

Überblick

- **Grundlagen**
 - Einführung in die automatische Mustererkennung
 - Grundlagen der Wahrscheinlichkeitsrechnung
- **Klassifikation bei bekannter Wahrscheinlichkeitsverteilung**
 - Entscheidungstheorie
 - Bayes-Klassifikator
 - **Entscheidungsfunktionen bei gaußverteilten Daten**
- **Überwachtes Lernen bei unbekannter Verteilung der Daten**
 - Nichtparametrische Klassifikation
 - Probleme bei hochdimensionalen Daten
 - Lineare Klassifikation, Perzeptron
 - Nicht linear trennbare Systeme
 - Nichtlineare Klassifikatoren
 - Vergleich von Klassifikatoren
- **Unüberwachtes Lernen**
 - Hauptkomponentenanalyse
 - K-Means-Clustering
 - Agglomeratives Clustern

Überblick

- **Wiederholung: Diskriminantenfunktionen**
- **Kontinuierliche Zufallsvariablen**
- **Gaußverteilung**
- **Diskriminantenfunktionen bei gaußverteilten Daten**

Diskriminantenfunktionen

Diskriminantenfunktionen sind die häufigste Art, einen Klassifikator zu beschreiben.

Vorgehensweise:

- Zu jeder Klasse ω_i wird eine Diskriminantenfunktion $g_i(\mathbf{x})$ definiert.
- Der Klassifikator klassifiziert den Inputvektor \mathbf{x} als zur Klasse ω_i zugehörig, wenn

$$g_i(\mathbf{x}) > g_j(\mathbf{x}) \quad \text{für alle } j \neq i$$

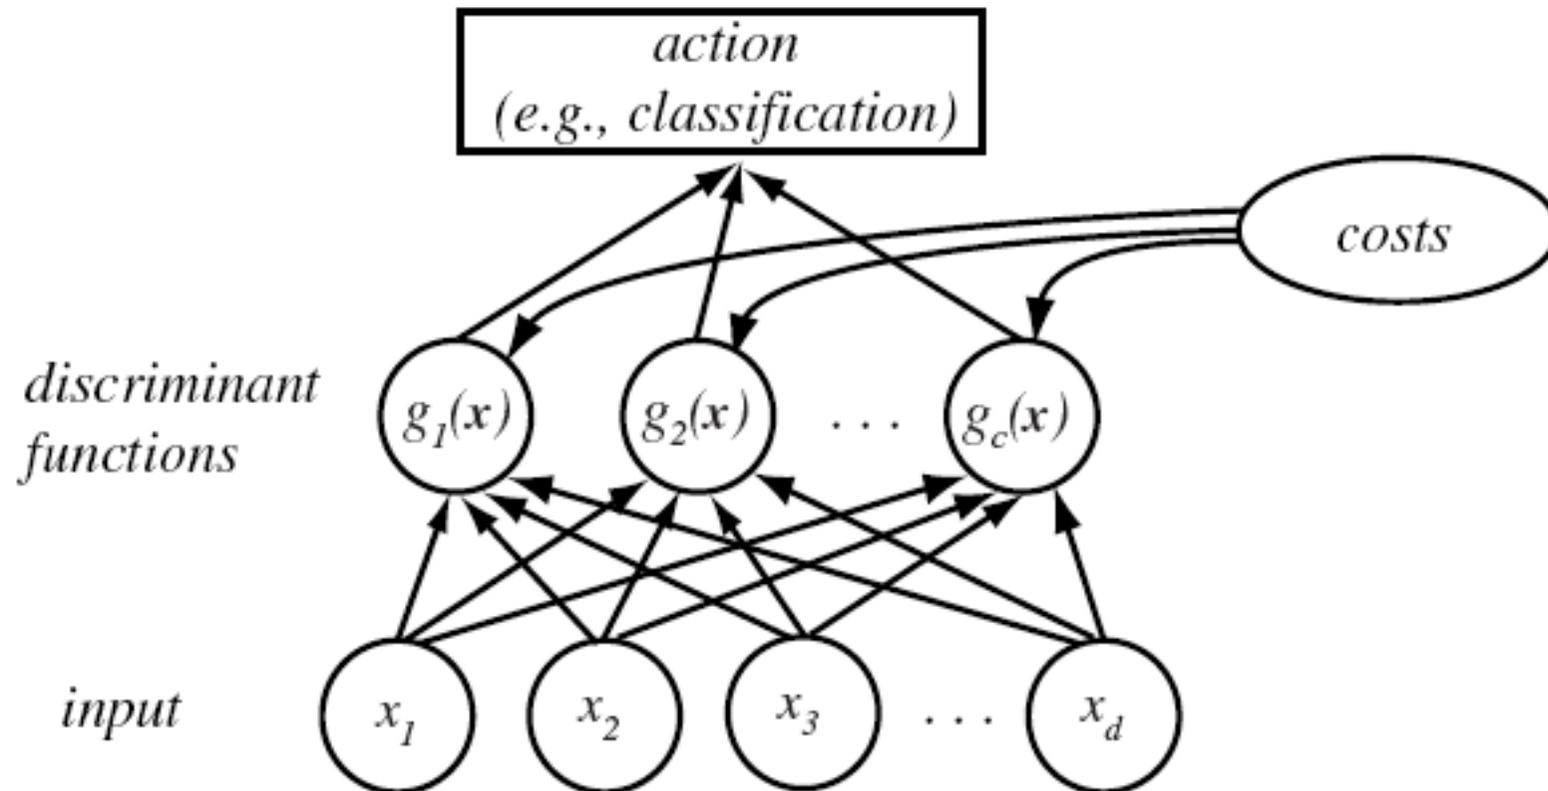
Beispiel Bayes-Klassifikator: „Wähle immer die Aktion α_i , die das bedingte Risiko für die gegebene Beobachtung \mathbf{x} minimiert.“, d.h. entscheide für Klasse ω_i , wenn gilt

$$R(\alpha_i | \mathbf{x}) < R(\alpha_j | \mathbf{x}) \text{ bzw. } p(\omega_i | \mathbf{x}) > p(\omega_j | \mathbf{x}) \quad \text{für alle } j \neq i$$

d.h. die Diskriminantenfunktion ist hier

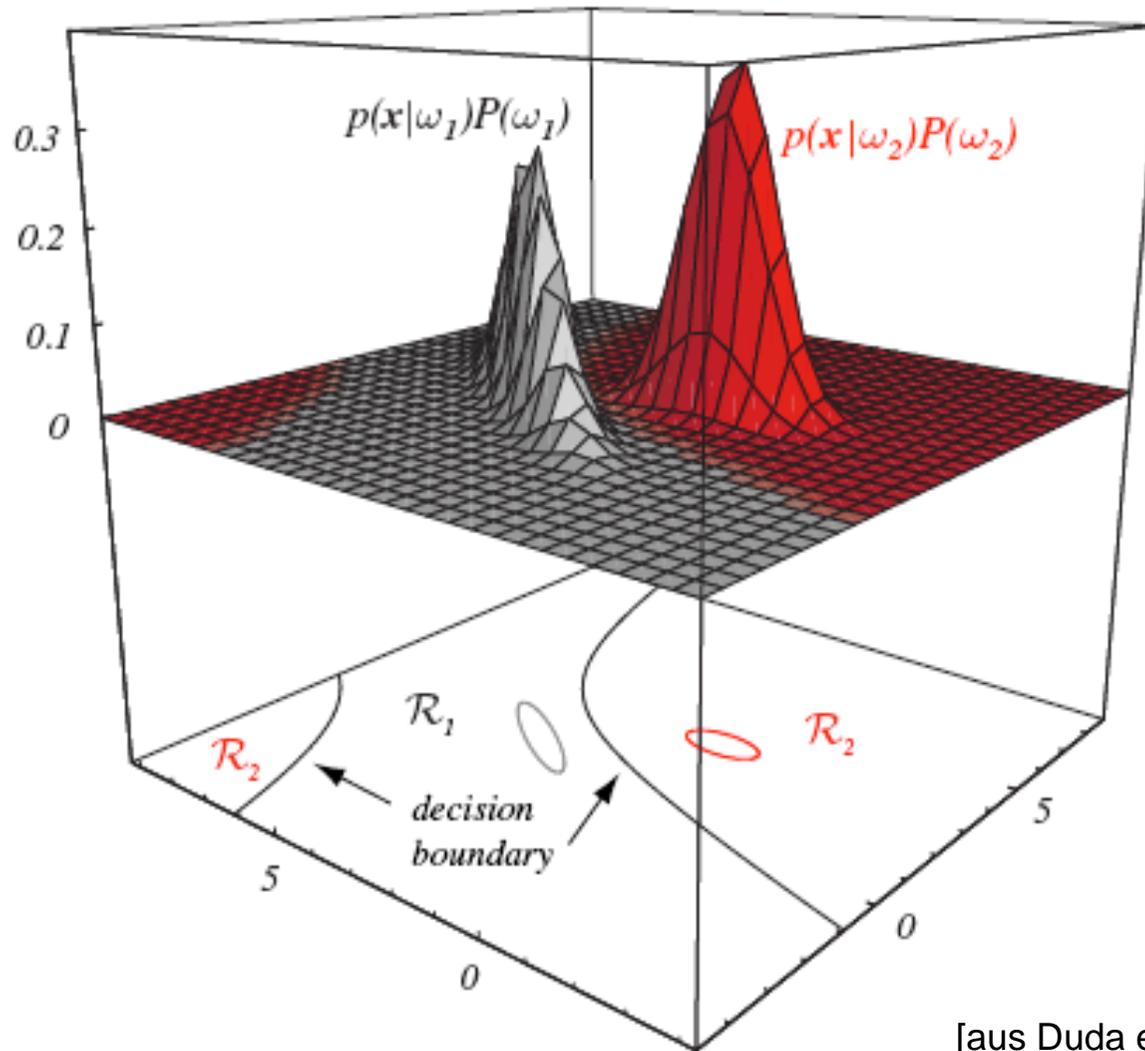
$$g_i(\mathbf{x}) = -R(\alpha_i | \mathbf{x}) \quad \text{bzw.} \quad g_i(\mathbf{x}) = p(\omega_i | \mathbf{x})$$

Allgemeiner Aufbau eines statistischen Klassifikators



[aus Duda et al., 2001]

Entscheidungsgrenzen und Entscheidungsregionen



Die Entscheidungsregel unterteilt den Inputraum in **Entscheidungsregionen**.

Die Entscheidungsregionen sind durch **Entscheidungsgrenzen** voneinander getrennt.

[aus Duda et al., 2001]

Überblick

- **Wiederholung: Diskriminantenfunktionen**
- **Kontinuierliche Zufallsvariablen**
- **Gaußverteilung**
- **Diskriminantenfunktionen bei gaußverteilten Daten**

Kontinuierliche Zufallsvariablen (1)

- Bisher: Zufallsvariablen, bei denen ein **diskreter** Wert a_i aus einem Alphabet mit einer Wahrscheinlichkeit p_i angenommen wird.
- Jetzt: Erweiterung auf Zufallsvariablen mit **kontinuierlichen** Werten
- Die Wahrscheinlichkeit für einen bestimmten Wert a_i ist bei kontinuierlichen Zufallsvariablen 0!
- Es macht mehr Sinn, davon zu sprechen, daß die ZV einen bestimmten Wert im Intervall $[a,b]$ annimmt.

• Bisher:
$$p(x \in [a,b]) = \sum_{x_i \in [a,b]} p(x)$$

Jetzt:
$$p(x \in [a,b]) = \int_a^b p(x) dx$$

(kontinuierliche Wahrscheinlichkeitsdichte)

i	a_i	p_i	
1	a	0.0575	a
2	b	0.0128	b
3	c	0.0263	c
4	d	0.0285	d
5	e	0.0913	e
6	f	0.0173	f
7	g	0.0133	g
8	h	0.0313	h
9	i	0.0599	i
10	j	0.0006	j
11	k	0.0084	k
12	l	0.0335	l
13	m	0.0235	m
14	n	0.0596	n
15	o	0.0689	o
16	p	0.0192	p
17	q	0.0008	q
18	r	0.0508	r
19	s	0.0567	s
20	t	0.0706	t
21	u	0.0334	u
22	v	0.0069	v
23	w	0.0119	w
24	x	0.0073	x
25	y	0.0164	y
26	z	0.0007	z
27	-	0.1928	-



Kontinuierliche Zufallsvariablen (2)

Die bisher benutzten Formeln für diskrete ZV können direkt übernommen werden, indem die Summierung durch ein Integral ersetzt wird:

- Positivität und Normierung: $p(x) \geq 0$ und $\int_{-\infty}^{\infty} p(x) dx = 1$

- Erwartungswert: $E[f(x)] = \int_{-\infty}^{\infty} f(x)p(x) dx$

- Mittelwert: $\mu = E[x] = \int_{-\infty}^{\infty} xp(x) dx$

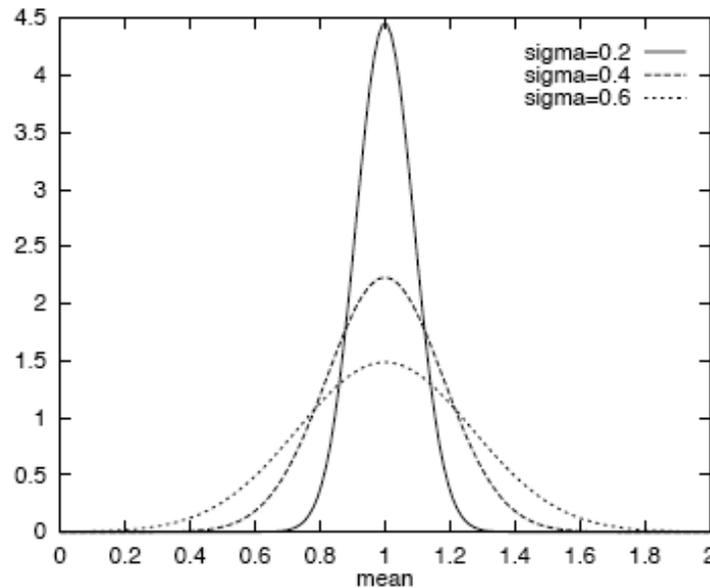
- Varianz: $\sigma^2 = E[(x - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx$

- Bayes-Formel: $p(x | y) = \frac{p(y | x)p(x)}{\int_{-\infty}^{\infty} p(y | x)p(x) dx}$

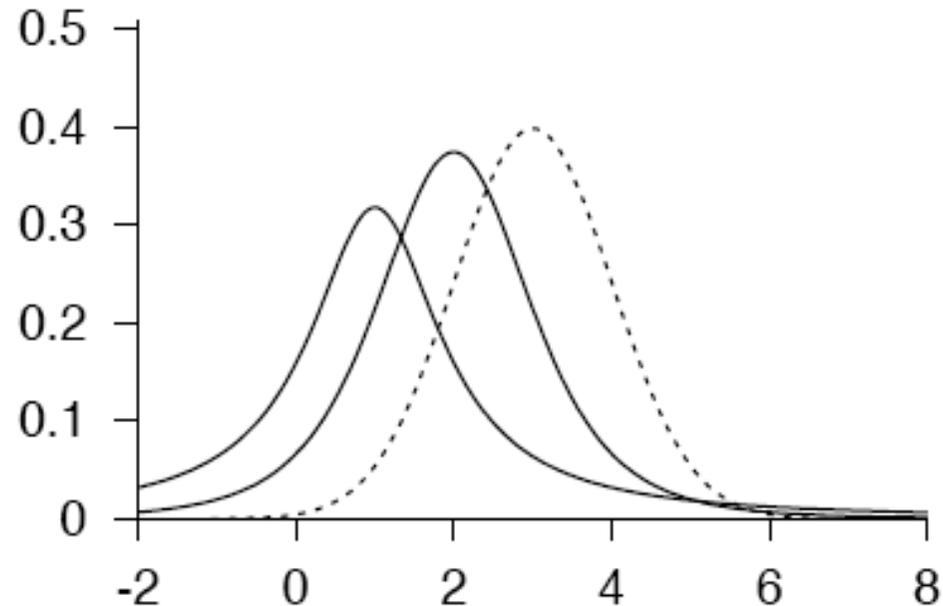
Häufig benutzte Verteilungen (1)

Da im Normalfall die genaue Verteilung der Daten nicht bekannt sind, benutzt man bestimmte Verteilungsfunktionen als **Modell** der Daten, um damit Vorwissen oder Vorannahmen zu beschreiben.

Beispiel: Verteilungen für ZV, deren Werte unbeschränkt sind:



Gaußverteilung

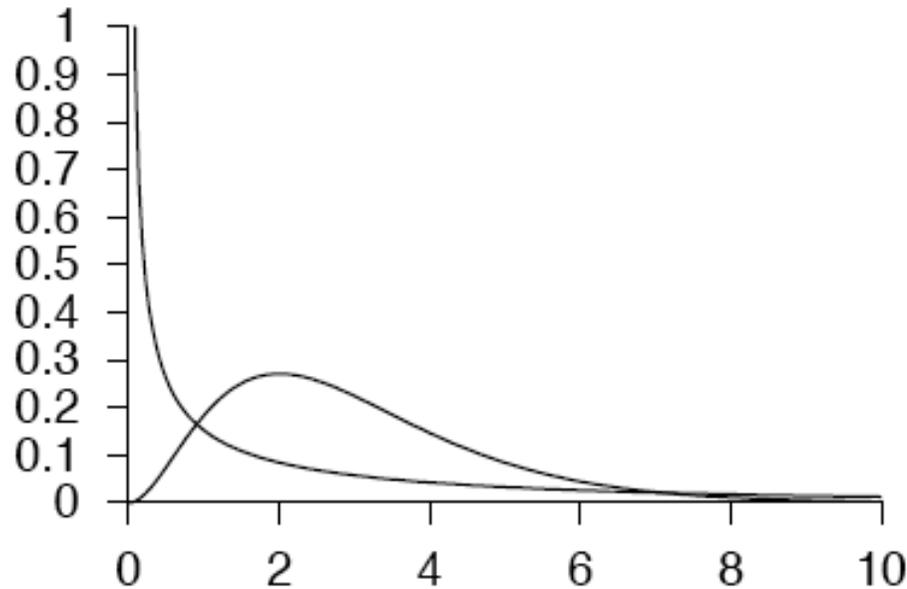


Student-t-Verteilung
(fällt langsamer ab)

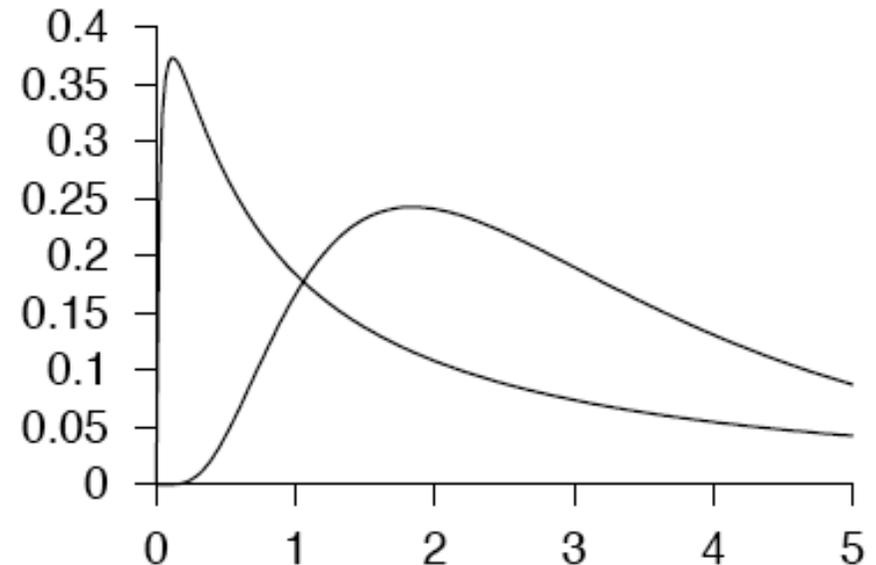
[aus McKay, 2003]

Häufig benutzte Verteilungen (2)

Verteilungen für ZV mit positiven Werten:



Gammaverteilung ($x \geq 0$)



Log-Normalverteilung ($x > 0$)

- Auswahl nach:
- Art der Daten (positiv, diskret, ...)
 - unimodal, bimodal
 - **einfache Berechenbarkeit**

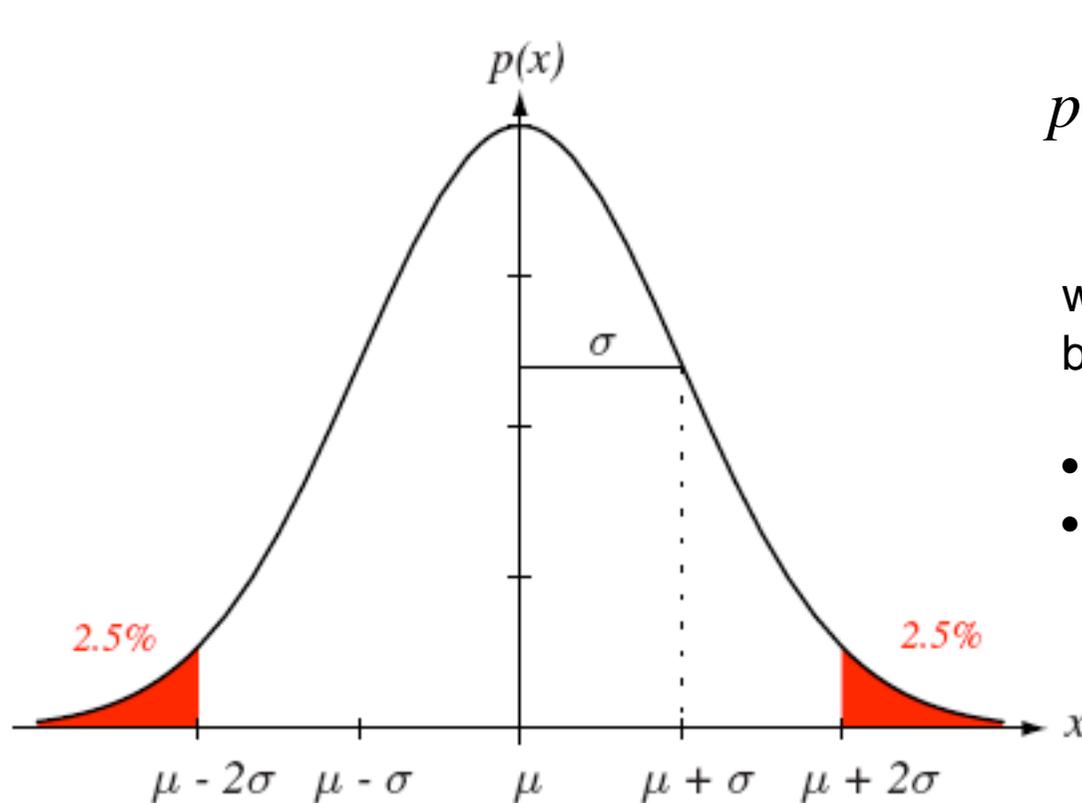
[aus McKay, 2003]

Überblick

- **Wiederholung: Diskriminantenfunktionen**
- **Kontinuierliche Zufallsvariablen**
- **Gaußverteilung**
- **Diskriminantenfunktionen bei gaußverteilten Daten**

Univariate Gaußverteilung (1)

Zentraler Grenzwertsatz der Wahrscheinlichkeitsrechnung: die Summe einer großen Zahl von (beinahe) beliebig verteilten Zufallsvariablen nähert sich der Gaußverteilung.



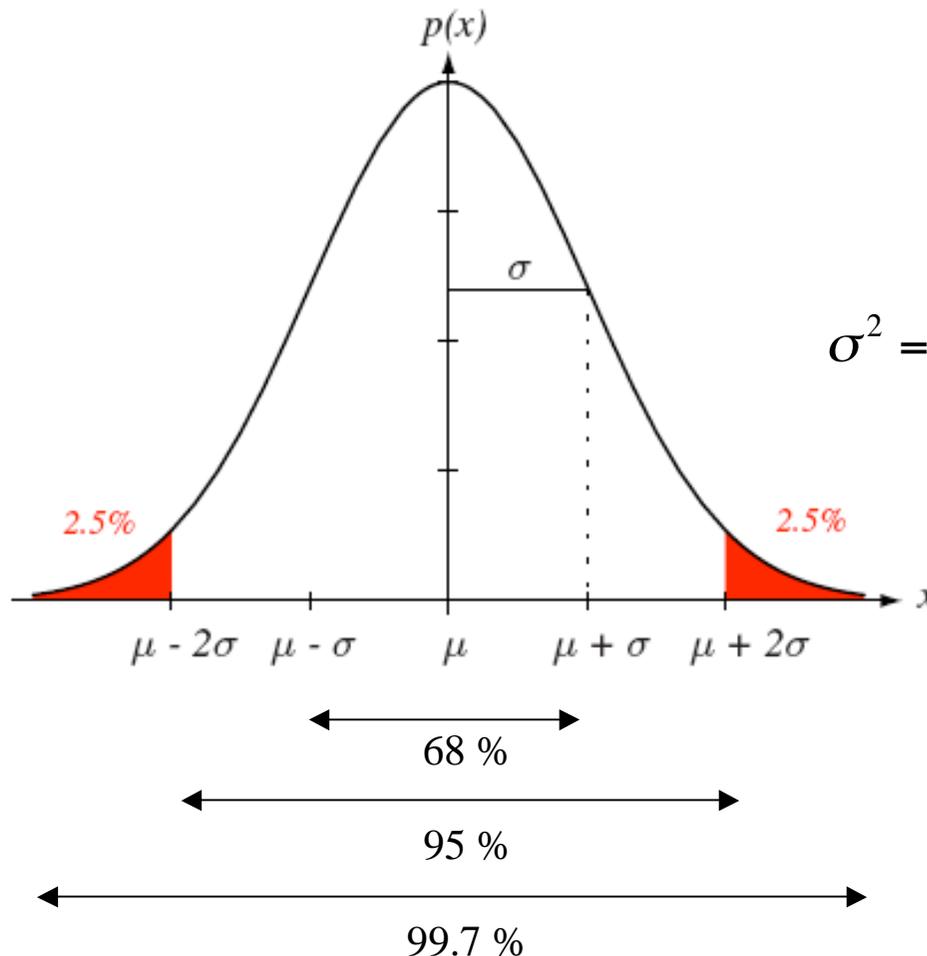
$$p(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}}$$

wird durch 2 Parameter beschrieben:

- Mittelwert μ
- Varianz σ^2

Schreibweise: $N(\mu, \sigma^2)$

Gaußverteilung (2)



$$\int_{-\infty}^{\infty} p(x) dx = 1$$

$$\mu = E[x] = \int_{-\infty}^{\infty} xp(x) dx$$

$$\sigma^2 = E[(x - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx$$

- Aufgrund des zentralen Grenzwertsatzes ist die Gaußverteilung oft ein gutes Modell.
- Viele Integrale lassen sich geschlossen lösen => häufig in probabilistischen Modellen.

Multivariate Gaußverteilung

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^N \det \Sigma}} \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu}_x)\right]$$

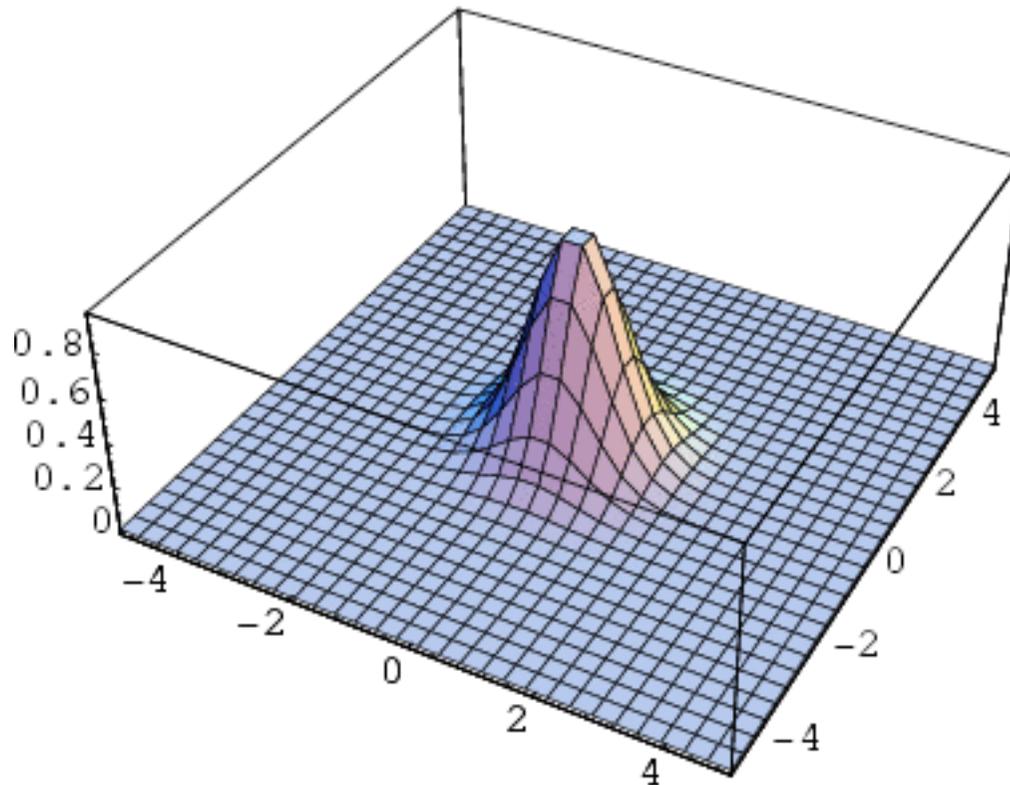
mit

$\boldsymbol{\mu}$: Mittelwertvektor
mit $\mu_i = E[x_i]$

Σ : **Kovarianzmatrix**

mit

$$\sigma_{ij} = E[(x_i - \mu_i)(x_j - \mu_j)]$$

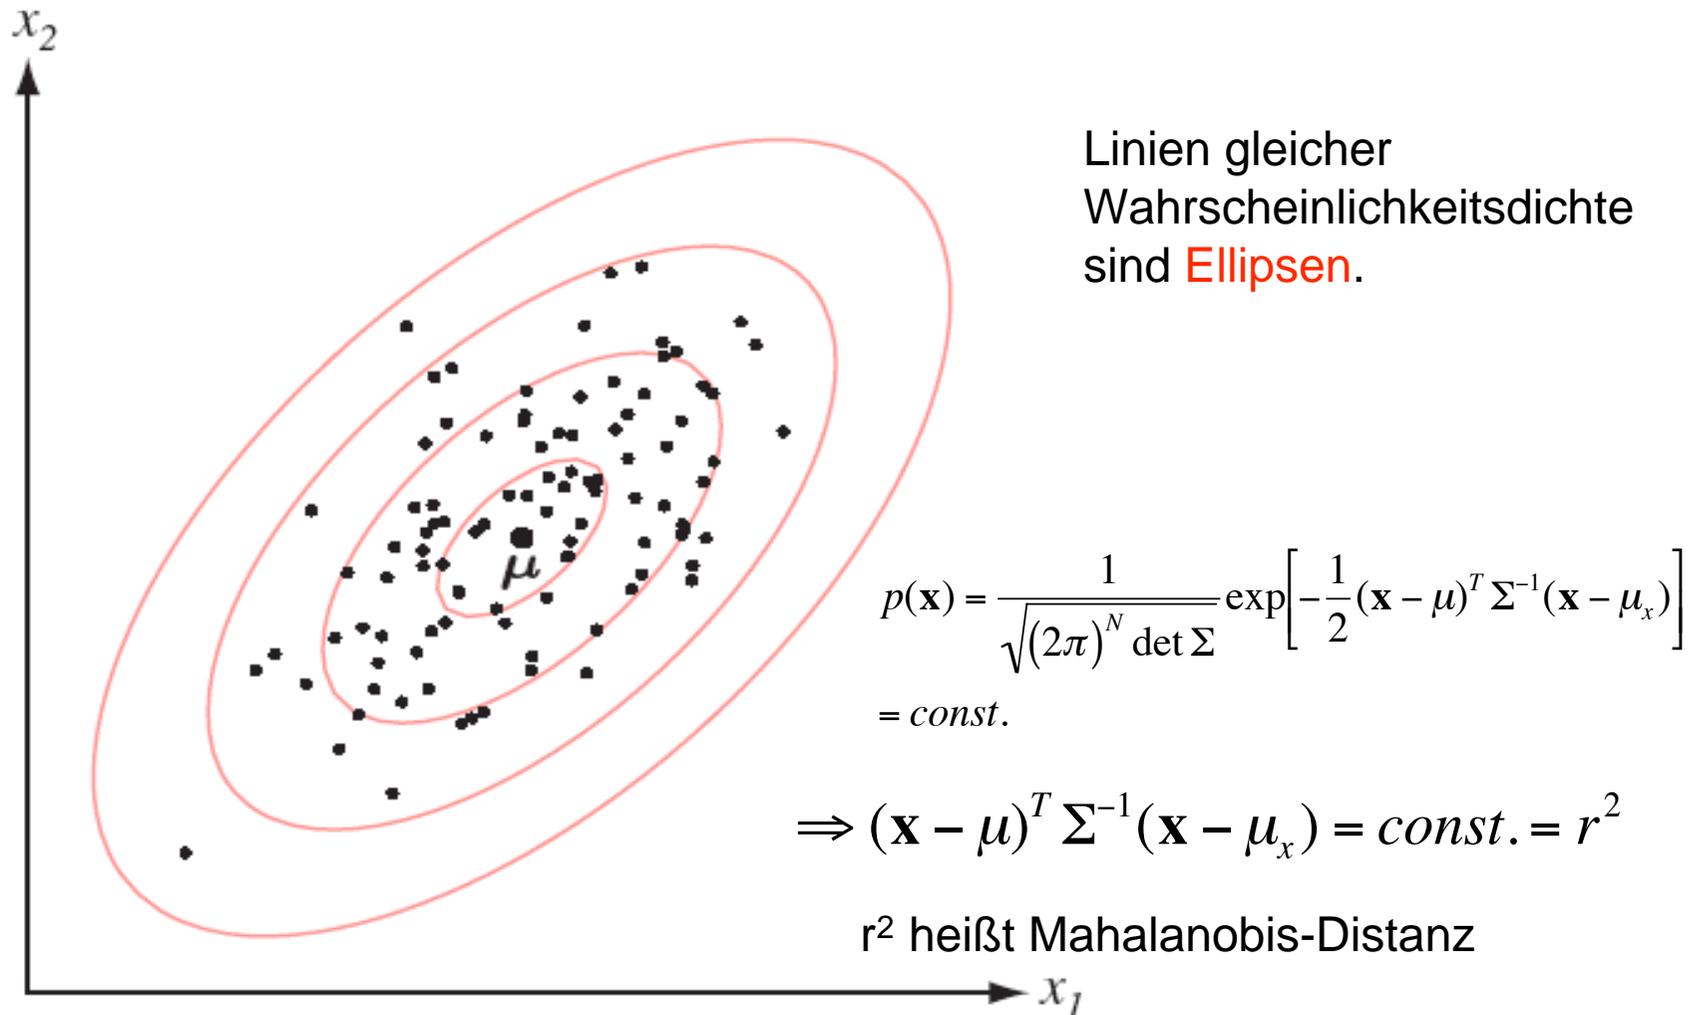


Die Diagonalelemente von Σ
sind die Varianzen der x_i .

Die nichtdiagonalen
Elemente von Σ sind die
Kovarianzen von x_i und x_j .

Die d-dimensionale Gaußverteilung ist durch $d + d(d + 1)/2$ Größen bestimmt.

Beispiel: von einer bivariaten Gaußverteilung erzeugt Daten



[aus Duda et al., 2001]

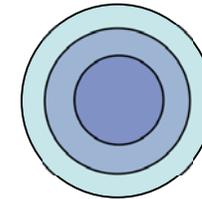
d.h. die Ellipsen haben konstante Mahalanobis-Distanz zum Mittelwert μ .

2D-Beispiele für Kovarianzmatrizen

$$\begin{pmatrix} \sigma & 0 \\ 0 & \sigma \end{pmatrix}$$

Diagonalelemente gleich, nichtdiagonale Elemente 0:

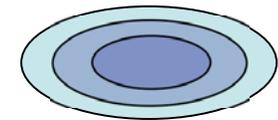
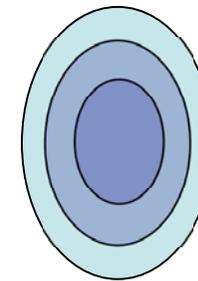
- Linien konstanter Dichte sind Kreise
- Verteilung isotrop
- beide Variablen sind statistisch unabhängig (es gilt $p(x_1, x_2) = p(x_1) p(x_2)$).



$$\begin{pmatrix} \sigma_{11} & 0 \\ 0 & \sigma_{22} \end{pmatrix}$$

Diagonalelemente ungleich, nichtdiagonale Elemente 0:

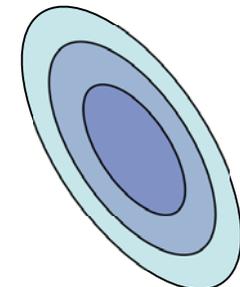
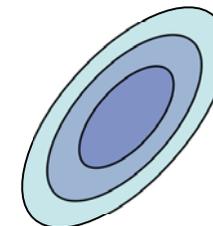
- Linien konstanter Dichte sind Ellipsen, die an den Koordinatenachsen ausgerichtet sind
- beide Variablen sind immer noch statistisch unabhängig.



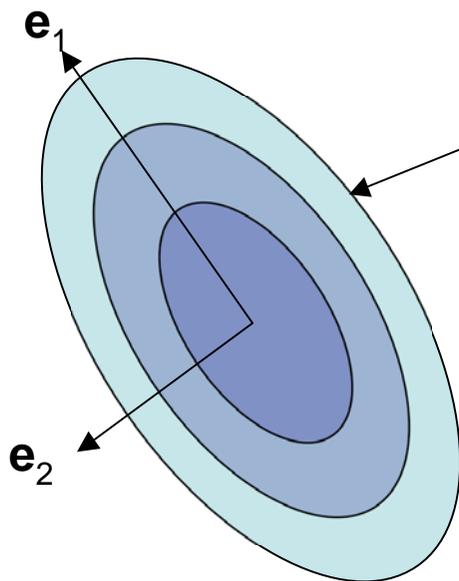
$$\begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix}$$

Alle Einträge von Σ sind ungleich 0, $\sigma_{12} = \sigma_{21}$:

- Linien konstanter Dichte sind beliebig ausgerichtete Ellipsen
- die Variablen sind statistisch abhängig.



Eigenwerte der Kovarianzmatrix



$$(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}_x) = \text{const.}$$

Mit der Kovarianzmatrix läßt sich die Varianz der Verteilung in einer beliebigen Richtung berechnen:

Sei \mathbf{e} ein Einheitsvektor in der gewünschten Richtung, dann ist die Varianz in dieser Richtung $\mathbf{e}^T \boldsymbol{\Sigma} \mathbf{e}$.

Die Ausrichtung der Ellipsen wird durch die **Eigenvektoren** beschrieben. Für einen Eigenvektor gilt:

$$\boldsymbol{\Sigma} \mathbf{e} = \lambda \mathbf{e} \quad \text{bzw.} \quad (\boldsymbol{\Sigma} - \lambda \mathbf{I}) \mathbf{e} = 0$$

mit dem **Eigenwert** λ .

Die Eigenwerte λ_1 und λ_2 geben die Varianz der Gaußverteilung entlang der Richtungen der Eigenvektoren \mathbf{e}_1 und \mathbf{e}_2 an.

Überblick

- **Wiederholung: Diskriminantenfunktionen**
- **Kontinuierliche Zufallsvariablen**
- **Gaußverteilung**
- **Diskriminantenfunktionen bei gaußverteilten Daten**

Diskriminantenfunktionen für gaußverteilte Daten

Der Bayesklassifikator hat im Falle der Minimierung der Fehlerwahrscheinlichkeit die Diskriminantenfunktion:

$$g_j(\mathbf{x}) = p(\omega_j | \mathbf{x}) = \frac{p(\mathbf{x} | \omega_j) p(\omega_j)}{p(\mathbf{x})}$$

bzw.

$$g_j(\mathbf{x}) = p(\mathbf{x} | \omega_j) p(\omega_j)$$

Besonders einfach für gaußverteilte Daten ist die log-transformierte Diskriminantenfunktion:

$$g_j(\mathbf{x}) = \ln p(\mathbf{x} | \omega_j) + \ln p(\omega_j)$$

Für
$$p(\mathbf{x} | \omega_j) = \frac{1}{\sqrt{(2\pi)^d \det \Sigma_j}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mu_j)^T \Sigma_j^{-1}(\mathbf{x} - \mu_j)\right]$$

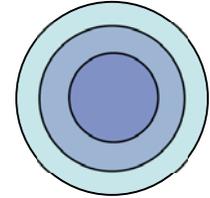
ergibt sich

$$g_j(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \mu_j)^T \Sigma_j^{-1}(\mathbf{x} - \mu_j) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln \det \Sigma_j + \ln p(\omega_j)$$

Spezialfall: $\Sigma_j = \sigma^2 \mathbf{I}$

$$g_j(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1}(\mathbf{x} - \boldsymbol{\mu}_j) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln \det \boldsymbol{\Sigma}_j + \ln p(\omega_j)$$

$$\boldsymbol{\Sigma} = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix} \Rightarrow g_j(\mathbf{x}) = -\frac{1}{2\sigma^2} \|\mathbf{x} - \boldsymbol{\mu}_j\|^2 + \ln p(\omega_j)$$



Die Diskriminantenfunktion ist also einfach der quadratische Abstand zum Mittelwert der Klasse (gewichtet durch σ^2) und einem Offset abhängig von der A-priori-Wahrscheinlichkeit der Klasse.

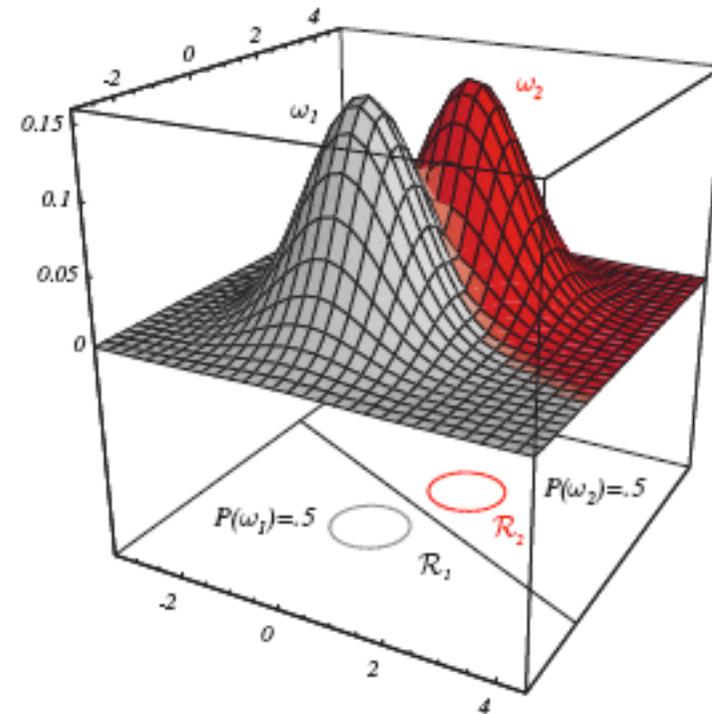
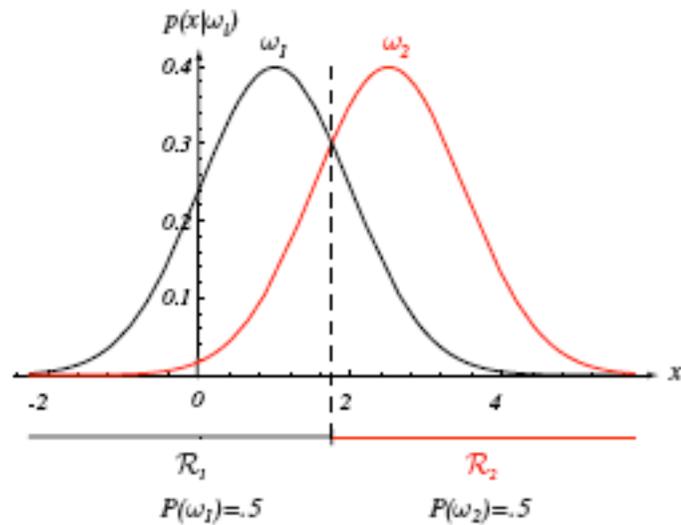
Noch einfachere Form: mit $\|\mathbf{x} - \boldsymbol{\mu}_j\|^2 = (\mathbf{x} - \boldsymbol{\mu}_j)^T (\mathbf{x} - \boldsymbol{\mu}_j) = \mathbf{x}^T \mathbf{x} - 2\boldsymbol{\mu}_j^T \mathbf{x} + \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j$

ergibt sich $g_j(\mathbf{x}) = \mathbf{w}_j^T \mathbf{x} + w_{j0}$

$$\text{mit } \mathbf{w}_j = \frac{1}{\sigma^2} \boldsymbol{\mu}_j \text{ und } w_{j0} = -\frac{1}{\sigma^2} \boldsymbol{\mu}_j^T \boldsymbol{\mu}_j + \ln p(\omega_j)$$

d.h. eine einfache **lineare Diskriminantenfunktion**. Der daraus konstruierte Klassifikator ist eine **lineare Maschine**.

Spezialfall: $\Sigma_j = \sigma^2 I$ in 1 und 2 Dimensionen

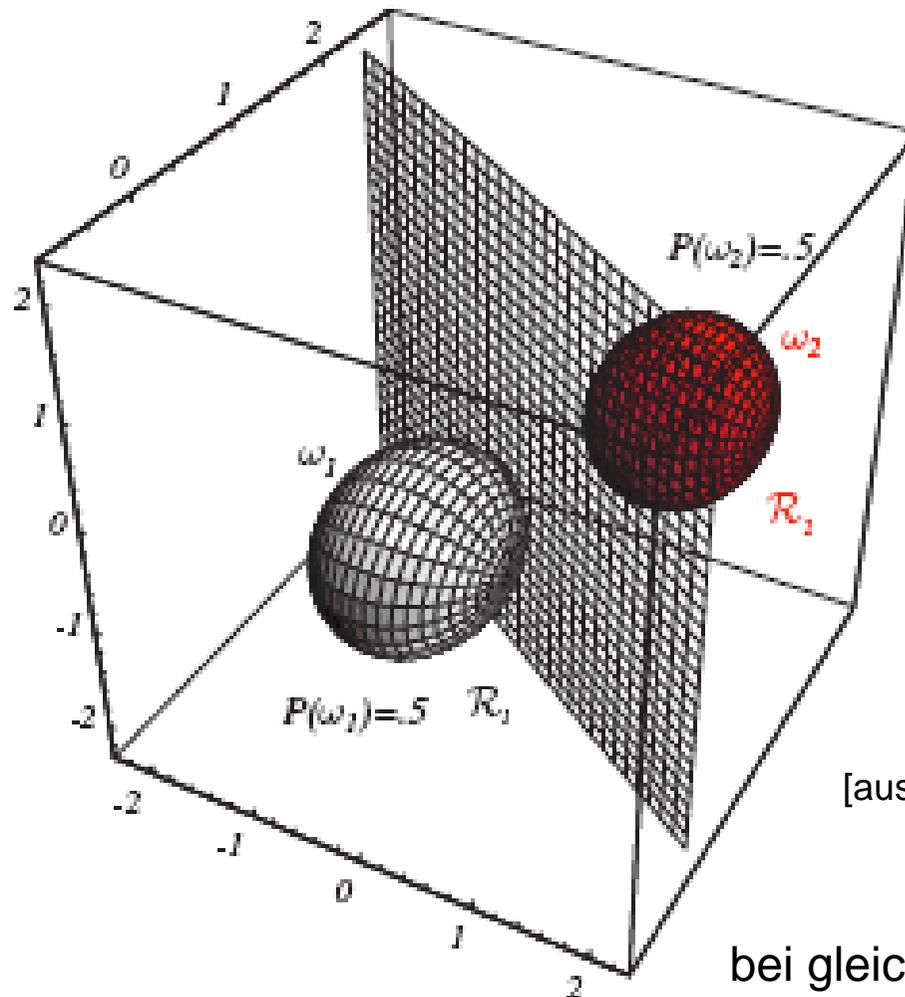


bei gleichen A-priori-Wahrscheinlichkeiten beider Klassen

Minimaldistanz-Klassifikator, Template Matching mit Mittelwert als Klassenprototyp

[aus Duda et al., 2001]

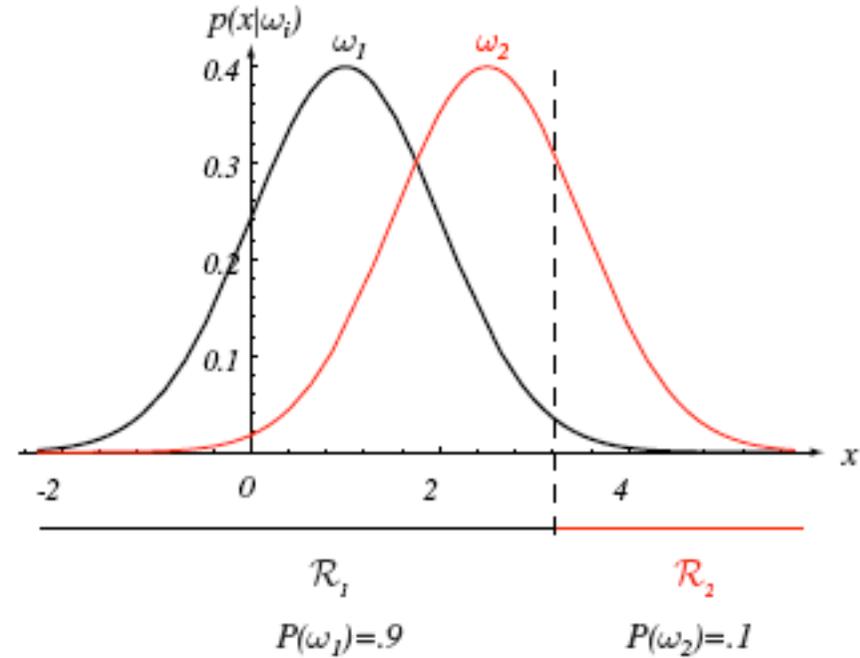
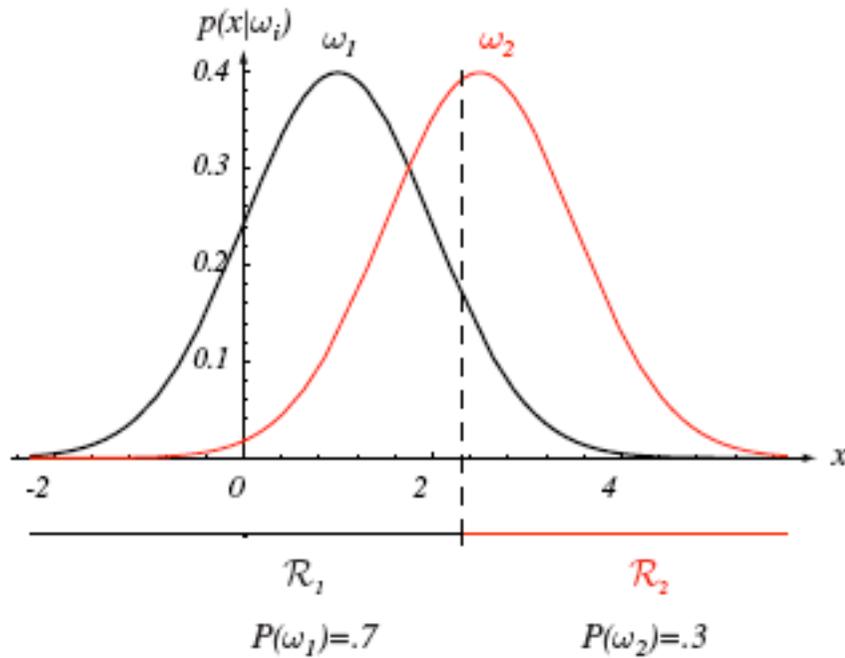
Spezialfall: $\Sigma_j = \sigma^2 I$ in 3 Dimensionen



[aus Duda et al., 2001]

bei gleichen A-priori-Wahrscheinlichkeiten
beider Klassen

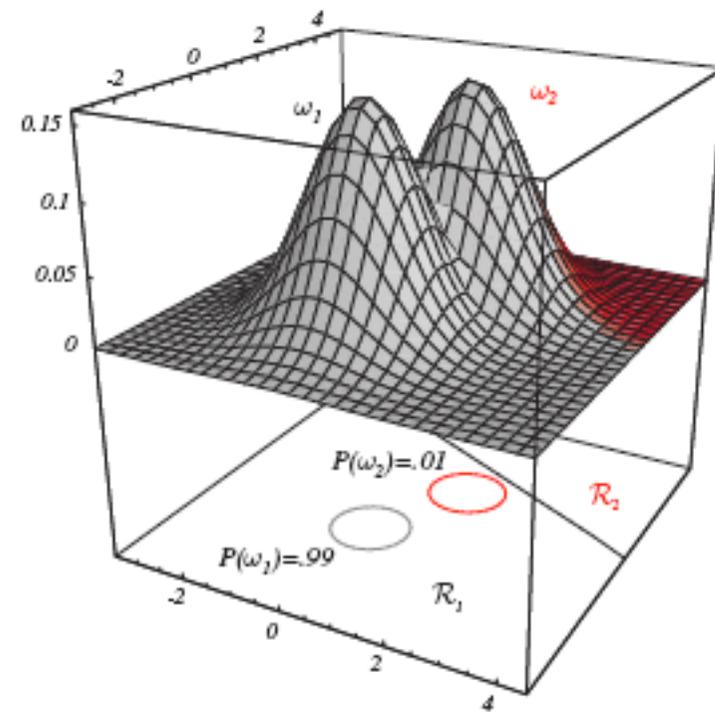
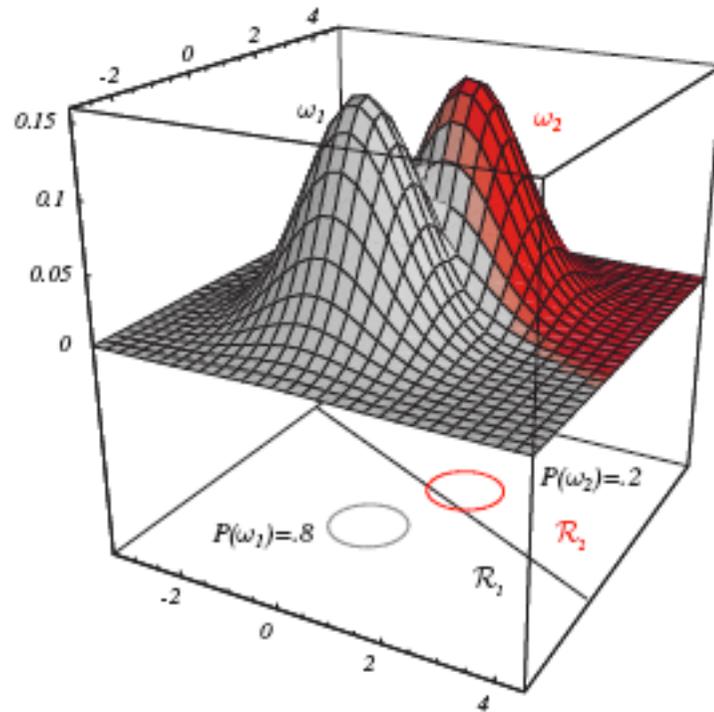
Spezialfall: $\Sigma_j = \sigma^2 I$ in einer Dimension



[aus Duda et al., 2001]

bei ungleichen A-priori-Wahrscheinlichkeiten beider Klassen

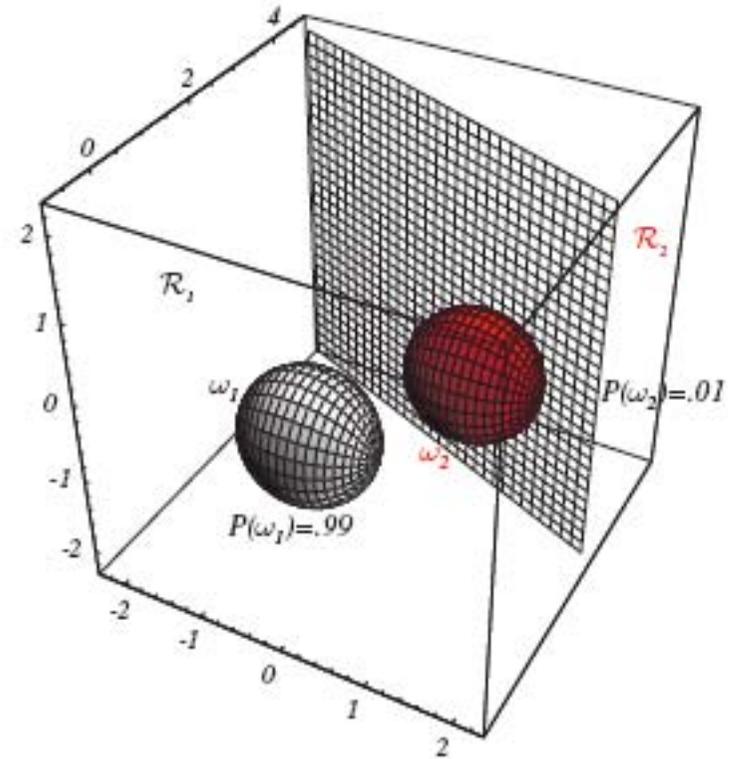
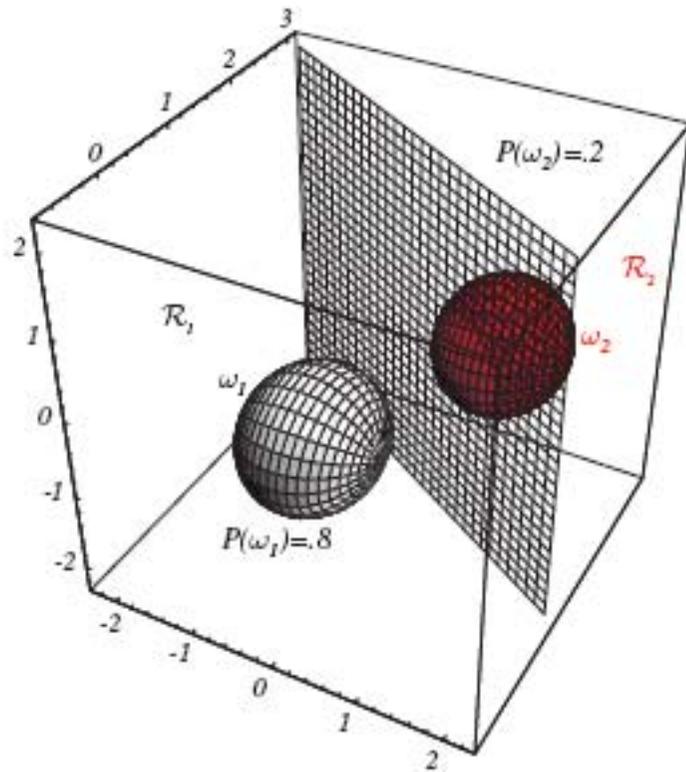
Spezialfall: $\Sigma_j = \sigma^2 I$ in zwei Dimensionen



[aus Duda et al., 2001]

bei ungleichen A-priori-Wahrscheinlichkeiten beider Klassen

Spezialfall: $\Sigma_j = \sigma^2 I$ in drei Dimensionen



[aus Duda et al., 2001]

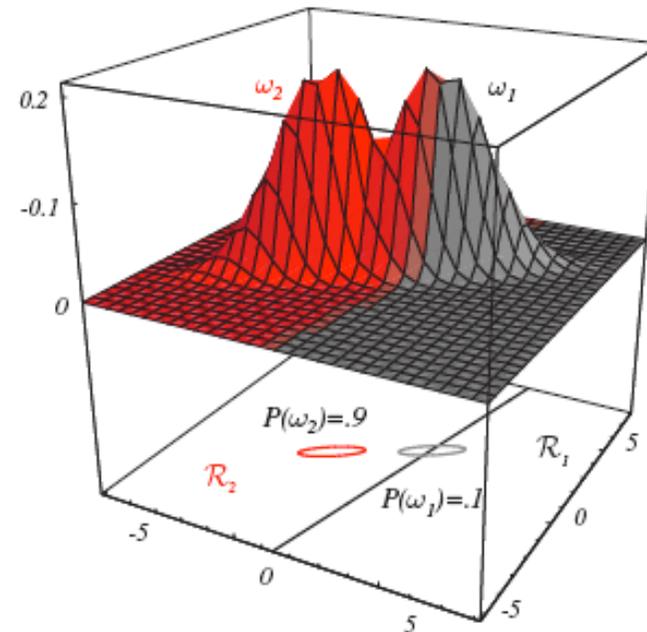
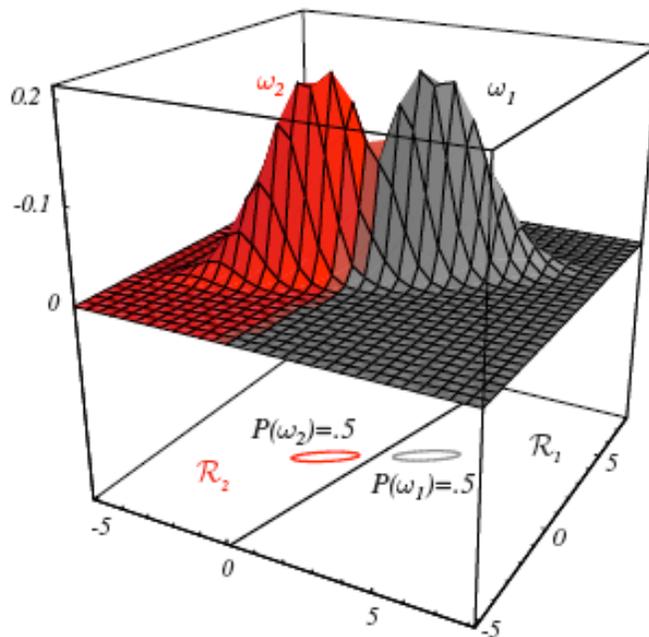
bei ungleichen A-priori-Wahrscheinlichkeiten beider Klassen

Spezialfall: beliebige, aber gleiche Kovarianzen

$$g_j(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \mu_j)^T \Sigma_j^{-1}(\mathbf{x} - \mu_j) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln \det \Sigma_j + \ln p(\omega_j)$$

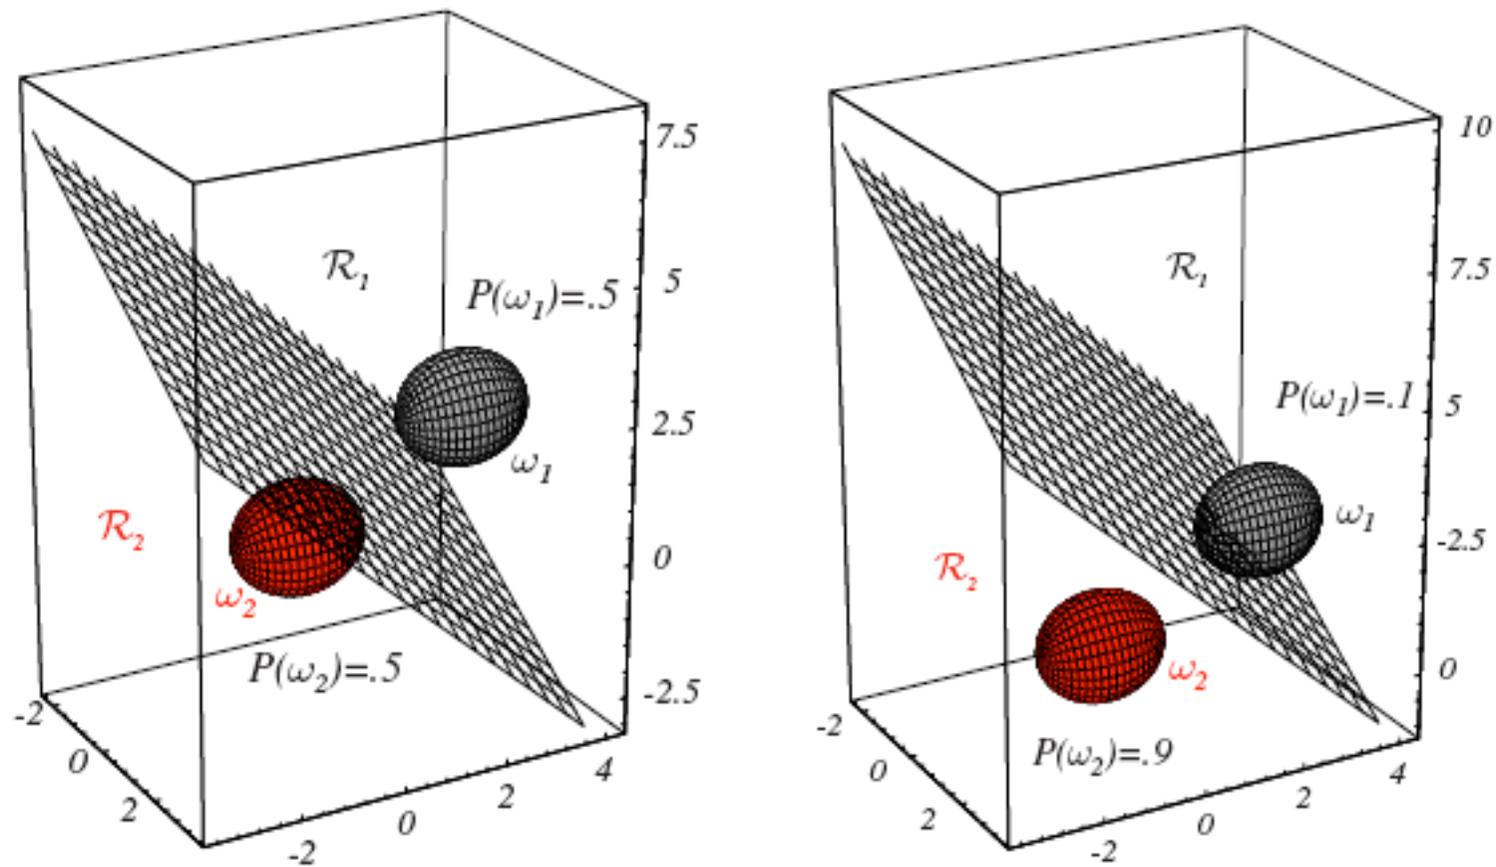
$$\Rightarrow g_j(\mathbf{x}) = -\frac{1}{2\sigma^2}(\mathbf{x} - \mu_j)^T \Sigma^{-1}(\mathbf{x} - \mu_j) + \ln p(\omega_j)$$

Läßt sich ebenfalls in eine lineare Form bringen: $g_j(\mathbf{x}) = w_j^T x + w_{j0}$



[aus Duda et al., 2001]

Spezialfall: beliebige, aber gleiche Kovarianzen (3D)



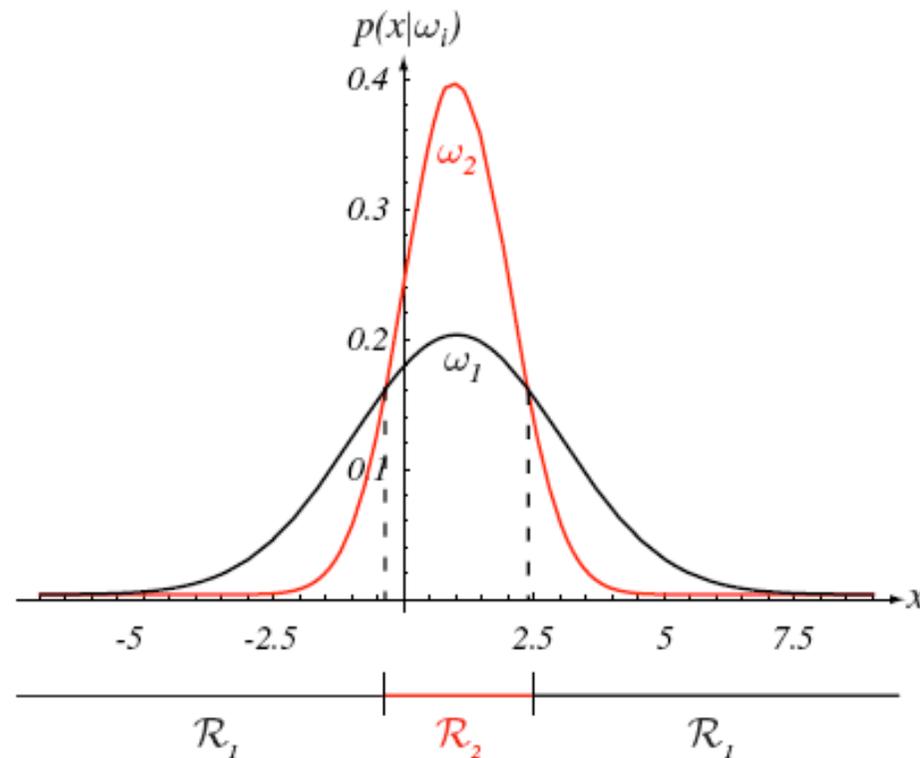
[aus Duda et al., 2001]

Trennflächen müssen nicht mehr senkrecht auf der Verbindungslinie der Klassenmittelwerte liegen

Beliebige, unterschiedliche Kovarianzen in allen Klassen

$$g_j(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1}(\mathbf{x} - \boldsymbol{\mu}_j) - \frac{d}{2} \ln 2\pi - \frac{1}{2} \ln \det \boldsymbol{\Sigma}_j + \ln p(\omega_j)$$
$$\Rightarrow g_j(\mathbf{x}) = -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1}(\mathbf{x} - \boldsymbol{\mu}_j) - \frac{1}{2} \ln \det \boldsymbol{\Sigma}_j + \ln p(\omega_j)$$

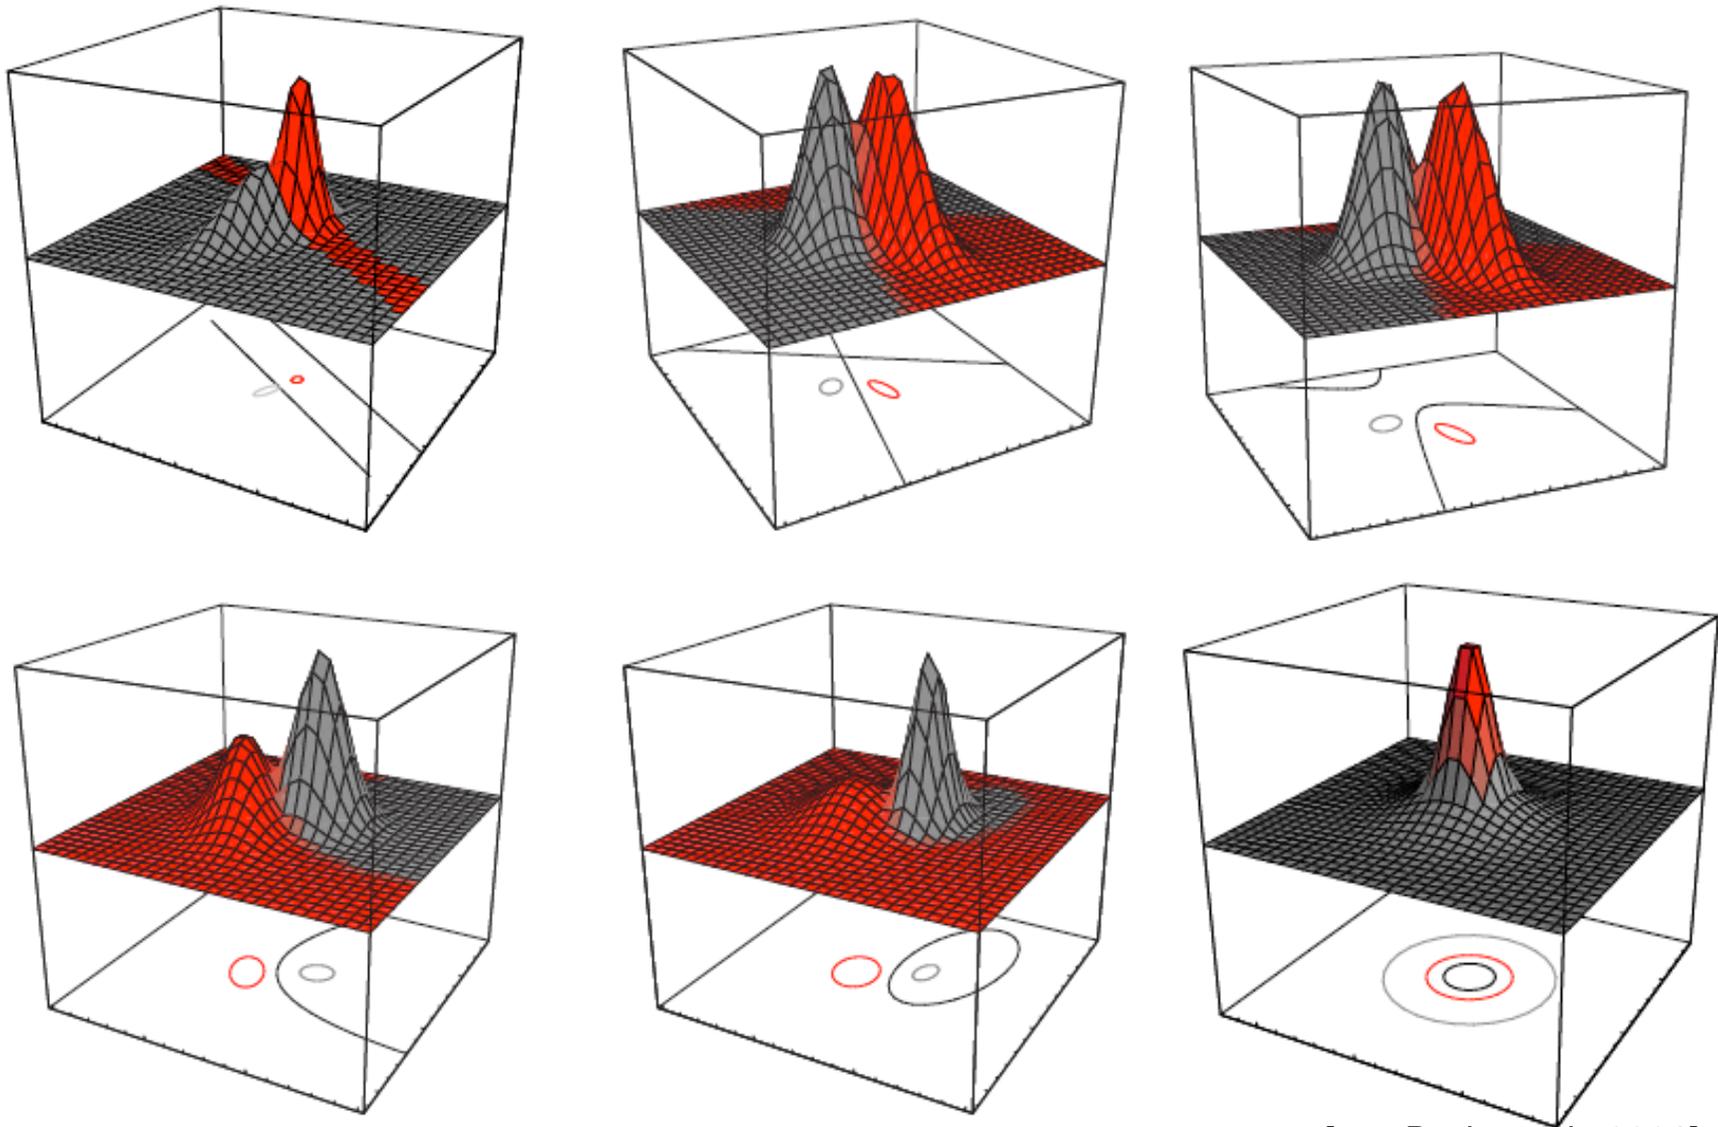
In 1 Dimension:



[aus Duda et al., 2001]

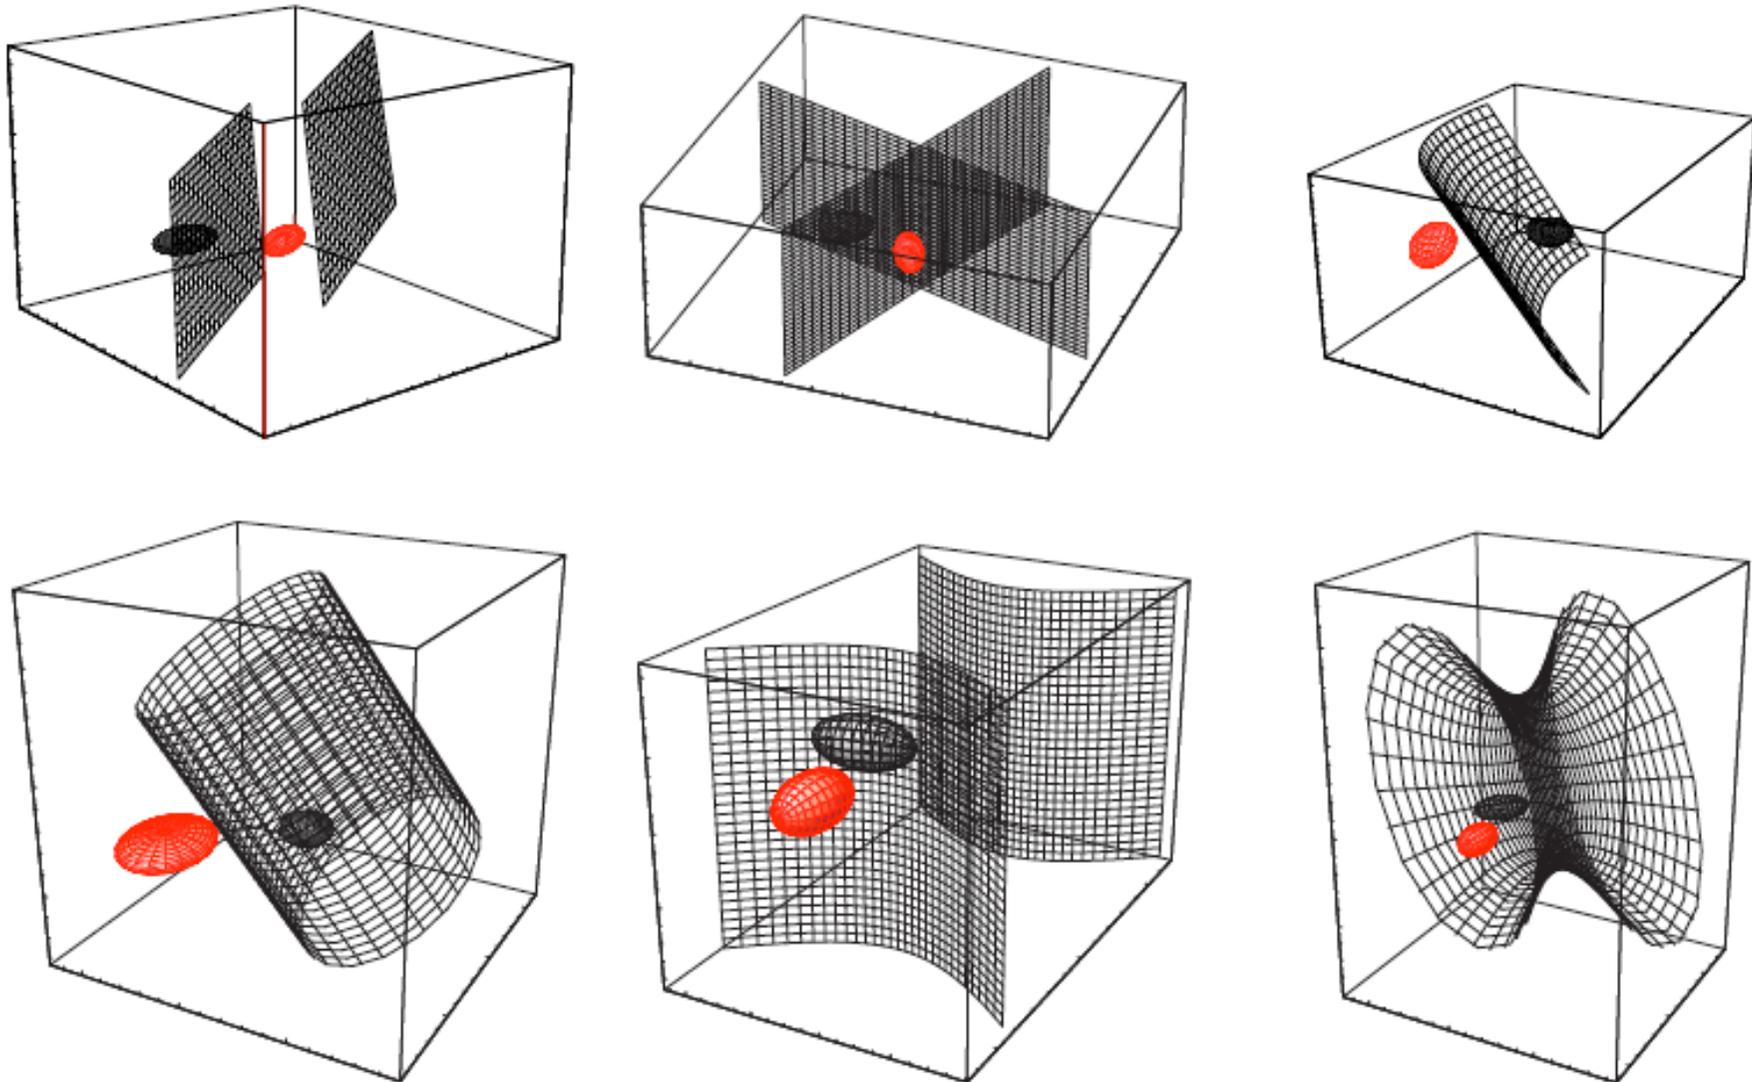
Entscheidungsregionen können aus unverbundenen Teilgebieten bestehen.

Bei 2 Kategorien: Quadriken als Trennflächen (2D)



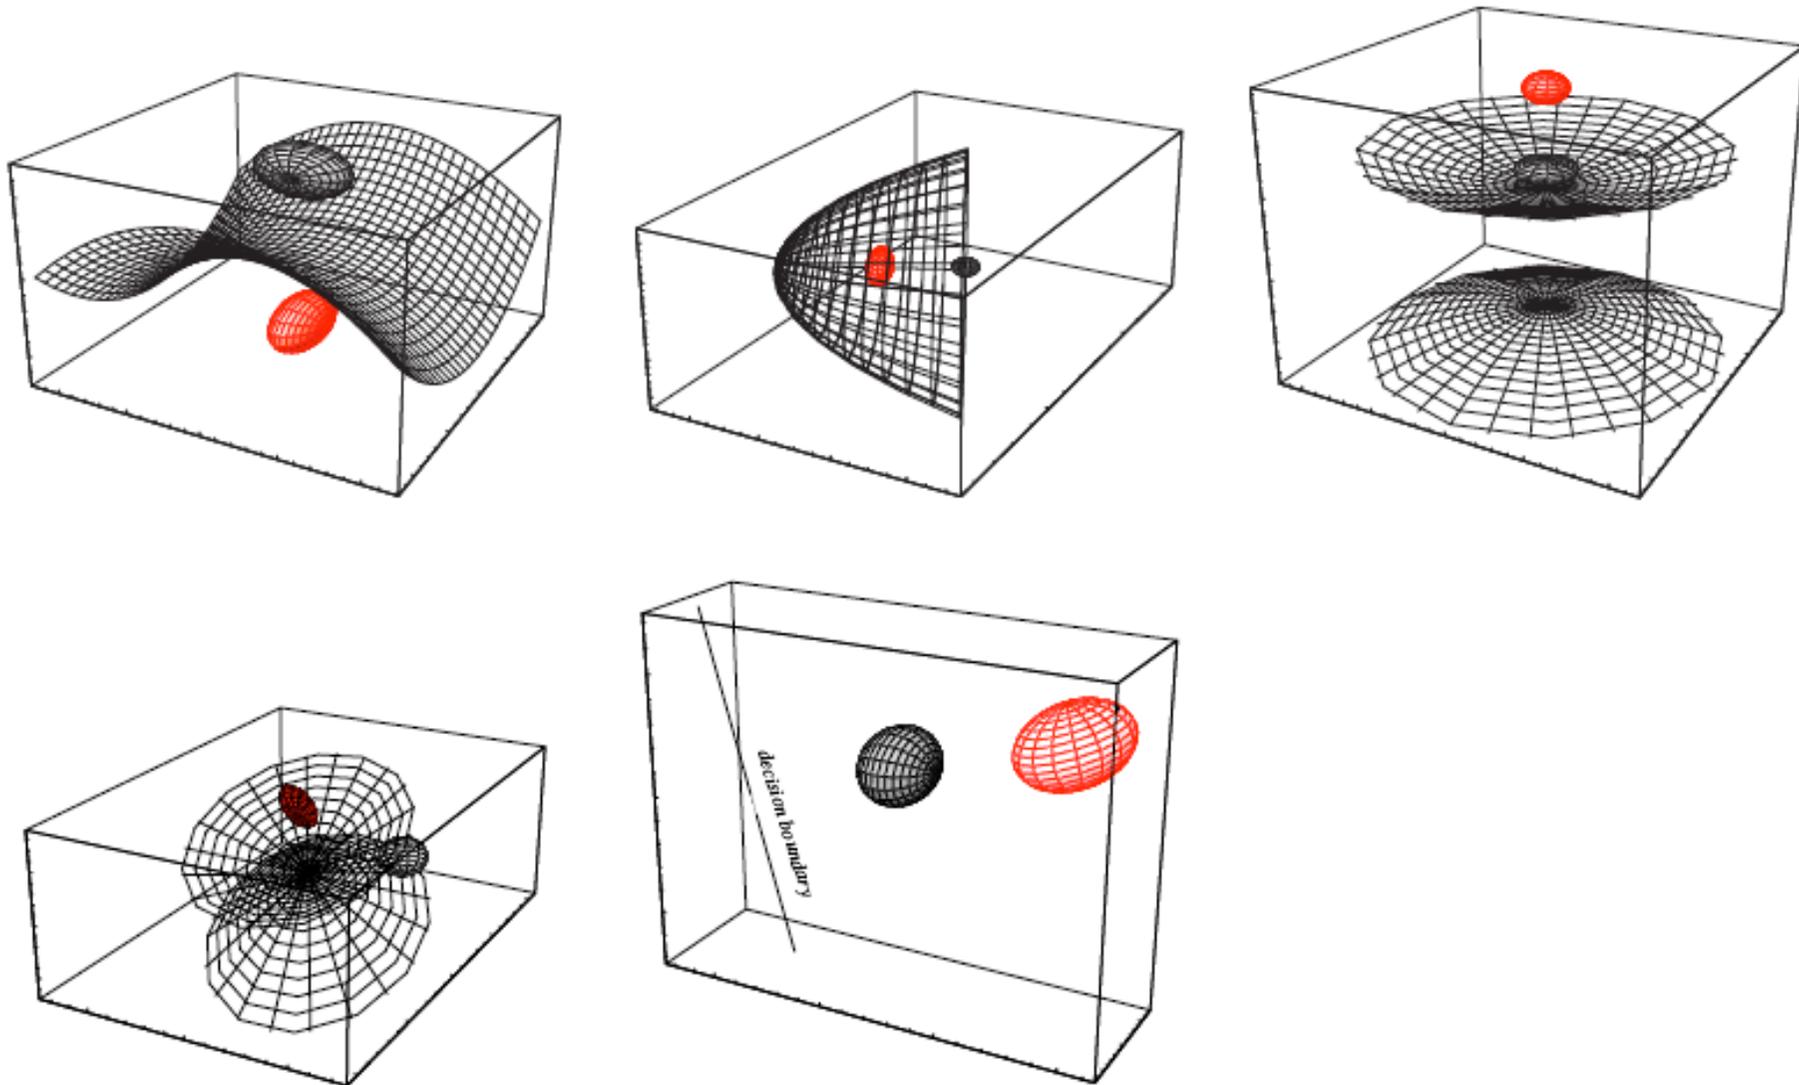
[aus Duda et al., 2001]

Bei 2 Kategorien: Quadriken als Trennflächen (3D)



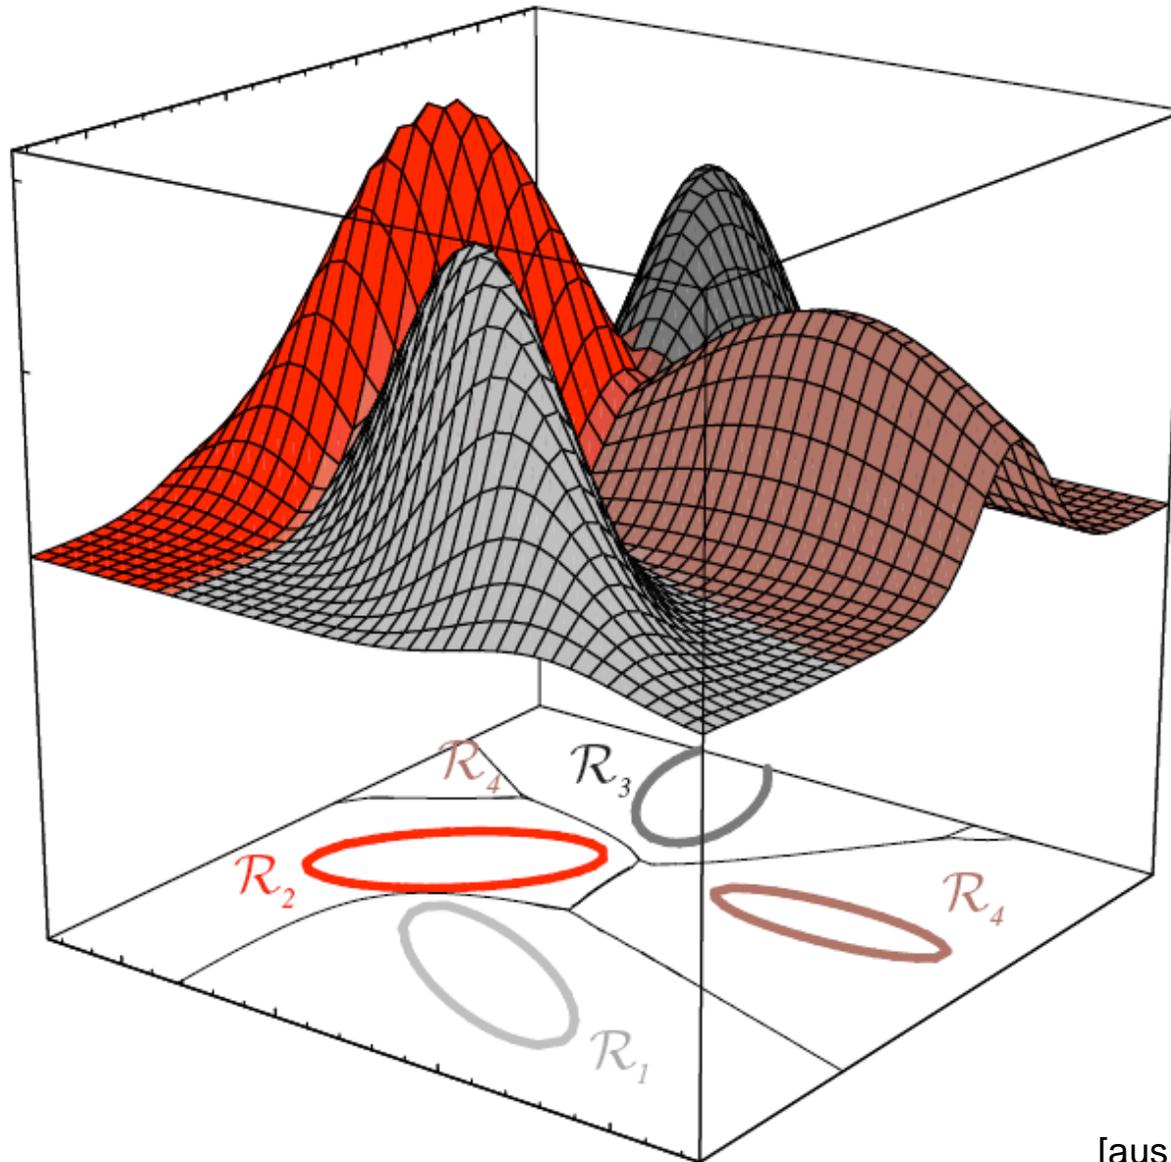
[aus Duda et al., 2001]

Bei 2 Kategorien: Quadriken als Trennflächen (3D) - 2



[aus Duda et al., 2001]

Bei mehr als 2 Kategorien...



[aus Duda et al., 2001]