

Kapitel 11



Extrema

Konvexe Menge




Eine Menge $D \subseteq \mathbb{R}^n$ heißt **konvex**, wenn für zwei beliebige Punkte $x, y \in D$ auch die Verbindungsstrecke dieser Punkte in D liegt, d.h.

$$(1 - h)x + hy \in D \quad \text{für alle } h \in [0, 1], \text{ und } x, y \in D$$

konvex:




nicht konvex:



Durchschnitt konvexer Mengen

Seien S_1, \dots, S_k konvexe Teilmengen des \mathbb{R}^n , dann ist auch der Durchschnitt $S_1 \cap \dots \cap S_k$ konvex.



Die Vereinigung zweier konvexer Mengen muss nicht konvex sein.

Beispiel – Halbräume

Seien $\mathbf{p} \in \mathbb{R}^n$ und m fest, $\mathbf{p} \neq 0$. Dann beschreibt

$$H = \{\mathbf{x} \in \mathbb{R}^n : \mathbf{p}^t \cdot \mathbf{x} = m\}$$

eine **Hyperebene**, die den \mathbb{R}^n in die zwei **Halbräume**

$$H_+ = \{\mathbf{x} \in \mathbb{R}^n : \mathbf{p}^t \cdot \mathbf{x} \geq m\}$$

$$H_- = \{\mathbf{x} \in \mathbb{R}^n : \mathbf{p}^t \cdot \mathbf{x} \leq m\}$$

teilt. Die Mengen H , H_+ und H_- sind konvex.

Sei \mathbf{x} ein Gütervektor, \mathbf{p} der entsprechende Preisvektor und m das verfügbare Einkommen. Dann ist die Budgetmenge konvex:

$$\begin{aligned} & \{\mathbf{x} \in \mathbb{R}^n : \mathbf{p}^t \cdot \mathbf{x} \leq m, \mathbf{x} \geq 0\} \\ &= \{\mathbf{x} : \mathbf{p}^t \cdot \mathbf{x} \leq m\} \cap \{\mathbf{x} : x_1 \geq 0\} \cap \dots \cap \{\mathbf{x} : x_n \geq 0\} \end{aligned}$$

Konvexe und konkave Funktionen

Eine Funktion f heißt **konvex** in $D \subseteq \mathbb{R}^n$, falls D konvex ist, und



$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \leq (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2)$$

für alle $\mathbf{x}_1, \mathbf{x}_2 \in D$ und alle $h \in [0, 1]$.

Die Funktion f heißt **konkav** in $D \subseteq \mathbb{R}^n$, falls D konvex ist, und

$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \geq (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2)$$

für alle $\mathbf{x}_1, \mathbf{x}_2 \in D$ und alle $h \in [0, 1]$.



Streng konvexe und streng konkave Funktionen

Eine Funktion f heißt **streng konvex** in $D \subseteq \mathbb{R}^n$, falls D konvex ist, und

$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) < (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2)$$

für alle $\mathbf{x}_1, \mathbf{x}_2 \in D$ mit $\mathbf{x}_1 \neq \mathbf{x}_2$ und alle $h \in (0, 1)$.

Die Funktion f heißt **streng konkav** in $D \subseteq \mathbb{R}^n$, falls D konvex ist, und

$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) > (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2)$$

für alle $\mathbf{x}_1, \mathbf{x}_2 \in D$ mit $\mathbf{x}_1 \neq \mathbf{x}_2$ und alle $h \in (0, 1)$.

Beispiel – Lineare Funktion

Sei $\mathbf{a} \in \mathbb{R}^n$ konstant.

Dann ist $f(\mathbf{x}) = \mathbf{a}^t \cdot \mathbf{x}$ eine lineare Funktion und es gilt:

$$\begin{aligned} f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) &= \mathbf{a}^t \cdot ((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \\ &= (1-h)\mathbf{a}^t \cdot \mathbf{x}_1 + h\mathbf{a}^t \cdot \mathbf{x}_2 \\ &= (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2) \end{aligned}$$

D.h., f ist sowohl konkav als auch konvex.

Die lineare Funktion ist aber weder streng konkav noch streng konvex, da die Ungleichung niemals strikt ist.

Beispiel – Quadratische Funktion in einer Variable

Die Funktion $f(x) = x^2$ ist streng konvex:

$$\begin{aligned} & f((1-h)x + hy) - [(1-h)f(x) + hf(y)] \\ &= ((1-h)x + hy)^2 - [(1-h)x^2 + hy^2] \\ &= (1-h)^2x^2 + 2(1-h)hxy + h^2y^2 - (1-h)x^2 - hy^2 \\ &= -h(1-h)x^2 + 2(1-h)hxy - h(1-h)y^2 \\ &= -h(1-h)(x-y)^2 \\ &< 0 \quad \text{für } x \neq y \text{ und } 0 < h < 1 \end{aligned}$$

Also

$$f((1-h)x + hy) < (1-h)f(x) + hf(y)$$

für alle $x \neq y$ und $0 < h < 1$.

D.h. $f(x) = x^2$ ist streng konvex.

Eigenschaften

- ▶ Falls $f(x)$ (streng) konvex ist, dann ist $-f(x)$ (streng) konkav (und umgekehrt).
- ▶ Falls $f_1(x), \dots, f_k(x)$ konvex (konkav) und $\alpha_1, \dots, \alpha_k > 0$ ist, dann ist auch

$$g(x) = \alpha_1 f_1(x) + \dots + \alpha_k f_k(x)$$

konvex (konkav).

- ▶ Falls (zumindest) eine der Funktionen $f_i(x)$ streng konvex (streng konkav) ist, dann ist auch $g(x)$ streng konvex (streng konkav).


Eigenschaften

Für eine differenzierbare Funktion f gilt:

- ▶ f ist **konkav** genau dann, wenn

$$f(\mathbf{x}) - f(\mathbf{x}_0) \leq \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0)$$

d.h., der Funktionsgraph liegt immer unterhalb der Tangente.




- ▶ f ist **streng konkav** genau dann, wenn

$$f(\mathbf{x}) - f(\mathbf{x}_0) < \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0) \quad \text{für alle } \mathbf{x} \neq \mathbf{x}_0$$

- ▶ f ist **konvex** genau dann, wenn

$$f(\mathbf{x}) - f(\mathbf{x}_0) \geq \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0)$$

(Analog für streng konvexe Funktion.)



Quadratische Form

Sei \mathbf{A} eine symmetrische Matrix und $q_{\mathbf{A}}(\mathbf{x}) = \mathbf{x}^t \mathbf{A} \mathbf{x}$ die entsprechende quadratische Form.

Wir können \mathbf{A} diagonalisieren, d.h., es gibt eine Orthonormalbasis aus Eigenvektoren, sodass \mathbf{A} zur Diagonalmatrix \mathbf{D} aus Eigenwerten wird.

Wenn \mathbf{c} der Koordinatenvektor von \mathbf{x} bezüglich dieser Basis ist, dann ist

$$q_{\mathbf{A}}(\mathbf{x}) = c_1^2 \lambda_1 + c_2^2 \lambda_2 + \dots + c_n^2 \lambda_n$$

- ▶ Wenn alle Eigenwerte $\lambda_i \geq 0$ sind, dann ist $q_{\mathbf{A}}$ eine Summe von konvexen Funktionen und damit selbst konvex.
- ▶ Wenn alle $\lambda_i \leq 0$ sind, dann ist $q_{\mathbf{A}}$ konkav.
- ▶ Wenn es Eigenwerte $\lambda_i > 0$ und $\lambda_i < 0$, dann ist $q_{\mathbf{A}}$ weder konvex noch konkav.

Quadratische Form

Für eine quadratische Form $q_{\mathbf{A}}$ gilt:

- ▶ *streng konvex* \Leftrightarrow *positiv definit*
- ▶ *konvex* \Leftrightarrow *positiv semidefinit*
- ▶ *streng konkav* \Leftrightarrow *negativ definit*
- ▶ *konkav* \Leftrightarrow *negativ semidefinit*
- ▶ *weder noch* \Leftrightarrow *indefinit*

Die Definitheit von \mathbf{A} kann festgestellt werden mit Hilfe

- ▶ der Eigenwerte von \mathbf{A} , oder
- ▶ der (allgemeinen) Hauptminoren von \mathbf{A} .

Beispiel – Quadratische Form

$$\text{Sei } \mathbf{A} = \begin{pmatrix} 2 & 1 & 0 \\ 1 & 3 & -1 \\ 0 & -1 & 2 \end{pmatrix}. \quad \text{Die Hauptminoren lauten:}$$

$$H_1 = 2 > 0$$

$$H_2 = \begin{vmatrix} 2 & 1 \\ 1 & 3 \end{vmatrix} = 5 > 0$$

$$H_3 = |\mathbf{A}| = \begin{vmatrix} 2 & 1 & 0 \\ 1 & 3 & -1 \\ 0 & -1 & 2 \end{vmatrix} = 8 > 0$$

\mathbf{A} ist daher positiv definit.

Die quadratische Form $q_{\mathbf{A}}$ ist somit *streng konvex*.

Beispiel – Quadratische Form

$$\text{Sei } \mathbf{A} = \begin{pmatrix} -1 & 0 & 1 \\ 0 & -4 & 2 \\ 1 & 2 & -2 \end{pmatrix}. \quad \text{Allgemeinen Hauptminoren:}$$

$$\tilde{H}_1 = -1$$

$$\tilde{H}_2 = -4$$

$$\tilde{H}_3 = -2$$

$$\tilde{H}_{1,2} = \begin{vmatrix} -1 & 0 \\ 0 & -4 \end{vmatrix} = 4 \quad \tilde{H}_{1,3} = \begin{vmatrix} -1 & 1 \\ 1 & -2 \end{vmatrix} = 1 \quad \tilde{H}_{2,3} = \begin{vmatrix} -4 & 2 \\ 2 & -2 \end{vmatrix} = 4$$

$$\tilde{H}_{1,2,3} = \begin{vmatrix} -1 & 0 & 1 \\ 0 & -4 & 2 \\ 1 & 2 & -2 \end{vmatrix} = 0$$

$$\tilde{H}_i \leq 0$$

$$\tilde{H}_{i,j} \geq 0$$

$$\tilde{H}_{1,2,3} \leq 0$$

\mathbf{A} ist daher negativ semidefinit.

Die quadratische Form $q_{\mathbf{A}}$ ist somit *konkav* (aber nicht streng konkav).

Krümmung differenzierbarer Funktionen

Sei $f: D \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ mit Taylorreihenentwicklung

$$f(\mathbf{x}_0 + \mathbf{h}) \approx f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0) \cdot \mathbf{h} + \frac{1}{2} \mathbf{h}^t \cdot \mathbf{H}_f(\mathbf{x}_0) \cdot \mathbf{h}$$

Die Hesse-Matrix $\mathbf{H}_f(\mathbf{x}_0)$ bestimmt die *Krümmung* von f in der Nähe des Entwicklungspunkts \mathbf{x}_0 .

► $\mathbf{H}_f(\mathbf{x}_0)$ positiv definit $\Rightarrow f$ streng konvex um \mathbf{x}_0

► $\mathbf{H}_f(\mathbf{x}_0)$ negativ definit $\Rightarrow f$ streng konkav um \mathbf{x}_0

► $\mathbf{H}_f(\mathbf{x})$ positiv semidefinit für alle $\mathbf{x} \in D \Leftrightarrow f$ konvex in D

► $\mathbf{H}_f(\mathbf{x})$ negativ semidefinit für alle $\mathbf{x} \in D \Leftrightarrow f$ konkav in D

Vorgangsweise – streng konvex

1. Berechne Hesse-Matrix

$$\mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} f_{x_1x_1}(\mathbf{x}) & f_{x_1x_2}(\mathbf{x}) & \cdots & f_{x_1x_n}(\mathbf{x}) \\ f_{x_2x_1}(\mathbf{x}) & f_{x_2x_2}(\mathbf{x}) & \cdots & f_{x_2x_n}(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ f_{x_nx_1}(\mathbf{x}) & f_{x_nx_2}(\mathbf{x}) & \cdots & f_{x_nx_n}(\mathbf{x}) \end{pmatrix}$$

2. Berechne die (führenden) *Hauptminoren* H_i .
3. $\blacktriangleright f$ *streng konvex* \Leftrightarrow alle $H_k > 0$ für (fast) **alle** $\mathbf{x} \in D$
 $\blacktriangleright f$ *streng konkav* \Leftrightarrow alle $(-1)^k H_k > 0$ für (fast) **alle** $\mathbf{x} \in D$
[$(-1)^k H_k > 0$ heißt: $H_1, H_3, \dots < 0$ und $H_2, H_4, \dots > 0$]
4. Andernfalls ist f in D *weder* streng konvex *noch* streng konkav.

Vorgangsweise – konkav

1. Berechne Hesse-Matrix

$$\mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} f_{x_1x_1}(\mathbf{x}) & f_{x_1x_2}(\mathbf{x}) & \cdots & f_{x_1x_n}(\mathbf{x}) \\ f_{x_2x_1}(\mathbf{x}) & f_{x_2x_2}(\mathbf{x}) & \cdots & f_{x_2x_n}(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ f_{x_nx_1}(\mathbf{x}) & f_{x_nx_2}(\mathbf{x}) & \cdots & f_{x_nx_n}(\mathbf{x}) \end{pmatrix}$$

2. Berechne die *allgemeinen Hauptminoren* $\tilde{H}_{i_1, \dots, i_k}$.
3. $\blacktriangleright f$ *konvex* \Leftrightarrow alle $\tilde{H}_{i_1, \dots, i_k} \geq 0$ für **alle** $\mathbf{x} \in D$.
 $\blacktriangleright f$ *konkav* \Leftrightarrow alle $(-1)^k \tilde{H}_{i_1, \dots, i_k} \geq 0$ für **alle** $\mathbf{x} \in D$.
4. Andernfalls ist f in D *weder* konvex *noch* konkav.

Offensichtlich ist jede *streng* konkave (konvexe) Funktion auch konkav (bzw. konvex).

Beispiel

Ist die Funktion (streng) konkav oder konvex?

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

1. Hesse-Matrix: $\mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} 12x^2 + 2 & -2 \\ -2 & 2 \end{pmatrix}$

2. Hauptminoren:

$$H_1 = 12x^2 + 2 > 0$$

$$H_2 = |\mathbf{H}_f(\mathbf{x})| = 24x^2 > 0 \quad \text{für alle } x \neq 0.$$

3. Alle Hauptminoren > 0 für (fast) alle \mathbf{x}
 $\Rightarrow f$ ist *streng konvex*. (und damit auch konvex)

Beispiel – Cobb-Douglas Funktion

Sei $f(x, y) = x^\alpha y^\beta$ mit $\alpha, \beta \geq 0$ und $\alpha + \beta \leq 1$,
und $D = \{(x, y) : x, y \geq 0\}$.

Hesse-Matrix an der Stelle \mathbf{x} :

$$\mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} \alpha(\alpha - 1) x^{\alpha-2} y^\beta & \alpha\beta x^{\alpha-1} y^{\beta-1} \\ \alpha\beta x^{\alpha-1} y^{\beta-1} & \beta(\beta - 1) x^\alpha y^{\beta-2} \end{pmatrix}$$

Allgemeine Hauptminoren:

$$\tilde{H}_1 = \underbrace{\alpha}_{\geq 0} \underbrace{(\alpha - 1)}_{\leq 0} \underbrace{x^{\alpha-2} y^\beta}_{\geq 0} \leq 0$$

$$\tilde{H}_2 = \underbrace{\beta}_{\geq 0} \underbrace{(\beta - 1)}_{\leq 0} \underbrace{x^\alpha y^{\beta-2}}_{\geq 0} \leq 0$$

Beispiel – Cobb-Douglas Funktion

$$\begin{aligned} \tilde{H}_{1,2} &= |\mathbf{H}_f(\mathbf{x})| \\ &= \alpha(\alpha - 1) x^{\alpha-2} y^\beta \cdot \beta(\beta - 1) x^\alpha y^{\beta-2} - (\alpha\beta x^{\alpha-1} y^{\beta-1})^2 \\ &= \alpha(\alpha - 1) \beta(\beta - 1) x^{2\alpha-2} y^{2\beta-2} - \alpha^2 \beta^2 x^{2\alpha-2} y^{2\beta-2} \\ &= \alpha\beta [(\alpha - 1)(\beta - 1) - \alpha\beta] x^{2\alpha-2} y^{2\beta-2} \\ &= \underbrace{\alpha\beta}_{\geq 0} \underbrace{(1 - \alpha - \beta)}_{\geq 0} \underbrace{x^{2\alpha-2} y^{2\beta-2}}_{\geq 0} \geq 0 \end{aligned}$$

$\tilde{H}_1 \leq 0$ und $\tilde{H}_2 \leq 0$, und $\tilde{H}_{1,2} \geq 0$ für alle $(x, y) \in D$.
 $f(x, y)$ ist daher *konkav* in D .

Für $0 < \alpha, \beta < 1$ und $\alpha + \beta < 1$ gilt sogar:

$H_1 = \tilde{H}_1 < 0$ und $H_2 = |\mathbf{H}_f(\mathbf{x})| > 0$ für fast alle $(x, y) \in D$.
 $f(x, y)$ ist dann sogar *streng konkav*.


Globales Extremum (Optimum)

Ein Punkt \mathbf{x}^* heißt **globales Maximum** (*absolutes Maximum*) von f ,
falls für alle $\mathbf{x} \in D_f$ gilt:

$$f(\mathbf{x}^*) \geq f(\mathbf{x})$$

Ein Punkt \mathbf{x}^* heißt **globales Minimum** (*absolutes Minimum*) von f , falls
für alle $\mathbf{x} \in D_f$ gilt:

$$f(\mathbf{x}^*) \leq f(\mathbf{x})$$




Lokales Extremum (Optimum)

Ein Punkt x_0 heißt **lokales Maximum** (*relatives Maximum*) von f , falls für alle x in einer geeigneten Umgebung von x_0 gilt:

$$f(x_0) \geq f(x)$$

Ein Punkt x_0 heißt **lokales Minimum** (*relatives Minimum*) von f , falls für alle x in einer geeigneten Umgebung von x_0 gilt:

$$f(x_0) \leq f(x)$$



Kritischer Punkt

In einem (lokalen) Maximum oder Minimum muss jede Richtungsableitung und damit auch der Gradient gleich Null sein.

Ein Punkt x_0 heißt **kritischer Punkt** (oder *stationärer Punkt*) einer Funktion f , wenn

$$\nabla f(x_0) = 0$$

Notwendige Bedingung:

Jedes Extremum von f ist ein kritischer Punkt von f .

Globales Extremum

Hinreichende Bedingung:

Sei x_0 ein kritischer Punkt einer **konkaven** (oder *konvexen*) Funktion f . Dann ist x_0 ein **globales Maximum** (bzw. *globales Minimum*) von f .

Falls f *streng* konkav (oder konvex) ist, dann ist das Extremum eindeutig bestimmt.

Die Aussage folgt unmittelbar aus den Eigenschaften (streng) konkaver Funktionen. Für alle $x \neq x_0$ gilt

$$f(x) - f(x_0) < \nabla f(x_0) \cdot (x - x_0) = 0 \cdot (x - x_0) = 0$$

und somit

$$f(x_0) > f(x)$$

Beispiel*

Sei $f(x) = e^x - 2x$.

Die Funktion ist streng konvex:

$$f'(x) = e^x - 2$$

$$f''(x) = e^x > 0 \quad \text{für alle } x \in \mathbb{R}$$

Kritischer Punkt:

$$f'(x) = e^x - 2 = 0 \quad \Rightarrow \quad x_0 = \ln 2$$

$x_0 = \ln 2$ ist das (eindeutig bestimmte) globale Minimum von f .

Beispiel

Sei $f: D = [0, \infty)^2 \rightarrow \mathbb{R}$, $f(x, y) = 4x^{\frac{1}{4}}y^{\frac{1}{4}} - x - y$

Hesse-Matrix an der Stelle \mathbf{x} :

$$\mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} -\frac{3}{4}x^{-\frac{7}{4}}y^{\frac{1}{4}} & \frac{1}{4}x^{-\frac{3}{4}}y^{-\frac{3}{4}} \\ \frac{1}{4}x^{-\frac{3}{4}}y^{-\frac{3}{4}} & -\frac{3}{4}x^{\frac{1}{4}}y^{-\frac{7}{4}} \end{pmatrix}$$

Hauptminoren:

$$H_1 = -\frac{3}{4}x^{-\frac{7}{4}}y^{\frac{1}{4}} < 0$$

f ist streng konkav in D .

$$H_2 = \frac{1}{2}x^{-\frac{3}{2}}y^{-\frac{3}{2}} > 0$$

Kritischer Punkt: $\nabla f = (x^{-\frac{3}{4}}y^{\frac{1}{4}} - 1, x^{\frac{1}{4}}y^{-\frac{3}{4}} - 1) = 0$


$$f_x = x^{-\frac{3}{4}}y^{\frac{1}{4}} - 1 = 0$$

$$\Rightarrow \quad \mathbf{x}_0 = (1, 1)$$

$$f_y = x^{\frac{1}{4}}y^{-\frac{3}{4}} - 1 = 0$$

\mathbf{x}_0 ist das globale Maximum von f .

Beispiel – Lokale Extrema



$$f(x, y) = \frac{1}{6}x^3 - x + \frac{1}{4}xy^2$$

Lokal konkav

Ein Punkt x_0 ist ein **lokales Maximum** (oder *Minimum*) von f , falls

- ▶ x_0 ist ein **kritischer Punkt** von f ,
- ▶ f ist **konkav** (bzw. *konvex*) um x_0 .

Hinreichende Bedingung:

f ist *lokal* streng konkav (konvex) um x_0 ist.

Sei x_0 ein kritischer Punkt von f . Dann gilt

- ▶ $\mathbf{H}_f(x_0)$ *negativ definit* $\Rightarrow x_0$ ist lokales Maximum
- ▶ $\mathbf{H}_f(x_0)$ *positiv definit* $\Rightarrow x_0$ ist lokales Minimum

Es ist ausreichend die Hesse-Matrix $\mathbf{H}_f(x)$ am kritischen Punkt x_0 auszuwerten. (Im Gegensatz zur Bedingung für globale Extrema.)

Vorgangsweise – Univariate Funktion*

Hinreichende Bedingung

für lokale Extremwerte einer Funktion in *einer* Variablen:

1. Berechne $f'(x)$ und $f''(x)$.
2. Suche alle Punkte x_i mit $f'(x_i) = 0$ (kritischen Punkte).
3. Falls $f''(x_i) < 0 \Rightarrow x_i$ ist ein *lokales Maximum*.
Falls $f''(x_i) > 0 \Rightarrow x_i$ ist ein *lokales Minimum*.
Falls $f''(x_i) = 0 \Rightarrow$ *keine Aussage möglich!*

Falls $f''(x_i) = 0$ dann werden andere Methoden benötigt!

Z.B. kann man Terme höherer Ordnung der Taylorreihe mit Entwicklungspunkt x_0 betrachten.

Beispiel – Univariate Funktion*


Gesucht sind die lokalen Extrema der Funktion

$$f(x) = \frac{1}{12}x^3 - x^2 + 3x + 1$$

1. $f'(x) = \frac{1}{4}x^2 - 2x + 3,$
 $f''(x) = \frac{1}{2}x - 2.$

2. $\frac{1}{4}x^2 - 2x + 3 = 0$
besitzt die Lösungen
 $x_1 = 2$ und $x_2 = 6.$

3. $f''(2) = -1 \Rightarrow x_1$ ist lokales Maximum.
 $f''(6) = 1 \Rightarrow x_2$ ist lokales Minimum.



Beispiel – Kritische Punkte

Suche alle kritischen Punkte von

$$f(x, y) = \frac{1}{6} x^3 - x + \frac{1}{4} x y^2$$

Partiellen Ableitungen:

$$(I) \quad f_x = \frac{1}{2} x^2 - 1 + \frac{1}{4} y^2 = 0$$

$$(II) \quad f_y = \frac{1}{2} x y = 0$$

$$(II) \Rightarrow \quad x = 0 \quad \text{oder} \quad y = 0$$


$$(I) \Rightarrow \quad -1 + \frac{1}{4} y^2 = 0 \quad \left| \quad \frac{1}{2} x^2 - 1 = 0 \right. \\ \quad \quad \quad y = \pm 2 \quad x = \pm \sqrt{2}$$

Kritische Punkte:


$$x_1 = (0, 2) \quad x_3 = (\sqrt{2}, 0)$$

$$x_2 = (0, -2) \quad x_4 = (-\sqrt{2}, 0)$$

Kritische Punkte – Lokale Extrema




Lokales Maximum




Lokales Minimum

Kritische Punkte – Sattelpunkte



Sattelpunkt



Beispiel für höhere Ordnung

Vorgangsweise – Lokale Extrema

1. Berechne Gradient ∇f und Hesse-Matrix \mathbf{H}_f .
2. Bestimme alle \mathbf{x}_i mit $\nabla f(\mathbf{x}_i) = 0$ (kritische Punkte).
3. Berechne alle Hauptminoren H_k für kritischen Punkt \mathbf{x}_0 :
 - (a) Alle Hauptminoren $H_k > 0$
 $\Rightarrow \mathbf{x}_0$ ist ein **lokales Minimum** von f .
 - (b) Für alle Hauptminoren gilt $(-1)^k H_k > 0$
[d.h., $H_1, H_3, \dots < 0$ und $H_2, H_4, \dots > 0$]
 $\Rightarrow \mathbf{x}_0$ ist ein **lokales Maximum** von f .
 - (c) $\det(\mathbf{H}_f(\mathbf{x}_0)) \neq 0$, aber weder (a) noch (b) sind erfüllt
 $\Rightarrow \mathbf{x}_0$ ist ein **Sattelpunkt** von f .
 - (d) Andernfalls ist *keine Aussage* möglich,
d.h. \mathbf{x}_0 kann ein lokales Extremum sein, muss aber nicht.

Vorgangsweise – Bivariate Funktion

1. Berechne Gradient ∇f und Hesse-Matrix \mathbf{H}_f .
2. Bestimme alle \mathbf{x}_i mit $\nabla f(\mathbf{x}_i) = 0$ (kritische Punkte).
3. Berechne die Hauptminoren H_1 und H_2 für kritischen Punkt \mathbf{x}_0 :
 - (a) $H_2 > 0$ und $H_1 > 0$
 $\Rightarrow \mathbf{x}_0$ ist ein **lokales Minimum** von f .
 - (b) $H_2 > 0$ und $H_1 < 0$
 $\Rightarrow \mathbf{x}_0$ ist ein **lokales Maximum** von f .
 - (c) $H_2 < 0$
 $\Rightarrow \mathbf{x}_0$ ist ein **Sattelpunkt** von f .
 - (d) $H_2 = \det(\mathbf{H}_f(\mathbf{x}_0)) = 0$
 \Rightarrow *keine Aussage* möglich.

Beispiel – Bivariate Funktion

Suche die lokalen Extrema von

$$f(x, y) = \frac{1}{6} x^3 - x + \frac{1}{4} x y^2$$

1. $\nabla f = \left(\frac{1}{2} x^2 - 1 + \frac{1}{4} y^2, \frac{1}{2} x y \right)$

$$\mathbf{H}_f(x, y) = \begin{pmatrix} x & \frac{1}{2} y \\ \frac{1}{2} y & \frac{1}{2} x \end{pmatrix}$$

2. Kritische Punkte:

$$\mathbf{x}_1 = (0, 2), \mathbf{x}_2 = (0, -2), \mathbf{x}_3 = (\sqrt{2}, 0), \mathbf{x}_4 = (-\sqrt{2}, 0)$$

Beispiel – Bivariate Funktion (Forts.)

3. Hauptminoren:

$$\mathbf{H}_f(\mathbf{x}_1) = \mathbf{H}_f(0, 2) = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

$$H_2 = -1 < 0 \Rightarrow \mathbf{x}_1 \text{ ist ein Sattelpunkt}$$

$$\mathbf{H}_f(\mathbf{x}_2) = \mathbf{H}_f(0, -2) = \begin{pmatrix} 0 & -1 \\ -1 & 0 \end{pmatrix}$$

$$H_2 = -1 < 0 \Rightarrow \mathbf{x}_2 \text{ ist ein Sattelpunkt}$$

Beispiel – Bivariate Funktion (Forts.)

3. Hauptminoren:

$$\mathbf{H}_f(\mathbf{x}_3) = \mathbf{H}_f(\sqrt{2}, 0) = \begin{pmatrix} \sqrt{2} & 0 \\ 0 & \frac{\sqrt{2}}{2} \end{pmatrix}$$

$$H_2 = 1 > 0 \text{ und } H_1 = \sqrt{2} > 0$$

$$\Rightarrow \mathbf{x}_3 \text{ ist ein lokales Minimum}$$

$$\mathbf{H}_f(\mathbf{x}_4) = \mathbf{H}_f(-\sqrt{2}, 0) = \begin{pmatrix} -\sqrt{2} & 0 \\ 0 & -\frac{\sqrt{2}}{2} \end{pmatrix}$$

$$H_2 = 1 > 0 \text{ und } H_1 = -\sqrt{2} < 0$$

$$\Rightarrow \mathbf{x}_4 \text{ ist ein lokales Maximum}$$

Konvexe Funktion und konvexe Menge

Sei f konvex.

Dann ist die **untere Niveaumenge** von f

$$\{\mathbf{x} \in D_f : f(\mathbf{x}) \leq c\}$$

konvex.


Seien $\mathbf{x}_1, \mathbf{x}_2 \in \{\mathbf{x} \in D_f : f(\mathbf{x}) \leq c\}$, d.h. $f(\mathbf{x}_1), f(\mathbf{x}_2) \leq c$. Sei

$$\mathbf{y} = (1-h)\mathbf{x}_1 + h\mathbf{x}_2 \text{ für ein } h \in [0, 1].$$

Dann ist

$$\begin{aligned} f(\mathbf{y}) &= f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \\ &\leq (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2) \\ &\leq (1-h)c + hc = c \end{aligned}$$

Also $\mathbf{y} \in \{\mathbf{x} \in D_f : f(\mathbf{x}) \leq c\}$.




Konkave Funktion und konvexe Menge

Sei f *konkav*.


Dann ist die **obere Niveaumenge** von f

$$\{x \in D_f : f(x) \geq c\}$$

konvex.



obere Niveaumenge



untere Niveaumenge

Extremum und monotone Transformation

Sei $T: \mathbb{R} \rightarrow \mathbb{R}$ eine *streng monoton steigende* Funktion.

Falls x^* ein *Maximum* (Minimum) von f ist,
dann ist x^* auch ein Maximum (bzw. Minimum) von $T \circ f$:

Da x^* ein *Maximum* von f ist, gilt

$$f(x^*) \geq f(x) \text{ für alle } x.$$

Da T streng monoton steigend ist, gilt

$$T(x_1) > T(x_2) \text{ falls } x_1 > x_2.$$

Wir erhalten daher

$$(T \circ f)(x^*) = T(f(x^*)) > T(f(x)) = (T \circ f)(x) \text{ für alle } x,$$

i.e., x^* ist ein Maximum von $T \circ f$.


Da T injektiv ist, gilt sogar die Umkehrung:

Falls x^* ein *Maximum* (Minimum) von $T \circ f$ ist, dann auch von f .


Extremum und monotone Transformation

Die streng monotone Transformation T erhält die Extrema von f .

T erhält aber auch die Niveaumengen von f .



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



$$T(f(x, y)) = \exp(-x^2 - y^2)$$

Quasi-konvex und quasi-konkav

Eine Funktion f heißt **quasi-konvex** in $D \subseteq \mathbb{R}^n$, falls D *konvex* ist und jede *untere Niveaumenge* $\{\mathbf{x} \in D_f : f(\mathbf{x}) \leq c\}$ *konvex* ist.

Eine Funktion f heißt **quasi-konkav** in $D \subseteq \mathbb{R}^n$, falls D *konvex* ist und jede *obere Niveaumenge* $\{\mathbf{x} \in D_f : f(\mathbf{x}) \geq c\}$ *konvex* ist.

Konvex und quasi-konvex

Jede *konkave* (konvexe) Funktion ist auch *quasi-konkav* (bzw. quasi-konvex).

Eine quasi-konkave Funktion muss aber nicht konkav sein.

Sei T eine streng monoton steigende Funktion. Falls eine Funktion $f(\mathbf{x})$ *konkav* (konvex) ist, dann ist $T \circ f$ *quasi-konkav* (bzw. quasi-konvex).

Die Funktion $g(x, y) = e^{-x^2 - y^2}$ ist quasi-konkav, da $f(x, y) = -x^2 - y^2$ konkav ist, und $T(x) = e^x$ streng monoton steigend ist.

$g = T \circ f$ ist aber nicht konkav.

Konvex, quasi-konvex und Extrema

Der Begriff *quasi-konvex* ist ein **schwächerer** Begriff als *konvex*, in dem Sinne, dass jede konvexe Funktion auch quasi-konvex ist, es aber viel mehr quasi-konvexe Funktionen gibt als konvexe.

Die Bedeutung dieses Begriffs liegt darin, dass sich manche Sätze über konvexe Funktionen auf quasi-konvexe Funktionen verallgemeinern lassen.

Quasi-konvex und quasi-konkav II

- ▶ f ist *quasi-konvex* genau dann, wenn



$$f((1-h)x_1 + hx_2) \leq \max\{f(x_1), f(x_2)\}$$

für alle x_1, x_2 und $h \in [0, 1]$.

- ▶ f ist *quasi-konkav* genau dann, wenn

$$f((1-h)x_1 + hx_2) \geq \min\{f(x_1), f(x_2)\}$$

für alle x_1, x_2 und $h \in [0, 1]$.



Streng quasi-konvex und streng quasi-konkav

- ▶ Eine Funktion f heißt **streng quasi-konvex**, wenn

$$f((1-h)x_1 + hx_2) < \max\{f(x_1), f(x_2)\}$$

für alle x_1, x_2 , mit $x_1 \neq x_2$, und $h \in (0, 1)$.

- ▶ Eine Funktion f heißt **streng quasi-konkav**, wenn

$$f((1-h)x_1 + hx_2) > \min\{f(x_1), f(x_2)\}$$

für alle x_1, x_2 , mit $x_1 \neq x_2$, und $h \in (0, 1)$.

Quasi-konvex und quasi-konkav III

Für eine differenzierbare Funktion f gilt:

- ▶ f ist *quasi-konvex* genau dann, wenn

$$f(\mathbf{x}) \leq f(\mathbf{x}_0) \Rightarrow \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0) \leq 0$$

- ▶ f ist *quasi-konkav* genau dann, wenn

$$f(\mathbf{x}) \geq f(\mathbf{x}_0) \Rightarrow \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0) \geq 0$$

Beispiel

Seien $p, r > 0$ und

$$f: D = [0, \infty)^2 \rightarrow \mathbb{R}, \quad f(x, y) = 4x^{\frac{1}{4}}y^{\frac{1}{4}} - px - ry$$

$$\text{Hesse-Matrix: } \mathbf{H}_f(\mathbf{x}) = \begin{pmatrix} -\frac{3}{4}x^{-\frac{7}{4}}y^{\frac{1}{4}} & \frac{1}{4}x^{-\frac{3}{4}}y^{-\frac{3}{4}} \\ \frac{1}{4}x^{-\frac{3}{4}}y^{-\frac{3}{4}} & -\frac{3}{4}x^{\frac{1}{4}}y^{-\frac{7}{4}} \end{pmatrix}$$

Hauptminoren:

$$H_1 = -\frac{3}{4}x^{-\frac{7}{4}}y^{\frac{1}{4}} < 0$$

f ist streng konkav in D .

$$H_2 = \frac{1}{2}x^{-\frac{3}{2}}y^{-\frac{3}{2}} > 0$$

$$\text{Kritischer Punkt: } \nabla f = (x^{-\frac{3}{4}}y^{\frac{1}{4}} - p, x^{\frac{1}{4}}y^{-\frac{3}{4}} - r) = 0$$

$$f_x = x^{-\frac{3}{4}}y^{\frac{1}{4}} - p = 0$$

$$f_y = x^{\frac{1}{4}}y^{-\frac{3}{4}} - r = 0$$

$$\Rightarrow \mathbf{x}_0 = \left(\sqrt{\frac{1}{rp^3}}, \sqrt{\frac{1}{r^3p}} \right)$$

\mathbf{x}_0 ist das globale Maximum von f .

Frage:

Wie ändert sich das Optimum $f^* = f(\mathbf{x}_0)$ mit den Parametern r und p ?

Umhüllungssatz (Envelope-Theorem)

Gegeben sei eine Funktion

$$\mathbf{x} \mapsto f(\mathbf{x}, \mathbf{r}) \quad \begin{array}{l} \mathbf{x} = (x_1, \dots, x_n) \dots \text{Variable (endogen)} \\ \mathbf{r} = (r_1, \dots, r_k) \dots \text{Parameter (exogen)} \end{array}$$

mit Extremum \mathbf{x}^* .

Das Extremum hängt vom Parameter \mathbf{r} ab:

$$\mathbf{x}^* = \mathbf{x}^*(\mathbf{r})$$

und damit auch der Extremalwert f^* :

$$f^*(\mathbf{r}) = f(\mathbf{x}^*(\mathbf{r}), \mathbf{r})$$

Es gilt:

$$\frac{\partial f^*(\mathbf{r})}{\partial r_j} = \frac{\partial f(\mathbf{x}, \mathbf{r})}{\partial r_j} \Big|_{\mathbf{x}=\mathbf{x}^*(\mathbf{r})}$$

Umhüllungssatz (Envelope-Theorem)

$$\begin{aligned} \frac{\partial f^*(\mathbf{r})}{\partial r_j} &= \frac{\partial f(\mathbf{x}^*(\mathbf{r}), \mathbf{r})}{\partial r_j} \Big|_{\mathbf{x}=\mathbf{x}^*(\mathbf{r})} && \text{[Kettenregel]} \\ &= \sum_{i=1}^n \underbrace{f_{x_i}(\mathbf{x}^*(\mathbf{r}), \mathbf{r})}_{=0 \text{ da kritischer Punkt}} \cdot \frac{\partial x_i^*(\mathbf{r})}{\partial r_j} + \frac{\partial f(\mathbf{x}, \mathbf{r})}{\partial r_j} \Big|_{\mathbf{x}=\mathbf{x}^*(\mathbf{r})} \\ &= \frac{\partial f(\mathbf{x}, \mathbf{r})}{\partial r_j} \Big|_{\mathbf{x}=\mathbf{x}^*(\mathbf{r})} \end{aligned}$$

Beispiel

Das (eindeutig bestimmte) Maximum von

$$f: D = [0, \infty)^2 \rightarrow \mathbb{R}, \quad f(x, y) = 4x^{\frac{1}{4}}y^{\frac{1}{4}} - px - ry$$

$$\text{ist } \mathbf{x}^*(p, r) = (x^*(p, r), y^*(p, r)) = \left(\sqrt{\frac{1}{rp^3}}, \sqrt{\frac{1}{r^3p}} \right).$$

Frage:

Wie ändert sich das Optimum $f^* = f(\mathbf{x}^*)$ mit den Parametern r und p ?


$$\frac{\partial f^*(p, r)}{\partial p} = \frac{\partial f(\mathbf{x}; p, r)}{\partial p} \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -x \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -\sqrt{\frac{1}{rp^3}}$$

$$\frac{\partial f^*(p, r)}{\partial r} = \frac{\partial f(\mathbf{x}; p, r)}{\partial r} \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -y \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -\sqrt{\frac{1}{r^3p}}$$

Eine geometrische Interpretation

Sei $f(x, r) = \sqrt{x} - rx$. Wir suchen $f^*(r) = \max_x f(x, r)$.

Zeichnen die Graphen von $g_x(r) = f(x, r)$ für verschiedene x .



Zusammenfassung

- ▶ Konvexe Menge
- ▶ Konvex und konkav
- ▶ Quasi-konvex und quasi-konkav
- ▶ Lokales und globales Extremum
- ▶ Minimum, Maximum und Sattelpunkt
- ▶ Kritischer Punkt
- ▶ Hesse-Matrix und Hauptminor
- ▶ Umhüllungssatz (Envelope-Theorem)