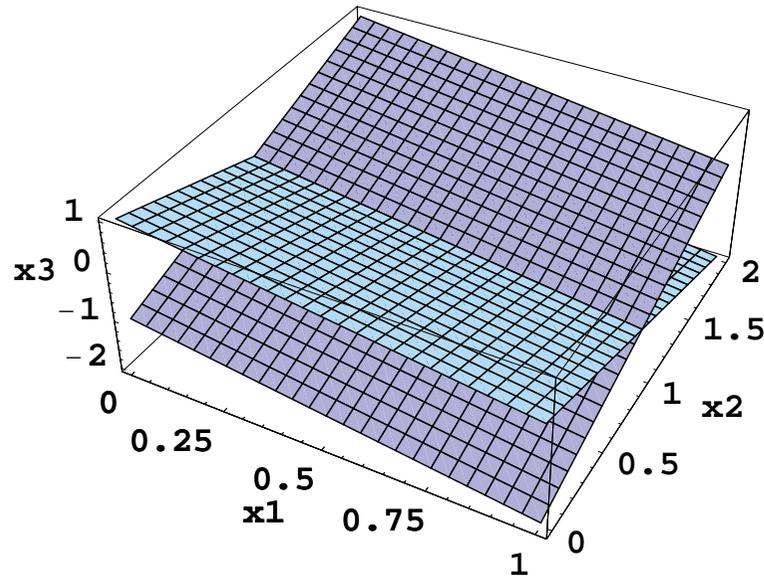
$$\begin{array}{l} x_1 + x_2 + x_3 = 1 \\ -x_1 + x_2 - x_3 = 1 \end{array} \quad \text{d.h.} \quad \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} + t \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}, \quad t \in \mathbb{R}.$$

Man bestimme denjenigen Punkt  $\underline{x}^* = (x_1^*, x_2^*, x_3^*)^T$  auf  $G$ , der den kleinsten euklidischen Abstand zum Koordinatenursprung hat, also

$$x_1^2 + x_2^2 + x_3^2 \rightarrow \min \quad \text{bezüglich } (x_1, x_2, x_3)^T \in G. \quad (*)$$

Hinweis: die euklidische Norm des Vektors  $(x_1, x_2, x_3)$  ist die Wurzel aus  $x_1^2 + x_2^2 + x_3^2$  - das liefert den gleichen Lösungspunkt.

\*Ro II = Rommelfanger, Band 2, SH = Sydsaeter/Hammond



Durch *Einsetzen der Parameterform* erhält man

$$x_1^2 + x_2^2 + x_3^2 = (0 - t)^2 + (1 + 0 \cdot t)^2 + (0 + t)^2 = 2t^2 + 1,$$

also ist die Aufgabe

$$2t^2 + 1 \rightarrow \min \quad \text{bezüglich } t \in \mathbb{R}$$

zu lösen (die eindeutige Lösung ist offenbar  $t^* = 0$ ), also ist

$$\underline{x}^* = (-t^*, 1, t^*)^\top = (0, 1, 0)^\top \text{ eindeutige Lösung von } (*).$$

Alternativ kann man die **Lagrangemethode** benutzen, man setzt

$$L(x_1, x_2, x_3, \lambda_1, \lambda_2) := x_1^2 + x_2^2 + x_3^2 - \lambda_1(x_1 + x_2 + x_3 - 1) - \lambda_2(-x_1 + x_2 - x_3 - 1)$$

und löst mit den partiellen Ableitungen  $L_{x_i}$ ,  $L_{\lambda_j}$  das Lagrangesystem

$$\begin{aligned} L_{x_i}(x_1, x_2, x_3, \lambda_1, \lambda_2) &= 0 & (i = 1, 2, 3) \\ -L_{\lambda_j}(x_1, x_2, x_3, \lambda_1, \lambda_2) &= 0 & (j = 1, 2). \end{aligned}$$

Das Lagrangesystem ist in diesem Falle ein inhomogenes LGS, nämlich

$$\begin{array}{rcccc} 2x_1 & & & -\lambda_1 & +\lambda_2 & = & 0 \\ & 2x_2 & & -\lambda_1 & -\lambda_2 & = & 0 \\ & & 2x_3 & -\lambda_1 & +\lambda_2 & = & 0 \\ x_1 & +x_2 & +x_3 & & & = & 1 \\ -x_1 & +x_2 & -x_3 & & & = & 1 \end{array}$$

Wie man leicht ausrechnet, ist die einzige Lösung dieses LGS

$$(x_1^*, x_2^*, x_3^*, \lambda_1^*, \lambda_2^*) = (0, 1, 0, 1, 1).$$

Im allgemeinen hat die Lagrangemethode den Nachteil, dass sie nur *stationäre Punkte*  $\underline{x}^*$  bestimmt, aber in unserem Beispiel liefert der geometrische Hintergrund, dass  $\underline{x}^*$  globaler Minimalpunkt ist.

**Beispiel 12.2:** Wohlfahrtsanalyse (vgl. Varian "Mikroökonomie" §13)

In einem Markt mit einem  $x$ -Gut und einem  $y$ -Gut habe man drei Konsumenten  $K_i$  ( $i = 1, 2, 3$ ) und zwei Unternehmen  $U_j$  ( $j = 1, 2$ ), die das  $x$ -Gut produzieren. Das  $y$ -Gut stehe "für alles andere", was konsumiert wird.

Jedem Konsumenten  $K_i$  ( $i = 1, 2, 3$ ) seien zugeordnet:

$x_i$	durch $K_i$ konsumierte Menge des $x$ -Gutes
$y_i$	durch $K_i$ konsumierte Menge des $y$ -Gutes
$\omega_i$	Anfangsausstattung von $K_i$ mit dem $y$ -Gut
$u_i(x_i) + y_i$	Nutzenfunktion des Konsumenten $K_i$

Jedem Unternehmen  $U_j$  ( $j = 1, 2$ ) seien zugeordnet:

$z_j$	produzierte Menge des $x$ -Gutes in $U_j$
$c_j z_j$	Kosten zur Produktion von $z_j$ in $U_j$

**Wohlfahrtsmaximierung:** Gesucht ist die *Allokation*

$$(x_1^*, x_2^*, x_3^*, y_1^*, y_2^*, y_3^*, z_1^*, z_2^*) \in \mathbb{R}^8,$$

die die Nutzensumme maximiert unter der Bedingung, dass die insgesamt produzierte und konsumierte Menge des  $x$ -Gutes gleich sind. Ferner nimmt man an, dass der Verbrauch des  $y$ -Gutes in  $U_j$  gleich den Kosten  $c_j z_j$  ist, womit die zweite Gleichung sinnvoll wird:

$$\text{Maximiere } \sum_{i=1}^3 u_i(x_i) + \sum_{i=1}^3 y_i$$

$$\text{unter den Nebenbedingungen } \begin{aligned} \sum_{i=1}^3 x_i &= \sum_{j=1}^2 z_j \\ \sum_{i=1}^3 y_i &= \sum_{i=1}^3 \omega_i - \sum_{j=1}^2 c_j z_j \end{aligned}$$

bezüglich der Variablen  $x_1, x_2, x_3, y_1, y_2, y_3, z_1, z_2$ .

Laut Modell sind  $c_j$ ,  $\omega_i$  und die Funktionen  $u_i(\cdot)$  gegeben.

Hier empfiehlt sich natürlich gleich die Substitution

$$\sum_{i=1}^3 y_i = \sum_{i=1}^3 \omega_i - \sum_{j=1}^2 c_j z_j,$$

so dass sich nur noch ein Problem in den Variablen  $x_i$  und  $z_j$  ergibt:

$$\begin{aligned} \text{Maximiere} \quad & \sum_{i=1}^3 u_i(x_i) + \sum_{i=1}^3 \omega_i - \sum_{j=1}^2 c_j z_j \\ \text{unter der Nebenbedingung} \quad & \sum_{i=1}^3 x_i = \sum_{j=1}^2 z_j. \end{aligned}$$

Beim Lösen der Optimierungsaufgabe kann man die Konstante  $\sum_{i=1}^3 \omega_i$  zunächst weglassen, das ergibt die Lagrangefunktion

$$L(x_1, x_2, x_3, z_1, z_2, \lambda) := \sum_{i=1}^3 u_i(x_i) - \sum_{j=1}^2 c_j z_j - \lambda \left( \sum_{i=1}^3 x_i - \sum_{j=1}^2 z_j \right).$$

**Übung:** Die Funktionen  $u_i(\cdot)$  seien stetig differenzierbar. Man gebe die Lagrangebedingungen an und zeige für die Lösung  $(x_1^*, x_2^*, x_3^*, z_1^*, z_2^*)$  mit zugehörigem  $\lambda^*$ , dass  $\lambda^* = u'_i(x_i^*) = c_j$  ( $\forall i, j$ ) gilt.

## Definition:

(Optimierungsprobleme unter linearen Gleichungsrestriktionen)

Gegeben sind eine nach allen Variablen stetig partiell differenzierbare Funktion

$$(x_1, x_2, \dots, x_n) \in \mathbb{R}^n \mapsto f(x_1, x_2, \dots, x_n) \in \mathbb{R}$$

sowie  $m \cdot n + m$  reelle Zahlen  $a_{ij}$  und  $b_i$  für  $i = 1, \dots, m$ ,  $j = 1, \dots, n$ .  
Wir betrachten das Optimierungsproblem (PMIN/LIN)

Minimiere  $f(x_1, x_2, \dots, x_n)$

unter den  $m$  linearen Gleichungsrestriktionen

$$\begin{array}{cccccc} a_{11}x_1 & + & a_{12}x_2 & + & \dots & + & a_{1n}x_n & = & b_1 \\ a_{21}x_1 & + & a_{22}x_2 & + & \dots & + & a_{2n}x_n & = & b_2 \\ \vdots & & \vdots & & & & \vdots & & \vdots \\ a_{m1}x_1 & + & a_{m2}x_2 & + & \dots & + & a_{mn}x_n & = & b_m \end{array}$$

Analog bezeichnen wir mit (PMAX/LIN) das entsprechende Maximierungsproblem.

Sei  $f_{x_j}(x_1, x_2, \dots, x_n)$  die partielle Ableitung von  $f$  bezüglich der Variablen  $x_j$  im Punkt  $\underline{x} = (x_1, x_2, \dots, x_n)^\top$ .

**Satz:** (Notwendige Optimalitätsbedingung nach Lagrange)

Sei  $\underline{x}^* = (x_1^*, x_2^*, \dots, x_n^*)^\top$  ein lokaler Lösungspunkt von (PMIN/LIN) oder (PMAX/LIN). Dann existiert ein Vektor  $\underline{\lambda}^* = (\lambda_1^*, \lambda_2^*, \dots, \lambda_m^*)^\top$ , so dass

$$f_{x_j}(x_1^*, x_2^*, \dots, x_n^*) - \sum_{i=1}^m \lambda_i^* a_{ij} = 0, \quad j = 1, 2, \dots, n. \quad (*)$$

$$\sum_{j=1}^n a_{ij} x_j^* = b_i, \quad i = 1, 2, \dots, m. \quad (**)$$

Das entspricht den Bedingungen

$$L_{x_j}(\underline{x}^*, \underline{\lambda}^*) = 0, \quad L_{\lambda_i}(\underline{x}^*, \underline{\lambda}^*) = 0 \quad (i = 1, \dots, m, \quad j = 1, \dots, n),$$

wobei  $L$  wieder die übliche **Lagrangefunktion**

$$L(\underline{x}, \underline{\lambda}) := f(\underline{x}) - \sum_{i=1}^m \lambda_i \left( \sum_{j=1}^n a_{ij} x_j - b_i \right)$$

ist mit  $\underline{x} = (x_1, x_2, \dots, x_n)^\top$  und  $\underline{\lambda} = (\lambda_1, \lambda_2, \dots, \lambda_m)^\top$ .

Ist  $f$  eine quadratische Funktion, so ist (\*), (\*\*) ein LGS!

(PMIN/LIN) bzw. (PMAX/LIN) in **Vektor-Matrix-Schreibweise**:

Minimiere/Maximiere  $f(\underline{x})$

unter der Restriktion  $A\underline{x} = \underline{b}$ ,

dabei werden hier und im folgenden alle Vektoren als Spaltenvektoren aufgefasst. Die Lagrangefunktion hat dann die Form

$$L(\underline{x}, \underline{\lambda}) = f(\underline{x}) - \underline{\lambda}^\top (A\underline{x} - \underline{b}).$$

Die Lagrangebedingungen lauten dann

$$\text{grad } f(\underline{x}^*) - A^\top \underline{\lambda}^* = 0, \quad A\underline{x}^* = \underline{b}.$$

### **Substitutionsmethode (am Beispiel (PMIN/LIN)):**

Die allgemeine Lösung des LGS  $A\underline{x} = \underline{b}$  lautet in Vektorschreibweise (falls die Lösungsmenge nichtleer ist):

$$\underline{x} = \underline{x}^0 + \sum_{k=1}^r t_k \underline{x}^k, \quad t_1, \dots, t_r \in \mathbb{R},$$

wobei  $\underline{x}^0$  eine spezielle Lösung des LGS  $A\underline{x} = \underline{b}$  ist und die Vektoren  $\underline{x}^1, \dots, \underline{x}^r$  eine Basis der Lösungsmenge von  $A\underline{x} = \underline{0}$  bilden.

## Satz über die Substitutionsmethode für (PMIN/LIN):

Das LGS  $A\underline{x} = \underline{b}$  sei lösbar und habe die allgemeine Lösung

$$\underline{x} = \underline{x}^0 + \sum_{k=1}^r t_k \underline{x}^k, \quad t_1, \dots, t_r \in \mathbb{R}.$$

Ist  $\underline{t} = (t_1, t_2, \dots, t_r)^\top$  und ist  $X$  die Matrix mit den Spaltenvektoren  $\underline{x}^1, \dots, \underline{x}^r$ , so schreibt sich das  $\underline{x} = \underline{x}^0 + X\underline{t}$ . Wir definieren

$$h(\underline{t}) := f(\underline{x}^0 + X\underline{t}), \quad \underline{t} \in \mathbb{R}^r,$$

und betrachten eine Optimierungsaufgabe **ohne** Restriktionen:

$$(\tilde{P}) \quad \min h(\underline{t}) \quad \text{bezüglich } \underline{t} \in \mathbb{R}^r.$$

Dann gilt:

$\underline{x}^* = \underline{x}^0 + X\underline{t}^*$  ist lokale (bzw. globale) Minimalstelle von (PMIN/LIN) genau dann, wenn

$\underline{t}^*$  lokale (bzw. globale) Minimalstelle von  $(\tilde{P})$  ist.

## 12.2.2. Semi-definite Matrizen und Optimalitätsbedingungen

### 2. Ordnung bei freien Extremalaufgaben [Ro II, §6.1, §7.2]

Wir betrachten die Optimierungsaufgabe(n) ohne Nebenbedingungen

Minimiere/Maximiere  $f(x_1, \dots, x_n)$ ,

wobei  $f$  stetige partielle Ableitungen 2. Ordnung  $f_{x_i x_j}(x_1, \dots, x_n)$  [damit auch stetige partielle Ableitungen 1. Ordnung  $f_{x_j}(x_1, \dots, x_n)$ ] bezüglich aller Variablen haben möge.

Da es keine Nebenbedingungen gibt, spricht man davon, es seien **freie Extremalaufgaben**. Wir schreiben wieder  $\underline{x} = (x_1, \dots, x_n)^T$ .

Für einen Punkt  $\underline{x}^0 \in \mathbb{R}^n$  sagt man,  $f$  habe in  $\underline{x}^0$  ein **globales Minimum** bzw.  $\underline{x}^0$  sei ein **globaler Minimalpunkt** von  $f$ , falls

$$f(\underline{x}^0) \leq f(\underline{x}) \quad \text{für alle } \underline{x} \in \mathbb{R}^n. \quad (4)$$

Ersetzt man in (4) " $\leq$ " durch " $\geq$ ", so heisst  $\underline{x}^0$  **globaler Maximalpunkt** von  $f$ , und man sagt,  $f$  habe ein **globales Maximum** in  $\underline{x}^0$ .

**Relative Extrema**: Man sagt,  $f$  habe in  $\underline{x}^0$  ein **relatives Minimum** bzw.  $\underline{x}^0$  sei ein **relativer Minimalpunkt** von  $f$ , falls ein  $\varepsilon > 0$  existiert, so dass

$$f(\underline{x}^0) \leq f(\underline{x}) \quad \text{für alle } \underline{x} \text{ mit } \|\underline{x} - \underline{x}^0\| < \varepsilon. \quad (5)$$

Ersetzt man in (5) " $\leq$ " durch " $\geq$ ", so heisst  $\underline{x}^0$  **relativer Maximalpunkt** von  $f$ , und man sagt,  $f$  habe ein **relatives Maximum** in  $\underline{x}^0$ .

Sammelname für relative Minima und Maxima: **relative Extrema**.

Ersetzt man in (5) " $\leq$ " durch " $<$ " bzw. " $>$ ", so spricht man von einem **strikten relativen Extremum**.

Wie im Falle  $n = 2$ , den wir aus der *Mathematik I* kennen, beweist man sehr einfach den folgenden Satz.

**Satz: Notwendige Bedingungen erster Ordnung** [Ro II Satz 7.2]

Falls  $f$  in  $\underline{x}^0$  ein relatives Extremum hat, so gilt

$$\text{grad } f(\underline{x}^0) := (f_{x_1}(\underline{x}^0), \dots, f_{x_n}(\underline{x}^0))^T = \underline{0}, \quad (6)$$

das heisst, der Gradient  $\text{grad } f(\underline{x}^0)$  von  $f$  im Punkt  $\underline{x}^0$  ist gleich dem Nullvektor. Begriff: Ein Punkt  $\underline{x}^0$  mit (6) heisst stationärer Punkt.

Natürlich braucht man hier nur vorauszusetzen, dass  $f$  partielle Ableitungen 1. Ordnung hat, denn wenn  $f$  in  $\underline{x}^0$  ein relatives Extremum hat, dann hat auch jede Funktion

$$x_j \mapsto f(x_1^0, \dots, x_{j-1}^0, x_j, x_{j+1}^0, \dots, x_n^0)$$

in  $\underline{x}^0$  ein relatives Extremum als Funktionen in einer Variablen – dafür ist als notwendige Bedingung wohlbekannt:  $f_{x_j}(\underline{x}^0) = 0$ .

Zur Anwendung des Satzes vgl. auch Abschnitt 12.3.

## Repetition: Hinreichende Bedingungen 2. Ordnung für $n=2$

Hat  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  stetige zweite partielle Ableitungen nach  $x_1$  und  $x_2$  und ist  $\underline{x}^0$  ein stationärer Punkt von  $f$ , dann gelten mit der

$$\text{Hesse-Matrix } H(\underline{x}^0) = (f_{x_i x_j}(\underline{x}^0)); \quad 1 \leq i, j \leq 2)$$

(sie ist symmetrisch!) die folgenden Aussagen:

1. Falls  $\det H(\underline{x}^0) > 0$  und  $f_{x_1 x_1}(\underline{x}^0) > 0$ , so hat  $f$  in  $\underline{x}^0$  ein striktes relatives Minimum.
2. Falls  $\det H(\underline{x}^0) > 0$  und  $f_{x_1 x_1}(\underline{x}^0) < 0$ , so hat  $f$  in  $\underline{x}^0$  ein striktes relatives Maximum.
3. Falls  $\det H(\underline{x}^0) < 0$ , so besitzt  $f$  in  $\underline{x}^0$  kein relatives Extremum ( $\underline{x}^0$  heisst dann Sattelpunkt von  $f$ ).
4. Falls  $\det H(\underline{x}^0) = 0$  gilt, kann noch keine Aussage über das Vorliegen eines relativen Extremums gemacht werden.

Beim Beweis der Aussagen 1 und 2 in der Vorlesung *Mathematik I* hatten wir davon Gebrauch gemacht, dass folgende Äquivalenzen gelten

$$( \det H(\underline{x}^0) > 0 \text{ und } f_{x_1x_1}(\underline{x}^0) > 0 )$$

$$\Leftrightarrow \underline{v}^T H(\underline{x}^0) \underline{v} > 0 \quad \forall \underline{v} \neq \underline{0}$$

$$( \det H(\underline{x}^0) > 0 \text{ und } f_{x_1x_1}(\underline{x}^0) < 0 )$$

$$\Leftrightarrow \underline{v}^T H(\underline{x}^0) \underline{v} < 0 \quad \forall \underline{v} \neq \underline{0}.$$

(7)

## Verallgemeinerung

Sie wird mit Beweis im Fach Mathematik III - Analysis für Ökonomen behandelt. Einen kurzen Beweis der folgenden Aussage 1' – und damit auch 2' – findet man z.B. auch im Lehrbuch F. Jarre, J. Stoer, *Optimierung*, Springer 2004, Satz 6.0.3.

Hat  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetige zweite partielle Ableitungen nach allen  $n$  Variablen, so bezeichnen wir wieder für  $\underline{x}^0 = (x_1^0, \dots, x_n^0)^\top$  den Gradienten von  $f$  in  $\underline{x}^0$  mit  $\text{grad } f(\underline{x}^0)$  und die Hesse-Matrix (sie ist wieder symmetrisch!) von  $f$  in  $\underline{x}^0$  mit

$$H(\underline{x}^0) := (f_{x_i x_j}(\underline{x}^0); 1 \leq i, j \leq n).$$

Die Aussagen 1, 2 oben gelten dann in der äquivalenten Form (7), Aussage 3 gilt in einer modifizierten Form:

**Satz.** [Ro II Satz 7.6]

Sei wieder  $\underline{x}^0$  stationärer Punkt von  $f$ , d.h.,  $\text{grad } f(\underline{x}^0) = \underline{o}$ .

- 1' Falls  $\underline{v}^\top H(\underline{x}^0)\underline{v} > 0 \quad \forall \underline{v} \neq \underline{o}$ , so hat  $f$  in  $\underline{x}^0$  ein striktes relatives Minimum.
- 2' Falls  $\underline{v}^\top H(\underline{x}^0)\underline{v} < 0 \quad \forall \underline{v} \neq \underline{o}$ , so hat  $f$  in  $\underline{x}^0$  ein striktes relatives Maximum.
- 3' Falls sowohl  $\underline{u}^\top H(\underline{x}^0)\underline{u} > 0$  für mindestens ein  $\underline{u} \neq \underline{o}$  als auch  $\underline{v}^\top H(\underline{x}^0)\underline{v} < 0$  für mindestens ein  $\underline{v} \neq \underline{o}$  gilt, so besitzt  $f$  in  $\underline{x}^0$  kein relatives Extremum (d.h.,  $\underline{x}^0$  ist ein Sattelpunkt).
- 4' Falls nur  $\underline{v}^\top H(\underline{x}^0)\underline{v} \geq 0 \quad \forall \underline{v}$  bzw.  $\underline{v}^\top H(\underline{x}^0)\underline{v} \leq 0 \quad \forall \underline{v}$  gilt, kann noch keine Aussage über das Vorliegen eines relativen Extremums gemacht werden.

Man spricht bei den Kriterien in den Aussagen 1 und 2 (bzw. 1' und 2') von positiver bzw. negativer Definitheit,

bei Aussage 3 (bzw. 3') von Indefinitheit

der symmetrischen Matrix  $H(\underline{x}^0)$  bzw. der betreffenden quadratischen Form  $\underline{v} \mapsto \underline{v}^T H(\underline{x}^0) \underline{v}$ .

Gelten die Bedingungen in 4', so heisst die Matrix  $H(\underline{x}^0)$  positiv bzw. negativ *semi*-definit.

Diese Begriffe werden wir nun in der Sprache der linearen Algebra für beliebige symmetrische  $n$ -reihige Matrizen formulieren.

**Definition.** Eine  $n$ -reihige symmetrische Matrix  $A$  heisst

**positiv definit**, wenn  $\underline{v}^T A \underline{v} > 0$  für alle  $\underline{v} \in \mathbb{R}^n \setminus \{0\}$  gilt;

**positiv semidefinit**, wenn  $\underline{v}^T A \underline{v} \geq 0$  für alle  $\underline{v} \in \mathbb{R}^n$  gilt;

**negativ definit**, wenn  $\underline{v}^T A \underline{v} < 0$  für alle  $\underline{v} \in \mathbb{R}^n \setminus \{0\}$  gilt;

**negativ semidefinit**, wenn  $\underline{v}^T A \underline{v} \leq 0$  für alle  $\underline{v} \in \mathbb{R}^n$  gilt;

**indefinit**, wenn keine dieser vier Eigenschaften gilt.

**Übung:** Man bestimme die symmetrische Matrix  $A$  im Falle  $n = 2$ , falls  $\underline{v}^T A \underline{v} > 0$  mit  $\underline{v} = (v_1, v_2)^T$  z.B. die folgende Gestalt hat:

- |                      |                                 |                              |
|----------------------|---------------------------------|------------------------------|
| (a) $v_1^2 + v_2^2$  | (b) $4v_1^2 - 4v_1v_2 + 2v_2^2$ | (positiv definit)            |
| (c) $-v_1^2 - v_2^2$ | (d) $-v_1^2 - 2v_1v_2 - 2v_2^2$ | (negativ definit)            |
| (e) $(v_1 - 2v_2)^2$ | (f) $-v_1^2 + 2v_1v_2 - v_2^2$  | (pos. bzw. neg. semidefinit) |

Diskussion der Begriffe an einem Beispiel mit ökonomischem Bezug.\*

**Beispiel.** Eine Unternehmung XYZ produziere 3 Güter mit den Outputmengen  $x_1, x_2, x_3$  (in Mengeneinheiten ME1, ME2, ME3) nach der Gesamtkostenfunktion

$$K(x_1, x_2, x_3) = x_1^2 + 2x_2^2 + 3x_3^2 + x_1x_2 + x_2x_3 + 100.$$

Die Marktpreise der Güter seien exogen vorgegeben mit

$$p_1 = 40 \text{ CHF/ME1}, \quad p_2 = 50 \text{ CHF/ME2}, \quad p_3 = 80 \text{ CHF/ME3}.$$

Bei welchem Outputvektor  $(x_1, x_2, x_3)$  operiert XYZ gewinnmaximal?

\*J. Tietze, *Einf. in die angewandte Wirtschaftsmathematik*, Vieweg, 1995, S. 7-47.

Lösung: Gegeben ist

$$K(x_1, x_2, x_3) = x_1^2 + 2x_2^2 + 3x_3^2 + x_1x_2 + x_2x_3 + 100.$$

Die Gewinnfunktion lautet

$$G(x_1, x_2, x_3) = 40x_1 + 50x_2 + 80x_3 - K(x_1, x_2, x_3).$$

Die notwendigen Optimalitätsbedingungen 1. Ordnung lauten

$$\begin{aligned} G_{x_1} &= -2x_1 - x_2 + 40 = 0 \\ G_{x_2} &= -x_1 - 4x_2 - x_3 + 50 = 0 \\ G_{x_3} &= -x_2 - 6x_3 + 80 = 0 \end{aligned}$$

Das ist ein LGS mit der eindeutigen Lösung (Nachrechnen!)

$$\underline{x}^0 := (x_1^0, x_2^0, x_3^0) = (17.5, 5, 12.5).$$

Handelt es sich wirklich um ein relatives Maximum? Ist es sogar ein globales Maximum?

Die Hesse-Matrix  $H(\underline{x})$  der Funktion  $G$  lautet

$$A := H(\underline{x}^0) = \begin{pmatrix} -2 & -1 & 0 \\ -1 & -4 & -1 \\ 0 & -1 & -6 \end{pmatrix}.$$

Sie ist nicht vom Punkt  $\underline{x}^0$  abhängig. Mit  $\underline{v} := (v_1, v_2, v_3)^T$  rechnet man leicht aus

$$\begin{aligned} \underline{v}^T A \underline{v} &= -2v_1^2 - 4v_2^2 - 6v_3^2 - 2v_1v_2 - 2v_2v_3 \\ &= -v_1^2 - 2v_2^2 - 5v_3^2 - (v_1 + v_2)^2 - (v_2 + v_3)^2 \\ &< 0 \quad (\text{falls } \underline{v} \neq \underline{0}). \end{aligned}$$

Damit ist die Matrix  $A$  negativ definit und folglich  $\underline{x}^0$  ein (strikt) relativer Maximalpunkt.

Es handelt sich sogar um ein globales Maximum. Man wende das folgende Theorem an (vgl. Mathematik III): Ist die Hesse-Matrix  $H(\underline{x})$  einer Funktion  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  negativ semidefinit für alle  $\underline{x}$ , so ist  $f$  konkav und somit jedes relative Maximum auch globales Maximum.

## Ein praktisches Kriterium für positive bzw. negative Definitheit: Hauptabschnittsdeterminanten

Entsteht  $A^{[k]}$  aus einer  $n$ -reihigen symmetrischen Matrix  $A = (a_{ij})$  durch Streichen sowohl der letzten  $k$  Zeilen als auch der letzten  $k$  Spalten von  $A$ , dann heisst

$\det A^{[k]}$  eine Hauptabschnittsdeterminante von  $A$ .

Alle Teilmatrizen  $A^{[k]}$  sind wieder symmetrisch. Insbesondere gilt also

$$\det A = \det A^{[0]} \quad \text{und} \quad a_{11} = \det A^{[n-1]}.$$

Zum Beispiel sind für eine  $(3 \times 3)$ -Matrix  $A = (a_{ij})$  die Zahlen

$$a_{11}, \quad \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix}, \quad \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix}$$

die Hauptabschnittsdeterminanten von  $A$ .

In der Repetition waren die hinreichenden Optimalitätskriterien für Aufgaben mit 2 Variablen mit Hauptabschnittsdeterminanten formuliert.

**Satz.** Sei  $A$  eine  $n$ -reihige symmetrische Matrix. Dann ist

$A$  positiv definit genau dann, wenn  
alle Hauptabschnittsdeterminanten von  $A$  positiv sind;

$A$  negativ definit genau dann, wenn  
die Hauptabschnittsdeterminanten  $\det A^{[k]}$  von  $A$   
positiv im Falle gerader Ordnung von  $A^{[k]}$ ,  
aber negativ im Falle ungerader Ordnung von  $A^{[k]}$  sind.

Zum Beispiel ist eine symmetrische  $(3 \times 3)$ -Matrix  $A = (a_{ij})$  negativ definit, falls

$$a_{11} < 0, \quad \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0, \quad \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix} < 0$$

gilt. Eine symmetrische  $(2 \times 2)$ -Matrix  $A = (a_{ij})$  ist negativ definit, falls

$$a_{11} < 0, \quad \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0.$$

## Anwendung der Hauptabschnittsdeterminanten auf das Beispiel

Wir betrachten die Determinante der Matrix  $A = H(\underline{x}^0)$  des Beispiels:

$$\det A = \begin{vmatrix} -2 & -1 & 0 \\ -1 & -4 & -1 \\ 0 & -1 & -6 \end{vmatrix}.$$

Dann gilt  $\det A^{[2]} = -2 < 0$ ,

$$\det A^{[1]} = \begin{vmatrix} -2 & -1 \\ -1 & -4 \end{vmatrix} = 8 - 1 = 7 > 0,$$

$$\begin{aligned} \det A^{[0]} = \det A &= \begin{vmatrix} -2 & -1 & 0 \\ -1 & -4 & -1 \\ 0 & -1 & -6 \end{vmatrix} \\ &= \begin{vmatrix} 0 & 7 & 2 \\ -1 & -4 & -1 \\ 0 & -1 & -6 \end{vmatrix} = -(-1) \begin{vmatrix} 7 & 2 \\ -1 & -6 \end{vmatrix} = -40 < 0. \end{aligned}$$

Damit ist  $A$  negativ definit – wie bereits oben überprüft.

## Notwendiges Optimalitätskriterium 2. Ordnung

In der Ökonomie (vgl. z.B. Varian, *Mikroökonomie*) wird auch oft das folgende notwendige Optimalitätskriterium benutzt:

Habe  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetige zweite partielle Ableitungen nach allen Variablen. Dann gelten folgende Kriterien:

1. Hat  $f$  in  $\underline{x}^0$  ein relatives Minimum, so ist

$$\text{grad } f(\underline{x}^0) = \underline{0} \text{ und } H(\underline{x}^0) \text{ ist positiv semidefinit.}$$

2. Hat  $f$  in  $\underline{x}^0$  ein relatives Maximum, so ist

$$\text{grad } f(\underline{x}^0) = \underline{0} \text{ und } H(\underline{x}^0) \text{ ist negativ semidefinit.}$$

Wieder ist also die Semidefinitheit wichtig. Zum Beweis vgl. z.B. F. Jarre, J. Stoer, *Optimierung*, Springer 2004, Satz 6.0.2.

Man mache sich die Kriterien z.B. an folgenden Funktionen klar:  
 $f(x, y, z) = (x + y + z)^2$  und  $g(x, y, z) = -(x - 2y + 3z)^2$ .

### 12.2.3 Hinreichende Bedingungen 2. Ordnung der Optimierung unter einer Gleichungsnebenbedingung (optional)

[Ro II §7.4], [SH §14.4]

Wir betrachten die Optimierungsaufgabe

(P) Minimiere  $f(x_1, x_2)$  bezüglich  $g(x_1, x_2) = 0$ ,  
wobei  $f$  und  $g$  zweimal stetig differenzierbar auf  $\mathbb{R}^2$  sind.

*Lagrangefunktion der Aufgabe (P):*

$$L(x_1, x_2, \lambda) := f(x_1, x_2) - \lambda g(x_1, x_2)$$

*Hessematrix* von  $L$  bezüglich  $(x_1, x_2)$  im Punkt  $(x_1^0, x_2^0, \lambda)$ ,  $\lambda$  fest:

$$H := \begin{pmatrix} f_{x_1x_1}(x_1^0, x_2^0) - \lambda g_{x_1x_1}(x_1^0, x_2^0) & f_{x_1x_2}(x_1^0, x_2^0) - \lambda g_{x_1x_2}(x_1^0, x_2^0) \\ f_{x_1x_2}(x_1^0, x_2^0) - \lambda g_{x_1x_2}(x_1^0, x_2^0) & f_{x_2x_2}(x_1^0, x_2^0) - \lambda g_{x_2x_2}(x_1^0, x_2^0) \end{pmatrix}$$

Der Nullpunkt im  $\mathbb{R}^2$  sei mit  $\underline{o}$  bezeichnet.

**Satz:** Hinreichende Bedingung 2. Ordnung für lokales Minimum

Seien in  $(x_1^0, x_2^0, \lambda)$  die Lagrange-Bedingungen der Aufgabe (P) erfüllt und bezeichne  $\text{grad } g(x_1^0, x_2^0)$  wieder den Gradienten von  $g$  in  $(x_1^0, x_2^0)$ .

Falls  $\underline{y}^T H \underline{y} > 0$  für alle  $\underline{y} = (y_1, y_2)^T \neq \underline{0}$  mit

$$\text{grad } g(x_1^0, x_2^0)^T \underline{y} = 0 \quad (8)$$

gilt, so ist  $(x_1^0, x_2^0)$  strikter lokaler Minimalpunkt von (P), d.h., es gilt

$$f(x_1, x_2) > f(x_1^0, x_2^0)$$

für alle Punkte  $(x_1, x_2)$  "nahe"  $(x_1^0, x_2^0)$ , die  $g(x_1, x_2) = 0$  erfüllen.

Im Falle strikter lokaler Maxima dreht sich das Zeichen  $>$  jeweils um.

## Definitheit unter linearen Nebenbedingungen:

Die hinreichende Bedingung für lokale Minima ist von der Form

$$\underline{y}^T H \underline{y} > 0 \quad \forall \underline{y} \neq \underline{0} : \underline{c}^T \underline{y} = 0$$

mit einem Vektor  $\underline{c}^T = (c_1, c_2)$  und symmetrischer  $(2, 2)$ -Matrix  $H$ , denn  $H$  ist Hesse-Matrix mit stetigen zweiten partiellen Ableitungen.

Die hinreichende Bedingung für lokale Maxima ist von der Form

$$\underline{y}^T H \underline{y} < 0 \quad \forall \underline{y} \neq \underline{0} : \underline{c}^T \underline{y} = 0$$

Man sagt im ersten Falle, dass die Matrix  $H$  *positiv definit* - im zweiten Falle *negativ definit* - *auf der Geraden  $\{\underline{y} \in \mathbb{R}^2 \mid \underline{c}^T \underline{y} = 0\}$*  ist.

**Beispiel:** Man betrachte die Aufgabe

$$\begin{aligned} \min \quad & f(x_1, x_2) := \frac{1}{2}(x_1^2 - x_2^2) - x_1 \\ \text{bezüglich} \quad & g(x_1, x_2) := -x_1 + 2x_2 = 0 \end{aligned} \quad (9)$$

**Lösung durch Substitution:** Es gilt  $x_1 = 2x_2$ , eingesetzt in die Zielfunktion ergibt sich

$$\varphi(x_2) := f(2x_2, x_2) = \frac{1}{2}(4x_2^2 - x_2^2) - 2x_2 = \frac{3}{2}x_2^2 - 2x_2.$$

Folglich

$$\varphi'(x_2) = 3x_2 - 2 = 0 \Leftrightarrow x_2 = \frac{2}{3}, \quad \text{somit } x_1 = \frac{4}{3}.$$

Die hinreichende Bedingung 2. Ordnung für freie Extrema lautet

$$\varphi''\left(\frac{2}{3}\right) = 3 > 0,$$

d.h.,  $\underline{x}^0 = \left(\frac{4}{3}, \frac{2}{3}\right)$  ist strikter lokaler Minimalpunkt.

Die Lagrange-Funktion ist im Beispiel gleich

$$L(x_1, x_2, \lambda) = \frac{1}{2}(x_1^2 - x_2^2) - x_1 - \lambda(-x_1 + 2x_2)$$

Die Lagrange-Bedingungen lauten

$$\begin{aligned} (i) \quad x_1 \quad \quad \quad + \lambda &= 1 \\ (ii) \quad \quad \quad -x_2 - 2\lambda &= 0 \\ (iii) \quad -x_1 + 2x_2 &= 0 \end{aligned}$$

Die Lösung des Systems der Lagrange-Bedingungen ist

$$x_1^0 = \frac{4}{3}, \quad x_2^0 = \frac{2}{3}, \quad \lambda = -\frac{1}{3}.$$

Die Bedingung (8) ist hier sehr einfach:

$$-y_1 + 2y_2 = 0, \quad \text{d.h. } y_2 = \frac{1}{2}y_1, \quad (10)$$

da  $\text{grad } g(x_1, x_2) = (-1, 2)^\top$  für alle  $(x_1, x_2)$ .

Die Hesse-Matrix von  $L$  bezüglich  $(x_1, x_2)$  in  $(x_1^0, x_2^0, \lambda)$  lautet hier

$$H = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \quad (\text{Hesse-Matrix}).$$

Sei nun  $\underline{y} = (y_1, y_2)^\top \neq \underline{0}$  ein beliebiger Vektor mit (10). Dann gilt

$$\underline{y}^\top H \underline{y} = (y_1, y_2) \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = y_1^2 - y_2^2$$

und nach Einsetzen von (10)

$$\underline{y}^\top H \underline{y} = y_1^2 - y_2^2 = y_1^2 - \frac{1}{4}y_1^2 = \frac{3}{4}y_1^2 > 0 \quad \forall \underline{y} \neq \underline{0} \quad \text{mit } y_2 = \frac{1}{2}y_1.$$

Folglich ist  $\underline{x}^0 = (\frac{4}{3}, \frac{2}{3})$  strikter lokaler Minimalpunkt.

## Spezialfall eines Kriteriums von Debreu

In der ökon. Literatur sind von Gerard Debreu (1983 Nobelpreis für Ökonomie) bewiesene Kriterien zum Checken der positiven/negativen Definitheit einer symmetrischen Matrix  $H$  unter linearen Nebenbedingungen

$$By = \underline{o}$$

( $B$  muss dabei eine Matrix passender Ordnung sein) sehr beliebt, die mit Determinanten/Unterdeterminanten einer "geränderten" Matrix

$$\begin{pmatrix} O & B \\ B^T & H \end{pmatrix}$$

arbeiten, vgl. am besten die Originalarbeit *G. Debreu, Definite and semidefinite quadratic forms, Econometrica 20 (1952) 295-300.*

Wir betrachten hier nur den Spezialfall für die Aufgabe (P).

Sei  $(x_1^0, x_2^0, \lambda)$  ein Punkt, der den Lagrange-Bedingungen von (P) genügt, und sei  $\text{grad } g(x_1^0, x_2^0) \neq \underline{0}$ .

Sei wieder  $H$  die Hesse-Matrix der Lagrange-Funktion  $L$  bezüglich  $(x_1, x_2)$  in  $(x_1^0, x_2^0, \lambda)$ :

$$H = \begin{pmatrix} h_{11} & h_{12} \\ h_{12} & h_{22} \end{pmatrix}$$

( $H$  symmetrisch!) und

$$\underline{c} = \text{grad } g(x_1^0, x_2^0).$$

## Satz.

Unter den gestellten Voraussetzungen gelten folgende Kriterien:

1. Die Bedingung

$$\det \begin{pmatrix} 0 & \underline{c}^T \\ \underline{c} & H \end{pmatrix} < 0$$

ist notwendig und hinreichend dafür, dass  $\underline{y}^T H \underline{y} > 0$  für alle  $\underline{y} \neq \underline{0}$  mit  $\underline{c}^T \underline{y} = 0$  gilt. Also ist unter dieser Bedingung  $(x_1^0, x_2^0)$  strikter lokaler Minimalpunkt von (P).

2. Die Bedingung

$$\det \begin{pmatrix} 0 & \underline{c}^T \\ \underline{c} & H \end{pmatrix} > 0,$$

ist notwendig und hinreichend dafür, dass  $\underline{y}^T H \underline{y} < 0$  für alle  $\underline{y} \neq \underline{0}$  mit  $\underline{c}^T \underline{y} = 0$  gilt. Also ist unter dieser Bedingung  $(x_1^0, x_2^0)$  strikter lokaler Maximalpunkt von (P).

## Beweisidee (Notwendigkeit).

Sei  $\underline{y} = (y_1, y_2)^\top$  ein Vektor mit

$$\underline{y} \neq \underline{0}, \quad \underline{c}^\top \underline{y} = 0 \quad \text{und} \quad \underline{y}^\top H \underline{y} > 0. \quad (11)$$

Nach Voraussetzung ist  $\underline{c} \neq \underline{0}$ , sei zum Beispiel  $c_1 \neq 0$ . Da  $\underline{c}^\top \underline{y} = 0$  und  $(y_1, y_2)^\top \neq \underline{0}$  gilt, darf dann  $y_2$  nicht Null sein, also folgt  $y_2 \neq 0$ .

Seien

$$\hat{H} := \begin{pmatrix} 0 & c_1 & c_2 \\ c_1 & h_{11} & h_{12} \\ c_2 & h_{12} & h_{22} \end{pmatrix} \quad \text{und} \quad Q := \begin{pmatrix} 0 & 1 & 0 \\ y_1 & 0 & 1 \\ y_2 & 0 & 0 \end{pmatrix}, \quad \text{d.h.,} \quad \det Q = y_2.$$

Unter Beachtung der Determinantengesetze folgt dann

$$\det(Q^\top \hat{H} Q) = (\det Q)^2 \det \hat{H} = y_2^2 \det \hat{H}. \quad (12)$$

Durch Ausmultiplizieren folgt unter Beachtung von  $\underline{c}^\top \underline{y} = 0$   
(Übungsaufgabe: Ausrechnen!)

$$Q^\top \hat{H} Q = \begin{pmatrix} \underline{y}^\top H \underline{y} & 0 & h_{11}y_1 + h_{12}y_2 \\ 0 & 0 & c_1 \\ h_{11}y_1 + h_{12}y_2 & c_1 & h_{11} \end{pmatrix},$$

also mit (12) und nach Ausrechnen von  $\det(Q^\top \hat{H} Q)$ :

$$y_2^2 \det \hat{H} = \det(Q^\top \hat{H} Q) = -c_1^2 \underline{y}^\top H \underline{y},$$

Es folgt wegen  $c_1^2 > 0$  und  $y_2^2 > 0$  sowie  $\underline{y}^\top H \underline{y} > 0$  sofort

$$\det \hat{H} < 0, \quad \text{was zu zeigen war.}$$

## Anwendung auf Beispiel (9)

Man muss  $\underline{c}$  als den Gradienten  $\text{grad } g(x_1^0, x_2^0) = (-1, 2)^\top$  nehmen und die oben ausgerechnete Hesse-Matrix einsetzen:

$$\det \begin{pmatrix} 0 & c^\top \\ c & H \end{pmatrix} = \begin{vmatrix} 0 & -1 & 2 \\ -1 & 1 & 0 \\ 2 & 0 & -1 \end{vmatrix} = -3 < 0,$$

also ist auch nach diesem Kriterium bestätigt, dass  $\underline{x}^0$  strikter lokaler Minimalpunkt ist.

## 12.3 (optional) Matrizenrechnung und Regressionsanalyse

Literatur: Schira *Statistische Methoden der VWL und BWL*, Pearson 2003.

Das folgende *lineare* Modell widerspiegele eine ökonomische Hypothese für die Beziehung zwischen zwei Variablen  $X$  und  $Y$ :

$$Y = \beta_0 + \beta_1 X.$$

Die *Parameter*  $\beta_0$  und  $\beta_1$  sind auf der Grundlage von Beobachtungen zu "bestimmen".

Beispiel (Konsumhypothese von Keynes). Der gesamtwirtschaftliche Konsum  $C$  sei eine Funktion des verfügbaren Einkommens  $Y^{verf}$ :

$$C = \beta_0 + \beta_1 Y^{verf}.$$

Dabei wird  $\beta_1 \in (0, 1)$  als *marginale Konsumneigung*,  $\beta_0 > 0$  als *autonomer Konsum* (einkommensunabhängiger Konsum) interpretiert.

Im allgemeinen Modell oben sind dann  $Y := C$  und  $X := Y^{verf}$ .

Der ökonometrische Modellansatz berücksichtigt weitere Einflüsse auf  $Y$  im ökonomischen Modell  $Y = \beta_0 + \beta_1 X$  und fügt eine **Störvariable**  $U$  (eine *Zufallsvariable*) hinzu,

$$Y = \beta_0 + \beta_1 X + U.$$

Geht man zu einer Beobachtung der Werte von  $X$  und  $Y$  über, so gilt für eine *Stichprobe* aus  $n$  Werten analog

$$y_i = \beta_0 + \beta_1 x_i + u_i \quad (i = 1, \dots, n), \quad (13)$$

dabei heissen

$y_i$  **endogene** Variablen (beobachtbar),

$x_i$  **exogene** Variablen (beobachtbar),

$u_i$  **latente** Variablen (nicht beobachtbar),

$\beta_0, \beta_1$  **Modellparameter** oder **Koeffizienten**, ("wahre" Werte)

$\hat{\beta}_0, \hat{\beta}_1$  **Schätzparameter** oder **Schätzer** (geschätzte Werte).

Die wahren Werte der Parameter  $\beta_0$  und  $\beta_1$  sind unbekannt, sie können nur **geschätzt** werden - das ist die Aufgabe der **Regressionsanalyse**.

Die Wahrscheinlichkeitsverteilungen der latenten Variablen sind unbekannt (oft wird aber Normalverteilung vorausgesetzt), aber man unterstellt für Erwartungswert  $E$ , Varianz  $V$  und Kovarianz  $Cov$ , dass  $E(u_i) = 0$  und  $V(u_i) = \sigma^2 = \text{const.}$  für alle  $i$  sowie  $Cov(u_i, u_k) = 0$  für alle  $i, k = 1, \dots, n, i \neq k$ .

Bei der Schätzung geht es darum, eine Schätzgerade  $y = \hat{\beta}_0 + \hat{\beta}_1 x$  zu finden, die der unbekannten Modellgeraden  $y = \beta_0 + \beta_1 x$  nahe kommt. Man vergleicht

$$\begin{aligned} y_i &= \beta_0 + \beta_1 x_i + u_i && \text{(Beobachtungswerte),} \\ \hat{y}_i &= \hat{\beta}_0 + \hat{\beta}_1 x_i && \text{(geschätzte Werte).} \end{aligned}$$

## Methode der kleinsten Quadrate

Gegeben beobachtete  $x_i, y_i, i = 1, \dots, n$ , finde  $(\hat{\beta}_0, \hat{\beta}_1)$ , so dass

$$\varphi(\hat{\beta}_0, \hat{\beta}_1) := \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2 \quad (14)$$

minimal wird.

Schreiben wir nun das System (13)

$$y_i = \beta_0 + \beta_1 x_i + u_i \quad (i = 1, \dots, n)$$

in Matrixschreibweise. Man setze - wir schreiben hier Vektoren fett -

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}, \quad \mathbf{u} = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}.$$

Dann hat (13) die völlig gleichbedeutende Darstellung

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}. \quad (15)$$

Die Zielfunktion (14) in der Methode der kleinsten Quadrate lautet dann, äquivalent umgeschrieben mit Matrizen und Vektoren,

$$\varphi(\hat{\boldsymbol{\beta}}) = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{y}^T \mathbf{y} - 2\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{y} + \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}},$$

wobei  $\hat{\boldsymbol{\beta}}$  der (gesuchte!) geschätzte  $\boldsymbol{\beta}$ -Vektor ist

Der Gradient einer gegebenen quadratischen Funktion

$$\begin{aligned} g(p, q) &= a_1 p + a_2 q + b_{11} p^2 + 2b_{12} p q + b_{22} q^2 \\ &= (p, q) \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} + (p, q) \begin{pmatrix} b_{11} & b_{12} \\ b_{12} & b_{22} \end{pmatrix} \begin{pmatrix} p \\ q \end{pmatrix} \end{aligned}$$

lautet offenbar (ausrechnen!)

$$\text{grad } g(p, q) = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} + 2 \begin{pmatrix} b_{11} & b_{12} \\ b_{12} & b_{22} \end{pmatrix} \begin{pmatrix} p \\ q \end{pmatrix}.$$

Damit gilt für den Gradienten der Kleinste-Quadrate-Funktion  $\varphi$  im Minimum  $\widehat{\beta}^*$  der Aufgabe (14)

$$\text{grad } \varphi(\widehat{\beta}^*) = -2X^T y + 2X^T X \widehat{\beta}^* = \mathbf{0}.$$

Die Matrix

$$X^T X = \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{pmatrix} \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} = \begin{pmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix}$$

(mit  $\sum = \sum_{i=1}^n$ ) ist genau dann **invertierbar**, wenn

$$\det X^T X = n \sum x_i^2 - (\sum x_i)^2 \neq 0.$$

Es gilt in diesem Falle sogar  $\det X^T X > 0$ , wie man leicht ausrechnet, also ist dann wegen  $n > 0$  die Matrix  $X^T X$  positiv definit und somit  **$\varphi$  (strikt) konvex**, d.h., der Punkt  $\widehat{\beta}^*$  aus

$$\mathbf{0} = -2X^T \mathbf{y} + 2X^T X \widehat{\beta}^* \Leftrightarrow \widehat{\beta}^* = (X^T X)^{-1} X^T \mathbf{y} \quad (16)$$

**definiert den eindeutig bestimmten Minimalpunkt der Aufgabe (14).**

Die Komponenten  $\hat{\beta}_0^*$  und  $\hat{\beta}_1^*$  von  $\hat{\beta}^*$  kann man als Lösung des LGS  $X^T X \beta = X^T y$  mit der **Cramerschen Regel** leicht ausrechnen:

$$X^T y = \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}$$

ergibt

$$\hat{\beta}_0^* = \frac{\begin{vmatrix} \sum y_i & \sum x_i \\ \sum x_i y_i & \sum x_i^2 \end{vmatrix}}{\det X^T X} = \frac{(\sum y_i)(\sum x_i^2) - (\sum x_i)(\sum x_i y_i)}{n \sum x_i^2 - (\sum x_i)^2}$$

$$\hat{\beta}_1^* = \frac{\begin{vmatrix} n & \sum y_i \\ \sum x_i & \sum x_i y_i \end{vmatrix}}{\det X^T X} = \frac{n(\sum x_i y_i) - (\sum x_i)(\sum y_i)}{n \sum x_i^2 - (\sum x_i)^2}$$

Mit den in der Statistik üblichen Bezeichnungen für Mittelwerte

$$\bar{x} = \frac{1}{n} \sum x_i, \quad \bar{y} = \frac{1}{n} \sum y_i, \quad \bar{x^2} = \frac{1}{n} \sum x_i^2, \quad \bar{xy} = \frac{1}{n} \sum x_i y_i$$

folgen sofort die in Lehrbüchern oft angegebenen Formeln

$$\hat{\beta}_0^* = \frac{\bar{y} \bar{x^2} - \bar{x} \bar{xy}}{\bar{x^2} \bar{x^2}}, \quad \hat{\beta}_1^* = \frac{\bar{xy} - \bar{x} \bar{y}}{\bar{x^2} \bar{x^2}}.$$

## Multiple lineare Regressionsanalyse

Lineare ökonomische Modelle mit zwei Variablen sind häufig zu einschränkend, deshalb spezifiziert man oft Modelle mit zwei oder mehr exogenen Variablen, d.h.,

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + U.$$

wobei  $U$  wieder als Störvariable (Zufallsvariable) angesehen wird.

Beispiel (Erweiterte Konsumhypothese). Der gesamtwirtschaftliche Konsum  $C$  wird als Funktion des verfügbaren Einkommens  $Y^{verf}$  und des Vermögens  $W$  angesehen und wir spezifizieren deshalb

$$C = \beta_0 + \beta_1 Y^{verf} + \beta_2 W + U, \quad 0 < \beta_1 < 1, \beta_0, \beta_2 > 0.$$

Mit einem solchen Modell kann man argumentieren, dass die Aktienkurse einen Einfluss auf die private Konsumnachfrage ausüben.

Beobachtet man nun wieder Stichprobenvektoren  $\mathbf{x}^j$ ,  $j = 1, \dots, k$ , und  $\mathbf{y}$  aus je  $n$  Elementen, so definiert man via

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad X = \begin{pmatrix} 1 & x^1_1 & \dots & x^k_1 \\ 1 & x^1_2 & \dots & x^k_2 \\ \vdots & \vdots & & \vdots \\ 1 & x^1_n & \dots & x^k_n \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}, \quad \mathbf{u} = \begin{pmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{pmatrix}$$

das **multiple lineare Regressionsmodell** in Matrixschreibweise

$$\mathbf{y} = X\boldsymbol{\beta} + \mathbf{u}. \quad (17)$$

Zu den oben getroffenen Annahmen über die latenten Variablen  $u_i$  wird zusätzlich gefordert, dass sie unabhängig und normalverteilt seien. Ferner setzen wir voraus:

$X^\top X$  ist regulär,

offenbar ist dabei  $X^\top X$  eine  $(k + 1, k + 1)$ -Matrix.

## Methode der kleinsten Quadrate (MKQ)

Gegeben  $\mathbf{y}$  und  $X$ , finde  $\hat{\boldsymbol{\beta}} \in \mathbb{R}^{k+1}$ , so dass

$$\Phi(\hat{\boldsymbol{\beta}}) = (\mathbf{y} - X\hat{\boldsymbol{\beta}})^\top (\mathbf{y} - X\hat{\boldsymbol{\beta}})$$

minimal wird. In den Klammern stehen Vektoren der Länge  $n$ ,  $\Phi(\hat{\boldsymbol{\beta}})$  ist also für jedes  $\hat{\boldsymbol{\beta}}$  eine reelle Zahl !

Ausgerechnet, erhalten wir

$$\Phi(\hat{\boldsymbol{\beta}}) = \mathbf{y}^\top \mathbf{y} - 2\hat{\boldsymbol{\beta}}^\top X^\top \mathbf{y} + \hat{\boldsymbol{\beta}}^\top X^\top X \hat{\boldsymbol{\beta}},$$

somit hat die notwendige Optimalitätsbedingung die Form

$$\text{grad } \Phi(\hat{\boldsymbol{\beta}}) = -2X^\top \mathbf{y} + 2X^\top X \hat{\boldsymbol{\beta}} = \mathbf{0}.$$

Die Voraussetzungen sichern die (strikte) Konvexität von  $\Phi$  (Beweis in *Mathematik III*). Damit hat der eindeutige Optimalpunkt in der MKQ die gleiche Form wie bei (14), (16) - nur der Typ von  $X$  bzw. die Länge von  $\boldsymbol{\beta}$  unterscheiden sich -, nämlich

$$\hat{\boldsymbol{\beta}}^* = (X^\top X)^{-1} X^\top \mathbf{y}.$$