



**Universität
Zürich** ^{UZH}

Institut für Betriebswirtschaftslehre

Service Management: Operations, Strategie und e-Services

Prof. Dr. Helmut M. Dietl



Übersicht

1. **Nachfrageprognose**
2. Variabilitätsmanagement und Service-Profit-Chain
3. Servicedesign, Serviceinnovation und Prozessanalyse
4. Projektmanagement
5. Qualitätsmanagement
6. Management von Service-Plattformen
7. Yield Management
8. Ökonomie und Psychologie von Warteschlangen
9. Warteschlangenmodelle



Lernziele

Nach dieser Veranstaltung sollten Sie

- die wichtigsten Prognosemethoden kennen
- Delphi-Befragungen und Cross-Impact Analysen durchführen können
- lineare Regressionen erstellen können
- Zeitreihenmethoden anwenden können
- die Vor- und Nachteile der verschiedenen Prognosemethoden beurteilen können
- für jede Prognosesituation die geeignete Prognosemethode auswählen können



Prognosemethoden

- Subjektive Verfahren
 - Delphi Methode
 - Cross-Impact Analyse
 - Historische Analogie
- Kausalmodelle
 - Regressionsmodelle
 - Ökonometrische Modelle
- Zeitreihenmodelle
 - Methode der gleitenden Durchschnitte
 - Exponentielle Glättung



Kurzübersicht

- Subjektive Verfahren
 - Delphi Methode
 - Cross-Impact Analyse
 - Historische Analogie
- Einsatz:
 - Geringe Datenverfügbarkeit oder
 - Daten nicht stabil über einen längeren Zeitraum



Subjektive Verfahren

Delphi Methode

- Experten werden bzgl. ihrer Zukunftseinschätzung befragt
- Ergebnisse werden zusammengefasst und den befragten Experten mitgeteilt
- Anschließend werden die Experten gebeten, neue Schätzungen abzugeben
- Diejenigen Experten, deren Meinungen stark vom Durchschnitt abweichen, werden gebeten, Ihre Einschätzung zu begründen
- Evtl. Wiederholung über mehrere Befragungs- und Auswertungsrunden



Subjektive Verfahren

Cross-Impact Analyse

- Zugrunde liegende Annahme: zukünftige Ereignisse korrelieren mit vergangenen Ereignissen
- Schätzung der unbedingten Wahrscheinlichkeiten
- Experten werden zunächst hinsichtlich ihrer Korrelationseinschätzung zu verschiedenen Ereignissen befragt
- Falls die geschätzten unbedingten Wahrscheinlichkeiten mit den bedingten Wahrscheinlichkeiten der ermittelten Korrelationsmatrix nicht übereinstimmen, werden die Experten hierüber informiert und um eine Anpassung ihrer Einschätzung gebeten
- Evtl. mehrere Iterationsschritte



Subjektive Verfahren

Historische Analogie

- Zugrunde liegende Annahme: Die Nachfrageentwicklung bei neuen Dienstleistungen verläuft in Analogie zur Nachfrage nach ähnlichen, bereits eingeführten Dienstleistungen
- Beispiel: Nachfrageentwicklung bei Internetanschlüssen erfolgt in historischer Analogie zur Nachfrageentwicklung bei Telefonanschlüssen




Kurzübersicht

- Kausalmodelle
 - Regressionsmodelle
 - Ökonometrische Modelle
- Einsatz
 - Grosse Datenverfügbarkeit und
 - Daten stabil über längeren Zeitraum und
 - Auswahl relevanter Information aus gesamter Datenmenge nötig

Kausalmodelle

Einfache lineare Regression

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

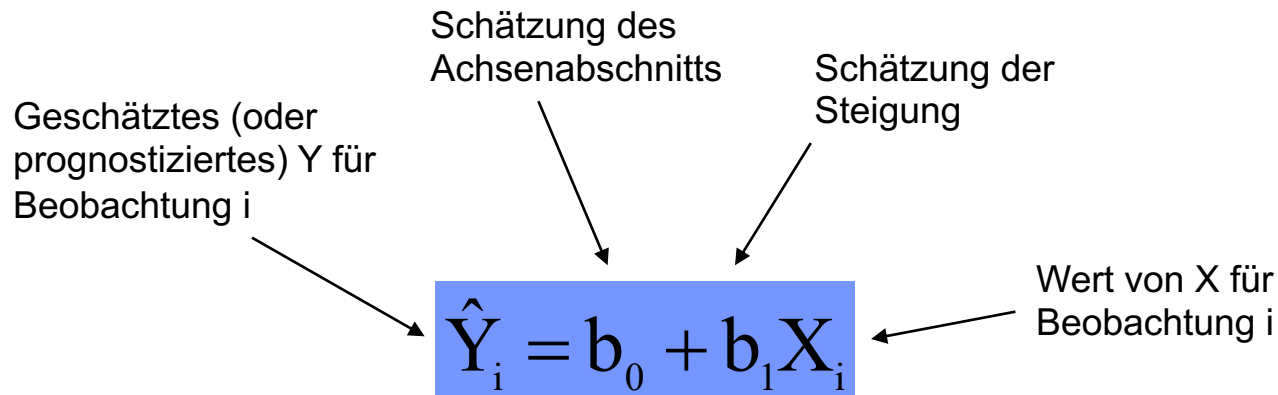




Kausalmodelle

Lineare Regressionsgleichung

Die lineare Regressionsgleichung ermittelt eine Schätzung der wahren Regressionsgleichung einer Population.





Kausalmodelle

Ordinary least squares (OLS)

Um b_0 und b_1 zu erhalten, werden die Differenzen zwischen dem wahren Wert Y_i und der Schätzung \hat{Y}_i für alle Beobachtungen quadriert, aufsummiert und dann minimiert.

$$\min \sum (Y_i - \hat{Y}_i)^2 = \min \sum (Y_i - (b_0 + b_1 X_i))^2$$

Dafür erhalten wir:

$$b_0 = \bar{Y} - b_1 \bar{X}$$

$$b_1 = \frac{\sum X_i Y_i - n \bar{Y} \bar{X}}{\sum X_i^2 - n \bar{X}^2}$$



Kausalmodelle

Beispiel: Lineare Regression (1/3)

Ziel ist die Ermittlung des Einflusses der Werbeausgaben auf den Umsatz

Firma i	Werbeausgaben (in 1'000)	Umsatz (in 100'000)
1	10	36
2	20	44
3	30	53
4	40	62
5	50	75
6	60	75
7	70	82



Kausalmodelle

Beispiel: Lineare Regression (2/3)

X_i	Y_i	$X_i Y_i$	X_i^2
10	36	360	100
20	44	880	400
30	53	1590	900
40	62	2480	1600
50	75	3750	2500
60	75	4500	3600
70	82	5740	4900
280	427	19300	14000



Kausalmodelle

Beispiel: Lineare Regression (3/3)

$$\bar{Y} = \frac{427}{7} = 61$$

$$\bar{X} = \frac{280}{7} = 40$$

$$b_1 = \frac{\sum X_i Y_i - n \bar{Y} \bar{X}}{\sum X_i^2 - n \bar{X}^2} = \frac{19300 - 7 * 61 * 40}{14000 - 7 * 1600} = 0.79$$

$$b_0 = \bar{Y} - b_1 \bar{X} = 61 - 0.79 * 40$$

Somit lautet die geschätzte Regressionsgerade

$$\hat{Y}_i = b_0 + b_1 X_i = 29.4 + 0.79 * X_i$$



Kausalmodelle

Das multivariate Regressionsmodell

- Das multivariate Regressionsmodell ist die allgemeine Form der einfachen linearen Regression
- Analog werden hier ein wahres Modell und eine Schätzung des wahren Zusammenhangs betrachtet
- Das Vorgehen bei der Schätzung und der Ermittlung der Koeffizienten verläuft analog zur einfachen linearen Regression

Ökonometrische Modelle

- Gleichungssysteme basierend auf einfachen Regressionsmodellen: mehrere abhängige Variablen werden durch verschiedene unabhängige Variablen erklärt
- Grosse Datenmengen nötig, daher sehr aufwendig



Kurzübersicht

- Zeitreihenmodelle
 - Methode der gleitenden Durchschnitte
 - Exponentielle Glättung
- Einsatz
 - Sinnvoll bei kurzfristigen Prognosen wenn die Beobachtungswerte stabilen und klaren Mustern folgen
 - Anpassung von Prognosen an spezifische Einflussgrößen möglich (z.B. Trends, Saisoneffekte)



Zeitreihenmodelle

Gleitender Durchschnitt mit N Perioden

Ziel: Vorhersage der Nachfrage auf Basis vergangener Beobachtungen

$$MA_t = \frac{A_t + A_{t-1} + A_{t-2} + \dots + A_{t-N+1}}{N}$$

MA_t = Gleitender N-Perioden-Durchschnitt am Ende der Periode t

A_t = Wert für Periode t

Eigenschaften

- Man benötigt N Beobachtungen
- Alle Beobachtungen werden gleich gewichtet
- Beobachtungen, die mehr als N Perioden zurückliegen, werden ignoriert



Zeitreihenmodelle

Beispiel gleitender Durchschnitt

Zimmerauslastung an Samstagen (100 Zimmer-Hotel)

Datum	Periode	Auslastung in %	Gleitender Durchschnitt (3 Perioden)	Prognose
August 1	1	79		
8	2	84		
15	3	83	82	
22	4	81	83	82
29	5	98	87	83
September 5	6	100	93	87
12	7			93



Zeitreihenmodelle

Exponentielle Glättung

Ziel: Vorhersage der Nachfrage auf Basis vergangener Beobachtungen unter Berücksichtigung früherer Prognosefehler

S_t = exponentiell geglätteter Wert am Ende von Periode t

A_t = tatsächlicher Wert der Periode t

F_{t+1} = Prognose für Periode $t+1$

$$S_t = S_{t-1} + \alpha[A_t - S_{t-1}]$$

$$S_t = \alpha A_t + (1 - \alpha)S_{t-1}$$

$$F_{t+1} = S_t$$



Zeitreihenmodelle

Beispiel exponentielle Glättung für $\alpha = 0.5$ (1/2)

Zimmerauslastung an Samstagen (100 Zimmer-Hotel)

Samstag	Periode t	Belegung A_t	Geglättete Belegung S_t	Prognose F_t	Prognosefehler $ A_t - F_t $
01.08.	1	79	79.00		
08.08.	2	84	81.50	79	5
15.08.	3	83	82.25	82	1
22.08.	4	81	81.63	82	1
29.08.	5	98	89.81	82	16
05.09.	6	100	94.91	90	10
12.09.	7			95	



Zeitreihenmodelle

Beispiel exponentielle Glättung für $\alpha = 0.5$ (2/2)

Periode 2:

$$\begin{aligned} S_2 &= S_1 + \alpha(A_2 - S_1) \\ &= 79 + 0.5(84 - 79) \\ &= 81.5 \end{aligned}$$

Damit ist die Prognose für $t=3$: 82 Zimmer werden belegt sein.



Zeitreihenmodelle

Exponentielle Glättung: Implizite Gewichtung

Durch Ersetzen von:

$$S_t = \alpha A_t + (1 - \alpha) S_{t-1}$$

$$S_{t-1} = \alpha A_{t-1} + (1 - \alpha) S_{t-2}$$

$$S_t = \alpha A_t + (1 - \alpha) [\alpha A_{t-1} + (1 - \alpha) S_{t-2}]$$

$$S_t = \alpha A_t + \alpha(1 - \alpha) A_{t-1} + (1 - \alpha)^2 S_{t-2} \quad \text{usw.}$$

erhält man:

$$S_t = \alpha A_t + \alpha(1 - \alpha) A_{t-1} + \alpha(1 - \alpha)^2 A_{t-2} + \dots + \alpha(1 - \alpha)^{t-1} A_1 + (1 - \alpha)^t S_0$$

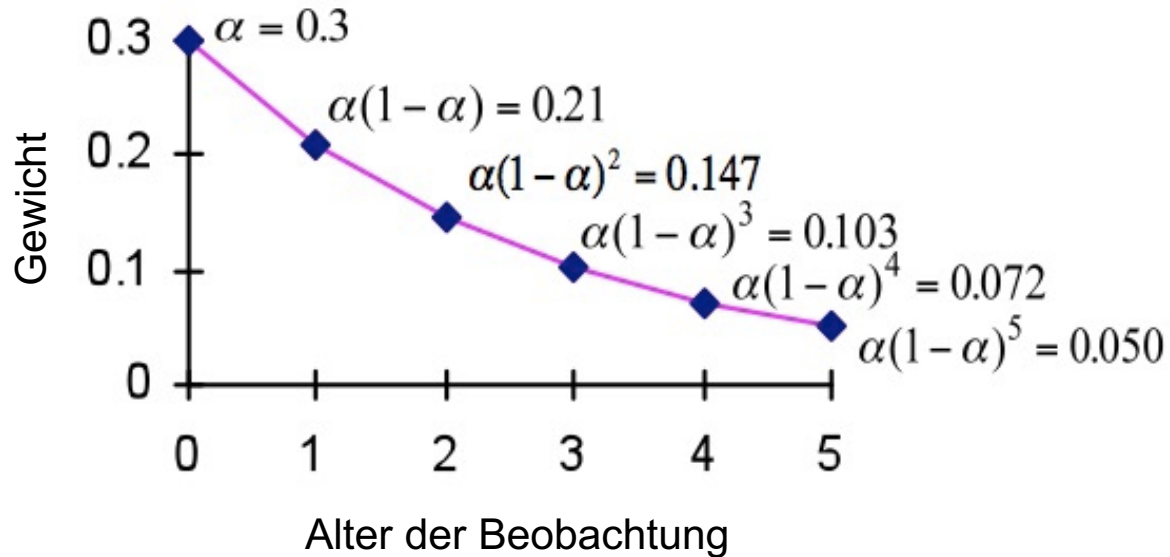
→ Die Gewichte vergangener Beobachtungen werden umso kleiner, je weiter ein Wert, der zur Prognose eingesetzt wird, in der Vergangenheit liegt.



Zeitreihenmodelle

Exponentielle Glättung:

Illustration Gewichtsverteilung am Beispiel $\alpha = 0.3$





Zeitreihenmodelle

Wahl von α : Weg 1

- Durchschnittliches Alter bei gleitendem Durchschnitt: $\frac{N-1}{2}$
- Durchschnittliches Alter bei exponentieller Glättung: $\frac{1-\alpha}{\alpha}$
- Gleichsetzen der durchschnittlichen Alter ergibt: $\alpha = \frac{2}{N+1}$

Zusammenhang zwischen α und N:

α :	0.05	0.1	0.2	0.3	0.4	0.5	0.67
N:	39	19	9	5.7	4	3	2



Zeitreihenmodelle

Wahl von α : Weg 2

- Minimierung der durchschnittlichen absoluten Abweichungen (mean absolute deviation)

$$\text{MAD} = \frac{\sum_t^n |A_t - F_t|}{n}$$

Wahl von α : Weg 3

- Eine weitere Option stellt die Minimierung der durchschnittlichen quadrierten Fehler dar (mean squared error)

$$\text{MSE} = \frac{\sum_t^n (A_t - F_t)^2}{n}$$



Zeitreihenmodelle

Wahl von α : Weg 4


- Eine weitere Option stellt die Minimierung der durchschnittlichen absoluten prozentualen Fehler dar (mean absolute percentage error)

$$\text{MAPE} = \frac{\sum_t^n \frac{|A_t - F_t|}{A_t}}{n} (100)$$

Zeitreihenmodelle

Beispiel exponentielle Glättung: Hotelbelegung

- Effekt von Alpha ($\alpha = 0.1$ vs. $\alpha = 0.5$)



- Wahl von α unterliegt dem Trade-Off zwischen einer Überreaktion auf zufällige Veränderungen und dem Erkennen einer permanenten Veränderung



Zeitreihenmodelle

Exponentielle Glättung mit Trendanpassung

Ziel ist die Vorhersage der Nachfrage an Hand exponentieller Glättung unter Berücksichtigung eines zeitlichen Trends

S_t = exponentiell geglätteter Wert am Ende von Periode t

A_t = Wert der Periode t

T_t = Trend der Periode t

F_{t+1} = Prognose für Periode $t+1$

$$S_t = \alpha(A_t) + (1 - \alpha)(S_{t-1} + T_{t-1})$$

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

$$F_{t+1} = S_t + T_t$$



Zeitreihenmodelle

Exponentielle Glättung mit Trendanpassung: Beispiel (1/2)

Flugzeugauslastung ($\alpha = 0.5$; $\beta = 0.3$)

Woche t	Auslastung in % A_t	Geglätteter Wert S_t	Geglätteter Trend T_t	Prognose F_t	Prognosefehler $ A_t - F_t $
1	31	31.00	0.00		
2	40	35.50	1.35	31.00	9.00
3	43	39.93	2.27	36.85	6.15
4	52	47.10	3.74	42.20	9.20
5	49	49.92	3.47	50.84	1.84
6	64	58.69	5.06	53.39	10.61
7	58	60.88	4.20	63.75	5.75
8	68	66.54	4.63	65.07	2.93

MAD 6.50



Zeitreihenmodelle

Exponentielle Glättung mit Trendanpassung: Beispiel (2/2)

Woche 3:

$$\begin{aligned} S_2 &= (0.5)(40) + (1 - 0.5)(31 + 0) \\ &= 35.5 \end{aligned}$$

$$\begin{aligned} T_2 &= (0.3)(35.5 - 31) + (1 - 0.3) \cdot 0 \\ &= 1.35 \end{aligned}$$

$$F_3 = 35.5 + 1.35 = 36.85$$

Damit ist die Prognose für $t=3$: Der Auslastungsgrad in Woche 3 wird 37% betragen.



Zeitreihenmodelle

Exponentielle Glättung mit Saison-Anpassung

Ziel ist die Vorhersage der Nachfrage an Hand exponentieller Glättung unter Berücksichtigung eines Saison-Effekts

S_t = exponentiell geglätteter Wert am Ende von Periode t

A_t = Wert der Periode t

I_t = Saison-Index der Periode t

F_{t+1} = Prognose für Periode $t+1$

Der Saison-Index I_t wird benötigt, um die Daten einer Periode L zu desaisonalisieren. Die I_t der ersten Periode werden folgendermassen berechnet:

$$I_t = \frac{A_t}{\bar{A}}$$

$$\bar{A} = (A_1 + A_2 + \dots + A_L) / L$$



Exponentielle Glättung mit Saisonangleichung: Beispiel Fährpassagiere ($\alpha = 0.2$; $\gamma = 0.3$)

Monat	Periode t	Belegung A_t	Gegl. Wert S_t	Index I_t	Prognose F_t	Prog.-Fehler $ A_t - F_t $
Jan 2008	1	1651	...	0.837	...	
Feb 2008	2	1305	...	0.662	...	
Mär 2008	3	1617	...	0.820	...	
Apr 2008	4	1721	...	0.873	...	
Mai 2008	5	2015	...	1.022	...	
Jun 2008	6	2297	...	1.165	...	
Jul 2008	7	2606	...	1.322	...	
Aug 2008	8	2687	...	1.363	...	
Sep 2008	9	2292	...	1.162	...	
Okt 2008	10	1981	...	1.005	...	
Nov 2008	11	1696	...	0.860	...	
Dez 2008	12	1794	1794.00	0.910	...	
Jan 2009	13	1806	1866.74	0.876
Feb 2009	14	1731	2016.35	0.721	1236	495
Mär 2009	15	1733	2035.76	0.829	1653	80
Apr 2009	16	1904	2064.81	0.888	1777	127
Mai 2009	17	2036	2050.28	1.013	2110	70



Zeitreihenmodelle

Somit berechnet sich der erste Index wie folgt:

$$I_1 = \frac{1.651}{(1.651 + 1.305 + \dots + 1.794) / 12} = \frac{1.651}{1.972} = 0.837$$

Die desaisonalisierten Werte werden dann wie üblich anhand der nachfolgenden Formel geglättet:

$$S_t = \alpha \left(\frac{A_t}{I_{t-L}} \right) + (1 - \alpha) S_{t-1}$$

Angewendet für Monat 14 ergibt dies:

$$S_{13} = (0.2) \frac{1806}{0.837} + (1 - 0.2)(1794) = 1866.74$$



Zeitreihenmodelle

Die Prognose erhält man, indem man den (desaisonalisierten) geglätteten Wert wieder saisonalisiert:

$$F_{t+1} = S_t I_{t-L+1}$$

Mit den Daten ergibt sich:

$$F_{14} = (1866.74)(0.662) = 1235.78$$

Nun kann noch der Saisonindex für die zweite Periode geglättet werden:

$$I_t = \gamma \frac{A_t}{S_t} + (1-\gamma)I_{t-L}$$

$$I_{13} = (0.3) \frac{1806}{1866.74} + (1-0.3)(0.837) = 0.876$$



Zusammenfassung der Prognoseverfahren

Subjektive Verfahren	Dateninput	Kosten	Horizont	Anwendungsbereich
Delphimethode	Umfrageergebnisse	Hoch	Langfristig	Technologieprognose
Cross-Impact Studie	Ereigniskorrelation	Hoch	Langfristig	Technologieprognose
Historische Analogie	Historische Daten	Hoch	Mittel- bis langfristig	Lebenszyklusnachfrageprognose
Kausalmodelle	Dateninput	Kosten	Horizont	Anwendungsbereich
Regression	Alle verfügbaren Daten	Mittel	Mittelfristig	Nachfrageprognose
Ökonometrie	Alle verfügbaren Daten	Mittel bis hoch	Mittel- bis langfristig	Ökonomisches Umfeld
Zeitreihenmodelle	Dateninput	Kosten	Horizont	Anwendungsbereich
Gleitender Durchschnitt	Die letzten N Beobachtungen	Niedrig	Kurzfristig	Nachfrageprognose
Exponentielle Glättung	Geglätteter Wert und letzte Beobachtungen	Niedrig	Kurzfristig	Nachfrageprognose