

DATENGESTÜTZTE ENTSCHEIDUNGS- FINDUNG

ÜBERBLICK ÜBER MASCHINELLES LERNEN

SOMMER, SKILL, BOCKERMANN

HOCHSCHULE BOCHUM

WINTERSEMESTER 2022 / 2023

Zur Orientierung

1	2	3	4	5	6	7	8	9	10	11
27.9.	4.10.	11.10.	18.10.	25.10.	1.11.	8.11.	15.11.	22.11.	29.11.	6.12.

Einführung
Wissenschaftstheorie
Überblick: Machine Learning
Statistik: Regression
Design Thinking
fällt aus (Allerheiligen)
Wie lese ich Statistik?
Feedback-Runde (bei Bedarf)
Vortragsrunde
Feedback-Runde (bei Bedarf)
Vortragsrunde (Optional)

Zur Orientierung

1	2	3	4	5	6	7	8	9	10	11

27.9. 4.10. 11.10. 18.10. 25.10. 1.11. 8.11. 15.11. 22.11. 29.11. 6.12.

Einführung
Wissenschaftstheorie
Überblick: Machine Learning
Statistik: Regression
Design Thinking
fällt aus (Allerheiligen)
Wie lese ich Statistik?
Feedback-Runde (bei Bedarf)
Vortragsrunde
Feedback-Runde (bei Bedarf)
Vortragsrunde (Optional)

Wiederholung: **Wissenschaftstheorie**


- Erkenntnisgewinn, Hypothesen + Tests
- Explorative Analysen
- “Philosophische Einordnung”

Wiederholung: **Wissenschaftstheorie**

- Erkenntnisgewinn, Hypothesen + Tests
- Explorative Analysen
- “Philosophische Einordnung”

Literaturempfehlung


Zen und die Kunst, ein Motorrad zu warten
Robert M. Pirsig






Machine Learning?


Maschinelles Lernen ist Teilgebiet der **künstlichen Intelligenz**



Maschinelles Lernen ist Teilgebiet der **künstlichen Intelligenz**



Maschinelles Lernen ist Teilgebiet der **künstlichen Intelligenz**



Kategorien des Lernens

Überwachtes Lernen

supervised learning

- Trainingsdaten enthalten Zielvariable (z.B. Spam=Ja/Nein)
- Zielvariable oft als *Klasse*, *Label* oder *Class* bezeichnet
- Mit Trainingsdaten, unbekannte Daten vorhersagen

Unüberwachtes Lernen

unsupervised learning

- Trainingsdaten enthalten keine Zielinformation
- Unbekannte Muster/Gruppen in Daten finden

Lernaufgaben definieren Ein- und Ausgabe, sowie das Ziel der Modellierung, z.B.

“Entscheide für einen Text x ob er zur Klasse *Spam* oder zur Klasse *KeinSpam* gehört.”

Lernaufgaben definieren Ein- und Ausgabe, sowie das Ziel der Modellierung, z.B.

“Entscheide für einen Text \mathbf{x} ob er zur Klasse *Spam* oder zur Klasse *KeinSpam* gehört.”

Eingabedaten werden typischerweise in einen **Merkmalsraum** \mathcal{X} der Dimension d abgebildet

$$\mathbf{x} \in \mathcal{X} \subseteq \mathbb{R}^d$$

Die Ausgabemenge \mathcal{Y} kann eine Menge von Klassen oder eine reelle Zahl sein, z.B.

$$\mathcal{Y} = \{\text{Spam}, \text{KeinSpam}\}$$

Das Ziel besteht darin, eine Funktion (Modell) $f : \mathcal{X} \rightarrow \mathcal{Y}$ zu lernen, mit

$$f(\mathbf{x}) = \begin{cases} +1, & \text{falls } \mathbf{x} \text{ Spam Nachricht} \\ -1, & \text{sonst} \end{cases}$$

Das Ziel besteht darin, eine Funktion (Modell) $f : \mathcal{X} \rightarrow \mathcal{Y}$ zu lernen, mit

$$f(\mathbf{x}) = \begin{cases} +1, & \text{falls } \mathbf{x} \text{ Spam Nachricht} \\ -1, & \text{sonst} \end{cases}$$

Bei der **binären Klassifikation** wird häufig $\mathcal{Y} = \{-1, +1\}$ gewählt.

Das Ziel besteht darin, eine Funktion (Modell) $f : \mathcal{X} \rightarrow \mathcal{Y}$ zu lernen, mit

$$f(\mathbf{x}) = \begin{cases} +1, & \text{falls } \mathbf{x} \text{ Spam Nachricht} \\ -1, & \text{sonst} \end{cases}$$

Bei der **binären Klassifikation** wird häufig $\mathcal{Y} = \{-1, +1\}$ gewählt.

Für die **Regression** gilt $\mathcal{Y} = \mathbb{R}$.

Lern-Algorithmen erwarten Daten häufig in Form einer Tabelle:

d Merkmale					
ID	a_1	a_2	...	a_d	y
1	0	0	...	1	-1
2	0	1	...	1	+1
3	1	0	...	1	-1

$$\begin{aligned}\text{Beispiel } \mathbf{x}_2 &= (x_{a_1}, x_{a_2}, \dots, x_{a_d}, y) \\ &= (0, 1, \dots, 1, +1)\end{aligned}$$

- Beispiele werden auch *examples* oder *instances* genannt
- Merkmale (engl. *features*) werden auch *attributes* oder *Variablen* (Statistik) bezeichnet

a_1	a_2	\dots	a_d	y
0	0	\dots	1	-1
0	1	\dots	1	+1
1	0	\dots	1	-1

Trainingsdaten \mathbf{X}, \mathbf{y}

Algorithmus/
Optimierung

$f: \mathcal{X} \rightarrow \mathcal{Y}$

Modell

a_1	a_2	\dots	a_d	y
0	0	\dots	1	-1
0	1	\dots	1	+1
1	0	\dots	1	-1

Trainingsdaten \mathbf{X}, \mathbf{y} Algorithmus/
Optimierung

$$f: \mathcal{X} \rightarrow \mathcal{Y}$$

Modell

a_1	a_2	\dots	a_d	y
1	1	\dots	0	?

Neue Daten \mathbf{x}' ,
 y unbekannt

a_1	a_2	\dots	a_d	y
0	0	\dots	1	-1
0	1	\dots	1	+1
1	0	\dots	1	-1

Trainingsdaten \mathbf{X}, \mathbf{y}

Algorithmus/
Optimierung

$$f: \mathcal{X} \rightarrow \mathcal{Y}$$

Modell

a_1	a_2	\dots	a_d	y
1	1	\dots	0	?

Neue Daten \mathbf{x}' ,
 y unbekannt

Vorhersage

$$\hat{y} = f(\mathbf{x}')$$

Wie lernt ein Algorithmus?

- Algorithmus hat Klasse von Lösungen (z.B. Trenn-Ebenen)
- Lösungsraum wird parametrisiert und die beste Lösung gesucht (**Optimierungsproblem**)

Beispiel: Lineare Modelle

- Alle Ebenen in \mathcal{X} darstellbar als

$$\vec{x} \cdot \vec{n} = d \quad (\text{Hessesche Normalform})$$

- Suche $\vec{n} = (n_1, \dots, n_k)$ und d , das möglichst viele Beispiele aus \mathbf{X} richtig klassifiziert (den Trainingsfehler minimiert)

Definition von Lernaufgaben

Überwachtes Lernen

- Klassifikation
- Regression

Unüberwachtes Lernen

- Clustering
- (Outlier-Detection)
- Frequent Itemsets / Frequent Patterns

Klassifikation ordnet Beispielen diskreten Klassen zu

- Vorgegebene Klassen $\mathcal{Y} = \{C_1, \dots, C_k\}$
- Gegeben Menge $\mathbf{X} \times \mathbf{y} \subset \mathcal{X} \times \mathcal{Y}$ bei der jedem Beispiel x_i die zugehörige Klasse zugeordnet ist: (x_i, y_i)
- Qualitätsfunktion $q : (\mathcal{X} \times \mathcal{Y}) \times (\mathcal{X} \rightarrow \mathcal{Y}) \rightarrow \mathbb{R}$

Ziel:

- Finde Modell

$$f : \mathcal{X} \rightarrow \mathcal{Y},$$

das die Qualitätsfunktion optimiert.

Klassifikation ordnet Beispielen diskreten Klassen zu

- Vorgegebene Klassen $\mathcal{Y} = \{C_1, \dots, C_k\}$
- Gegeben Menge $\mathbf{X} \times \mathbf{y} \subset \mathcal{X} \times \mathcal{Y}$ bei der jedem Beispiel x_i die zugehörige Klasse zugeordnet ist: (x_i, y_i)
- Qualitätsfunktion $q : (\mathcal{X} \times \mathcal{Y}) \times (\mathcal{X} \rightarrow \mathcal{Y}) \rightarrow \mathbb{R}$

Ziel:

- Finde Modell

$$f : \mathcal{X} \rightarrow \mathcal{Y},$$

das die Qualitätsfunktion optimiert.

Lernen als Optimierungsproblem!

Beispiel: Klassifikation von Schwertlilien

- Klassen: $\mathcal{Y} = \{\text{setosa}, \text{versicolor}, \text{virginica}\}$
- Menge $\mathbf{X} \times \mathbf{y}$ mit 150 Beispiele mit Spalte "species"
- Qualitätsfunktion

$$q(\mathbf{X} \times \mathbf{y}, f) = \sum_{(x,y) \in \mathbf{X} \times \mathbf{y}} \underbrace{\text{err}(y, f(x))}_{=\hat{y}}, \quad \text{err}(y, \hat{y}) = \begin{cases} 0, & \text{falls } y = \hat{y} \\ 1, & \text{sonst.} \end{cases}$$

Beispiel: Klassifikation von Schwertlilien

- Klassen: $\mathcal{Y} = \{\text{setosa}, \text{versicolor}, \text{virginica}\}$
- Menge $\mathbf{X} \times \mathbf{y}$ mit 150 Beispiele mit Spalte "species"
- Qualitätsfunktion

$$q(\mathbf{X} \times \mathbf{y}, f) = \sum_{(x,y) \in \mathbf{X} \times \mathbf{y}} \underbrace{\text{err}(y, f(x))}_{=\hat{y}}, \quad \text{err}(y, \hat{y}) = \begin{cases} 0, & \text{falls } y = \hat{y} \\ 1, & \text{sonst.} \end{cases}$$

Funktion q zählt die Anzahl der Vorhersagefehler des Modells f auf der Menge \mathbf{X}

Beispiel: Klassifikation von Schwertlilien

- Klassen: $\mathcal{Y} = \{\text{setosa}, \text{versicolor}, \text{virginica}\}$
- Menge $\mathbf{X} \times \mathbf{y}$ mit 150 Beispiele mit Spalte "species"
- Qualitätsfunktion

$$q(\mathbf{X} \times \mathbf{y}, f) = \sum_{(x,y) \in \mathbf{X} \times \mathbf{y}} \underbrace{\text{err}(y, f(x))}_{=\hat{y}}, \quad \text{err}(y, \hat{y}) = \begin{cases} 0, & \text{falls } y = \hat{y} \\ 1, & \text{sonst.} \end{cases}$$

Funktion q zählt die Anzahl der Vorhersagefehler des Modells f auf der Menge \mathbf{X}

Ziel: Finde f^* mit minimalem $q(\mathbf{X}, f)$

Beispiel: **Klassifikation von Schwertlilien**


- Klassen: $\mathcal{Y} = \{\text{setosa}, \text{versicolor}, \text{virginica}\}$
- Menge $\mathbf{X} \times \mathbf{y}$ mit 150 Beispiele mit Spalte "species"
- Qualitätsfunktion

$$q(\mathbf{X} \times \mathbf{y}, f) = \sum_{(x,y) \in \mathbf{X} \times \mathbf{y}} \underbrace{\text{err}(y, f(x))}_{=\hat{y}}, \quad \text{err}(y, \hat{y}) = \begin{cases} 0, & \text{falls } y = \hat{y} \\ 1, & \text{sonst.} \end{cases}$$


Funktion q zählt die Anzahl der **Vorhersagefehler des Modells f auf der Menge \mathbf{X}**

Ziel: Finde f^* mit minimalem $q(\mathbf{X}, f)$ \rightarrow **Optimierungsproblem**

Beispiel: **Klassifikation von Schwertlilien**



Beispiel: Klassifikation von Schwertlilien




In diesem Fall wurde eine Trenn-Ebene als Mittelsenkrechte auf der Strecke zwischen den Schwerpunkten der Klasse setosa und versicolor bestimmt.

Einfacher Algorithmus:

Trenn-Ebene über die Klassenschwerpunkte der Attribute `sepal_length` und `sepal_width`

Beispiel: Klassifikation von Schwertlilien




In diesem Fall wurde eine Trenn-Ebene als Mittelsenkrechte auf der Strecke zwischen den Schwerpunkten der Klasse *setosa* und *versicolor* bestimmt.

Die rot umkreisten Punkte werden von der Trenn-Ebene falsch klassifiziert.

Einfacher Algorithmus:

Trenn-Ebene über die Klassenschwerpunkte der Attribute *sepal_length* und *sepal_width*

Beispiel: **Klassifikation von Schwertlilien**



Die Daten sind *linear separierbar* – eine andere Ebene schafft dies ohne Fehler.
Die Optimierung der Qualitätsfunktion sucht nach der besten Ebene.

Regression liefert reellwertige Vorhersagen

- Für Regression gilt $\mathcal{Y} = \mathbb{R}$
- Menge $\mathbf{X} \times \mathbf{y}$, d.h. jedem Beispiel x_i ist ein $y_i \in \mathbb{R}$ zugeordnet
- Qualitätsfunktion $q : (\mathcal{X} \times \mathcal{Y}) \times (\mathcal{X} \rightarrow \mathcal{Y}) \rightarrow \mathbb{R}$

Ziel:

- Finde Modell

$$f : \mathcal{X} \rightarrow \mathcal{Y},$$

das die Qualitätsfunktion optimiert.

Regression liefert reellwertige Vorhersagen

- Für Regression gilt $\mathcal{Y} = \mathbb{R}$
- Menge $\mathbf{X} \times \mathbf{y}$, d.h. jedem Beispiel x_i ist ein $y_i \in \mathbb{R}$ zugeordnet
- Qualitätsfunktion $q : (\mathcal{X} \times \mathcal{Y}) \times (\mathcal{X} \rightarrow \mathcal{Y}) \rightarrow \mathbb{R}$

Ziel:


- Finde Modell

$$f : \mathcal{X} \rightarrow \mathcal{Y},$$

das die Qualitätsfunktion optimiert.

Auch hier wieder: Lernen als Optimierungsproblem!

Beispiel: Regression




Qualitätsfunktion:

Summe der Abstände von $f(x)$ zu den “richtigen” Werten

$$q(X, f) = \sum_{(x, y) \in X} (y - f(x))^2 = \text{RSS}(X, f)$$

Beispiel: Regression



Qualitätsfunktion:

Summe der Abstände von $f(x)$ zu den "richtigen" Werten

$$q(X, f) = \sum_{(x, y) \in X} (y - f(x))^2 = \text{RSS}(X, f)$$

Residual Sum of Squares

Clustering sucht Aufteilung von Daten in ähnliche Gruppen


- Datenmenge \mathbf{X} von Beispielen (keine Klassen gegeben!)
- Parameter k zu findender Gruppen
- Abstandsmaß $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$
- Qualitätsfunktion q

Ziel:

- Abstand *innerhalb* der Gruppen soll minimiert, Abstand *zwischen* den Gruppen soll maximiert werden

Beispiel: Clustering

Sei $\mathbf{C} = C_1, \dots, C_k$ eine Aufteilung der Daten X (ein *Clustering*)




Qualitätsfunktion: (Innere Abstände)

$$q_{inner}(\mathbf{C}) = \sum_{i=1}^k \sum_{x \in C_i} d(x, \bar{c}_i) \quad , \text{ mit } \bar{c}_i \text{ Zentrum von } C_i$$

Beispiel: Clustering

Sei $\mathbf{C} = C_1, \dots, C_k$ eine Aufteilung der Daten X (ein *Clustering*)



Clustering auf Datenpunkten mit $k = 4$. Die schwarzen Kreise markieren jeweils das Zentrum \bar{c}_i des jeweiligen Cluster C_i .

Qualitätsfunktion: (Innere Abstände)

$$q_{inner}(\mathbf{C}) = \sum_{i=1}^k \sum_{x \in C_i} d(x, \bar{c}_i) \quad , \text{ mit } \bar{c}_i \text{ Zentrum von } C_i$$

Beispiel: Clustering

- Clustering unter mehreren Qualitätsaspekten:

$$q_{inner}(\mathbf{C}) = \sum_{i=1}^k \sum_{x \in C_i} d(x, \bar{\mathbf{c}}_i) \quad \longrightarrow \text{Minimieren}$$

$$q_{outer}(\mathbf{C}) = \sum_{i=1}^k \sum_{x \in C_j, j \neq i} d(x, \bar{\mathbf{c}}_i) \quad \longrightarrow \text{Maximieren}$$


Outlier-Detection sucht nach *isolierten* Punkten

- Gegen ist Datensatz \mathbf{X} (keine Label)
- i.d.R. noch Abstandsmaß $d : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$


Ziel:

- Finde Punkte, die *weit weg* von allen anderen Punkten liegen

Beispiel: **Outlier-Detection**




Beispiel: Outlier-Detection



Die rot markierten Punkte sind Ausreißer die im Abstand von $d = 0.35$ keine Nachbarnpunkte haben.

Beispiel: Outlier-Detection



Die rot markierten Punkte sind Ausreißer die im Abstand von $d = 0.35$ keine Nachbarpunkte haben.

Unterschiedliche Ansätze für Ausreißer-Erkennung:

- Vorgabe des minimalen Abstandes zu Nachbarn (siehe oben)
- Dichte-basiert - Verteilung der Abstände
- Über Mini-Clustering (ganz viele kleine Cluster finden)

Frequent Itemset Mining sucht häufige Muster

- Gegeben ist Menge \mathbf{S} von Symbolen (z.B. Artikel)
- Eingabe ist Menge \mathbf{X} von Transaktionen (Einkäufe) über \mathbf{S}

$$\mathbf{X} = \{x \mid x \subseteq \mathbf{S}\}$$

Ziel:

- Fragestellung: Welche Symbole tauchen häufig zusammen auf?
- Finde die Muster $p \in \mathcal{P}(\mathbf{S})$ die in \mathbf{X} am häufigsten vorkommen

Beispiel: Frequent Itemsets auf Einkäufen

ID	Artikel
1	{ A, B, F }
2	{ B, D, E, F }
3	{ C, E }
4	{ B, E, F }
5	{ A, B, E }

Beispiel: Frequent Itemsets auf Einkäufen

ID	Artikel
1	{ A, B, F }
2	{ B, D, E, F }
3	{ C, E }
4	{ B, E, F }
5	{ A, B, E }

- Artikel B = Muster { B } taucht in 4/5 der Einkäufe auf

Beispiel: Frequent Itemsets auf Einkäufen

ID	Artikel
1	{ A, B, F }
2	{ B, D, E, F }
3	{ C, E }
4	{ B, E, F }
5	{ A, B, E }

- Artikel B = Muster { B } taucht in 4/5 der Einkäufe auf
- Muster { B, F } taucht in 3/5 aller Einkäufe auf


Beispiel: Frequent Itemsets auf Einkäufen

ID	Artikel
1	{ A, B, F }
2	{ B, D, E, F }
3	{ C, E }
4	{ B, E, F }
5	{ A, B, E }

- Artikel B = Muster { B } taucht in 4/5 der Einkäufe auf
- Muster { B, F } taucht in 3/5 aller Einkäufe auf

Welche Artikel werden häufig zusammen gekauft?





Was hat das mit Sternen zu tun?

Machine Learning als Werkzeug

- Hypothesen für Forschungsfragestellung
- Experimente zur Überprüfung der Hypothesen
- Datenanalyse zur Beantwortung auf Basis der Experimentergebnisse


Machine Learning als Werkzeug

- Hypothesen für Forschungsfragestellung
- Experimente zur Überprüfung der Hypothesen
- Datenanalyse zur Beantwortung auf Basis der Experimentergebnisse

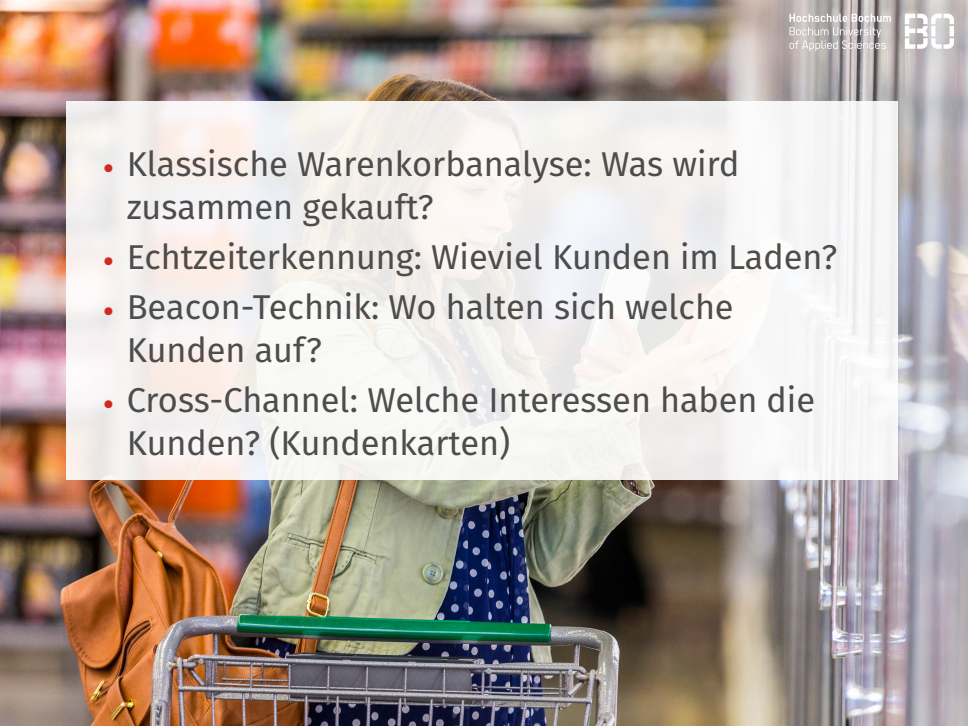
Betriebswirtschaftliche Anwendungen?

- Entscheidungshilfe für Strategie/Budgetierung?
- Was sind die Zielsetzungen?





Welche Lernaufgabe?

- 
- A woman with brown hair, wearing a light green jacket over a blue polka-dot dress, is pushing a silver shopping cart with a green handle. She is looking down at a smartphone in her hands. The background is a blurred supermarket aisle with shelves of products.
- Klassische Warenkorbanalyse: Was wird zusammen gekauft?
 - Echtzeiterkennung: Wieviel Kunden im Laden?
 - Beacon-Technik: Wo halten sich welche Kunden auf?
 - Cross-Channel: Welche Interessen haben die Kunden? (Kundenkarten)

hugo boss bottled - Google-Su x +

https://www.google.com/search?q=hugo+boss+bottled&oq=hugo+boss+...

Google hugo boss bottled

Alle Shopping Bilder Videos News Mehr Einstellungen Tools


Ungefähr 6.320.000 Ergebnisse (0,47 Sekunden)

HUGO BOSS - BOSS Bottled | Duft für Herren | HugoBoss.com
[Anzeige](#) www.hugoboss.com/ ▾
 4,9 ★★★★★ Bewertung für hugoboss.com
BOSS Bottled, die Verkörperung von **BOSS** in einem Duft. Der Kult-Klassiker! Kostenloser Versand. Kostenlose Rücksendung. Offizielle **HUGO BOSS** Site. Typen: Deo-Spray, Deo-Stick, Geschenk-Set. [HUGO BOSS Düfte · Düfte für Damen · BOSS The Scent Intense](#)

Hugo Boss bei Douglas | 2 Gratis-Proben Ihrer Wahl | douglas.de
[Anzeige](#) www.douglas.de/Hugo-Boss ▾
 4,7 ★★★★★ Bewertung für douglas.de
 Versandkostenfrei ab 25€ / Gratis Geschenkverpackung / Beauty Card Prämien. Gratis-Versand ab 25€. 2 Gratis-Proben. Kauf auf Rechnung. Über 40.000 Markenartikel. 1-3 Tage Lieferzeit. [Dauerhaft reduziert % · Douglas Collection: -20% · Happy Women's Day · Douglas Beauty Card](#)

Hugo Boss Bottled Parfum kaufen » bis zu -58% sparen
[Anzeige](#) www.easycosmetic.de/ ▾
 Markenkosmetik reduziert & schnell · Trusted-Shops Garantie · Retour gratis

Boss Bottled für Herren bei Flaconi kaufen - flaconi.de
[Anzeige](#) www.flaconi.de/ ▾
 Schnelle Lieferung in 1-2 Tagen. Jetzt bestellen und zwei Gratisproben sichern! Kauf auf Rechnung.

Boss Bottled Eau de Toilette ... 

4,8 ★★★★★ (5745)

Einkaufen Anzeigen

200 ml ▾

64,95 € · [Douglas.de](#) · [Von Adference Shopping](#)
 32,48 € / 100 ml, versand gratis

64,95 € · [Flaconi.de](#) · [Von Google](#)
 32,48 € / 100 ml, versand gratis

39,99 € · [Sephora.de](#) · [Von Google](#)
 Versand gratis

53,99 € · [easycosmetic.DE](#) · [Von Google](#)
 27,00 € / 100 ml, +3,99 € versand

hugo boss bottled - Google-Su x +

https://www.google.com/search?q=hugo+boss+bottled&oq=hugo+boss+...

Google hugo boss bottled

Alle Shopping Bilder Videos News Mehr Einstellungen Tools


Ungefähr 6.320.000 Ergebnisse (0,47 Sekunden)

Wieviel € bieten Sie für Platz 1?

Hugo Boss bei Douglas | 2 Gratis-Proben Ihrer Wahl | douglas.de
[Anzeige](#) www.douglas.de/Hugo-Boss ▼
4,7 ★★★★★ Bewertung für douglas.de
Versandkostenfrei ab 25€ / Gratis Geschenkverpackung / Beauty Card Prämien. Gratis-Versand ab 25€. 2 Gratis-Proben. Kauf auf Rechnung. Über 40.000 Markenartikel. 1-3 Tage Lieferzeit.
Dauerhaft reduziert % - Douglas Collection: -20% - Happy Women's Day - Douglas Beauty Card

Hugo Boss Bottled Parfum kaufen » bis zu -58% sparen
[Anzeige](#) www.easycosmetic.de/ ▼
Markenkosmetik reduziert & schnell - Trusted-Shops Garantie - Retour gratis

Boss Bottled für Herren bei Flaconi kaufen - flaconi.de
[Anzeige](#) www.flaconi.de/ ▼
Schnelle Lieferung in 1-2 Tagen. Jetzt bestellen und zwei Gratisproben sichern! Kauf auf Rechnung.

Boss Bottled Eau de Toilette ...
4,8 ★★★★★ (5745) 

Einkaufen Anzeigen

200 ml ▼

64,95 € · Douglas.de · Von Adference Shopping
32,48 € / 100 ml, versand gratis

64,95 € · Flaconi.de · Von Google
32,48 € / 100 ml, versand gratis

39,99 € · Sephora.de · Von Google
Versand gratis

53,99 € · easycosmetic.DE · Von Google
27,00 € / 100 ml, +3,99 € versand

Was wissen wir über die Besucher/Kunden?

# 12 M	€ 12 M	Class	Budget
4	948.33	High	10 €
3	402.25	Mid	5 €
5	1210.89	High	20 €
4	423.43	Mid	5 €
1	89.99	Low	0 €
1	125.37	Low	0 €

Was wissen wir über die Besucher/Kunden?

# 12 M	€ 12 M	Class	Budget	Schoki
4	948.33	High	10 €	X
3	402.25	Mid	5 €	
5	1210.89	High	20 €	X
4	423.43	Mid	5 €	X
1	89.99	Low	0 €	
1	125.37	Low	0 €	



Was wissen wir über die Besucher/Kunden?

# 12 M	€ 12 M	Class	Budget
4	948.33	High	10 €
3	402.25	Mid	5 €
5	1210.89	High	20 €
4	423.43	Mid	5 €
1	89.99	Low	0 €
1	125.37	Low	0 €

Schoki	Katzen
X	X
X	X
X	X
	X
	X



Was wissen wir über die Besucher/Kunden?

# 12 M	€ 12 M	Class	Budget
4	948.33	High	10 €
3	402.25	Mid	5 €
5	1210.89	High	20 €
4	423.43	Mid	5 €
1	89.99	Low	0 €
1	125.37	Low	0 €

Schoki	Katzen	Hugo B
X	X	X
		X
X	X	X
X	X	X
	X	
	X	

