Non-Standard-Datenbanken und Data Mining

Temporale Daten und das relationale Modell

Prof. Dr. Ralf Möller
Universität zu Lübeck
Institut für Informationssysteme

Übersicht

- Semistrukturierte Datenbanken (JSON, XML) und Volltextsuche
- Information Retrieval
- Mehrdimensionale Indexstrukturen
- Cluster-Bildung
- Einbettungstechniken
- First-n-, Top-k-, und Skyline-Anfragen
- Probabilistische Datenbanken, Anfragebeantwortung, Top-k-Anfragen und Open-World-Annahme
- Probabilistische Modellierung, Bayes-Netze, Anfragebeantwortungsalgorithmen, Lernverfahren,
- Temporale Datenbanken und das relationale Modell, SQL:2011
- Probabilistische Temporale Datenbanken
- SQL: neue Entwicklungen (z.B. JSON-Strukturen und Arrays), Zeitreihen (z.B. TimeScaleDB)
- Stromdatenbanken, Prinzipien der Fenster-orientierten inkrementellen Verarbeitung
- Approximationstechniken für Stromdatenverarbeitung, Stream-Mining
- Probabilistische raum-zeitliche Datenbanken und Stromdatenverarbeitungsssysteme: Anfragen und Indexstrukturen, Raum-zeitliches Data Mining, Probabilistische Skylines
- Von NoSQL- zu NewSQL-Datenbanken, CAP-Theorem, Blockchain-Datenbanken

Non-Standard-Datenbanken

Von probabilistischen zu temporalen Datenbanken

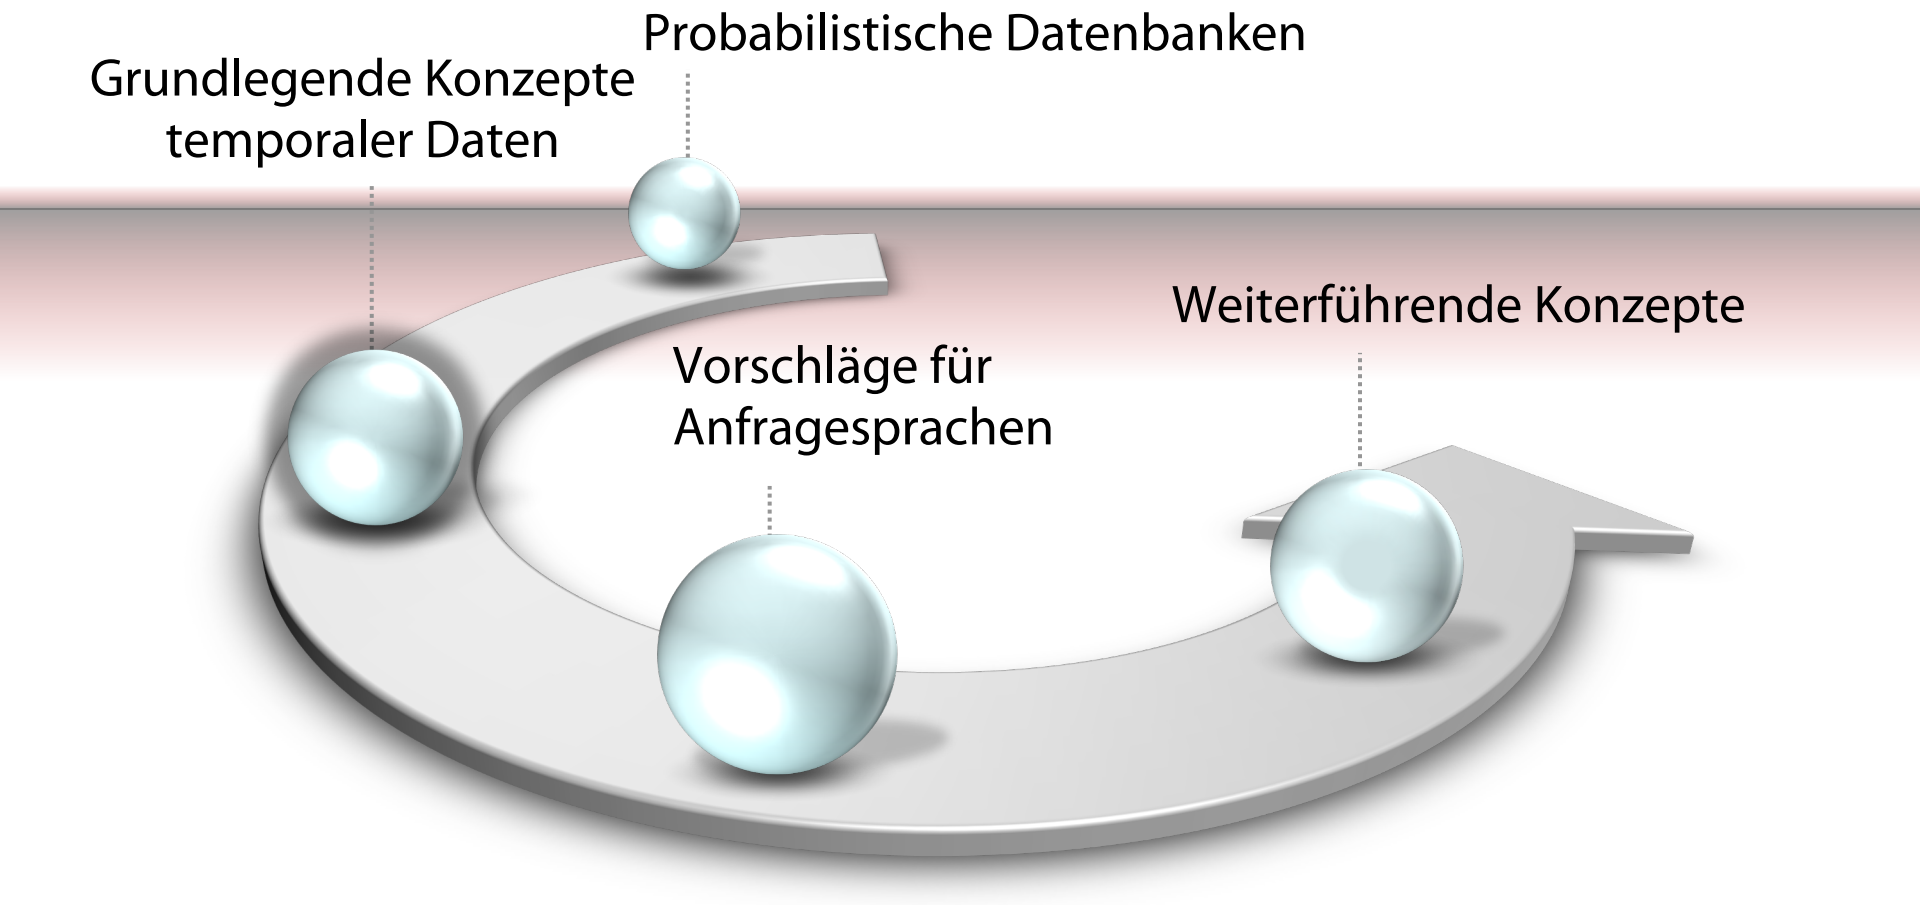

Standard-Datenbanken

"Suppliers and Shipments"

S

S#
S1
S2
S3
S4
S5

Prädikat:
"Supplier S# is under contract"

SP

S#	P#
S1	P1
S1	P2
S1	P3
S1	P4
S1	P5
S1	P6
S2	P1
S2	P2
S3	P2
S4	P2
S4	P4
S4	P5

Prädikat
"Supplier S# is able to supply part P#"

Anfragen:

- *Which suppliers can supply something?*
- *Which suppliers cannot supply anything?*

Semitemporalisiert: Linear geordnete Struktur

S_SINCE

Prädikat:
"Supplier S# has been under contract since day SINCE"

S#	SINCE
S1	*d04*
S2	*d07*
S3	*d03*
S4	*d04*
S5	*d02*

SP_SINCE

Prädikat:
"Supplier S# has been able to supply part P# since day SINCE"

S#	P#	SINCE
S1	P1	*d04*
S1	P2	*d05*
S1	P3	*d09*
S1	P4	*d05*
S1	P5	*d04*
S1	P6	*d06*
S2	P1	*d08*
S2	P2	*d09*
S3	P2	*d08*
S4	P2	*d06*
S4	P4	*d04*
S4	P5	*d05*

- **Zeitstruktur** (T, <) wobei T eine Menge und < eine totale Ordnung über T ist
- **Granularität** ist **anwendungsabhängig** zu wählen

Anfragen:

- *Since when has supplier S# been able to supply something?* (einfach)
- *Since when has supplier S# been unable to supply anything?* (unmöglich)

Voll temporalisiert (Versuch 1)

S_FROM_TO

Predicate:
"Supplier S# was under contract from day FROM to day TO."

S#	FROM	TO
S1	d04	d10
S2	d02	d04
S2	d07	d10
S3	d03	d10
S4	d04	d10
S5	d02	d10

SP_FROM_TO

Predicate:
"Supplier S# was able to supply part P# from day FROM to day TO."

S#	P#	FROM	TO
S1	P1	d04	d10
S1	P2	d05	d10
S1	P3	d09	d10
S1	P4	d05	d10
S1	P5	d04	d10
S1	P6	d06	d10
S2	P1	d08	d10
S2	P1	d02	d04
S2	P2	d08	d10
S2	P2	d03	d03
S3	P2	d09	d10
S4	P2	d06	d09
S4	P4	d04	d08
S4	P5	d05	d10

Anfragen:

- What does supplier S1 supply at day d6? (leicht)
- Does S1 supply something between d2 and d11?
- During which times was supplier S# able to supply something?
- During which times was supplier S# unable to supply something?

Zu prüfende Einschränkungen

S_FROM_TO

Ein Lieferant soll nicht einen Vertrag in unterschiedlichen aber überlappenden oder aneinandergrenzenden Intervallen haben

S#	FROM	TO
S1	d04	d10
S2	d02	d04
S2	d07	d10
S3	d03	d10
S4	d04	d10
S5	d02	d10

SP_FROM_TO

Ein Lieferant soll nicht die gleichen Dinge in überlappenden oder aneinanderstoßenden Intervallen liefern

S#	P#	FROM	TO
S1	P1	d04	d10
S1	P2	d05	d10
S1	P3	d09	d10
S1	P4	d05	d10
S1	P5	d04	d10
S1	P6	d06	d10
S2	P1	d08	d10
S2	P1	d02	d04
S2	P2	d08	d10
S2	P2	d03	d03
S3	P2	d09	d10
S4	P2	d06	d09
S4	P4	d04	d08
S4	P5	d05	d10

Einschränkungen sind nicht einfach repräsentierbar

Wie kann für **zeitlich begrenzt gültige Einträge** ein **Schlüssel** definiert werden? Will man das?

Interpretation? Sind die FROM und TO Daten enthalten? Z.B.: Hatte Lieferant S1 einen Vertrag am Tag 10?

Voll temporalisiert (Versuch 2)

S_DURING

S#	DURING
S1	[*d04*:*d10*]
S2	[*d02*:*d04*]
S2	[*d07*:*d10*]
S3	[*d03*:*d10*]
S4	[*d04*:*d10*]
S5	[*d02*:*d10*]

SP_DURING

S#	P#	DURING
S1	P1	[*d04*:*d10*]
S1	P2	[*d05*:*d10*]
S1	P3	[*d09*:*d10*]
S1	P4	[*d05*:*d10*]
S1	P5	[*d04*:*d10*]
S1	P6	[*d06*:*d10*]
S2	P1	[*d08*:*d10*]
S2	P1	[*d02*:*d04*]
S2	P2	[*d08*:*d10*]
S2	P2	[*d03*:*d03*]
S3	P2	[*d09*:*d10*]
S4	P2	[*d06*:*d09*]
S4	P4	[*d04*:*d08*]
S4	P5	[*d05*:*d10*]

Einführung von ***Intervalltypen***[1] und ihren ***Punkttypen***

Der Typ des Attributs DURING könnte sein:
INTERVAL_DATE (mit Punkttypen **DATE**)

DURING als Schlüssel? Möglich, aber hier nicht sinnvoll

Für einen Punkttypen ist eine Nachfolgerfunktion definiert – hier: **NEXT_DATE (*d*)**. Hier zeigt sich die Skalierung.

[1]Nicht zu verwechseln mit dem Typ INTERVAL in SQL-92

Intervallspezifikationen

- [a, b] – Anfangszeitpunkt a und Endzeitpunkt b enthalten
- (a, b] – Anfangszeitpunkt a nicht enthalten,
  Endzeitpunkt b enthalten
- [a, b) – Anfangszeitpunkt a enthalten,
  Endzeitpunkt b nicht enthalten
- (a, b) – Anfangszeitpunkt a nicht enthalten,
  Endzeitpunkt b nicht enthalten,
  d.h. nur die Chronons dazwischen

PRE (*i*)	Offener Anfang
BEGIN (*i*)	Geschlossener Anfang
END (*i*)	Geschlossenes Ende
POST (*i*)	Offenes Ende
COUNT (*i*)	Länge (Anzahl der Punkte)

Intervalle werden oft auch Perioden (periods) genannt.

Intervalle: Mehrere Deutungen

- Etwas gilt zu irgendeinem Zeitpunkt im Intervall (Unsicherheit)
- Etwas gilt zu jedem Zeitpunkt des Intervalls
- Etwas wurde als Wert über (alle) Zeitpunkte im Intervall bestimmt?
  - Beispiel: Inflation – hier DURING als Schlüssel!
- Intervall definiert Periode in der höheren Skala
- ... weitere ...

DURING	PERCENTAGE
[*m01*:*m03*]	18
[*m04*:*m06*]	20
[*m07*:*m09*]	20
[*m07*:*m07*]	25
.....	..
[*m01*:*m12*]	20

Einschränkung: keine „Lücken“

Nicht einfach zu prüfen

Automatische Verschmelzung von Intervallen?

DURING	PRESIDENT
[1974 : 1976]	Ford
[1977 : 1980]	Carter
[1981 : 1984]	Reagan
[1985 : 1988]	Reagan
[1993 : 1996]	Clinton
[1997 : 2000]	Clinton
[2009 : 2012]	Obama
[2013 : 2016]	Obama

Danksagung und Literaturhinweis

Die vorigen 9 Präsentationen
sind in Anlehnung an Präsentationen
von Hugh Darwen zu folgendem Buch
gestaltet.

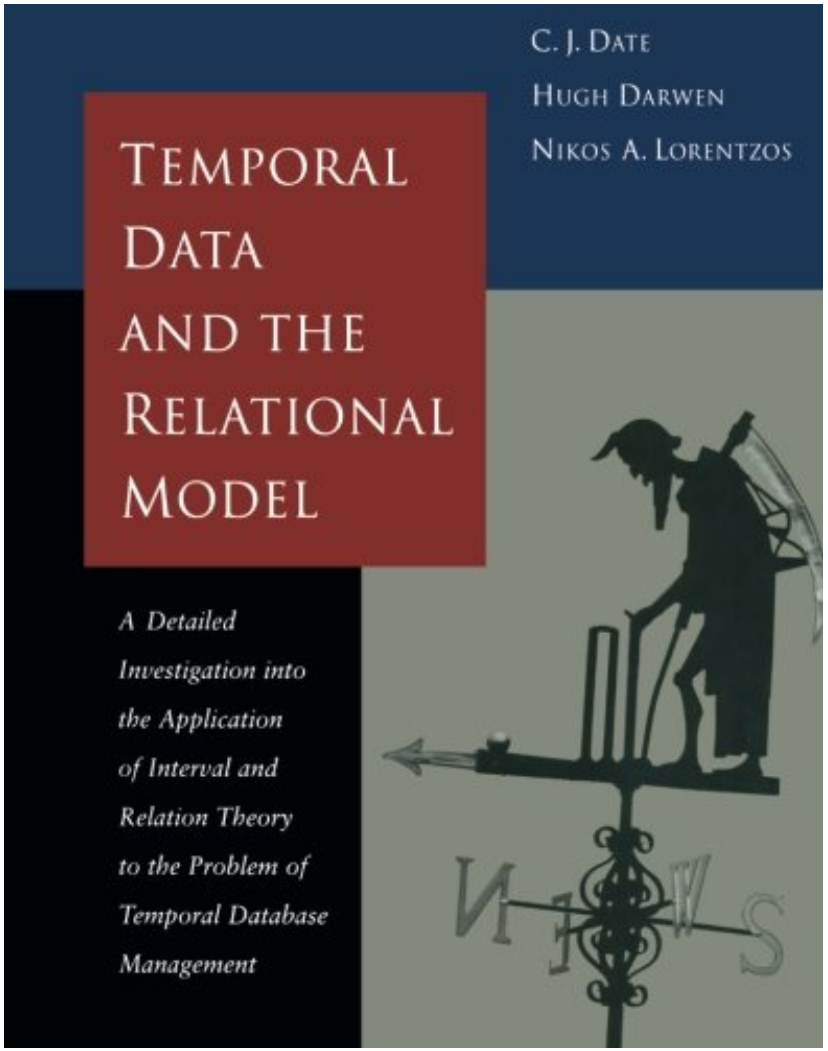

Operators on Time Periods

- Membership test of point in period
- Union, intersection, minus, count
  - Union and minus not defined for all periods. Why?
- Comparison predicates: Allen's operators (are not symmetric!)
  - p1 meets p2
  - p1 starts p2
  - p1 during p2
  - p1 finishes p2
  - p1 overlaps p2
  - p1 before p2
  - p1 = p2

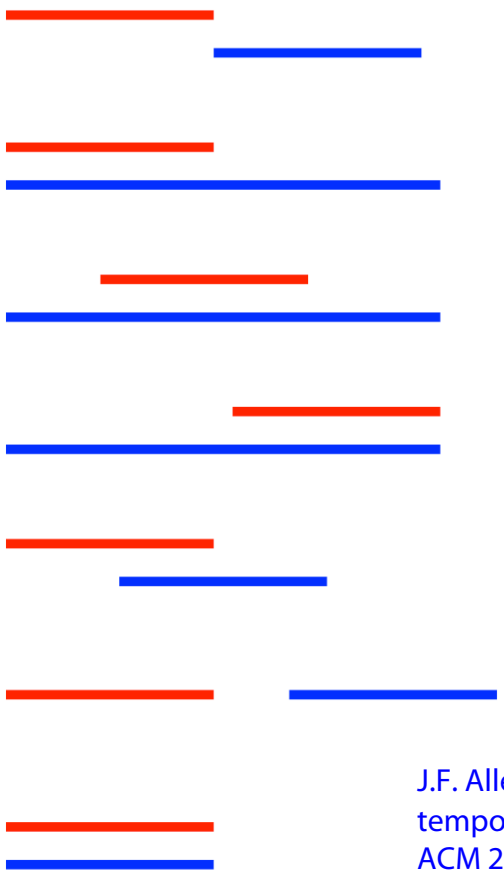

J.F. Allen, "Maintaining knowledge about temporal intervals", Communications of ACM 26(11), November **1983**

Dimensionen der Zeit

- Gültigkeit aus Sicht der Anwendung
  (Gültigkeitszeit – valid time, Anwendungszeit, ...)
- Zeitpunkt der Eintragung eines Tupels in die Datenbank
  „Bekannt“ aus Sicht des Systems
  Zeitpunkt, an dem ein neuer Wert eingetragen wird
  (Transaktionszeit – transaction time, Systemzeit, ...)
- Bitemporal: Beides gleichzeitig repräsentiert

- Auch möglich: benutzerdefinierte Zeitangaben

- Seit langem untersuchtes Gebiet im Datenbankbereich[1]

[1] R. Snodgrass, The temporal query language TQuel, ACM Transactions on Database Systems (TODS) TODS, 12:2, pp. 247-298, **1987**

Relationen in zeitlichen Dimensionen

- Schnappschuss

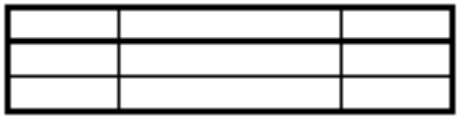

- Gültigkeitszeiten

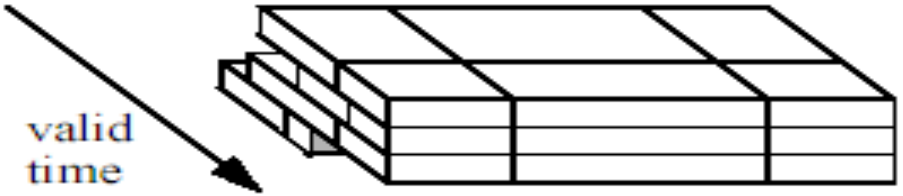

- Transaktionszeiten

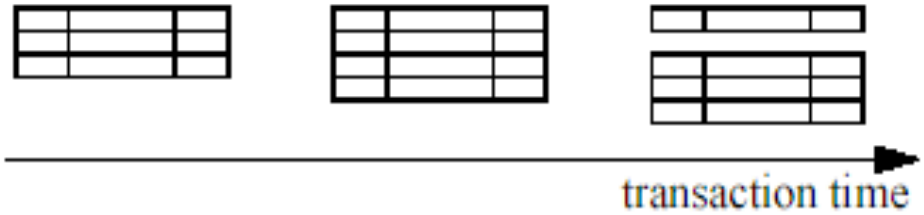

- Bitemporale Relation

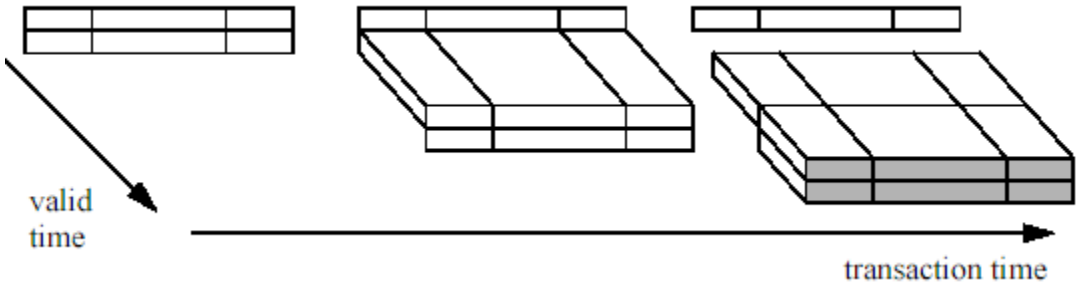

Transaktionszeit: Wofür benötigt?

- Repräsentation von früheren Zuständen (z.B. für Auditing-Zwecke)
- Schreibzugriffe für frühere Zustände könnten limitiert sein (z.B. für sicheres Auditing)
  - Stattdessen: Kompensationstransaktionen zur Fehlerkorrektur

Bitemporale Daten

Emp	Dept	Valid Time	Transaction Time
Jake	Shipping	[1995-06-10 - 1995-06-16)	[1995-06-05 - 1995-06-10)
Jake	Shipping	[1995-06-05 - 1995-06-21)	[1995-06-10 - 1995-06-15)
Jake	Shipping	[1995-06-10 - 1995-06-16)	[1995-06-15 - 1995-06-20)
Jake	Loading	[1995-06-10 - 1995-06-16)	[1995-06-20 - 9999-12-31)

- Beispiel: Anstellung von Jake
- Darstellung einer einzigen Anstellung, mit Änderungen in der modellierten Realität mit jeweils zugehörigem Änderungszeitpunkt

Temporale Datenbank: Definition

- Eine temporale Datenbank ist eine Datenbank mit Unterstützung für Anwendungszeit und/oder Transaktionszeit
- Anfrageevaluierung in temporalen Datenbanken ist nicht als einfaches multidimensionales Indizierungsproblem zu verstehen

Non-Standard-Datenbanken

Von der multidimensionalen Indizierung zu temporalen Daten

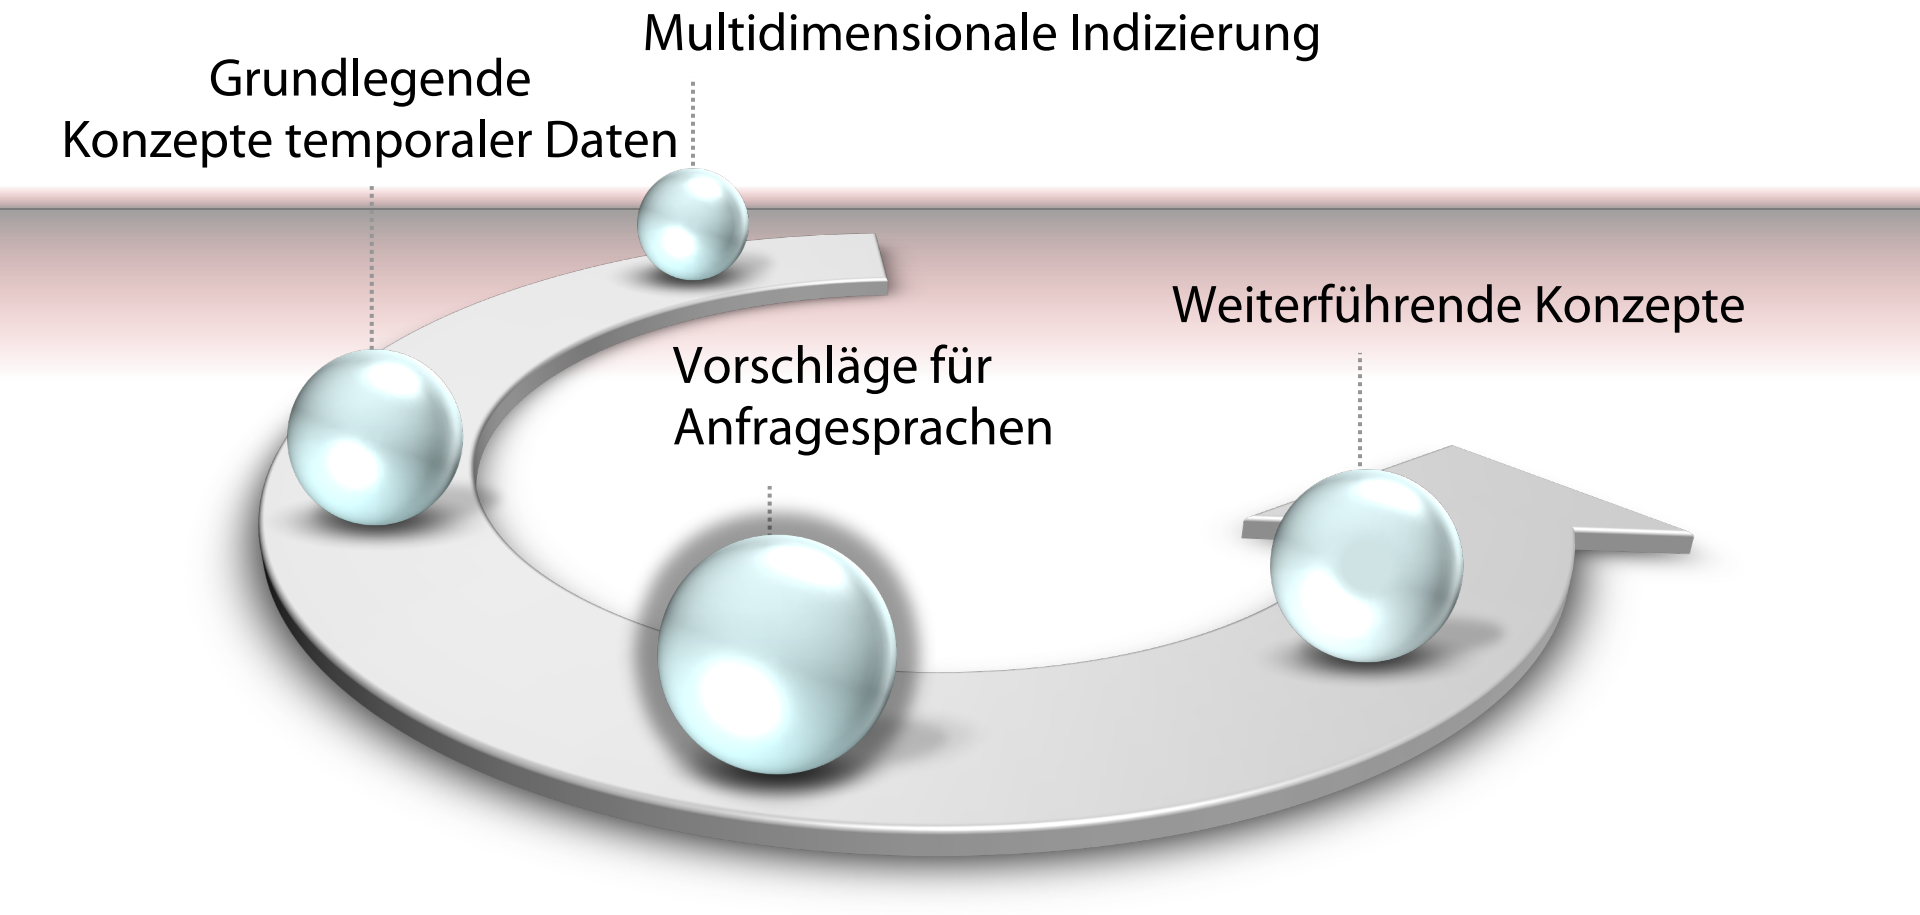

Standisierung schwierig

- TSQL2:
  - Bitemporale Repräsentation möglich
  - Zeitdimensionen implizit (keine normalen Attribute)
  - Zeitdimensionen vom Benutzer (dynamisch) angefordert
  - Modifizierer für SQL-Ausdrücke zur Berücksichtigung von zeitlichen Aspekten

R.T. Snodgrass, et. al., TSQL2 Language Specification.
SIGMOD Record (SIGMOD) 23(1):65-86, **1994**

Richard T. Snodgrass, Michael H. Böhlen, Christian S. Jensen und
Andreas Steiner, "Transitioning Temporal Support in TSQL2 to SQL3,"
in Temporal Databases: Research and Practice, O. Etzion, S. Jajodia, and S. Sripada (eds.),
Springer, LNCS 1399, pp. 150––194, **1998**

- Viel Kritik an TSQL2

Hugh Darwen, C.J. Date, An overview and Analysis of Proposals Based on
the TSQL2 Approach, In Date on Database: Writings 2000-2006, C.J. Date,
Apress, pp. 481-514, **2006**

Standardisierung

- TSQL2 konnte sich nicht durchsetzen
- Auch nicht SQL/Temporal als Teil von SQL:1999 (SQL3)
- Neuer Versuch: SQL:2011

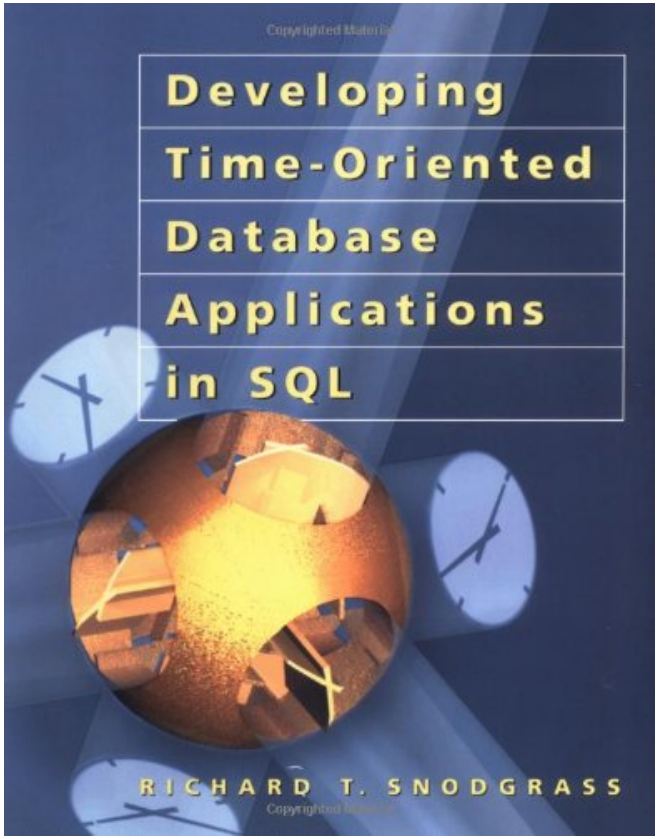

Snodgrass, Richard T., Developing Time-Oriented Database Applications in SQL, Morgan Kaufmann, **1999**

Vgl. auch: C. J. Date, H. Darwen, N.A. Lorentzos, Temporal Data and the Relational Model, Morgan Kaufman, **2003**

Kulkarni, Krishna, and Jan-Eike Michels. Temporal features in SQL:2011. ACM SIGMOD Record 41.3, pp. 34-43, **2011**

Danksagung

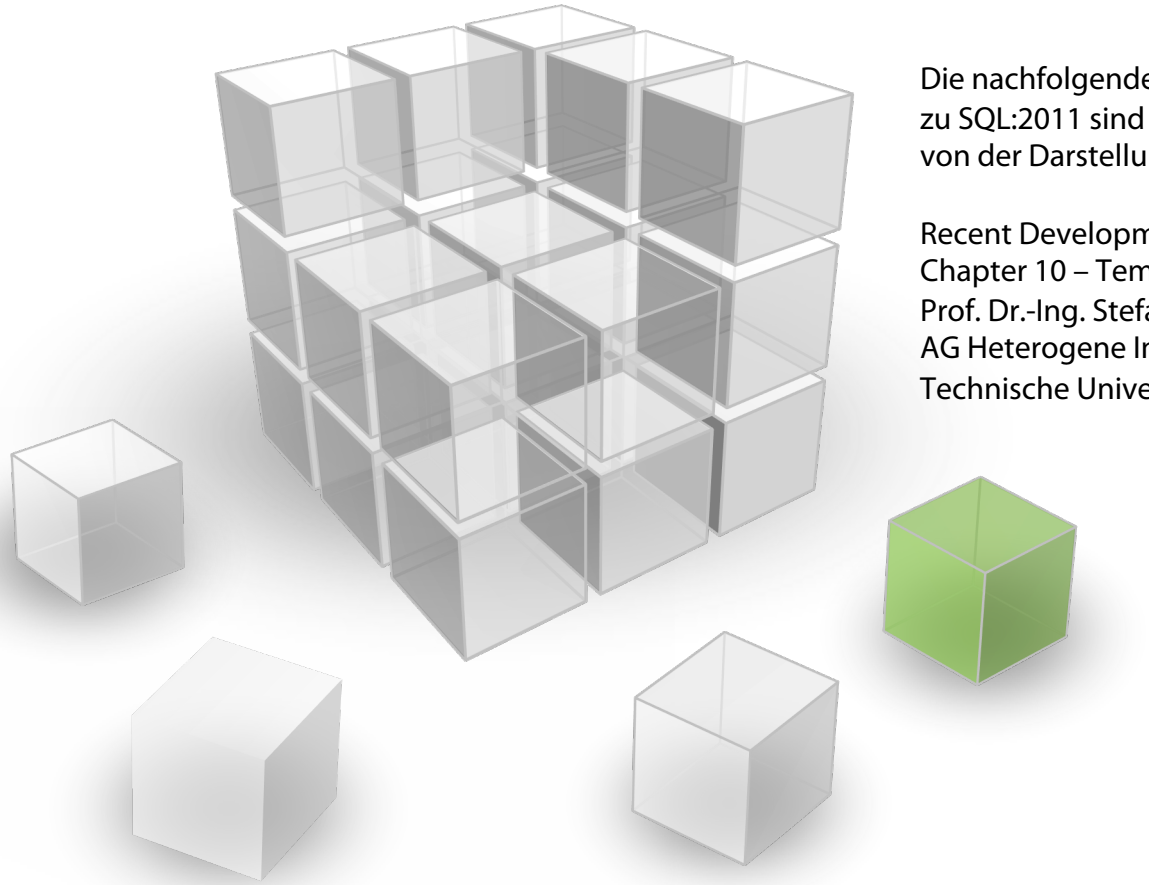

Die nachfolgenden 15 Präsentationen zu SQL:2011 sind inspiriert von der Darstellung in

Recent Developments for Data Models
Chapter 10 – Temporal Data Models
Prof. Dr.-Ing. Stefan Deßloch
AG Heterogene Informationssysteme
Technische Universität Kaiserslautern

SQL:2011 – Unterstützung für temporale Daten

- Kein neuer Datentyp Zeitperiode
- Definition von Perioden für Tabellen mit Bezug auf Paaren von Spalten für Beginn und Ende (→ **Tabellenperioden**)
- Zugrundeliegendes Intervallmodell: [Start, Ende)

SQL:2011 – Unterstützung für temporale Daten

- System-Versionierung von Tabellen
  - Unterstützung für Transaktionszeit
  - Standardanfragen beziehen sich auf „aktuelle“ Daten
  - Bezugnahme auf „historische“ Version möglich durch FOR SYSTEM TIME-Schlüsselwort
- Anwendungszeit von Tabellen durch Perioden
  - Unterstützung für Gültigkeitszeit (Valid Time)
  - Primärschlüssel und Referentielle Integrität
  - Anfragen beziehen sich auf alle gültigen Tupel
  - Prädikate über Perioden für Zugriff auf temporale Bereiche
- Bitemporale Tabellen

Tabellenperioden für Anwendungszeit

- Anwendungszeit/Gültigkeitszeit durch Nutzer bestimmt
- Neues Schlüsselwort PERIOD FOR
- Beispiel:

```
CREATE TABLE Emp(
        ENo     INTEGER,
        EStart  DATE,
        EEnd    DATE,
        EDept   INTEGER,
        PERIOD FOR EPeriod (EStart, EEnd) )
```

- Namen für Perioden frei wählbar
- Anfangs- und End-Attribute als normale Spalten
- Einfügen von Tupeln über INSERT wie bekannt

```
INSERT INTO Emp
VALUES (22217, DATE '2010-01-01', DATE '2011-11-12', 3)
```

Anwendungszeit – Änderung und Löschung

- Modifikationen beziehen sich auf eine effektive Periode
- Änderungen wirksam
  auf allen Tupeln mit über-
  lappenden Zeitperioden

Anwendungszeit und Primär-/Fremdschlüssel

- Primärschlüssel auf Anwendungszeitperiode bezogen
  - Überlappungen von Beginn/Ende-Spalten vermeiden

```
ALTER TABLE EMP
ADD PRIMARY KEY (ENo, EPeriod WITHOUT OVERLAPS)
```

- Referentielle Einschränkungen generalisiert auf jeden gültigen Zeitpunkt

ENo	EStart	EEnd	EDept
22218	2010-01-01	2011-02-03	3
22218	2011-02-03	2011-11-12	4

DNo	DStart	DEnd	DName
3	2009-01-01	2011-12-31	Test
4	2011-06-01	2011-12-31	QA

- Zeitperiodenangaben für Primär- und Fremdschlüssel

```
CREATE TABLE Dept
(DNo INTEGER, ..., PERIOD FOR DPeriod (DStart, DEnd),
PRIMARY KEY (DNo, DPeriod WITHOUT OVERLAPS))

ALTER TABLE Emp
ADD FOREIGN KEY (Edept, PERIOD EPeriod)
REFERENCES Dept (DNo, PERIOD DPeriod)
```

Anwendungszeit in Anfragen

- Verwendung von SELECT wie gehabt
  - Zeitperiodenspalten verwendbar wie gewohnt
- Spezielle Prädikate für Zeitperioden

```
SELECT EName, EDept
FROM Emp
WHERE ENo = 22217 AND EPeriod CONTAINS DATE '2011-01-02'
```

- Semantik (basierend auf Allen'sche Intervallbeziehungen)
  - x CONTAINS y ~ (x contains y) or (x starts y) or (x finishes y) or (x equal y)
  - x OVERLAPS y ~ (x overlaps y) or (y overlaps x) or (x contains y) or (y contains x) or (x starts y) or (y starts x) or (x finishes y) or (y finishes x) or (x equals y)
  - x EQUALS y ~ x equals y
  - x PRECEDES y ~ (x before y) or (x meets y)
  - x SUCCEEDS y ~ (y before x) or (y meets x)
  - x IMMEDIATELY PRECEDES y ~ x meets y
  - x IMMEDIATELY SUCCEEDS y ~ y meets x

Temporale Verbunde mit Anwendungszeit

ENo	EStart	EEnd	EDept
22218	2010-01-01	2011-02-03	3
22218	2011-02-03	2011-11-12	4

DNo	DStart	DEnd	DName
3	2009-01-01	2011-12-31	Test
4	2009-06-01	2011-01-31	Quality
4	2011-02-01	2011-12-31	QA

- Normale Verbunde betrachten Anwendungszeit nicht

  SELECT ENo, EDept, DName FROM Emp, Dept
  WHERE EDept = DNo

- Temporale Verbunde unter Verwendung von Zeitperioden

  SELECT ENo, EDept, DName
  FROM Emp, Dept
  WHERE EDept = DNo AND **EPeriod OVERLAPS DPeriod**

Tabellen und Versionierung mit Systemzeit

- Versionierung von Tabellen durch Systemzeitattribute (auch Transaktionszeit genannt)
- Beispiel

```
CREATE TABLE Emp (
        ENo INTEGER,
        Sys_start TIMESTAMP(12) GENERATED ALWAYS AS ROW START,
        Sys_end TIMESTAMP(12) GENERATED ALWAYS AS ROW END,
        EName VARCHAR(30),
        PERIOD FOR SYSTEM_TIME (Sys_start, Sys_end))WITH SYSTEM VERSIONING
```

Tabellen und Versionierung mit Systemzeit

- Versionierung von Tabellen durch Systemzeitattribute (auch Transaktionszeit genannt)
- Nur das DBMS kann (und muss) Start- und Endzeitpunkte für Systemzeitperioden liefern
  - Datentyp für Zeitpunkte systemabhängig
- Modifikation → zusätzliches Tupel für den alten Zustand vor der Änderung
  - Aktueller Zeilenzustand: Zeitstempel ist der neueste
  - Historischer Zeilenzustand: Zeitstempel nicht der neueste

Änderung von systemversionierten Tabellen

INSERT

- Systemzeitstart wird auf Transaktionszeit gesetzt
- Systemzeitende wird auf Maximalwert gesetzt
  INSERT INTO Emp (ENo, EName) VALUES (22217, 'Joe')

ENo	Sys_start	Sys_end	EName
22217	2012-01-01 09:00:00	9999-12-31 23:59:59	Joe

UPDATE und DELETE

- Operationen nur auf aktuellen Zeilen
- Automatisches Erzeugen von historischen Zeilen für jede geänderte oder gelöschte Zeile
- Bei UPDATE wird der neue Startzeitpunkt auf die Transaktionszeit gesetzt

ENo	Sys_start	Sys_end	EName
22217	2012-01-01 09:00:00	2012-02-03 10:00:00	Joe
22217	2012-02-03 10:00:00	9999-12-31 23:59:59	Tom

Einschränkungen und Anfragen

- Primärschlüssel und Fremdschlüssel für systemversionierte Tabellen
  - Sollen nur für die aktuellen Zeilen geprüft werden
  - Systemzeitperiode muss nicht als Teil des Schlüssels deklariert werden
- Anfragen auf systemversionierten Tabellen:
  - Beziehen sich standardmäßig auf aktuelle Zeilen
  - Bezugnahme auf historische Zeilen durch Schlüsselwort FOR SYSTEM TIME

Beispiele

- Bestimme Zeilen, die zu einem gegebenen Zeitpunkt die aktuellen Zeilen sind

```
SELECT ENo, EName, Sys_Start, Sys_End
FROM Emp FOR SYSTEM_TIME AS OF TIMESTAMP '2011-01-02 00:00:00‘
```

- Bestimme Zeilen, die in einer Zeitperiode aktuell waren (ohne Endpunkt der Periode)

```
SELECT ENo, EName, Sys_Start, Sys_End
FROM Emp FOR SYSTEM_TIME
      FROM TIMESTAMP '2011-01-02 00:00:00’ TO TIMESTAMP '2011-12-31 00:00:00'
```

- Bestimme Zeilen, die in einer Zeitperiode aktuell waren (mit Endpunkt der Periode)

```
SELECT ENo, EName, Sys_Start, Sys_End
FROM Emp FOR SYSTEM_TIME
      BETWEEN TIMESTAMP '2011-01-02 00:00:00‘ AND TIMESTAMP '2011-12-31 00:00:00'
```

Bitemporale Tabellen

- Anwendungszeit und Systemzeit kombiniert
- Beispiel

```
CREATE TABLE Emp(
        ENo INTEGER,
        EStart DATE,
        EEnd DATE,
        EDept INTEGER,
        PERIOD FOR EPeriod (EStart, EEnd),
        Sys_start TIMESTAMP(12) GENERATED ALWAYS AS ROW START,
        Sys_end TIMESTAMP(12) GENERATED ALWAYS AS ROW END,
        EName VARCHAR(30),
        PERIOD FOR SYSTEM_TIME (Sys_start, Sys_end),
        PRIMARY KEY (ENo, EPeriod WITHOUT OVERLAPS),
        FOREIGN KEY (EDept, PERIOD EPeriod)
            REFERENCES Dept (DNo, PERIOD DPeriod))
WITH SYSTEM VERSIONING
```

Anfragen an bitemporale Tabellen

- Anfragen können Prädikate für Systemzeitperioden und Anwendungszeitperioden enthalten
- Beispiel

```
SELECT ENo, EDept
FROM Emp FOR SYSTEM_TIME
        AS OF TIMESTAMP '2011-07-01 00:00:00'
WHERE ENo = 22217
         AND EPeriod CONTAINS DATE '2010-12-01'
```

Temporale Daten – Zusammenfassung

- Zentralen Anforderung in vielen Anwendungen
  - Zeitperioden, Prädikate (z.B. mit Allen-Operatoren)
  - Anwendungszeit vs. Systemzeit, bitemporale Tabellen
- Wichtige frühere Ansätze[1]
  - TSQL2, SQL/Temporal
- SQL:2011
  - Definition von Perioden, Anwendungszeit und Systemzeit
- SQL: Weitere Entwicklungen
  - Outer Join, Gruppierung, Aggregation mit Zeitperioden
  - Normalisierung (z.B. Zusammenfassung von Perioden)
  - Viele weitere

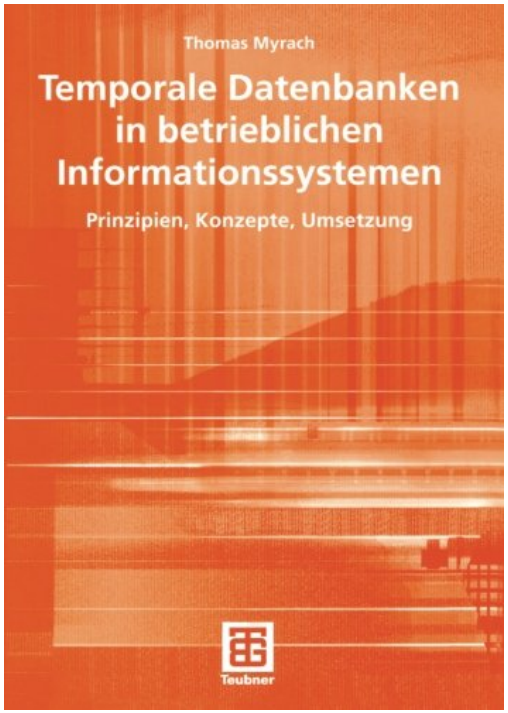

[1] CS Jensen, RT Snodgrass, Semantics of time-varying information, Journal of Information Systems, 21:4, pp. 311-352, **1996**

Non-Standard-Datenbanken

Von der multidimensionalen Indizierung zu temporalen Daten

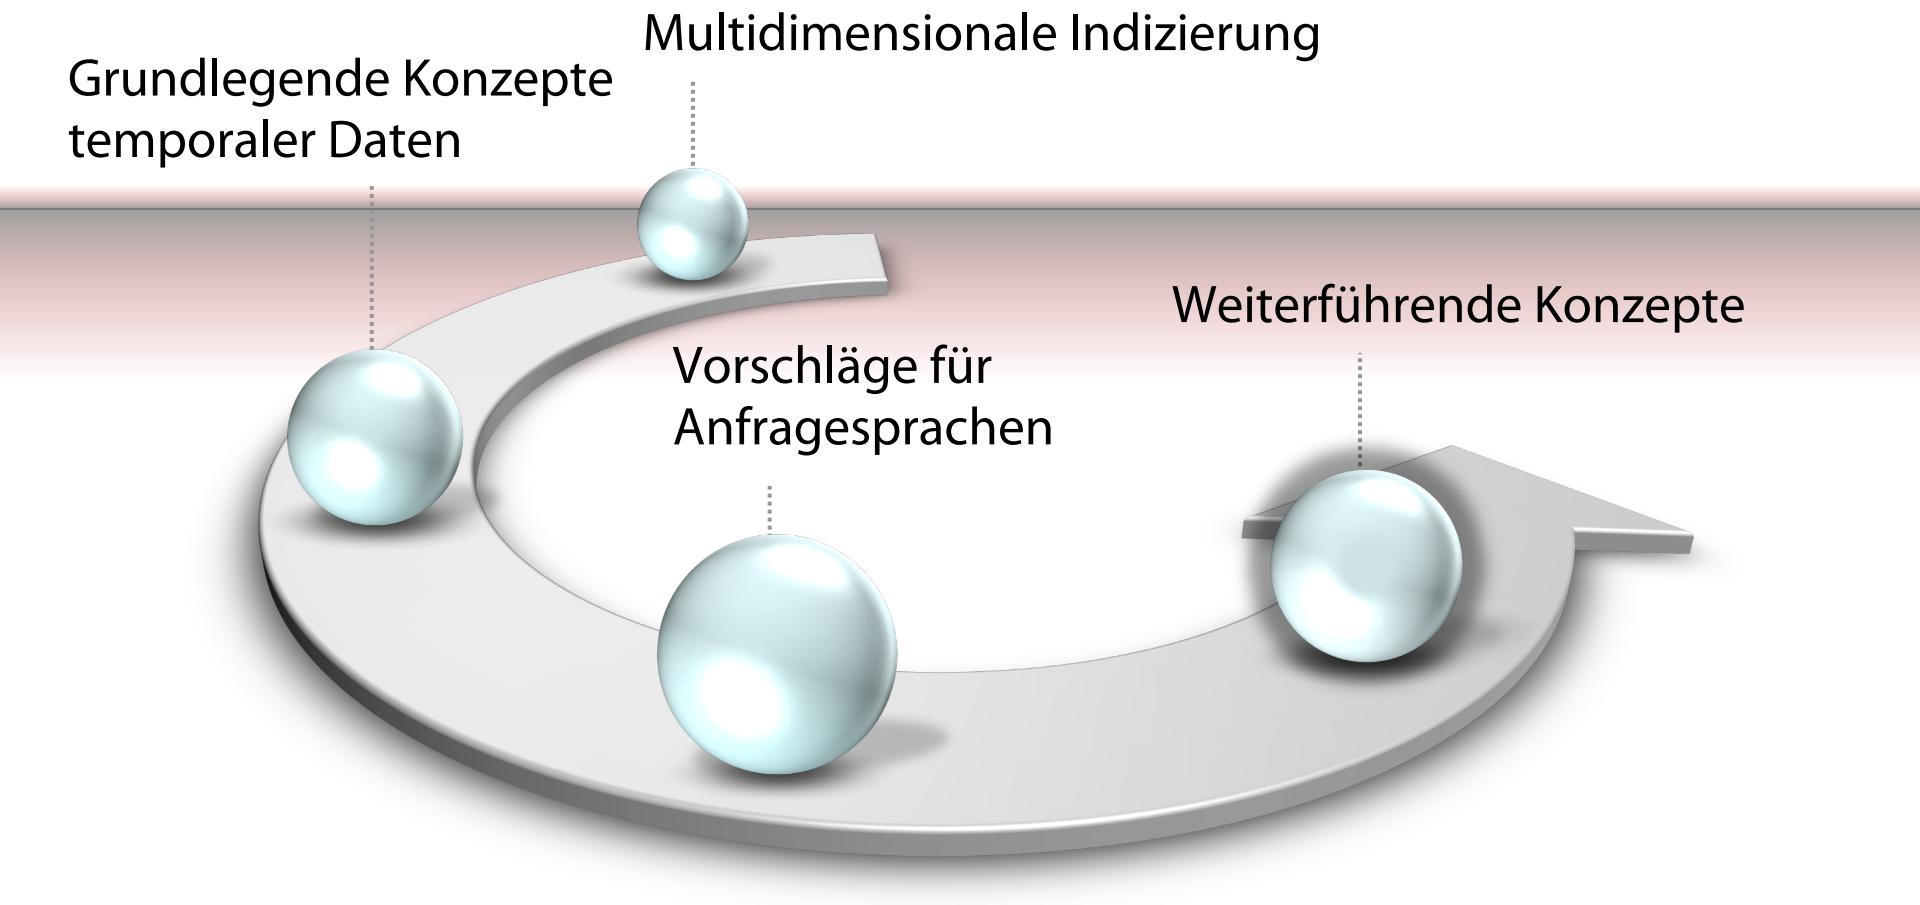

Sequenzen in SQL:2011

- Unterstützung für Datenanalyse in SQL:2011 durch Bildung von Sequenzen aus einer Relation
- Siehe auch OLAP-Funktionen in SQL:2003
- Auch für Analyse zeitlicher Daten geeignet

- Nachfolgende 11 Präsentationen sind angelehnt an ein Tutorial „Advanced SQL“ von Marcin.Blaszczyk@cern.ch

Analytische Funktionen – Überblick

- Allgemeine Syntax:

```
SELECT analytical-function(col-expr)
       OVER (window-spec) [AS col-alias]
FROM [TABLE];
```

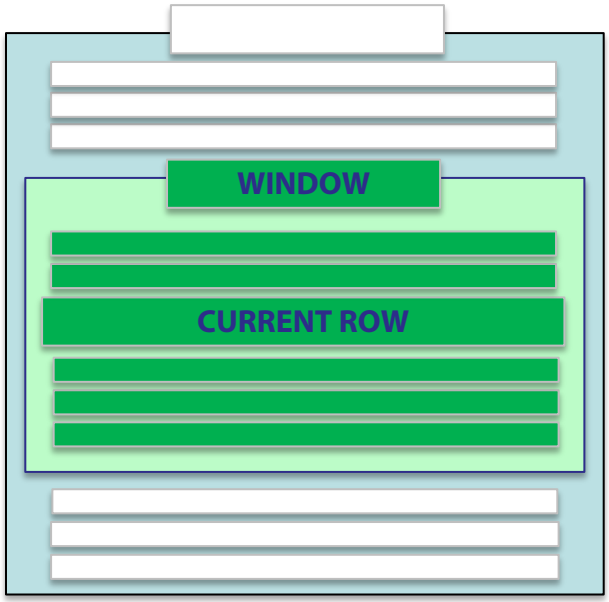

- Fensterspezifikation – Syntax

```
[PARTITION BY [expr list]]
ORDER BY [sort spec] [range spec]
```

- Beispiel für Bereichspezifikation (siehe Dokumentation)

```
• ROWS UNBOUNDED PRECEDING AND CURRENT ROW (default)
• ROWS BETWEEN CURRENT ROW AND UNBOUNDED FOLLOWING
• RANGE BETWEEN n PRECEDING AND m FOLLOWING
```

Geordnetes Analytisches Fenster

Analytische Funktion auf alle Tupel des Fensters angewandt

```
SQL>  select employee_id, last_name, manager_id, salary
      sum(salary) over (order by  employee_id, last_name, salary)
      as cumulative from employees;

EMPLOYEE_ID LAST_NAME MANAGER_ID SALARY CUMULATIVE
----------- --------- ---------- ------ ----------
        100 King                24000      24000
        101 Kochhar          100 17000      41000
        102 De Haan          100 17000      58000 = 24000 + 17000 + 17000
        103 Hunold           102  9000      67000
        104 Ernst            103  6000      73000
        105 Austin           103  4800      77800
        106 Pataballa        103  4800      82600
        107 Lorentz          103  4200      86800
        108 Greenberg        101 12000      98800
        109 Faviet           108  9000     107800
        110 Chen             108  8200     116000
```

Bereichsangabe – Beispiel (1)

RANGE BETWEEN 2 PRECEDING AND 1 FOLLOWING

```
SQL> select manager_id, last_name, salary, sum(salary) over (order by
          last_name, salary rows between 2 preceding and 1 following) as
          cumulative from employees;

MANAGER_ID LAST_NAME SALARY CUMULATIVE
---------- --------- ------ ----------
       103 Austin      4800      10800
       103 Ernst       6000      22800
       101 Greenberg  12000      31800
       102 Hunold      9000      51000 = 6000 + 12000 + 9000 + 24000
           King       24000      62000
       100 Kochhar    17000      54200
       103 Lorentz     4200      45200
```

Bereichsangabe – Beispiel (2)

ROWS BETWEEN CURRENT ROW AND UNBOUNDED FOLLOWING

```
SQL> select manager_id, last_name, salary, sum(salary) over (order by
          last_name, salary rows between current row and unbounded
          following) as cumulative from emp_part;

MANAGER_ID LAST_NAME  SALARY CUMULATIVE
---------- --------- ------ ----------
       103 Austin      4800      77000
       103 Ernst       6000      72200
       101 Greenberg  12000      66200
       102 Hunold      9000      54200 = 9000 + 24000 + 17000 + 4200
           King       24000      45200
       100 Kochhar    17000      21200
       103 Lorentz     4200       4200
```

Partitioniertes analytisches Fenster

Analytische Funktion wird auf jede Partition angewandt

```
SQL> break on manager_id
SQL> SELECT manager_id, last_name, employee_id, salary,
     sum(salary) over (PARTITION BY manager_id order by employee_id) as cumulative
     FROM employees order by manager_id, employee_id, last_name;

MANAGER_ID LAST_NAME       EMPLOYEE_ID SALARY CUMULATIVE
---------- --------------- ----------- ------ ----------
       100 Kochhar                 101  17000      17000
           De Haan                 102  17000      34000
           Raphaely                114  11000      45000
           Weiss                   120   8000      53000
       101 Greenberg               108  12000      12000
           Whalen                  200   4400      16400
           Mavris                  203   6500      22900
           Baer                    204  10000      32900
       102 Hunold                  103   9000       9000
       103 Ernst                   104   6000       6000
           Austin                  105   4800      10800
           Pataballa               106   4800      15600
```

Partitioniertes analytisches Fenster

Analytische Funktion wird auf jede Partition angewandt

```
SQL> break on manager_id
SQL> SELECT manager_id, last_name, employee_id, salary,
     sum(salary) over (PARTITION BY manager_id order by employee_id) as cumulative
     FROM employees order by manager_id, employee_id, last_name;

MANAGER_ID LAST_NAME       EMPLOYEE_ID SALARY CUMULATIVE
---------- --------------- ----------- ------ ----------
       100 Kochhar                 101  17000      17000
           De Haan                 102  17000      34000
           Raphaely                114  11000      45000
           Weiss                   120   8000      53000
       101 Greenberg               108  12000      12000
           Whalen                  200   4400      16400
           Mavris                  203   6500      22900
           Baer                    204  10000      32900
       102 Hunold                  103   9000       9000
       103 Ernst                   104   6000       6000
           Austin                  105   4800      10800
           Pataballa               106   4800      15600
```

Partitioniertes analytisches Fenster

Analytische Funktion wird auf jede Partition angewandt

```
SQL> break on manager_id
SQL> SELECT manager_id, last_name, employee_id, salary,
     sum(salary) over (PARTITION BY manager_id order by employee_id) as cumulative
     FROM employees order by manager_id, employee_id, last_name;

MANAGER_ID LAST_NAME       EMPLOYEE_ID SALARY CUMULATIVE
---------- --------------- ----------- ------ ----------
       100 Kochhar                 101  17000      17000
           De Haan                 102  17000      34000
           Raphaely                114  11000      45000
           Weiss                   120   8000      53000
       101 Greenberg               108  12000      12000
           Whalen                  200   4400      16400
           Mavris                  203   6500      22900
           Baer                    204  10000      32900
       102 Hunold                  103   9000       9000
       103 Ernst                   104   6000       6000
           Austin                  105   4800      10800
           Pataballa               106   4800      15600
```

Partitioniertes analytisches Fenster

Analytische Funktion wird auf jede Partition angewandt

```
SQL> break on manager_id
SQL> SELECT manager_id, last_name, employee_id, salary,
     sum(salary) over (PARTITION BY manager_id order by employee_id) as cumulative
     FROM employees order by manager_id, employee_id, last_name;

MANAGER_ID LAST_NAME       EMPLOYEE_ID SALARY CUMULATIVE
---------- --------------- ----------- ------ ----------
       100 Kochhar                 101  17000      17000
           De Haan                 102  17000      34000
           Raphaely                114  11000      45000
           Weiss                   120   8000      53000
       101 Greenberg               108  12000      12000
           Whalen                  200   4400      16400
           Mavris                  203   6500      22900
           Baer                    204  10000      32900
       102 Hunold                  103   9000       9000
       103 Ernst                   104   6000       6000
           Austin                  105   4800      10800
           Pataballa               106   4800      15600
```

Partitioniertes analytisches Fenster

Analytische Funktion wird auf jede Partition angewandt

```
SQL> break on manager_id
SQL> SELECT manager_id, last_name, employee_id, salary,
     sum(salary) over (PARTITION BY manager_id order by employee_id) as cumulative
     FROM employees order by manager_id, employee_id, last_name;

MANAGER_ID LAST_NAME       EMPLOYEE_ID SALARY CUMULATIVE
---------- --------------- ----------- ------ ----------
       100 Kochhar                 101  17000      17000
           De Haan                 102  17000      34000
           Raphaely                114  11000      45000
           Weiss                   120   8000      53000
       101 Greenberg               108  12000      12000
           Whalen                  200   4400      16400
           Mavris                  203   6500      22900
           Baer                    204  10000      32900
       102 Hunold                  103   9000       9000
       103 Ernst                   104   6000       6000
           Austin                  105   4800      10800
           Pataballa               106   4800      15600
```

= 6000 + 4800 + 4800

Vordefinierte analytische Funktionen

- Aggregatsfunktionen
  - SUM
  - MAX
  - MIN
  - AVG
  - COUNT
- Zusätzlich für Fensterbereiche:
  - LAG
  - LEAD
  - FIRST
  - LAST
  - FIRST VALUE
  - LAST VALUE
  - ROW_NUMBER
  - RANK
  - DENSE_RANK

Analytische Funktion – Beispiel LAG

```
SQL> select * from currency order by 1;

DAY                    EURCHF
-------------------- ------
01-JUN-2012 00:00:00  1.240
02-JUN-2012 00:00:00  1.223
03-JUN-2012 00:00:00  1.228
04-JUN-2012 00:00:00  1.217
05-JUN-2012 00:00:00  1.255
06-JUN-2012 00:00:00  1.289
07-JUN-2012 00:00:00  1.291
08-JUN-2012 00:00:00  1.247
09-JUN-2012 00:00:00  1.217
10-JUN-2012 00:00:00  1.265
```

```
SQL> select day, EURCHF, lag(EURCHF,1) over
(order by day) as prev_eurchf from currency;

DAY                    EURCHF    PREV_EURCHF
-------------------- ------ --------------
01-JUN-2012 00:00:00  1.240
02-JUN-2012 00:00:00  1.223           1.240
03-JUN-2012 00:00:00  1.228           1.223
04-JUN-2012 00:00:00  1.217           1.228
05-JUN-2012 00:00:00  1.255           1.217
06-JUN-2012 00:00:00  1.289           1.255
07-JUN-2012 00:00:00  1.291           1.289
08-JUN-2012 00:00:00  1.247           1.291
09-JUN-2012 00:00:00  1.217           1.247
10-JUN-2012 00:00:00  1.265           1.217
```

Offene Punkte bei der Datenmodellierung

- Periodische Gültigkeit
- Unsicherheit:
  - Gültigkeit zu mindestens einem Zeitpunkt in einem Intervall
- Abhängigkeiten zwischen Anwendungszeitperioden bzw. Systemzeitperioden
  - Etwas gilt, nachdem/bis/bevor/während etwas anderes gilt, ohne dass die tatsächlichen Intervallgrenzen bekannt sind
- Open-World-Annahme: Wenn etwas nicht als gültig eingetragen ist, ist es nicht notwendigerweise ungültig
- Komplexere Zeitstrukturen
  - Verzweigende Zeit (branching time)
  - Dichte Zeitstrukturen
- Repräsentation und Erkennung von Ereignissen

Weitere Aspekte und Ausblick

- Zeit in **XML** (valid time / transaction time in XPath)
  - Ähnliche Prinzipien wie im relationalen Modell
- Zeit auf der Ebene der **konzeptuellen Datenmodellierung**
- Deklarationen für **physikalische Ebene** von temporalen Datenbanken (z.B. Indexe)
- **Strom-orientierte Datenverarbeitung**
  - Hohe Datenraten, Zwischendaten pro Fenster akkumulierend
  - Sekundärspeicher nötig, aber ggf. auch zu langsam, um Zwischenresultate aufzunehmen
  - Speicherbegrenzung und damit Approximation nötig