



KSFE 2003



VERLAGSGRUPPE

Heuristische Verfahren zur Aggregation addierbarer Zeitreihen



VERLAGVERTRIEBS KG

VKG Verlagvertriebs KG
Abt. Data Mining

Stefan Pohl
Dr. S. Steinberg

Agenda

- Heinrich Bauer Verlag
- Typisches Problem des Vertriebs
- Lösungsansatz: Supervised Clustering
- Vergleich verschiedener Verfahren
- SAS/EM-Knoten: „Cluster Comparison“
- Vergleich von Clusterscorings oder Klassifikationen
- Zusammenfassung

Heinrich Bauer Verlag

- Europas führender Zeitschriftenverlag
- weltweit: **Wenige**
 - ca. 6300 Mitarbeiter
 - 120 auflagenstarke Erfolgstitel
- in Deutschland Marktführer in den Segmenten:
 - Programmzeitschriften (55% = 9,8 Mio. Exemplare)
 - Jugendzeitschriften (39% = 1,4 Mio. Exemplare)
 - unterhaltende Frauenzeitschriften (35% = 4,0 Mio. Exemplare)
- Special Interest Magazine

VKG

Vertriebsfirma der Verlagsgruppe Bauer

- 730 Mio. € Umsatz
- 150 Mitarbeiter
- ca. 20 Mio. Hefte pro Erscheinungsintervall
- 3,8 Mio. Abonnenten
- jährlich ca. 800.000 neue Abonnenten
- HH Abdeckung durch VKG Logistik ca. 80%
- über 215 Mio. Liefertakte p.a. Logistik
- ca. 30% WBZ und Fremdtakte

Typisches Problem des Vertriebs

- Problem:


Wie können Auswirkungen von vertrieblichen Aktivitäten

- Bezugsänderungen
- Werbemaßnahmen
- ...

nachgewiesen werden?

- Lösungsansatz

Einteilung der Vertriebsgebiete in Test- & Referenzgebiete



Konkretisierung

- Begriffe
 - Verhalten =
Verkäufe als einzige Rückmeldung im Einzelhandel
 - Einflüsse =
Inhalte der Zeitschrift,
Titelbild (Hintergrundfarbe, Model, ...),
Regionalität (Ost/West, Groß-/Kleinstadt, Wetter, ...)
 - Vertriebsgebiete =
logistisch bedingte Einteilung Deutschlands
- Probleme
 - Titelthemen können regionale, zeitlich begrenzte Verkaufsschlager sein
 - Verkäufe abhängig von Affinitäten der Kunden,
beliebig geographisch verteilt
 - Einfluß bisheriger Testaktivitäten verzerrt Historie



Lösung

- Zusammenfassung von Vertriebsgebieten zu Clustern, die ein besseres Verhalten haben

**Zeitreihe der Verkaufsanteile
von ausgewählten Grosslisten**






Abbildung auf Verfahren des SAS/EM

- Zufallsauswahl
keine Optimalität erwartbar,
kann aber gut als Referenz dienen



Sampling

- Clustering


Probleme:

- Statik der Elementeigenschaften
- Elemente erhalten neue Eigenschaften bei jedem Iterationsschritt
- unabhängig von der aktuellen Clusterzusammenstellung
- unüberwacht



Clustering

- Anlehnung an Variablenselektion
teilt Variablen in die beiden Gruppen
„erklärend“ und „redundant“ ein



**Variable
Selection**

Anforderungen

... an Testumgebung:


- mehrere Tests
- unterschiedliche Aktivitäten
(Bezugsänderung, Werbung, ...)
- gleichzeitige Durchführbarkeit
- statistisch gesicherter Erkenntnisgewinn
- nicht nur: gab es Einfluß,
sondern: wie hoch war der Einfluß



... an Zusammenstellung der Cluster:

- Regelwerk von Bedingungen
an Vertriebsgebiete und Cluster


Algorithmus



- Beschränkung auf eine Untermenge der Möglichkeiten
- Abbildung der menschlichen Vorgehensweise:
 - Inkrementelle, lokale Optimierung
 - Ausgehend von Einzelelementen, Elemente zusammenführen, die dadurch eine Verbesserung bzgl. einer Zielfunktion erfahren

Komplexität

- Beispiel: maximal 5 Gruppen mit 50 Elementen
- Anzahl zu untersuchender Möglichkeiten:
 - Gesamtkomplexität: $> 10^{34}$
 - Pro Gruppe genau 10 Elemente: $> 10^{31}$
 - Supervised Clustering: $< 10^5$




* Ausführungszeit aufgenommen mit Pentium 800 MHz, nichtoptimierter Interpretercode

Implementierung


- Prototyphaftigkeit aufgrund
 - vorher unklarer Anforderungen, Bedingungen
 - Umfang der Verbesserung unbekannt
(generell und auf Basis spezieller Daten)
- Prototyp in Prolog (logische Programmierung)
 - Datenbasis
beliebige Daten assoziativ speicherbar
 - Regelbasiert
einfache nachträgliche Definition von einschränkenden Bedingungen
bei jeder Aktion
- Stabile Version in SAS
 - Nahtlose Integration in
 - andere Untersuchungen
 - SAS/Enterprise Miner

Implementierung in SAS

- SAS ist insgesamt „datengetrieben“:
 - Steps u. Procs kommunizieren über Datasets u. Macrovariablen
- Algorithmus fest in Data-Steps implementiert
- Extensive Nutzung von SAS/Macro zur funktionalen Wiederverwendung von Data-Steps
- Skalierbarkeit gesichert durch Nutzung externer Speicher (Datasets) optimierter Dataset-Operationen




Ergebnis



- deutliche Fehlerreduktion in allen Gruppen
- es gibt wenige sich gut für diese Zeitschrift ausgleichende Vertriebsgebiete
 - Volatilität
 - Regionalität

Lösungsvergleich


- Frage:
 - Wie unterscheiden sich verschiedene Gruppierungen?oder
 - Auf welche Cluster einer anderen Gruppierung verteilen sich die Elemente eines Clusters?



- Mittel: Kreuztabellen

SAS/EM-Knoten: „Cluster Comparison“

- Beliebige Aggregatfunktionen über Elemente möglich: Anzahl, Summe, Min/Max, ...




Zusammenfassung



Supervised Clustering

- Supervised Clustering
 - Testbarkeit bei auflagenschwachem Titel durch das Verfahren erst möglich geworden
 - Agglomerationsverhalten gibt Auskunft über
 - Eigenschaften der Daten
 - zugrundeliegende Prozesse



Cluster Comparison

- Cluster Comparison
 - Vollständige Integration in Tools des SAS/EM
 - Überlappungsgrad gibt Hinweis auf Stabilität einer Aggregation



VERLAGVERTRIEBS KG

Stefan Pohl: mail@s-pohl.de

Dr. Sergej Steinberg: s.steinberg@bauerverlag.de