

# Kapitel 11

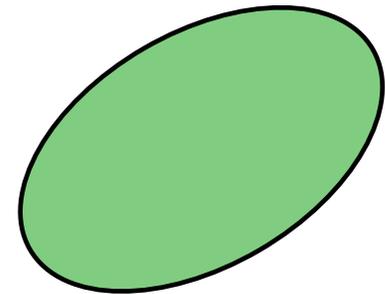
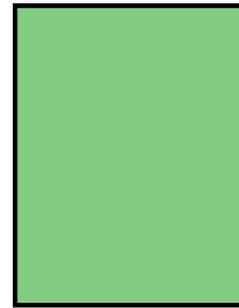
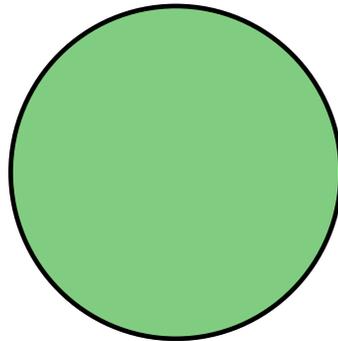
# **Extrema**

# Konvexe Menge

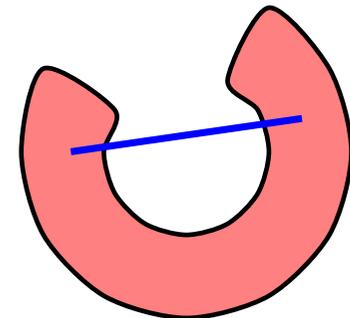
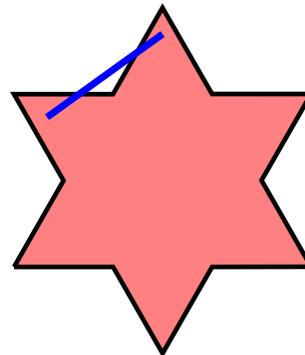
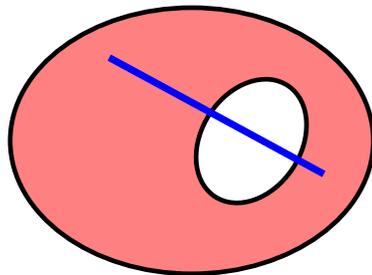
Eine Menge  $D \subseteq \mathbb{R}^n$  heißt **konvex**, wenn für zwei beliebige Punkte  $\mathbf{x}, \mathbf{y} \in D$  auch die Verbindungsstrecke dieser Punkte in  $D$  liegt, d.h.

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

konvex:

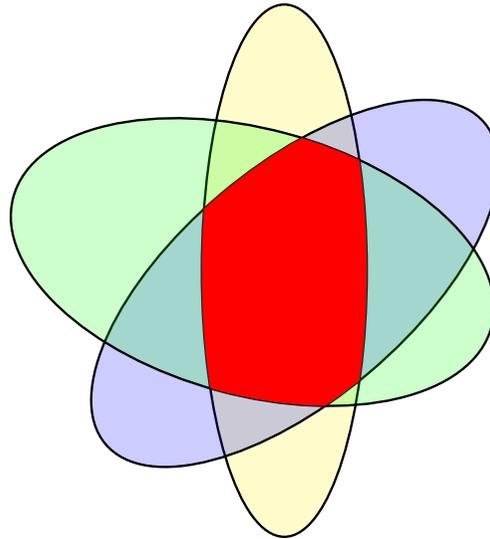


nicht konvex:



# 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

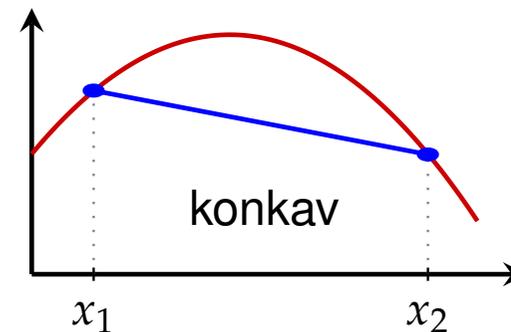
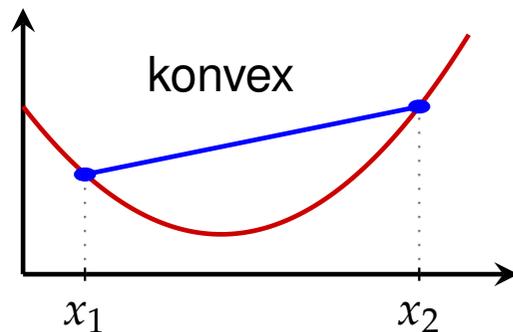
$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \leq (1-h)f(\mathbf{x}_1) + hf(\mathbf{x}_2)$$

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:

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

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

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

*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.

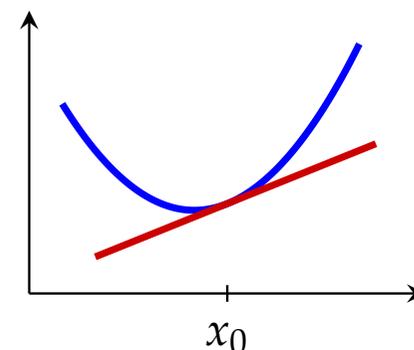
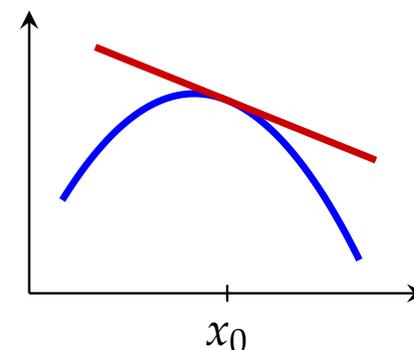
- ▶  $f$  ist **streng konkav** genau dann, wenn

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

- ▶  $f$  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

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

- ▶ 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

Sei  $\mathbf{A} = \begin{pmatrix} 2 & 1 & 0 \\ 1 & 3 & -1 \\ 0 & -1 & 2 \end{pmatrix}$ . 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

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

$$\tilde{H}_1 = -1 \qquad \tilde{H}_2 = -4 \qquad \tilde{H}_3 = -2$$

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

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

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

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

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

$\mathbf{A}$  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. ▶  $f$  streng konvex  $\Leftrightarrow$  alle  $H_k > 0$  für (fast) **alle**  $\mathbf{x} \in D$

▶  $f$  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 – 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 *allgemeinen Hauptminoren* $\tilde{H}_{i_1, \dots, i_k}$ .

3. ▶  $f$  konvex  $\Leftrightarrow$  alle  $\tilde{H}_{i_1, \dots, i_k} \geq 0$  für **alle**  $\mathbf{x} \in D$ .

▶  $f$  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*.

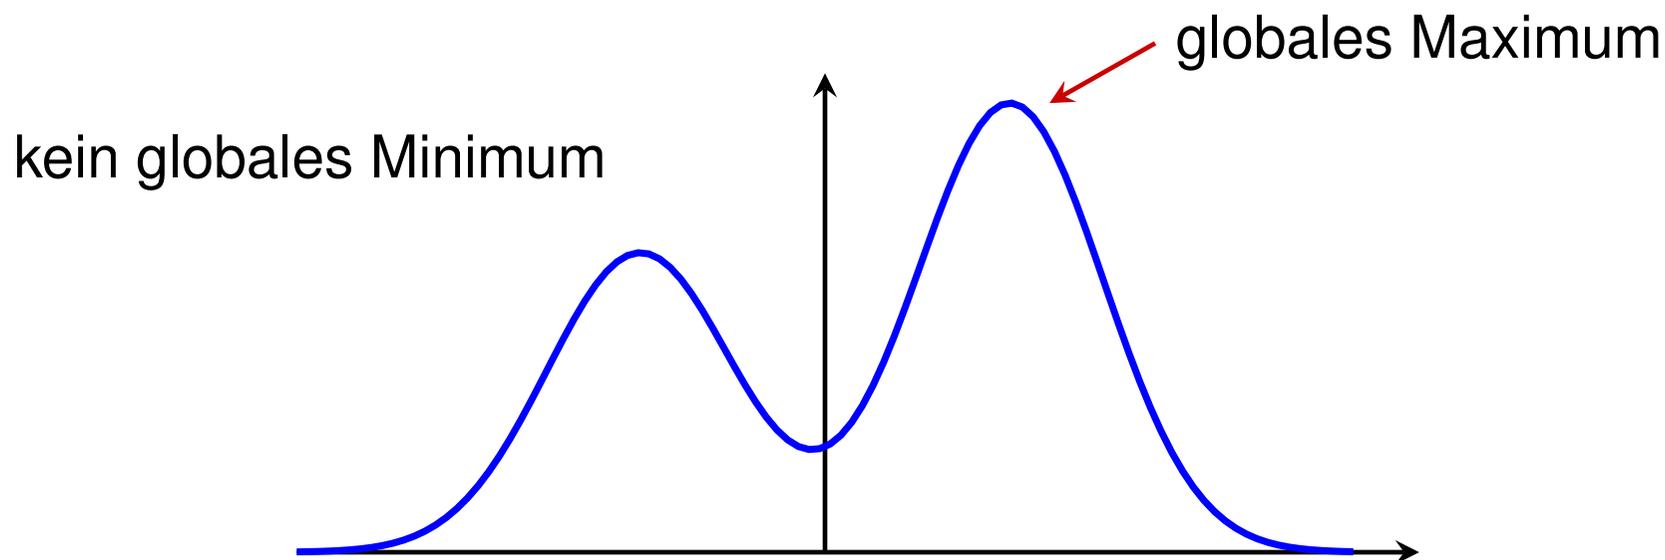
# Globales Extremum (Optimum)

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

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



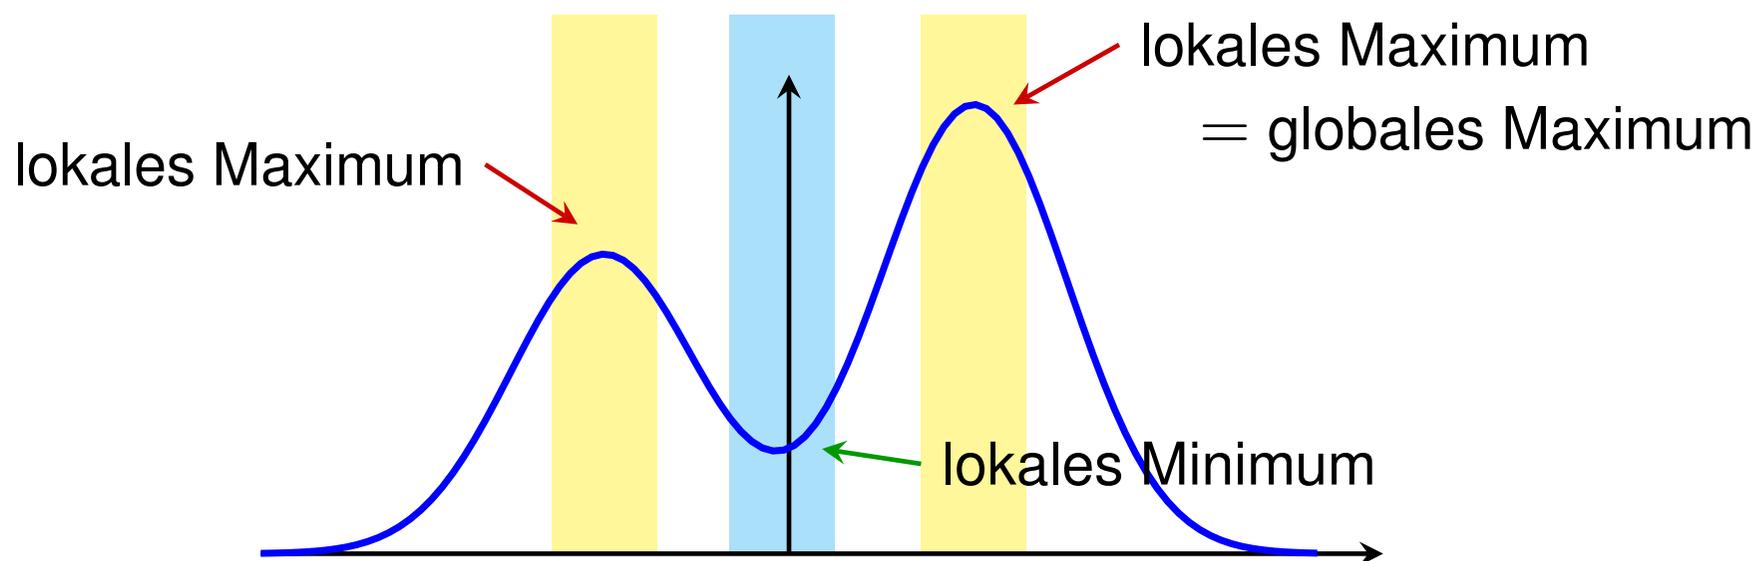
# Lokales Extremum (Optimum)

Ein Punkt  $\mathbf{x}_0$  heißt **lokales Maximum** (*relatives Maximum*) von  $f$ , falls für alle  $\mathbf{x}$  in einer geeigneten Umgebung von  $\mathbf{x}_0$  gilt:

$$f(\mathbf{x}_0) \geq f(\mathbf{x})$$

Ein Punkt  $\mathbf{x}_0$  heißt **lokales Minimum** (*relatives Minimum*) von  $f$ , falls für alle  $\mathbf{x}$  in einer geeigneten Umgebung von  $\mathbf{x}_0$  gilt:

$$f(\mathbf{x}_0) \leq f(\mathbf{x})$$



# Kritischer Punkt

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

Ein Punkt  $\mathbf{x}_0$  heißt **kritischer Punkt** (oder *stationärer Punkt*) einer Funktion  $f$ , wenn

$$\nabla f(\mathbf{x}_0) = 0$$

*Notwendige Bedingung:*

Jedes Extremum von  $f$  ist ein kritischer Punkt von  $f$ .

# Globales Extremum

*Hinreichende Bedingung:*

Sei  $\mathbf{x}_0$  ein kritischer Punkt einer **konkaven** (oder *konvexen*) Funktion  $f$ . Dann ist  $\mathbf{x}_0$  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  $\mathbf{x} \neq \mathbf{x}_0$  gilt

$$f(\mathbf{x}) - f(\mathbf{x}_0) < \nabla f(\mathbf{x}_0) \cdot (\mathbf{x} - \mathbf{x}_0) = 0 \cdot (\mathbf{x} - \mathbf{x}_0) = 0$$

und somit

$$f(\mathbf{x}_0) > f(\mathbf{x})$$

# 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:

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

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

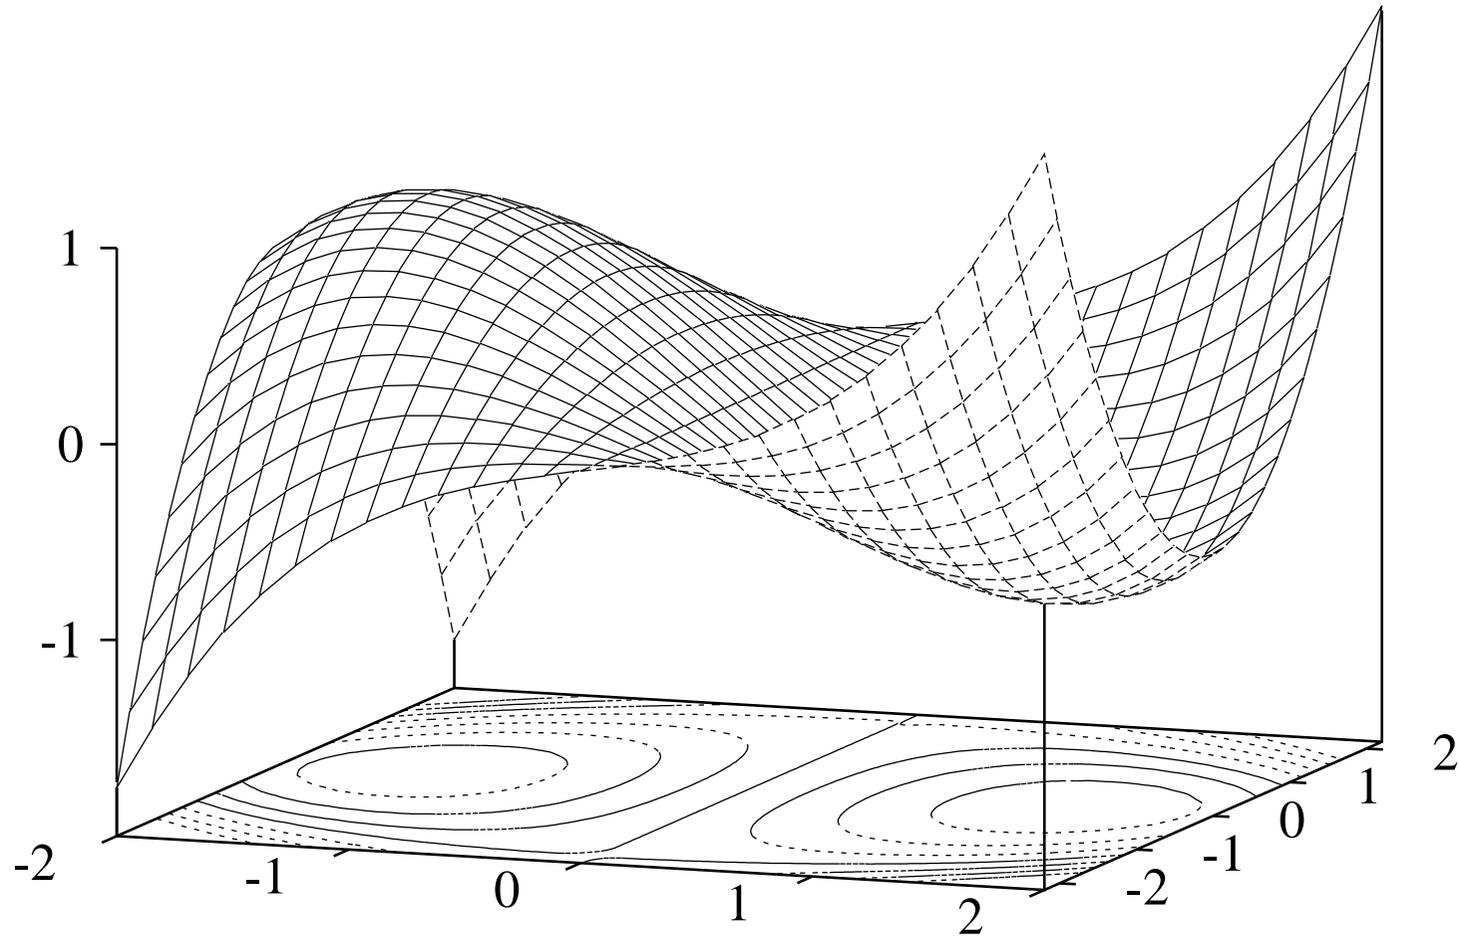
$f$  ist streng konkav in  $D$ .

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

$$\begin{aligned} f_x &= x^{-\frac{3}{4}}y^{\frac{1}{4}} - 1 = 0 \\ f_y &= x^{\frac{1}{4}}y^{-\frac{3}{4}} - 1 = 0 \end{aligned} \quad \Rightarrow \quad \mathbf{x}_0 = (1, 1)$$

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

# Beispiel – Lokale Extrema



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

# Lokal konkav

Ein Punkt  $\mathbf{x}_0$  ist ein **lokales Maximum** (oder *Minimum*) von  $f$ , falls

- ▶  $\mathbf{x}_0$  ist ein **kritischer Punkt** von  $f$ ,
- ▶  $f$  ist **konkav** (bzw. *konvex*) um  $\mathbf{x}_0$ .

*Hinreichende Bedingung:*

$f$  ist *lokal* streng konkav (konvex) um  $\mathbf{x}_0$  ist.

Sei  $\mathbf{x}_0$  ein kritischer Punkt von  $f$ . Dann gilt

- ▶  $\mathbf{H}_f(\mathbf{x}_0)$  *negativ definit*  $\Rightarrow$   $\mathbf{x}_0$  ist lokales Maximum
- ▶  $\mathbf{H}_f(\mathbf{x}_0)$  *positiv definit*  $\Rightarrow$   $\mathbf{x}_0$  ist lokales Minimum

Es ist ausreichend die Hesse-Matrix  $\mathbf{H}_f(\mathbf{x})$  am kritischen Punkt  $\mathbf{x}_0$  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.  $f'(x) = \frac{1}{4} x^2 - 2x + 3,$   
 $f''(x) = \frac{1}{2} x - 2.$

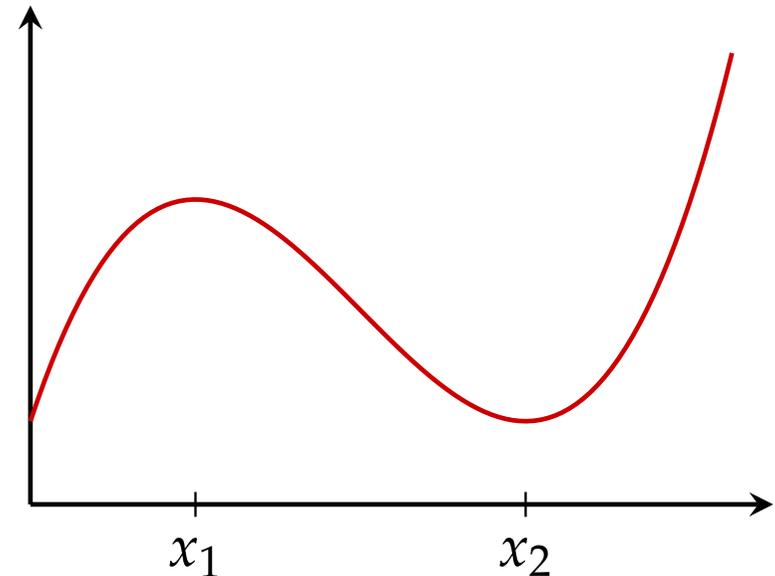
2.  $\frac{1}{4} x^2 - 2x + 3 = 0$

besitzt die Lösungen

$$x_1 = 2 \text{ und } x_2 = 6.$$

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

$$f''(6) = 1 \Rightarrow x_2 \text{ ist lokales Minimum.}$$



# 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:

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

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

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

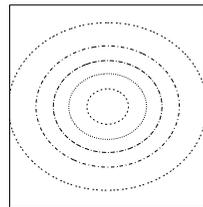
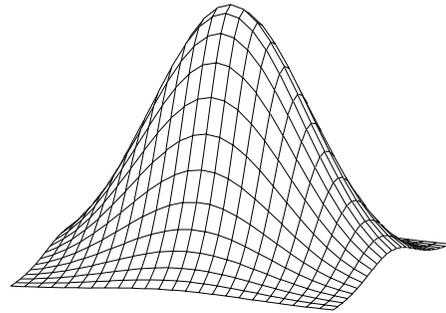
$$(I) \quad \Rightarrow \quad \begin{array}{l|l} -1 + \frac{1}{4} y^2 = 0 & \frac{1}{2} x^2 - 1 = 0 \\ y = \pm 2 & x = \pm \sqrt{2} \end{array}$$

Kritische Punkte:

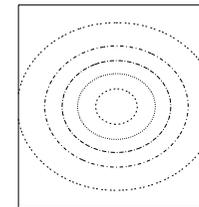
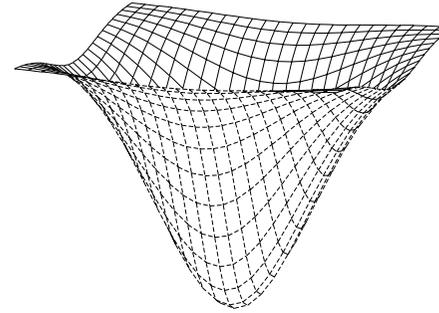
$$\mathbf{x}_1 = (0, 2) \quad \mathbf{x}_3 = (\sqrt{2}, 0)$$

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

# Kritische Punkte – Lokale Extrema

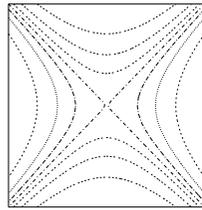
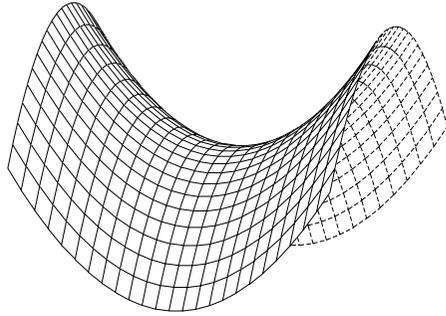


Lokales Maximum

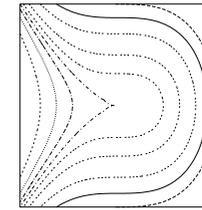
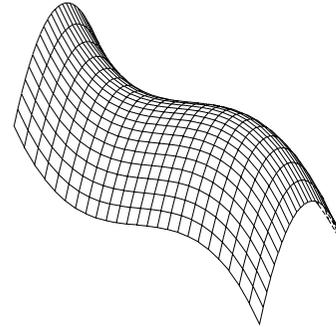


Lokales Minimum

# Kritische Punkte – Sattelpunkte



Sattelpunkt



Beispiel für höhere Ordnung

# Vorgangsweise – Lokale Extrema

1. Berechne Gradient  $\nabla f$  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  $\nabla f$  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:

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

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

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

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

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

$\Rightarrow \mathbf{x}_4$  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.

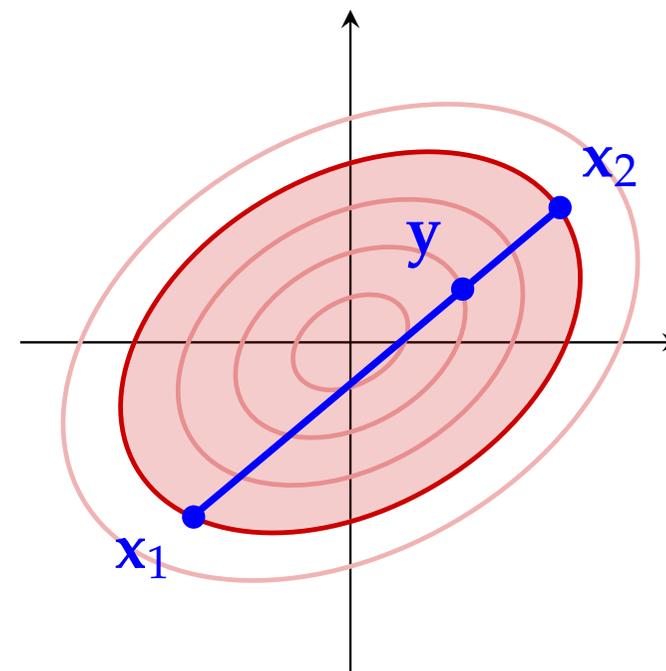
$f(\mathbf{x}_1), f(\mathbf{x}_2) \leq c$ . Sei

$\mathbf{y} = (1 - h)\mathbf{x}_1 + h\mathbf{x}_2$  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  $\mathbf{y} \in \{\mathbf{x} \in D_f : f(\mathbf{x}) \leq c\}$ .



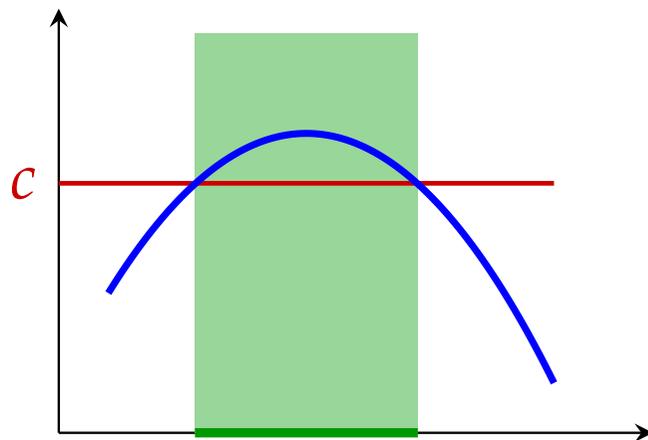
# Konkave Funktion und konvexe Menge

Sei  $f$  konkav.

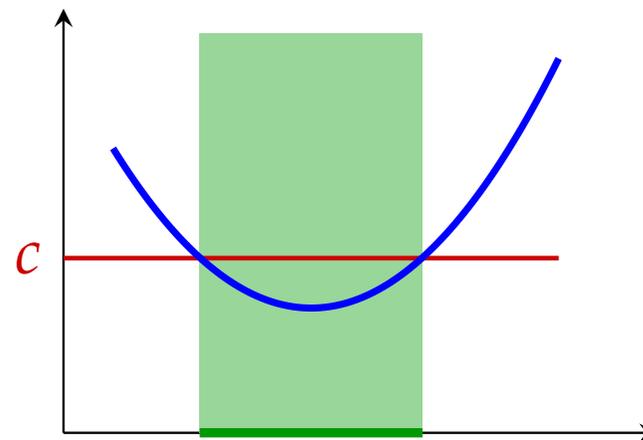
Dann ist die **obere Niveaumenge** von  $f$

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

*konvex.*



obere Niveaumenge



untere Niveaumenge

# Extremum und monotone Transformation

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

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

Da  $\mathbf{x}^*$  ein *Maximum* von  $f$  ist, gilt

$$f(\mathbf{x}^*) \geq f(\mathbf{x}) \text{ f\u00fcr alle } \mathbf{x}.$$

Da  $T$  streng monoton steigend ist, gilt

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

Wir erhalten daher

$$(T \circ f)(\mathbf{x}^*) = T(f(\mathbf{x}^*)) > T(f(\mathbf{x})) = (T \circ f)(\mathbf{x}) \text{ f\u00fcr alle } \mathbf{x},$$

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

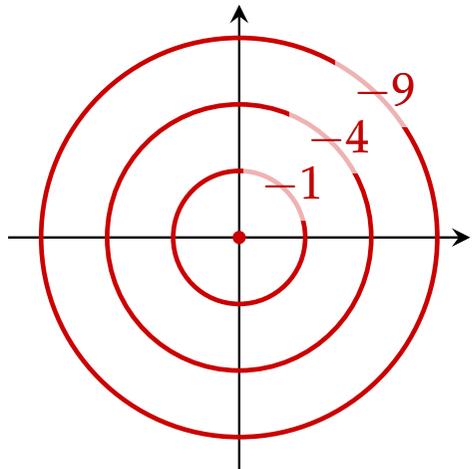
Da  $T$  injektiv ist, gilt sogar die Umkehrung:

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

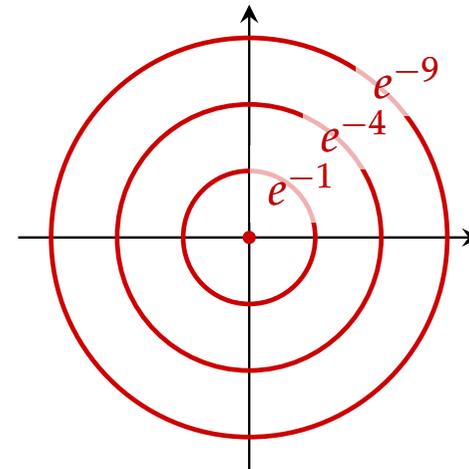
# Extremum und monotone Transformation

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

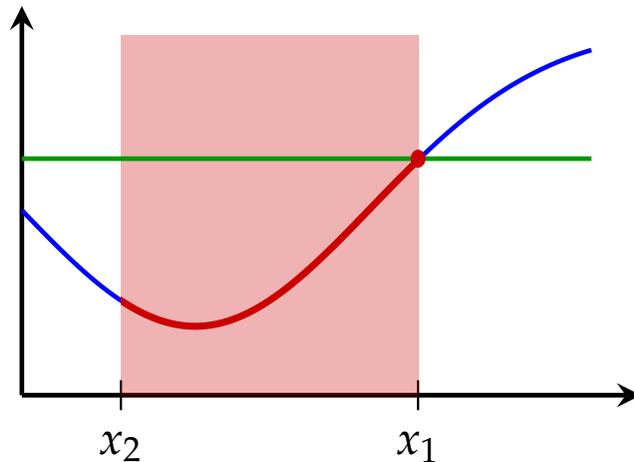
$$f((1-h)\mathbf{x}_1 + h\mathbf{x}_2) \leq \max\{f(\mathbf{x}_1), f(\mathbf{x}_2)\}$$

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

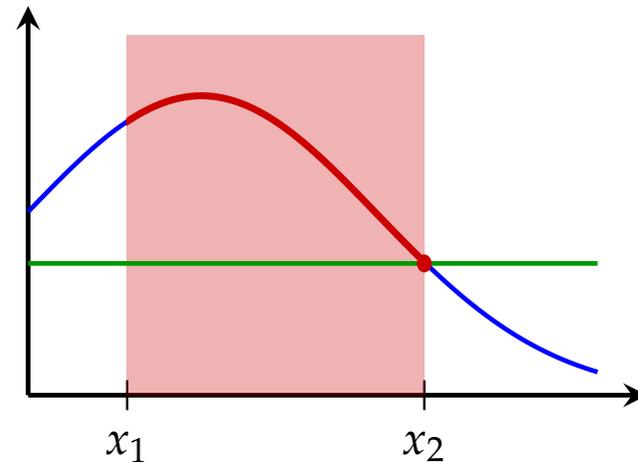
- ▶  $f$  ist *quasi-konkav* genau dann, wenn

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

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



quasi-konvex



quasi-konkav

# Streng quasi-konvex und streng quasi-konkav

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

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

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

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

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

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

# Quasi-konvex und quasi-konkav III

Für eine differenzierbare Funktion  $f$  gilt:

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

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

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

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

# 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:

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

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

$f$  ist streng konkav in  $D$ .

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

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

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

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

$\mathbf{x}_0$  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)

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

# 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  $p$ ?

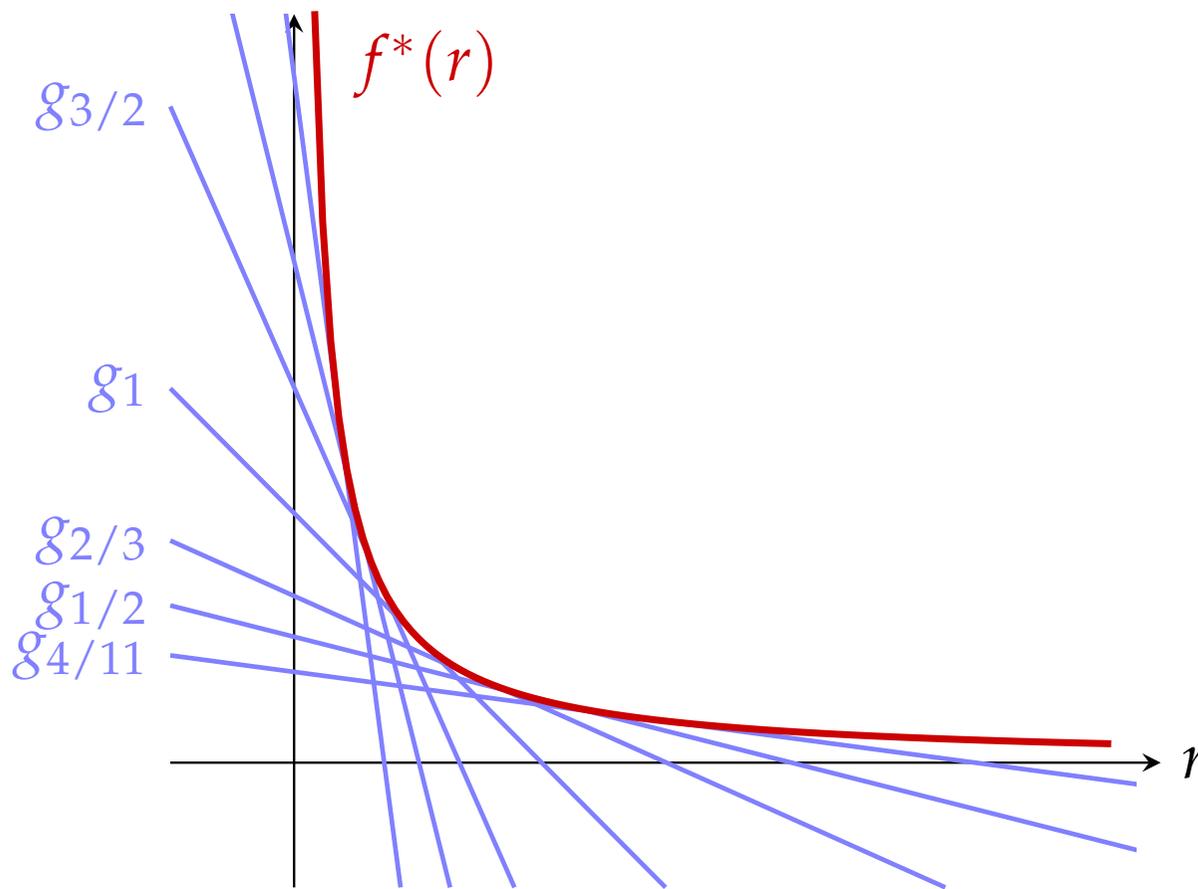
$$\frac{\partial f^*(p, r)}{\partial p} = \frac{\partial f(\mathbf{x}; p, r)}{\partial p} \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -x \Big|_{\mathbf{x}=\mathbf{x}^*(p, r)} = -\sqrt{\frac{1}{rp^3}}$$

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

# 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)