



LEUPHANA
UNIVERSITÄT LÜNEBURG

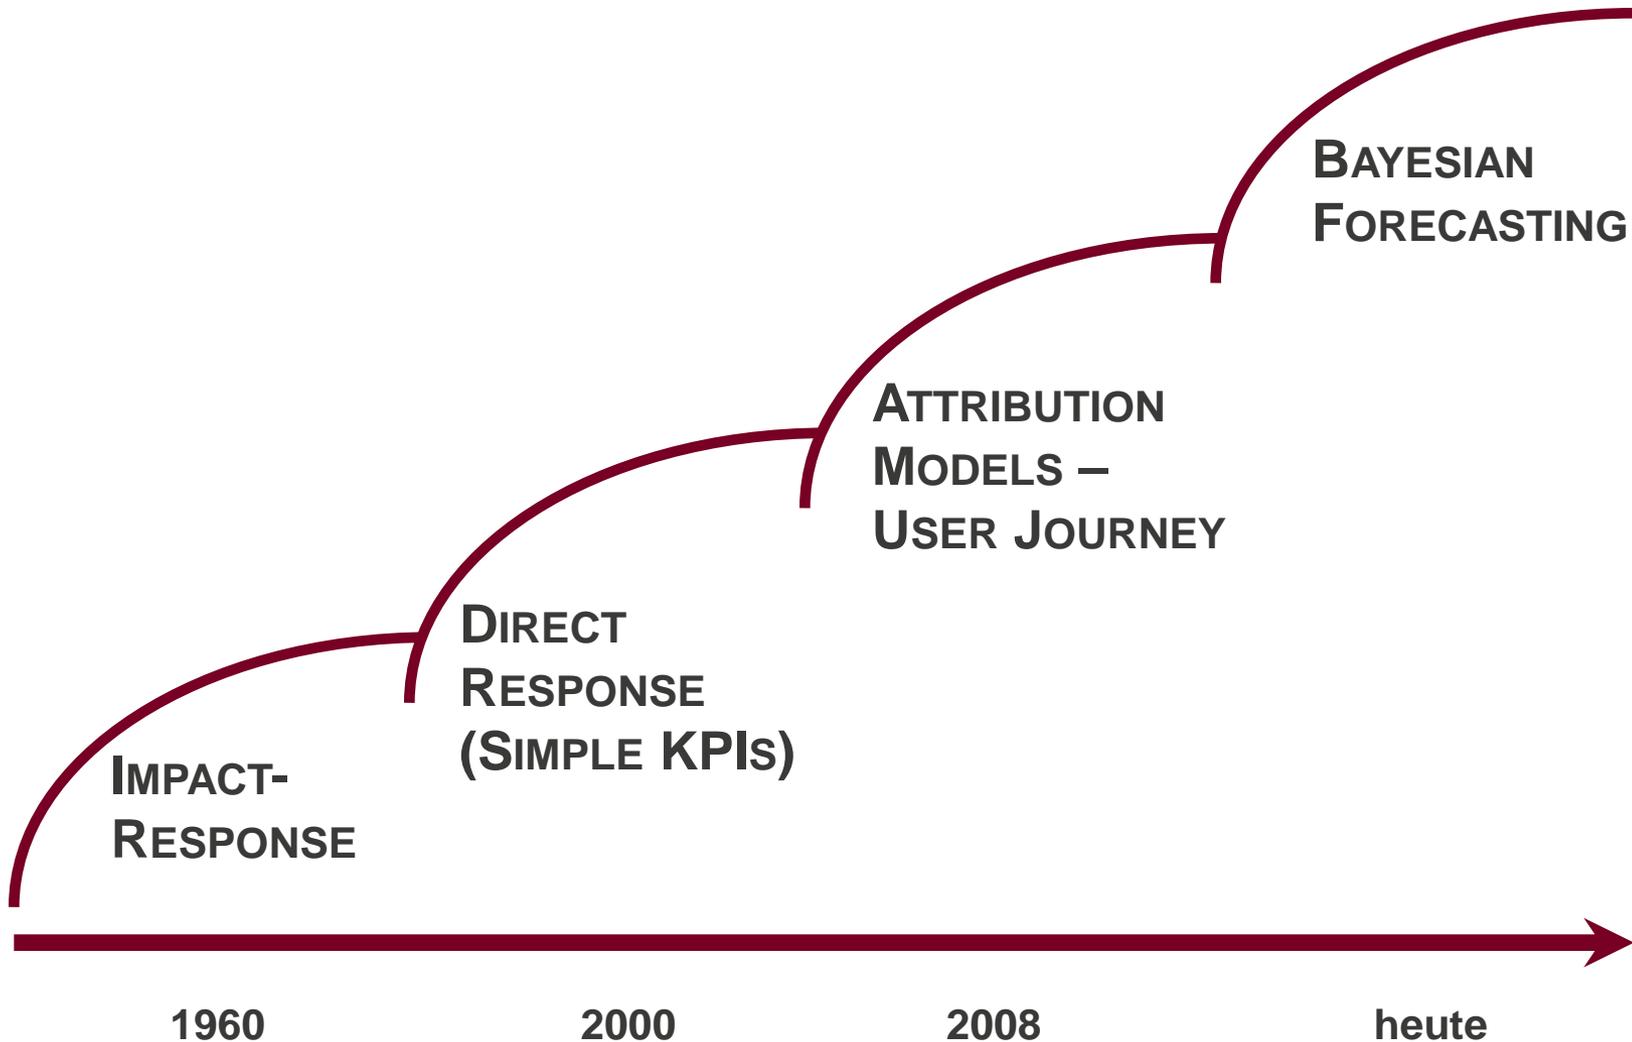
Cross-Kanal-Werbewirkung – die Welt ist keine Badewanne



Burkhardt Funk
Hamburg, 20.02.2013



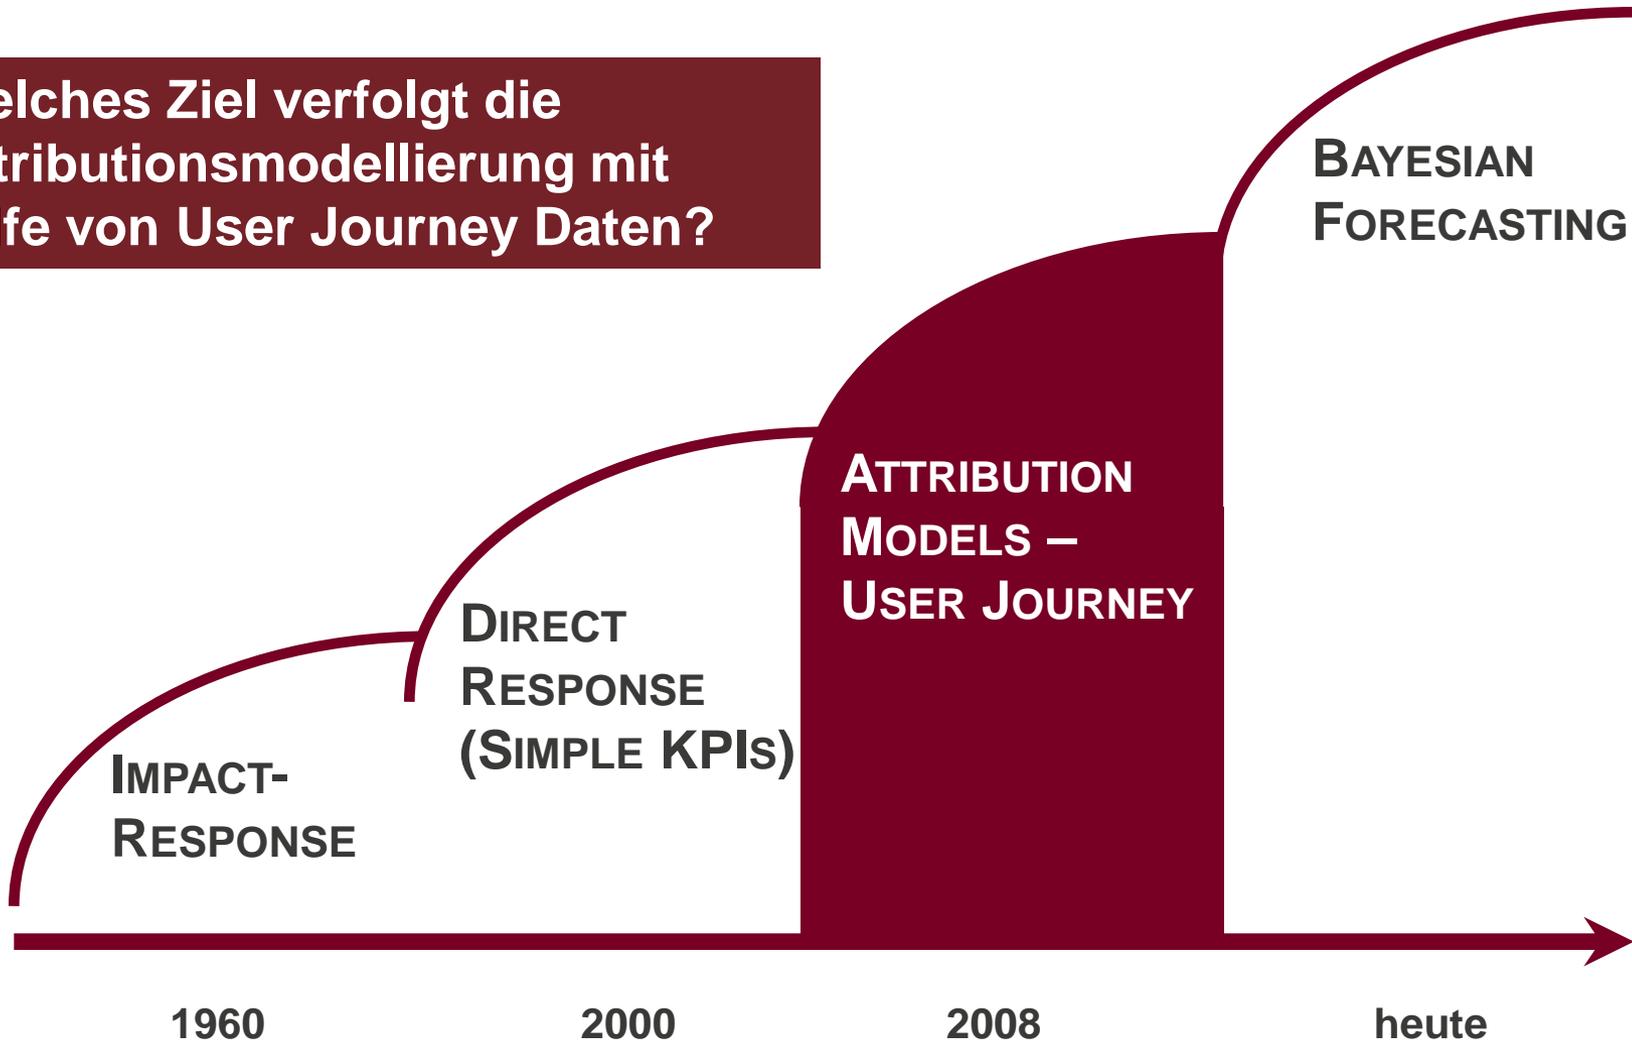
Eine kurze Geschichte der Werbewirkungsmodelle





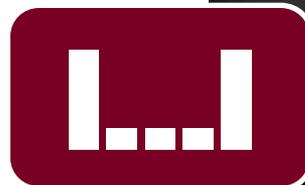
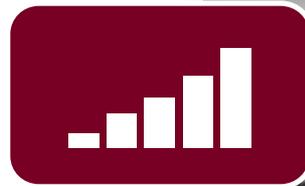
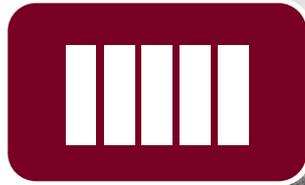
Ziele der Attributionsmodellierung

Welches Ziel verfolgt die Attributionsmodellierung mit Hilfe von User Journey Daten?





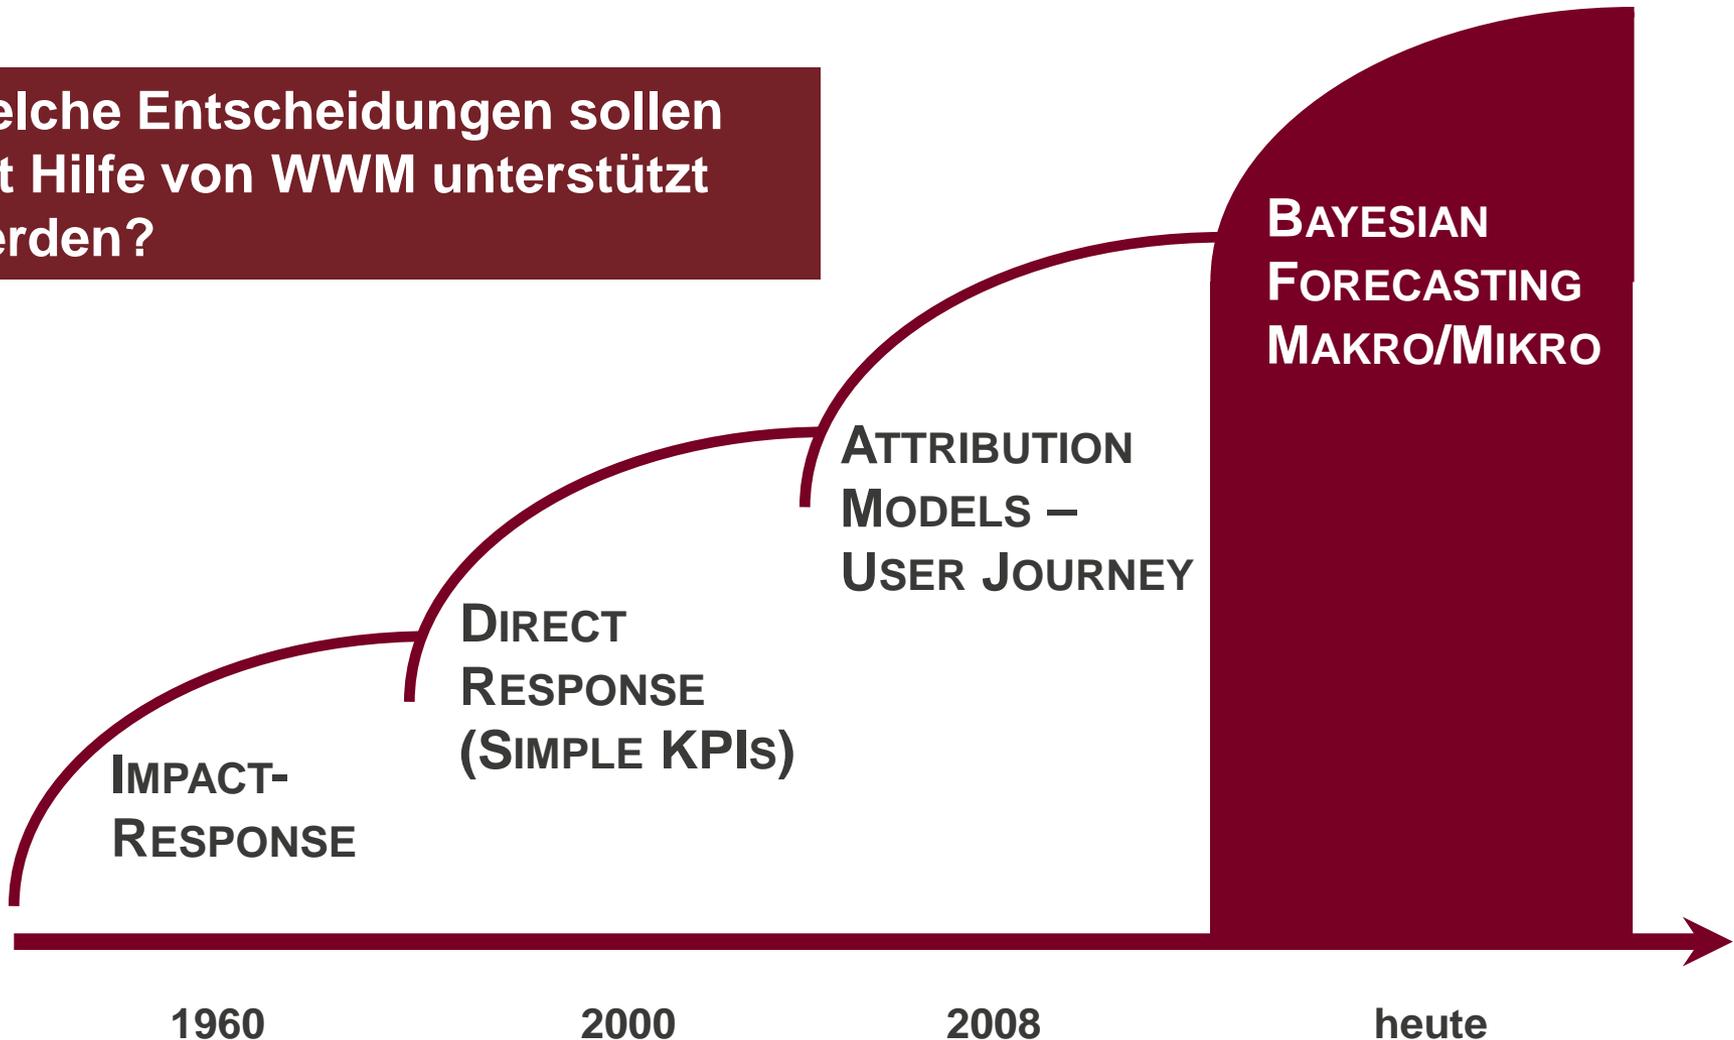
Attributionsmodellierung – Ansätze





Entscheidungen mit Hilfe von WWM

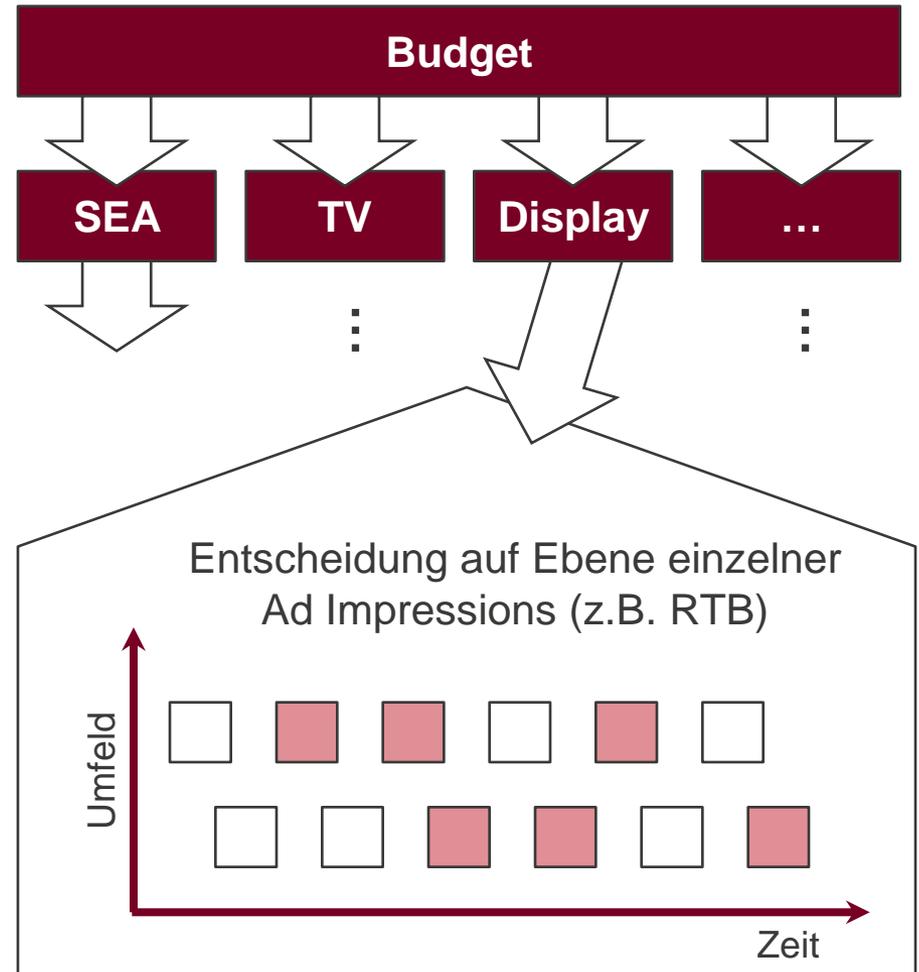
Welche Entscheidungen sollen mit Hilfe von WWM unterstützt werden?





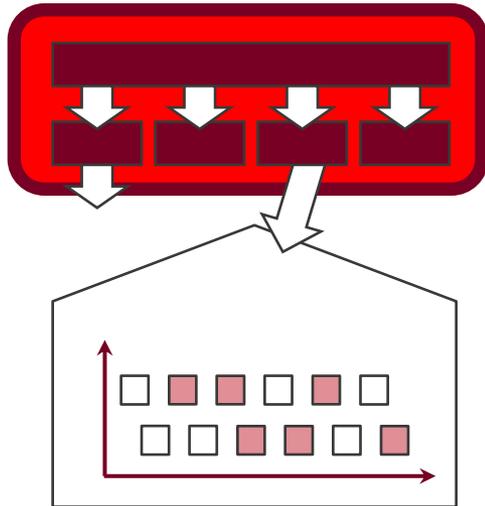
Entscheidungsebenen und geeignete Methoden

Ziel	Methode
<ul style="list-style-type: none">▪ Budgetallokation nach Kanälen	<ul style="list-style-type: none">▪ Einfache Regressionsmodelle▪ Mehrebenenmodelle▪ SEM▪ Zustandsraummodelle
<ul style="list-style-type: none">▪ Automatisierung und Optimierung auf Mikroebene	<ul style="list-style-type: none">▪ Logit Modelle▪ Assoziationsanalyse (FP mining)▪ „Mixture of Normals“ Modelle





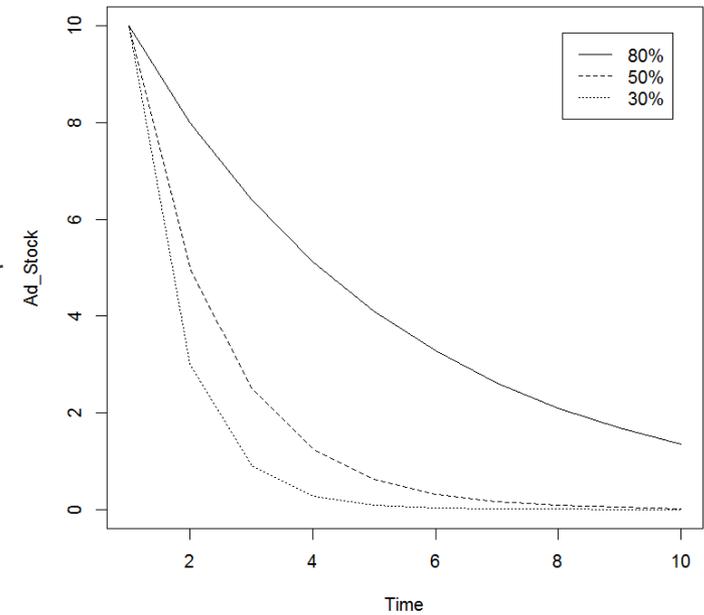
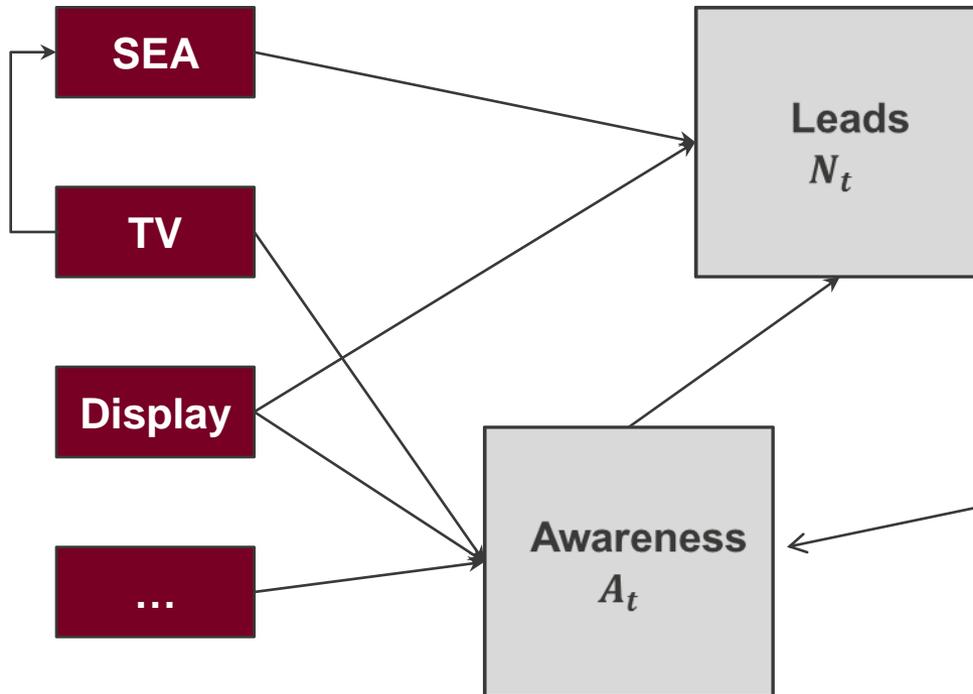
Dynamisch lineare Modelle (DLMs)



- Relativ neue Methode der **Zeitreihenanalyse** (derzeit zahlreiche Publikationen in der Wissenschaft); gehören zur Klasse der Zustandsraummodelle
- DLM modellieren die dynamische Entwicklung der **zu erklärenden Größen ab**
- Zusätzlich lassen sich “**latente Konstrukte**” (nicht meßbar) nutzen, die es zulassen, den Einfluss der jeweiligen Werbeaktivität zu quantifizieren (z.B. Aufmerksamkeit für eine Marke)
- DLM können besser mit Nicht-Stationarität und Autokorrelation umgehen als traditionelle Ansätze (z.B. vektorautoregressive Modelle)
- Anwendung erfordert kein Cookie-Tracking



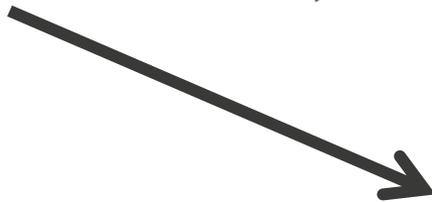
Modellentwicklung – graphischer Zusammenhang





Modellentwicklung – vereinfacht

$$A_t = \beta_{TV} B_{t,TV} + \zeta_{dis} B_{t,dis} + \dots + \alpha_A A_{t-1}$$



$$N_t = \beta_{time} I_t + \gamma A_t + \vartheta_{SEA} B_{t,SEA} \dots + \alpha_N N_{t-1}$$

Anzahl Leads

Saisonaler Impact

Spill-over

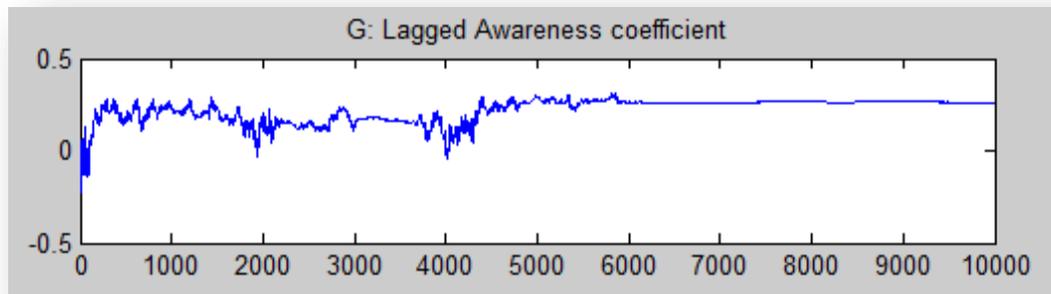
Direct Impact

Carry-over



Modellbestimmung

- Vorteil: Modellspezifikation bietet hohe Flexibilität bei der Festlegung der erwarteten Abhängigkeiten der Größen
- Nachteil: Modellberechnung/-bestimmung ist weder analytisch noch (einfach) numerisch möglich → Simulation erforderlich
- Anwendung **Bayes'scher Statistik** und **Markov Chain Monte Carlo (MCMC)** Methoden, Anwendung heute möglich aufgrund von
 - methodischen Fortschritten
 - Verfügbarkeit von Werkzeugen und Pakete, z.B. in R und MATLAB
 - Rechnerleistung
- Modell (aposteriori Verteilung der Parameter) wird iterativ in $\sim 10^5 - 10^7$ Durchläufe ermittelt; Verwendung sog. Gibbs Sampler





Ergebnisse

- Bereits veröffentlichte Anwendung von DLMs im Bereich Paid Search (*Rutz&Bucklin 2011, Nottorf&Funk 2013*)
- Wir arbeiten an einer Übertragung auf aggregierte Cross-Kanal-Analyse, welche Ergebnisse können abgeleitet werden?
 - Kanalspezifische CPOs (als Maß der Werbewirkung einzelner Kanäle)
 - Konkret: Facebook → Search und TV → Direct-Type-Ins
 - Zukünftig (noch nicht realisiert): (i) nicht lineare Effekte (Wear-In/ Wear-Out), (ii) Einfluß verschiedener Kovariate (Wetter, Wettbewerb, Markt)



SPECIAL THEME

A cross-industry analysis of the spillover effect in paid search advertising

Florian Nottorf · Burkhardt Funk

Received: 30 October 2011 / Accepted: 14 September 2012
© Institute of Information Management, University of St. Gallen 2013

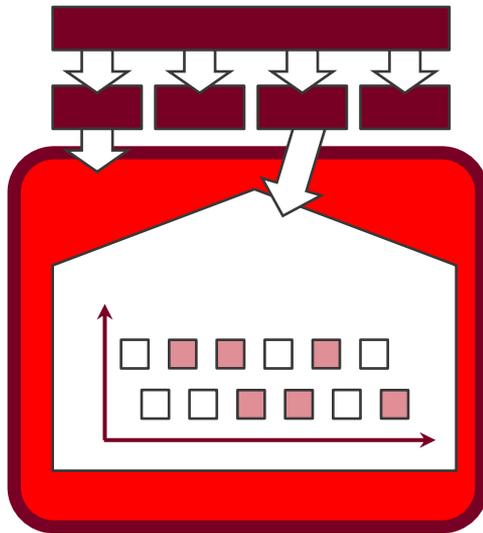
Abstract For the management of paid search advertising campaigns, metrics collected at keyword-level are often used in practice whereas the users' search process is of secondary importance and thus wholly or partially neglected. In contrast to brand-related keywords ("T-mobile contract"), general keywords, often referred to as generic ("mobile phone contract"), seem at first glance to be economically unattractive. Extending the approach of Rutz and Bucklin, *Journal of Marketing Research*, 48(1):87–102 (2011), we investigate the role of generic search activities

Introduction

80 % of all users start their internet session calling up a search engine to reach appropriate websites and to satisfy their needs (eReleases 2010). Search processes frequently begin with general terms and show a progressive narrowing as they proceed. For example, a user might begin the search with the term "mobile phone contract", then continue with "mobile phone flat rate", and end with "T-Mobile contract". The course of the search process from general searches,



„Mixture of Normals“-Modelle



- Ebf. aktuell viel beachtete und derzeit im wissenschaftlichen Kontext häufig genutzte Methode; Ziel hier: Entscheidungsunterstützung (z.B. Click- oder Kaufentscheidung) auf Ebene einzelner User
- Mixture-Modelle basieren auf bzw. erweitern einfache Logit-Modelle („log. Regr.“)
- Dazu wird auf Ebene einzelner Nutzer eine Nutzenfunktion (utility function) definiert, diese kann berücksichtigen
 - Verhaltensdaten (z.B. Ad Impressions, Clicks, Searches)
 - Nutzerspezifische Daten (z.B. Audience data, bisher noch nicht umgesetzt)
- Mixture-Modelle erlauben die Berücksichtigung von unterschiedlichen Nutzergruppen (z.B. werbeaffin vs. werbeavers)



Modellentwicklung (1/2)

$$Click_{ist} = \begin{cases} 1 & \text{if user } i \text{ clicks on a display ad at time } t \text{ in session } s \\ 0 & \text{otherwise,} \end{cases}$$

$$Pr(Click_{ist} = 1) = \frac{\exp(I_{ist}\alpha_i + X_{ist}\beta_i + Y_{is}\gamma_i + \epsilon_{ist})}{1 + \exp(I_{ist}\alpha_i + X_{ist}\beta_i + Y_{is}\gamma_i + \epsilon_{ist})}$$



Modellentwicklung (2/2)

$$I_{ist} = \{I_{ist}^{\text{ban}}, I_{ist}^{\text{ret}}, I_{ist}^{\text{vid}}\},$$

$$X_{ist} = \{x_{ist}^{\text{ban}}, x_{ist}^{\text{ret}}, x_{ist}^{\text{vid}}, x_{ist}^{\text{ban|sea}}, x_{ist}^{\text{ret|sea}}, x_{is(t-1)}^{\text{click}}, \\ \text{Click}_{is(t-1)}, \text{Search}_{ist}, \text{TLClick}_{ist}\},$$

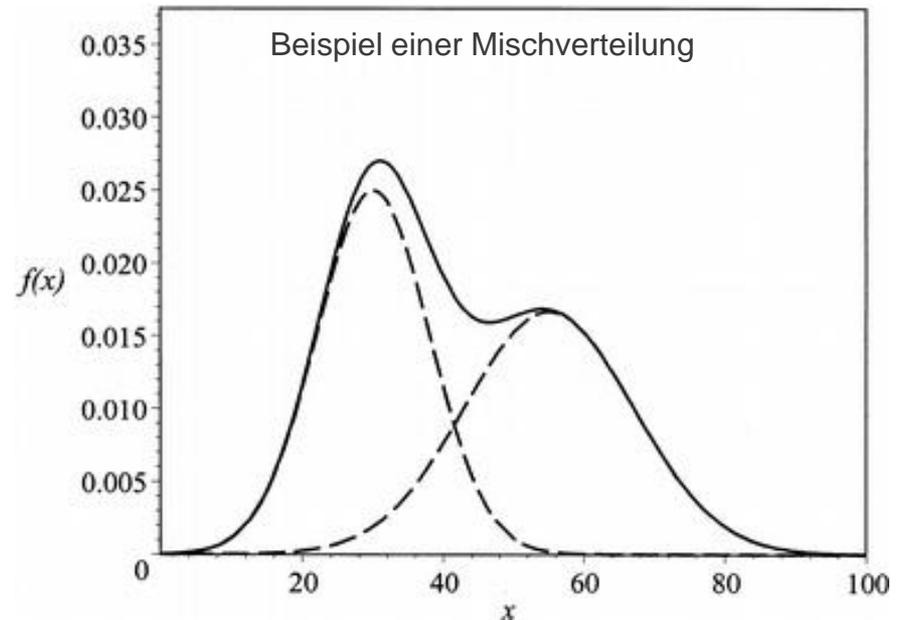
$$Y_{is} = \{y_{is}^{\text{ban}}, y_{is}^{\text{ret}}, y_{is}^{\text{vid}}, y_{is}^{\text{ban|sea}}, y_{is}^{\text{ret|sea}}, \\ y_{i(s-1)}^{\text{click}}, \text{IST}_{is}, \text{Session}_{is}\}$$



Bayesian Mixture of Normals

$$\theta_i = \{\alpha_i, \beta_i, \gamma_i\}$$

$$\theta_i \sim N(\mu_{\text{ind}_i}, \Sigma_{\text{ind}_i})$$



Lösung erfolgt ebf. über MCMC Methode



Ergebnisse erster Analysen

Setting

- Cross-Channel-Analyse mit unterschiedlichen Werbekanälen (Video, Retargeting, Search, Plain Display) → User-Pool extrahiert mit mind. 4 Werbekontakte
- Ziel: Prognose der Clickwahrscheinlichkeiten (Zwischenschritt, letztendliches Ziel ist die Prognose von Conversions)

Ergebnisse

- Gruppe 1: Großteil der User (ca. 90%)
 - jede weitere wiederholte Anzeige von Display Ads senkt die Klickwahrscheinlichkeit (*Wear-Out*)
 - Klickwahrscheinlichkeiten sind somit bei der Einblendung der ersten Display Ad am höchsten
- Gruppe 2 (ca. 10%)
 - Klickwahrscheinlichkeit erhöht sich mit jedem weiteren eingeblendeten Bannern (*Wear-In*)
 - Ferner positive Effekte nach Klick auf Paid Search Ad, Effektivität Display steigt
- Generell: Prognose auf Ebene einzelner User (out-of Sample Test)



Herausforderungen und Ausblick

Herausforderungen

- Sehr rechenintensiv: Von Minuten bis Woche/Dekaden (Parallelisierbarkeit?)
- Umgang mit Big Data (insb. auf der Mikroebene)
- Vereinbarkeit der Makro/Mikro-Modelle
- Methodische Weiterentwicklung

Ausblick

- Integration weiterer Variablen und Kanäle
- Erklärung von Conversionwahrscheinlichkeiten
- Produktspezifische Weiterentwicklung und Eichung der Modelle

**Interesse an
Kooperation?**



Es kann nur besser werden ...



Bayesian Forecasting

- Methodisch fundiert
- Hoch flexibel in der Modellbildung
- Sowohl auf „Makro“- als auch auf „Mikro“-Ebene anwendbar
- Leider sehr rechenintensiv



Vielen Dank für Ihr Interesse

Cross-Kanal-Werbewirkung – die Welt ist keine Badewanne



Prof. Dr. Burkhardt Funk
Lehrstuhl Wirtschaftsinformatik
Leuphana Universität Lüneburg
E: funk@uni.leuphana.de
W: www.onlinemedia-research.com
T: 04131 – 677 1593