

Folien zum Lehrmodul

Objektorientierte Datenbanksysteme

Lernziele:

- OODBMS als Technologie einordnen kennen
- wesentliche Funktionsmerkmale von OODBMS kennen (komplexe Objekte, komplexe Werte, Surrogate, ...)
- Persistenzkonzepte in Programmiersprachen kennen
- Vor- und Nachteile / sinnvolle Anwendungsbereiche von OODBMS kennen

Inhaltsverzeichnis

1 Einleitung	5
2 Nichtkonventionelle Anwendungen	6
3 Eigenschaften objektorientierter DBMS	9
4 Datenkapselung	12
4.1 Motivation	12
4.2 Implementierungssprachen und Ausführungsart von Operationen .	15
5 Objekte und Beziehungen	21
5.1 Homogenität der Typsysteme	22
5.2 Komplexe Objekte	23
5.3 Beziehungen	26
5.4 Objektidentität	27
5.5 Komplexe Objekte vs. komplexe Werte	28

6 Vererbung	30
7 Persistente Programmiersprachen	31
7.1 Konzeptuelle Trennung persistenter und transienter Daten	32
7.2 Bindung persistenter Objekte an Pro grammalausführungen	36
7.3 Persistenzmechanismen	37
7.3.1 Grundformen	38
7.3.2 Seitenorientierte Persistenzmechanismen	40
8 Märkte und Standards	52

1 Einleitung

Objektorientierte DBMS (OODBMS) vereinigen

1. Datenbankkonzepte (Abfragesprachen, Transaktionen, ...)
2. Konzepte der objektorientierten Programmierung / Modellierung

Historie:

- 1980er Jahre: sehr viel Forschung
- später 1980er Jahre: erste kommerzielle Systeme
- frühe 1990er Jahre: gewisse Euphorie; mehrere Standards
- heute: wenige Überlebende, primär oo Erweiterungen relationaler Systeme

2 Nichtkonventionelle Anwendungen

Merkmale *konventioneller* Anwendungen:

- relativ einfach und *homogen* strukturierter Daten
- relativ *kleine* Tupel, oft Sätze fester Länge
- *atomare* Datenfelder
- Datenbankschemata werden sehr selten geändert
- *kurze Transaktionen*

Beispiele für nichtkonventionelle Anwendungen:

- Technische Entwurfsumgebungen (CAD, CASE usw.): textuelle und binäre Dokumente, Bitmaps, Versionen, komplexe Struktur
- Multimedia-Datenbanken: u.a. Video- und Audio-“Dateien”, *streaming* Formate
- Büroinformationssysteme: Briefe, digitalisierte Papiervorlagen u.ä.; Information Retrieval
- Expertensystem-Datenbanken

Konventionelle DBMS für nichtkonventionelle Anwendungen wenig geeignet, weil:

- *unnatürliche Datenmodellierung*
z.B. Syntaxbaum → Relationen; beim Lesen sehr komplexe, ineffiziente Verbunde; z.T. rekursive Datenstrukturen
- *spezielle Datentypen* wie Videos, Rasterbilder etc. nicht unterstützt
- *impedance mismatch*: aufwendige Konversion zwischen den Typsystemen von Programmiersprachen und Datenbankmodellen (viel Programmcode)
- oft auch bei Transaktionen, Verteilungs- und Zugriffsschutzkonzepten usw. spezielle Leistungen erforderlich

3 Eigenschaften DBMS

objektorientierter

Ziel: Vorteile von DBMS und objektorientierten Programmiersprachen vereinigen; oft Kompromisse erforderlich

- Ausgangsbasis objektorientierte Programmiersprache: erweitert um Persistenzkonzept, Transaktionen, mengenorientierte Abfragen, Mehrbenutzerunterstützung
- Ausgangsbasis relationales DBMS: erweitert um “lange Felder”, benutzerdefinierbare Datentypen usw.
→ **objektrelationale DBMS**

Merkmale von OODBMS gemäß dem “*object-oriented database system manifesto*”

[oo Merkmale:]

- komplexe Objekte, strukturierte Attributwerte
- Objektidentität
- Datenabstraktion (Kapselung, Schnittstellen)
- typisierte Objekte
- Typ hierarchien
- Polymorphie
- algorithmisch vollständige Datenbank-Programmiersprache (kein *impedance mismatch*)

[DBMS-Merkmale:]

- Persistenz
- internes Schema
- Concurrency-Control- und Recovery-Mechanismen
- mengenorientierte, deklarative Abfragesprache
- dynamisch erweiterbares Datenbankschema

[weitere wünschenswerte Merkmale:]

- versionierbare Objekte
- lange Transaktionen
- Trigger und andere Merkmale “aktiver” Datenbanken
- verteilte Datenbank
- Unterstützung multimedialer Objekte

4 Datenkapselung

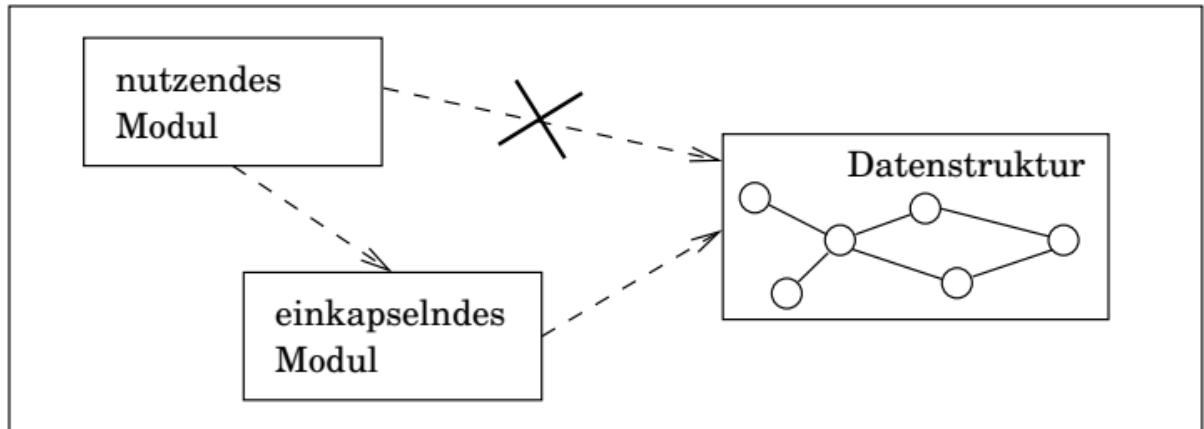
4.1 Motivation

konventionelle Datenbanken widersprechen dem Prinzip Datenkapselung:

- DB = komplexe Variable
- Schema = Datenstruktur — ist offen!!

Sonst wären keine ad-hoc-Abfragen möglich

Warum überhaupt Datenkapselung? (in konventionellen Programmiersprachen)



Datenkapselung ist bei konventionellen Datenbank-Anwendungen *meistens verzichtbar (!):*

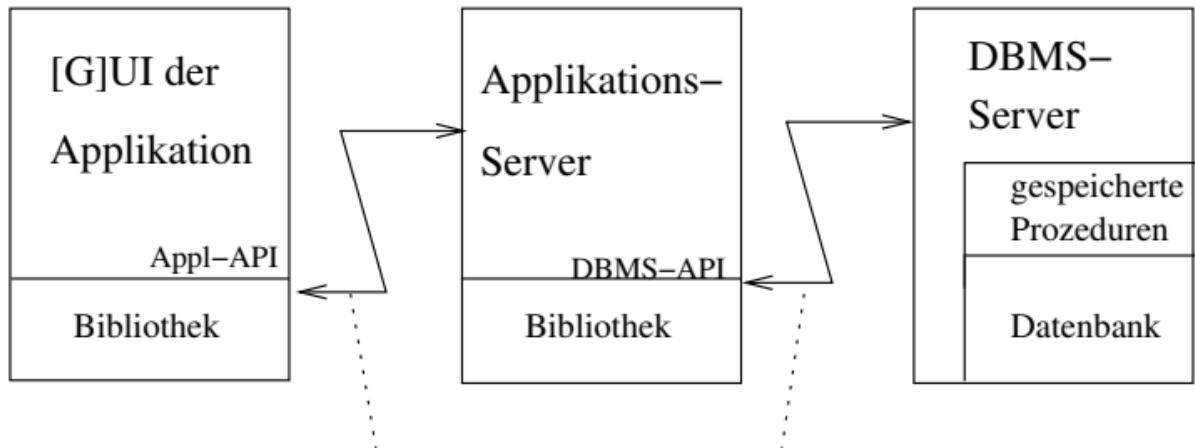
- Änderung der Datenstruktur unwahrscheinlich
 - u.a. weil sehr aufwendig wegen erforderlicher DB-Konversion – ein analoges Problem existiert bei Laufzeitobjekten nicht
- oft nur 1:1-Zuordnung Attribut zu Lese-/Schreiboperation, Datenstruktur wird nicht wirklich versteckt
- Schutz der Konsistenz der Daten besser durch Identifizierungs- und Fremdschlüssel u.ä. als durch individuelle Algorithmen

4.2 Implementierungssprachen und Ausführungsart von Operationen

mögliche Ausführungsorte von einkapselnden Operationen:

- GUI / Applikations-Serverprozeß
- DBMS-Serverprozeß (stored procedures)

involvierte Prozesse und deren virtuelle Hauptspeicher:



Kommunikation z.B. über RPC oder über Sockets

1. Ausführung von Operationen im DBMS-Serverprozeß:

Vorteile:

- spart aufwendige Kommunikationen und Datentransporte
- effizient bei vielen Zugriffen zu einzelnen Datenelementen,
motiviert *stored procedures* (unabhängig von Datenkapselung)

Probleme:

1. Sicherheit:

- einkapselnde Operationen sind von Anwendern geschrieben
- suspekt, sehr hohes Schadenspotential bei unsicheren Sprachen wie C / C++
- nur Skriptsprachen u.ä. erlauben (aber ineffizient / eingeschränkte Mächtigkeit)

2. Arbeitslast / Performance:

CPU-Belastung des Rechners, auf dem der DBMS-Serverprozeß läuft (komplexe Algorithmen, Endlosschleife, ...)

problematisch: Verlagerung der Rechenlast vom Arbeitsplatzrechner / Applikationsserver auf DBMS-Server

→ Ansatz ungeeignet für Systeme mit *vielen Nutzern*

2. Ausführung von Operationen im Applikationsprozeß:

Problem: wer stellt sicher, daß auf einem Objekt nur passende Operationen ausgeführt werden?

DBMS als zentrale Aufsichtsinstanz? (lädt Bibliotheken in die Applikationsprozesse? Für beliebige Plattformen?)

5 Objekte und Beziehungen

i.f. Gestaltungsspielräume / Hauptvarianten von wesentlichen Aspekten von oo Datenbankmodellen

5.1 Homogenität der Typsysteme

Aspekt: Wahl des Typsystems des ooDBMS

impedance mismatch: Differenzen im Datenbankmodell von DBMS und Programmiersprache

Idee: DBMS-Modell identisch wie *eine* bestimmte Programmiersprache wählen

- Probleme mit anderen Programmiersprachen
- Programmiersprache alleine reicht nicht; Bibliotheken usw.
→ sehr hoher Spezifikations- und Implementierungsaufwand
- Typsystem der Programmiersprache ggf. zu komplex als Basis für Abfragesprachen

5.2 Komplexe Objekte

Aspekt: Typkonstruktoren, nichtatomare Objekte

Programmiersprachen haben Typkonstruktoren wie array, set of, record, ... sind Teil-von-Strukturen

DBMS-seitige Nachbildung: **komplexe Objekte mit Komponentenobjekten**

- Strukturierung der Komponentenobjekte mit Typkonstruktoren wie array, set, map, record, file; beliebig schachtelbar
- können mit 1 Operationsaufruf **als Ganzes** bearbeitet werden.
Operationen: löschen, kopieren, versionieren, sperren, ...

Alternativen für die Struktur komplexer Objekte:

- *baum-* bzw. *waldartige* Struktur
- *halbgeordnete* (also zyklusfreie) Struktur, gemeinsame Teilobjekte
- *Graph*, Zyklen erlaubt

Alternativen für die Handhabung von Komponentenobjekten:

- (spezielle) Attribute, die *Objektreferenzen* oder Mengen von Objektreferenzen enthalten
- Menge der Komponenten eines Objekts als *abstraktes Datenobjekt* mit Interface betrachten (kein explizites Attribut)
- Teil-von-Eigenschaft als *Merkmal von Beziehungstypen*

5.3 Beziehungen

Aggregationen und Assoziationen erforderlich

referentielle Integrität auf Wunsch überprüfbar → paarweise gegenläufige Beziehungen

5.4 Objektidentität

wertbasierte Identität hat diverse Nachteile →

Surrogate; Eigenschaften:

- bei Erzeugung eines Objekt automatisch zugewiesen
- wird nie verändert
- zeitlich und “räumlich” eindeutig

Benutzung für:

- Test, ob zwei Objektreferenzen auf gleiches Objekt verweisen
- teilweise für Direktzugriff

Realisierung: längerer String (externe Darstellung, komprimierbar)
→ “schwergewichtige” Objekte (auch wegen anderer Features)

5.5 Komplexe Objekte vs. komplexe Werte

komplexer Wert in einem Attribut:

- wird auf 1 **Bytefeld** abgebildet, Länge u.U. schon zur Compile-Zeit bestimmbar
- wird nur **als ganzes** zwischen der Datenbank und dem Adressraum der Anwendung übertragen
 - sehr **effiziente** Verarbeitung
- “Komponenten” in komplexem Wert sind keine Objekte:
 - haben **keine Identität** (kein Surrogat)
 - können **keine Rolle in Beziehungen** spielen
 - können nicht Ziel von Objektreferenzen sein
- Struktur des komplexen Werts ist **offen**

Probleme mit komplexen Werten:

- heterogene Plattformen
- Typsystem von DBMS und Gastsprache müssen kompatibel sein → i.w. nur 1 Gastsprache möglich
- Abhängigkeit vom Compiler / Laufzeitsystem

6 Vererbung

Frage zu Bedeutung von Abfragen:

gegeben ein Typ, welche Basismenge an Instanzen gehört dazu?

1. Instanzen nur des **exakten** Objekttyps (ohne Subtypen)
(Vergleich: horizontale Partitionierung)
2. Instanzen eines Typs und aller seiner direkten und indirekten
Subtypen
(Vergleich: vertikale Partitionierung)
3. statt pauschaler Festlegung: Objektmengen völlig unabhängig
von der Typstruktur definieren (eher lästig)

7 Persistente Programmiersprachen

Grundidee:

- Typsysteme von Programmiersprache und DBMS identisch
- persistente Objekte: werden automatisch beim Programmende gerettet und beim erneuten Programmstart rekonstruiert

7.1 Konzeptuelle Trennung persistenter und transienter Daten

transiente (normale) Daten: werden bei Programmende gelöscht

Problem: es werden transiente **und** persistente Daten benötigt

transiente Varianten sind anders:

- kein Surrogat
- i.a. Konsistenzbedingungen des DB-Schemas nicht anwendbar
- ggf. andere Rechte

Anforderungen (ideal):

- einfache Spezifikation der Persistenz
- kein Unterschied in der Handhabung persistenter und transienter Daten
- wenig Korrekturaufwand bei Umstellung

Methoden zur Spezifikation, daß Daten persistent sein sollen:

1. Persistenz als Klasseneigenschaft:

vordefinierte Klasse namens `persistent_object` o.ä.;
hiervon Unterklassen bilden

Nachteil: transiente und persistente Instanzen der gleichen
Klasse schlecht zu trennen

2. Explizite Markierung:

Angabe zu beliebigem Zeitpunkt während Lebensdauer

3. Persistente Wurzel(n):

alle von dort erreichbaren Objekte implizit persistent

→ wenig Spezifikationsaufwand,

u.U. schlecht durchschaubare Effekte von Änderungen an Objektstrukturen

nur implizites Löschen

7.2 Bindung persistenter Objekte an Programmausführungen

gleiches Programm muß mit verschiedenen Objekten ausführbar sein;

Auswahl der DB-Objekte, mit denen ein Programm ausgeführt werden soll, über:

1. Surrogate
2. identifizierende Attribute an Objekten
(ggf. nur für Wurzelobjekte relevanter Teilbäume)
3. einzelne OODB-Objekte erhalten *explizit* einen Namen (ähnlich Tagging in SVN), explizite Bindung der OODB-Objekte an Programmvariablen
nur bei kleiner Anzahl von komplexen Objekten praktikabel

7.3 Persistenzmechanismen

bisher offen: Implementierung der Persistenz

irrelevant für Konzepte, sehr relevant für **Performance**
(-versprechungen)

Annahme i.f.: Programmteile, die auf die Datenstrukturen von Objekten zugreifen, werden *im Applikationsprozeß* ausgeführt

7.3.1 Grundformen

als persistent markierte Laufzeitobjekte müssen bei Beendigung des Programms in die Datenbank übertragen werden

Implementierungsansätze:

1. **Verarbeiten einzelner (atomarer) Objekte:**

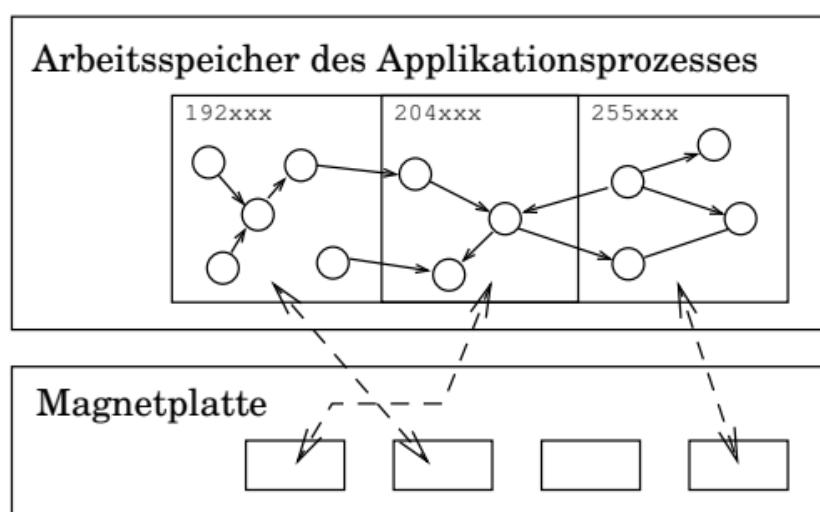
Struktur der Objekte durchlaufen, atomare Objekte einzeln speichern (1 Objekt = 1 Tupel)

erlaubt Einsatz beliebiger DBMS, automatische Konversionen

2. **Behandlung komplexer Objekte als komplexe Werte:**
weniger Kommunikationen zum DBMS-Serverprozeß
Zerlegung des komplexen Werts im DBMS-Serverprozeß, ggf.
Konversion in anderes Typsystem;
Sonderfall hiervon: Paging-Verfahren

7.3.2 Seitenorientierte Persistenzmechanismen

Grundidee: einzelne Seiten des Hauptspeichers, in denen Objekte gespeichert sind, direkt auf Sektoren der Platte speichern



ähnlich Paging / *memory-mapped IO*

Schichtenarchitektur des DBMS-Kerns: Verwaltung von Speichersätzen und Einzeltupeln entfällt!

unter “persistente Programmiersprache” wird oft dieses Implementierungsverfahren verstanden;

wirkt sehr elegant und performant (Hardware-Unterstützung!)

ABER:

1. funktioniert doch nicht so einfach
2. Performance-Vorteile nur unter speziellen günstigen Randbedingungen
3. bedingt Verzicht auf viele übliche Leistungsmerkmale eines DBMS

Pointer Swizzling.

Problem: Referenzen auf andere Objekte werden im Laufzeitsystem durch *Zeiger* (Adresswerte) realisiert

Zeiger stehen *mitten in komplexen Werten*

Frage: wo stehen die Objekte nach Neuladen im Hauptspeicher???

1. an der gleichen Adresse wie vorher → Zeiger bleiben korrekt
→ Objekte müssen feste Hauptspeicheradresse haben
→ DB-Größe durch virtuellen Adressraum beschränkt!
nicht akzeptabel bei 32-Bit-Rechnern

2. andere Adresse als vorher

→ Zeiger müssen angepaßt werden, d.h.:

- beim Speichern Adressen in Objektidentifizierer umsetzen
d.h. Seite kann nicht unverändert gespeichert werden!
- beim Laden Adressen in dann gültige Adressen umsetzen

Bezeichnung hierfür: **pointer swizzling**

Probleme beim *pointer swizzling*:

- braucht Rechenzeit und/oder Speicherplatz
- Applikation kann (bei “unsicheren” Programmiersprachen wie C++) Inhalt der Seite beschädigt haben
→ Analyse der Seite vor dem Speichern notwendig
- nicht anwendbar bei heterogenen Plattformen

Wann verbessern die seitenorientierten Verfahren die Performance?

- 1. Zugriff auf ein Objekt: zeitraubender Transport eines Sektors von der Platte in den Hauptspeicher unverändert notwendig
- 2. und folgende Zugriffe zum *gleichen* Objekt: Performance verbessert

- Performance-Verbesserung beim initialen Laden: allenfalls durch günstige Gruppierung (Clusterung):
 - mehrere kleine Objekte auf 1 Seite
 - gemäß Zugriffsverhalten EINER Applikation

Angabe der Clusterungsstruktur durch Applikation! (erzeuge neues Objekt “in der Nähe” eines vorhandenen)

ABER: diese Angaben gehören zum “*internen Schema*”, widersprechen dem Ziel der Datenunabhängigkeit (die aber bei nichtkonventionellen Anwendungen sowieso nicht erreicht wird)

Fehlende Leistungen von Datenbanksystemen bei seitenorientierten Verfahren.

1. Sprachunabhängigkeit:

DBMS ist abhängig von Compiler oder sogar Versionen “des-selben” Compilers

2. heterogene Plattformen

3. Sichten:

Basis für Zugriffskontrollen und Datenunabhängigkeit

Filterung im DBMS → ggf. volliger Umbau der Seiteninhalte

Filterung im Laufzeitsystem der Programmiersprache: u.U. nicht sicher, bedingt völlig neue Sprachkonzepte

4. effiziente Suche durch Indexe:

Datenstrukturen in Laufzeitsystemen unterstützen i.a. keine (Primär-) Indexe (sind nicht plattenorientiert)

Sekundärindexe: verschlechtern Performance

Problem: Daten, die andere Prozesse frisch erzeugt haben

5. paralleler Zugriff:

gleiche Seite in *mehrere* Adressräume einspiegeln

→ lokale Änderungen der Kopien; wie mischen??

→ Seiten müssen gleichgehalten werden

→ zeitaufwendige Prozeßkommunikation

Sperren / Concurrency-Control: nicht dezentral handhabbar

6. *Recovery:*

hoher Aufwand für Logging; wird nicht reduziert

Schattenobjekte erfordern völlig andere Handhabung von Objekten als in Laufzeitsystemen

Quintessenz:

- klassische Leistungen eines DBMS haben ihren Preis, nur marginale Performance-Gewinne, wenn klassische DBMS-Leistungen gefragt sind
- “Effizienz” der seitenorientierten Verfahren besteht darin, diese Leistungen nicht zu erbringen.

8 Märkte und Standards

OODBMS sind sehr komplexe Systeme → teuere Implementierung
enge Märkte → lange Reifezeit, teuer; als Produkte kaum überlebensfähig

Standards:

- **SQL3**: Erweiterungen von SQL2 um ADTs, rekursive Verbunde, Trigger und weitere Merkmale
- **IRDS** und **PCTE**: spezielle OODBMS, als Basis von Software-Entwicklungsumgebungen konzipiert
- Standards der **ODMG**

Standards der ODMG (Object Data Management Group; hat sich inzwischen aufgelöst)

- *Objektmodell (OM)*, das grundlegende Konzepte wie Objekt, Typ. Attribut usw. definiert.
- Objekt[typ]definitionssprache (*object definition language; ODL*)
 - vergleichbar mit DDL
 - definiert auch Signaturen von Operationen
- *object query language (OQL)*
 - Abfragesprache für Objektbanken, angelehnt an SQL
- Sprachanbindungen für die Sprachen C++, Java und Smalltalk

- *object interchange format (OIF)*

Sprache zur Definition von Objekten (Instanzen von Objekttypen); zum Transport von Datenbankinhalten zwischen Datenbanken

Objektrelationale DBMS (ORDBMS)

Basis: erprobtes relationales DBMS

mit Erweiterungen, die die Anforderungen der Objektorientierung zumindest teilweise erfüllen:

- benutzerdefinierte Attributtypen
- abgeleitete Attribute, die durch eine Abfrage definiert sind
- automatisch vergebene Surrogate
- benutzerdefinierte Funktionen
- Typ hierarchien
- erweiterte Triggermechanismen
- lange Felder (*binary large objects*, BLOBs)

Umfang und die konkrete Ausgestaltung der Erweiterungen nicht einheitlich bei verschiedenen Produkten