# 4. Datenallokation in VDBS und PDBS

- Fragmentierung und Allokation
- Fragmentierungsvarianten
  - horizontale / vertikale /hybride Fragmentierungen
- Verteilungstransparenz
- Datenallokation für Shared Nothing PDBS
  - Verteilgrad
  - Varianten der horizontalen Fragmentierung
    - Round Robin, Hash-Fragmentierung
    - Bereichsfragmentierung: einfach, verfeinert
    - mehrdimensionale und mehrstufige Fragmentierung
  - Allokation der Fragmente
- Datenallokation für Shared Storage / Shared Everything
- NoSQL Datenallokation
  - Consistent Hashing
  - MongoDB

# Bestimmung der Datenverteilung

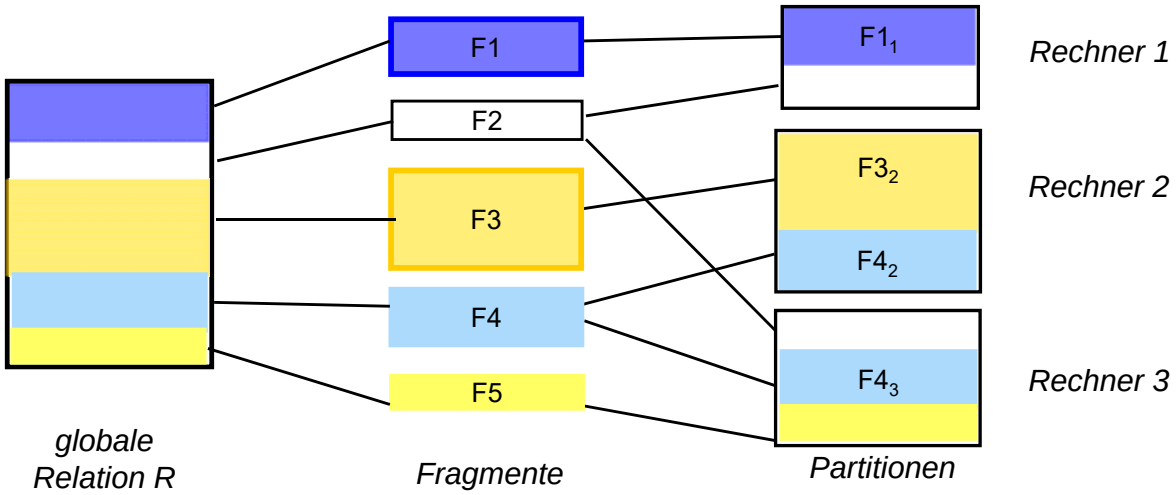


- Fragmentierung
  - Fragmente: Einheiten der Datenverteilung
  - wünschenswert: (horizontale / vertikale) Teile von Relationen
- Allokation von Fragmenten
  - bestimmt weitgehend Ausführungsort von DB-Operationen
  - Zielkonflikt: Minimierung der Kommunikationskosten vs. Lastbalancierung
  - ggf. replizierte Speicherung von Fragmenten

# Fragmentierung

- Gründe für (horizontale bzw. vertikale) Fragmentierung
  - Lastbalancierung (relativ wenige, teilweise große Tabellen)
  - Nutzung von Lokalität
  - Reduzierung des Verarbeitungsumfangs für Anfragen („*Fragment Pruning*“ bzw. „*Partition Elimination*“)
  - Unterstützung von Parallelverarbeitung
  - bessere Administrierbarkeit sehr großer Tabellen (Sicherung, Reorganisation)

- Anforderungen
  - *Vollständigkeit*: jedes Datenelement muss in wenigstens einem Fragment enthalten sein
  - *Rekonstruierbarkeit*: Verlustfreiheit der Zerlegung
  - (weitestgehende) *Disjunktheit*

# Horizontale Fragmentierung

- zeilenweise Aufteilung von Relationen („*Sharding*“)
- Definition der Fragmentierung durch Selektionsprädikate Pi auf der Relation: $R_i := \sigma_{Pi}\ (R)\ \ (1 \leq i \leq\ n)$

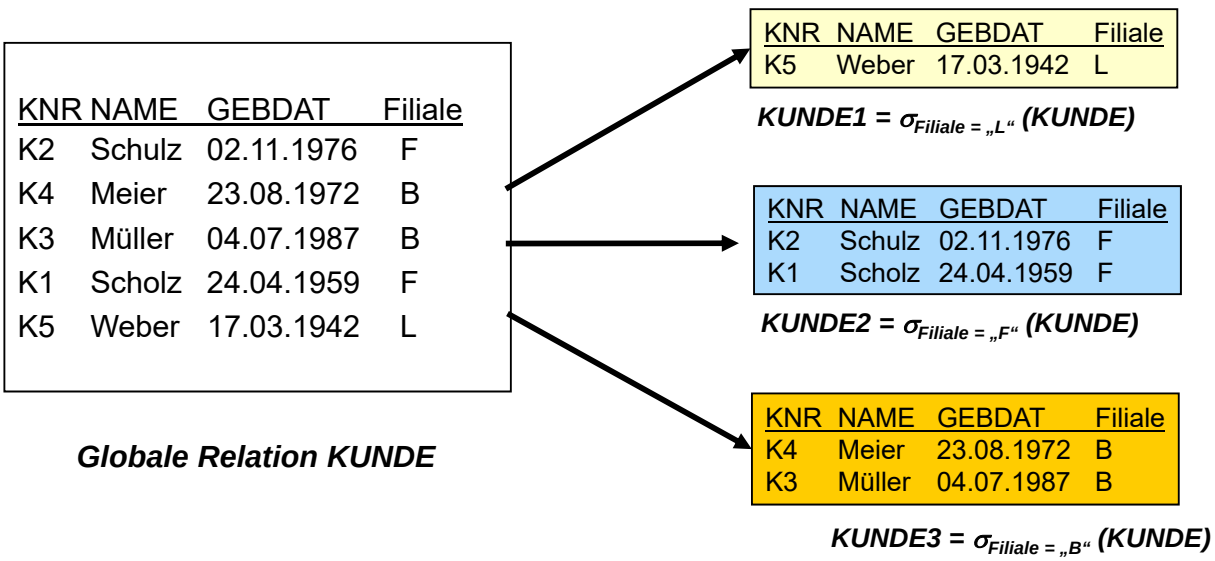

# Horizontale Fragmentierung (2)

- Fragmentierungsprädikate zu wählen, damit gilt
  - Vollständigkeit: jedes Tupel ist einem Fragment eindeutig zugeordnet
  - Fragmente sind disjunkt: $R_i \cap R_j = \{\}$ $(i \neq j)$
  - Verlustfreiheit (Relation ist Vereinigung aller Fragmente): $R = \cup R_i \ (1 \leq i \leq n)$

- Vorteile
  - Anfragen können ggf. auf Teilmenge der Fragmente begrenzt werden
  - Nutzung von Lokalität für Fragmentzugriffe
  - optimale Parallelisierbarkeit von Anfragen auf großen Tabellen

# Abgeleitete horizontale Fragmentierung

- horizontale Fragmentierung einer Tabelle S wird über Prädikate einer anderen Relation R definiert, zu der S abhängig ist
- i.a. funktionale Abhängigkeit (n:1) über Fremdschlüssel-Primärschlüssel-Beziehungen
- Beispiel: Fragmentierung von Relation KONTO analog zu KUNDE

***Globale Relation KONTO***

KUNDE-Partitionierung (über FILIALE) bestimmt KONTO-Partitionierung

| KTONR | KNR | KTOSTAND |
|---|---|---|
| 1234 | K2 | 122,34 |
| 2345 | K4 | - 12,43 |
| 3231 | K1 | 1222,22 |
| 7654 | K5 | 63,79 |
| 9876 | K2 | 55,77 |
| 5498 | K4 | - 4506,77 |

| KTONR | KNR | KTOSTAND |
|---|---|---|
| 7654 | K5 | 63,79 |

***KONTO1: Konten zu KUNDE1 (Filiale „L“)***

| KTONR | KNR | KTOSTAND |
|---|---|---|
| 1234 | K2 | 122,34 |
| 3231 | K1 | 1222,22 |
| 9876 | K2 | 55,77 |

***KONTO2: Konten zu KUNDE2 (Filiale „F“)***

| KTONR | KNR | KTOSTAND |
|---|---|---|
| 2345 | K4 | - 12,43 |
| 5498 | K4 | - 4506,77 |

***KONTO3: Konten zu KUNDE3 (Filiale „B“)***

# Abgeleitete horizontale Fragmentierung (2)

- Semi-Join zwischen Relationen S und R

$$S \ltimes R = \pi_{\text{S-Attribute}} (S \bowtie R)$$

  - asymmetrischer Operator
- Sei R horizontal in Fragmente $R_1$, $R_2$, ... $R_n$ zerlegt. Eine von R abgeleitete horizontale Fragmentierung einer Tabelle S hat die Fragmente

$$S_i = S \ltimes R_i = S \ltimes \sigma_{Pi} (R) \qquad (1 \leq i \leq n)$$

  - Beispiel: $KONTO_i$ =
- effiziente Join-Verarbeitung zwischen R und S
  - lokale Join-Durchführung falls Fragmente $R_i$ und $S_i$ am selben Rechner („colocated“)
  - reduzierte Datenmengen für Suche nach Verbundpartnern
- Vollständigkeit?

# Vertikale Fragmentierung

- spaltenweise Aufteilung von Relationen
- Definition der Fragmentierung durch Projektion

***Globale Relation KUNDE***

| KNR | NAME | GEBDAT | Filiale |
|---|---|---|---|
| K2 | Schulz | 02.11.1976 | F |
| K4 | Meier | 23.08.1972 | B |
| K3 | Müller | 04.07.1987 | B |
| K1 | Scholz | 24.04.1959 | F |
| K5 | Weber | 17.03.1942 | L |

| KNR | NAME | Filiale |
|---|---|---|
| K2 | Schulz | F |
| K4 | Meier | B |
| K3 | Müller | B |
| K1 | Scholz | F |
| K5 | Weber | L |

| KNR | GEBDAT |
|---|---|
| K2 | 02.11.1976 |
| K4 | 23.08.1972 |
| K3 | 04.07.1987 |
| K1 | 24.04.1959 |
| K5 | 17.03.1942 |

***KUNDE1 = $\pi_{KNR, NAME, Filiale}$ (KUNDE)***

***KUNDE2 = $\pi_{KNR, GEBDAT}$ (KUNDE)***

# Vertikale Fragmentierung (2)

- Vollständigkeit:
  - jedes Attribut in wenigstens 1 Fragment enthalten
- verlustfreie Zerlegung:
  - Primärschlüssel i.a. in jedem Fragment enthalten
  - JOIN-Operation zur Rekonstruktion des gesamten Tupels

- Vorteile
  - „kürzere“ Tupel -> kleinere Datenmengen
  - ggf. weniger Fragmente (Kommunikationseinsparung)
- Nachteile
  - geringe Anzahl möglicher Fragmente
  - Einfügen neuer Sätze betrifft alle Fragmente

# Hybride Fragmentierung

- Kombination von horizontaler und vertikaler Fragmentierung

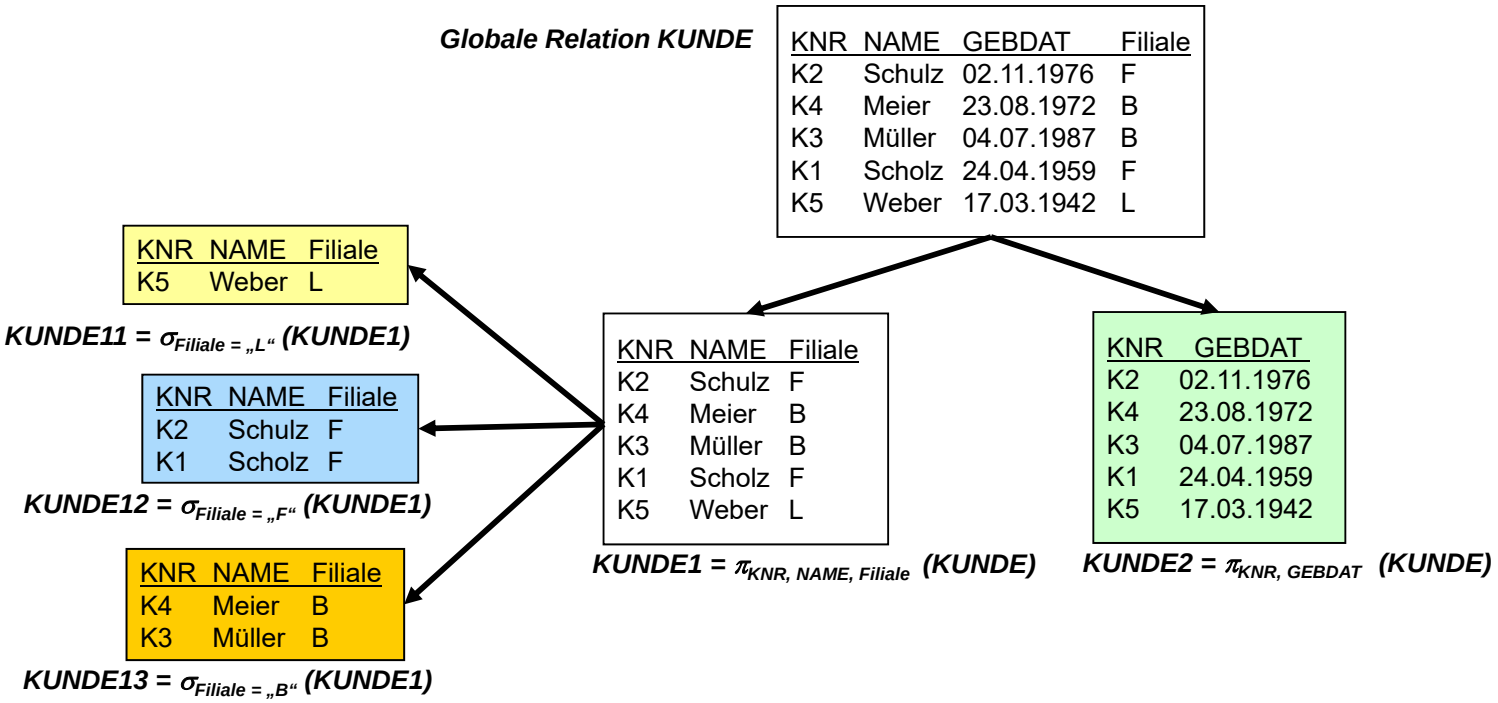

# Hybride Fragmentierung (2)

a) vertikale gefolgt von horizontaler Partitionierung

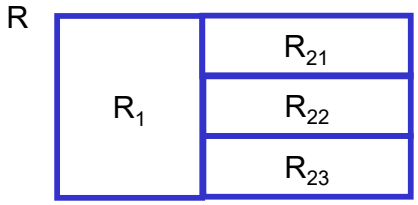


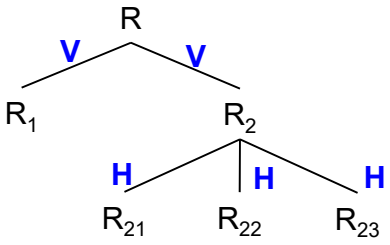


*Fragmentierungsbaum*

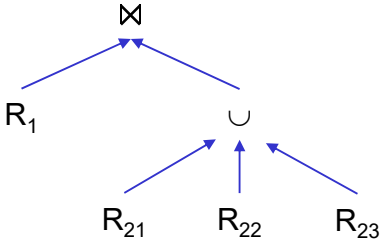


*Operatorbaum (Rekonstruktion)*

b) horizontale gefolgt von vertikaler Partitionierung

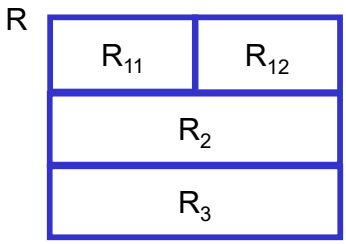

# Verteilungstransparenz

**Beispiel 1:**

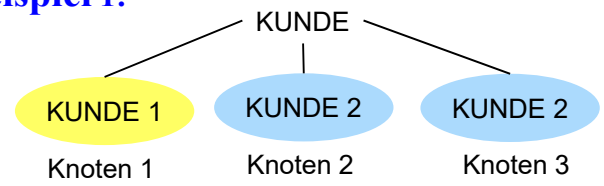


KUNDE wurde horizontal in zwei Fragmente zerlegt, wobei Fragment KUNDE2 an zwei Knoten repliziert gespeichert ist

- keine Transparenz:

```
SELECT      NAME INTO $NAME   FROM        Knoten1@KUNDE1
            WHERE  KNR = $KNO
IF NOT FOUND THEN
   SELECT   NAME INTO $NAME  FROM        Knoten3@KUNDE2
            WHERE  KNR = $KNO      . . .
```

- Orts- und Replikationstransparenz:
  - Weglassen der Ortsbezeichnungen (Knoten@) bzw. Synonyme
- Orts-, und Replikations- und Fragmentierungstransparenz:

```
SELECT      NAME INTO $NAME FROM     KUNDE
  WHERE     KNR = $KNO
```

# Verteilungstransparenz (2)

## Beispiel 2:
### Hybride Fragmentierung

**KUNDE1** (KNR, NAME)
**KUNDE2** (KNR, GEBDAT, FILIALE)
**KUNDE3** (KNR, NAME, FILIALE)
**KUNDE4** (KNR, GEBDAT)

$KUNDE_i$ sei an $Knoten_i$ gespeichert;
KUNDE1 zusätzlich an Knoten 5 und KUNDE4 an Knoten 6

- Orts-, Replikations- und Fragmentierungstransparenz

```
UPDATE  KUNDE SET FILIALE = "L" WHERE  KNR = "K3";
(*Wechsel von B nach L*)
```

- Orts- und Replikations-, keine Fragmentierungstransparenz

```
SELECT  NAME  INTO  $Name FROM KUNDE3 WHERE  KNR = "K3";
SELECT  GEBDAT  INTO $Geb FROM KUNDE4 WHERE  KNR = "K3";
INSERT INTO KUNDE1 (KNR, NAME) VALUES ("K3", $Name)
INSERT INTO KUNDE2 (KNR, GEBDAT, FILIALE) VALUES ("K3", $Geb, "L")
DELETE  KUNDE3  WHERE KNR = "K3";
DELETE  KUNDE4  WHERE KNR = "K3";
```

# Verteilungstransparenz (3)

- Beispiel 2: keine Transparenz

```
SELECT  NAME  INTO  $Name FROM Knoten3@KUNDE3 WHERE  KNR = "K3";
SELECT  GEBDAT  INTO $Geb FROM Knoten4@KUNDE4 WHERE  KNR = "K3";
INSERT INTO Knoten1@KUNDE1 (KNR, NAME) VALUES ("K3", $Name)
INSERT INTO Knoten5@KUNDE1 (KNR, NAME) VALUES ("K3", $Name)
INSERT INTO Knoten2@KUNDE2 (KNR, GEBDAT, FILIALE)
                           VALUES ("K3", $Geb, "L")
DELETE  Knoten3@KUNDE3  WHERE KNR = "K3";
DELETE  Knoten4@KUNDE4  WHERE KNR = "K3";
DELETE  Knoten6@KUNDE4  WHERE KNR = "K3";
```

# 4. Datenallokation in VDBS und PDBS

- Fragmentierung und Allokation
- Fragmentierungsvarianten
  - horizontale / vertikale /hybride Fragmentierungen
- Verteilungstransparenz
- Datenallokation für Shared Nothing PDBS
  - Verteilgrad
  - Varianten der horizontalen Fragmentierung
    - Round Robin, Hash-Fragmentierung
    - Bereichsfragmentierung: einfach, verfeinert
    - mehrdimensionale und mehrstufige Fragmentierung
  - Allokation der Fragmente
- Datenallokation für Shared Storage / Shared Everything
- NoSQL Datenallokation
  - Consistent Hashing
  - MongoDB

# Datenallokation in PDBS

- zunächst: Shared Nothing
- horizontale Verteilung von Relationen über mehrere Rechner
  - Nutzung von Datenparallelität
  - Lastbalancierung
- Teilaufgaben zur Bestimmung der Datenverteilung
  - Festlegung des Verteilgrades einer Relation
  - Fragmentierung
  - Allokation
- Bestimmung des "optimalen" Verteilgrades schwierig
  - wachsende Rechneranzahl erhöht Kommunikations-Overhead und reduziert Parallelisierungsgewinn, v.a. für kleinere Relationen
  - "Full Declustering" oft nicht sinnvoll
  - einfache Anfragen (kleine Relationen) -> wenige Partitionen
  - datenintensive Anfragen (große Relationen) -> viele Partitionen

# Bestimmung des Verteilgrades einer Relation

- einfaches Antwortzeitmodell (K = Kardinalität der Relation):

$$R(p) = a + b \times p + \frac{c \times K}{p} \quad \longrightarrow \quad R'(p) =$$

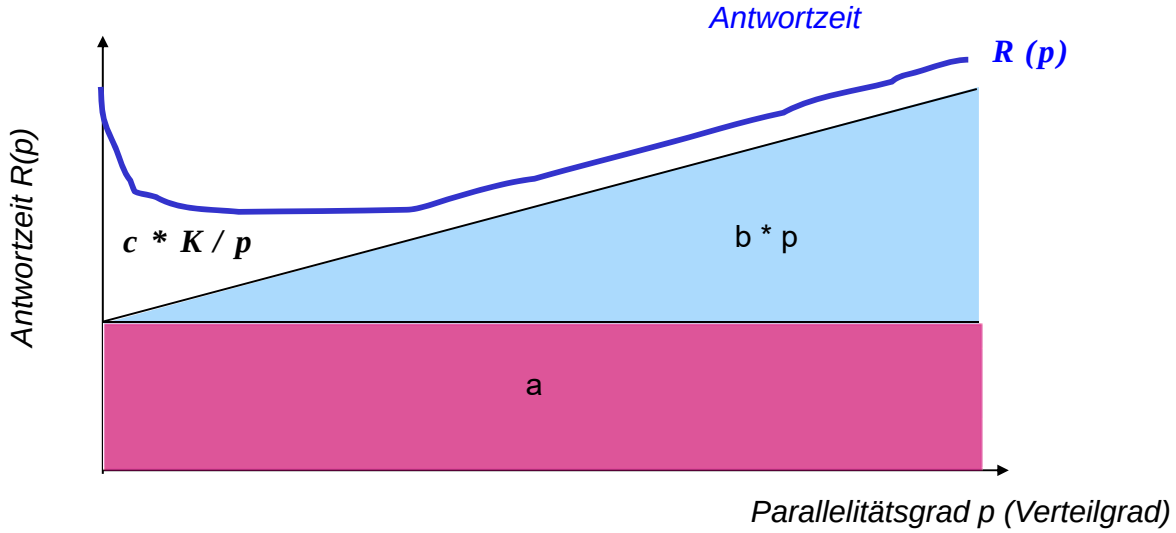


- optimaler Parallelitäts-/Verteilgrad

$$p_{opt} = \sqrt{\frac{c \times K}{b}}$$



# Bestimmung des Verteilgrades



- Bestimmung des Verteilgrades D
  - für jeden Anfragetyp $p_{opt}$ bestimmen
  - Verteilgrad D ergibt sich aus gewichtetem Mittel (=> Kompromisslösung für erwartetes Lastprofil)

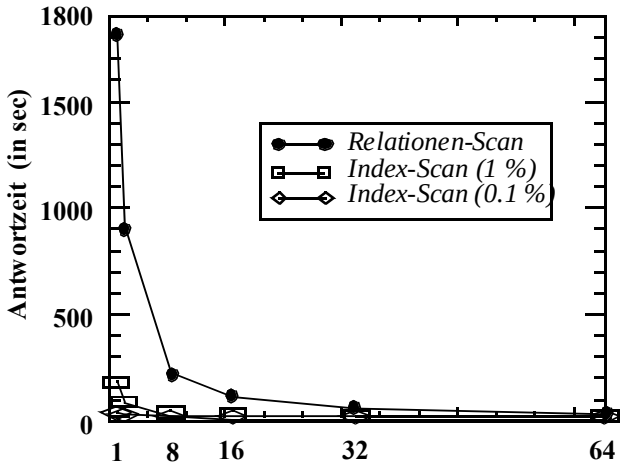


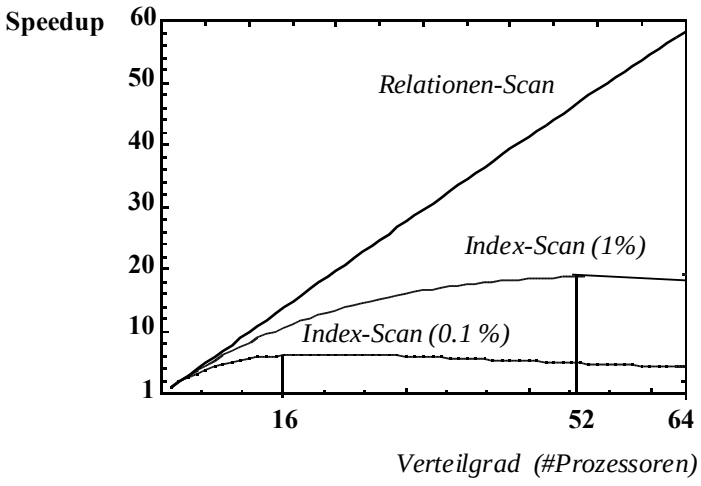


Relationen-Scan: $p_{opt} = 64$ (Lastanteil 20%)
Index-Scan (1 %): : $p_{opt} = 52$ (Lastanteil 40%)
Index-Scan (0.1 %): : $p_{opt} = 16$ (Lastanteil 40%)

# PDBS: Horizontale Fragmentierungsansätze

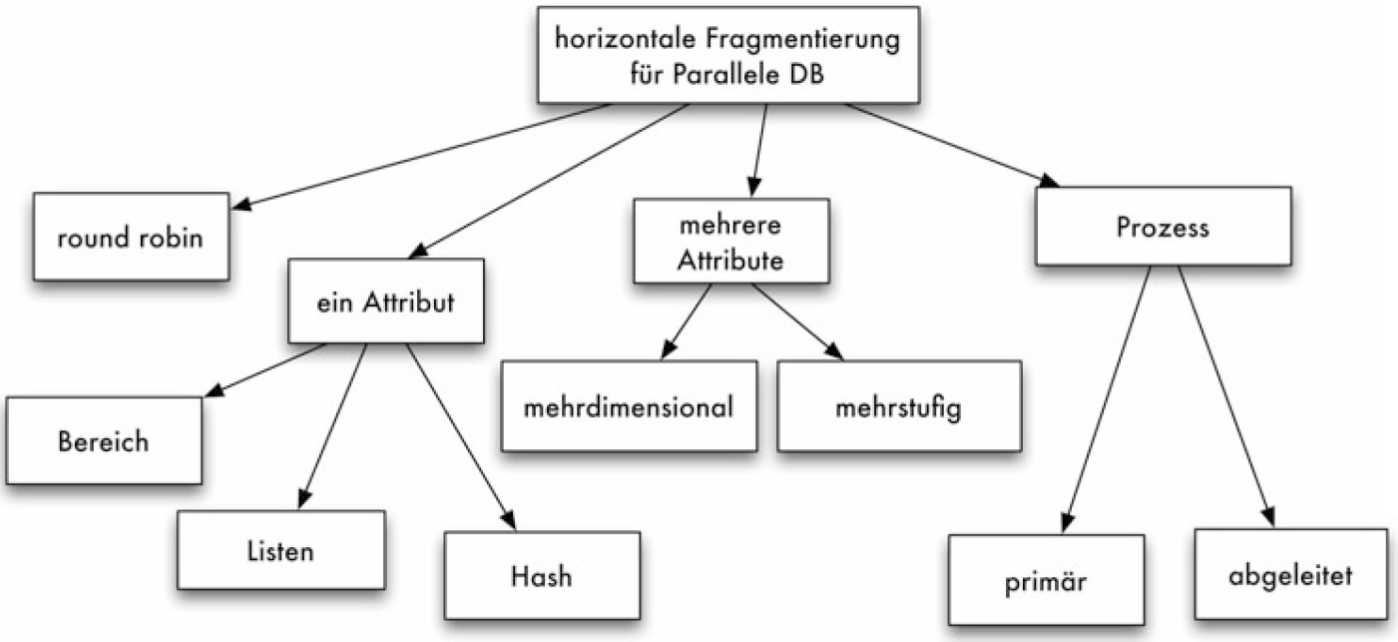

# Fragmentierung: Round-Robin

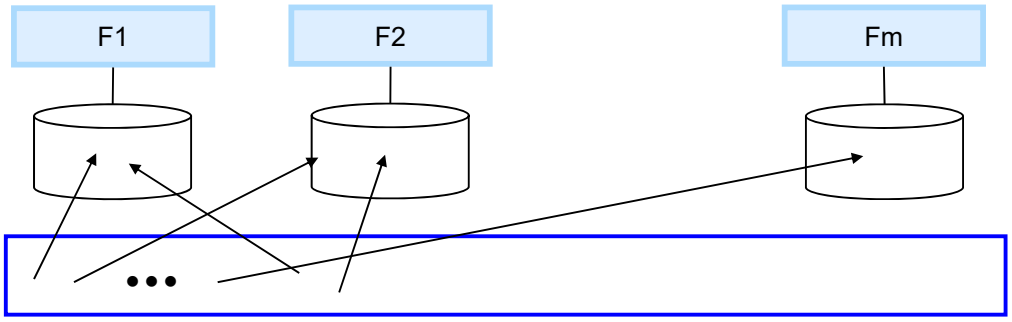


***m*** Fragmente

Satz i -> Fragment (i mod m) + 1

- Vorteile
  - gleichmäßige Fragmentgrößen
  - günstige Lastbalancierung bei gleichmäßiger Zugriffsverteilung (kein "Skew" für Relationen-Scans)
- Nachteil: Verteilung von Attributwerten unbekannt
  - sämtliche Anfragen an allen Rechnern zu bearbeiten
  - besonders ineffizient für Exact-Match-Anfragen und Einzelsatzzugriffe

# Hash-Fragmentierung

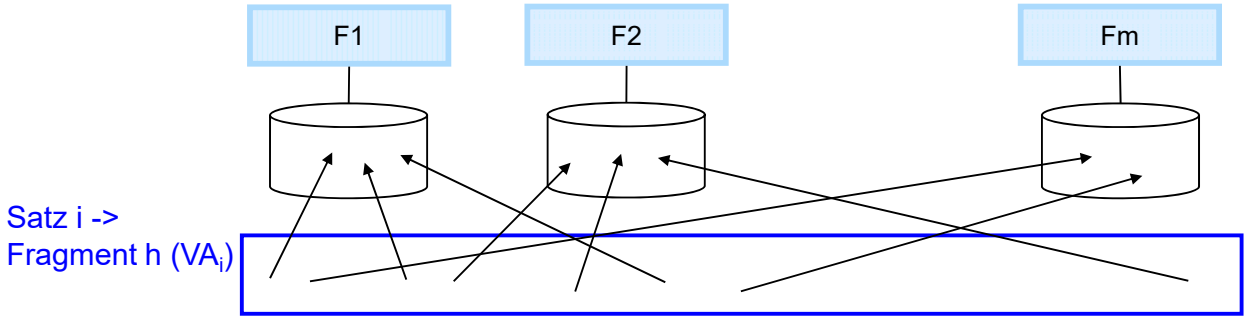


- Hash-Funktion h auf Fragmentierungs- bzw. Verteilattribut
  - z. B. Primärschlüssel oder Join/Gruppierungsattribut
- Vorteile:
  - Einfachheit
  - Exact-Match-Queries auf Verteilattribut auf 1 Fragment eingrenzbar
  - Equi-Joins sowie Group-By für das Verteilattribut werden unterstützt
- Nachteile:
  - keine Unterstützung für Bereichsanfragen (range queries)
  - Gefahr ungleichmäßiger Partitionsgrößen (-> Skew)

# Bereichsfragmentierung

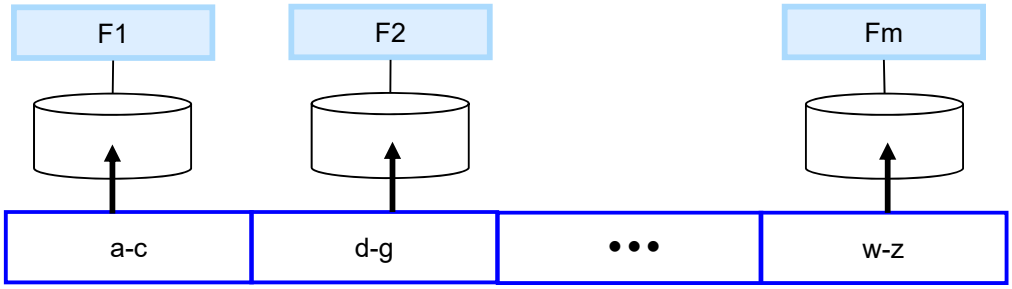


- Fragmentierung über Wertebereiche auf Verteilattribut (VA)
  - Spezifizierung durch Bereichsprädikate
  - Fragmentierungsansatz verteilter DBS
  - Spezialfälle: Listenfragmentierung (Fragment enthält Liste von Werten), abhängige Bereichsfragmentierung
- Vorteile:
  - Exact-Match- sowie Range-Queries auf VA auf relevante Fragmente eingrenzbar
  - Unterstützung für Equi-Joins über das Verteilattribut
- Nachteile:
  - Gefahr eingeschränkter Parallelisierung
  - Bestimmung geeigneter Wertebereiche

# Übungsaufgabe

**Verteilattribute TPC-H:** Angelehnt an Schema des TPC-H-Benchmarks seien folgende Relationen zu Kunden, Bestellungen und Bestellposten in einem Shared-Nothing-DBS unter allen Knoten aufzuteilen:

CUSTOMER (CUSTKEY, NAME, ADDRESS, NATION)
ORDERS (ORDERKEY, CUSTKEY, ORDERSTATUS, TOTALPRICE)
LINEITEM (ORDERKEY, PART, QUANTITY, PRICE, DISCOUNT).

Übereinstimmende Attributnamen kennzeichnen Fremdschlüssel-Primärschlüssel-Beziehungen. Die Kardinalität von ORDERS bzw. LINEITEM sei 10-mal bzw. 40-mal höher als von CUSTOMER. Auf diesem DB-Ausschnitt seien u.a. diese beiden Anfragen auszuführen:

- SELECT PART, SUM (QUANTITY) FROM LINEITEM
  GROUP BY PART;
- SELECT NATION, SUM (PRICE) FROM CUSTOMER C, ORDERS O, LINEITEM L
  WHERE C.CUSTKEY=O.CUSTKEY and O.ORDERKEY=L.ORDERKEY
  GROUP BY NATION;

Für Relation CUSTOMER soll CUSTKEY als Verteilattribut dienen. Diskutieren Sie, welche Attribute bzw. Attributkombinationen für die beiden anderen Relationen zur horizontalen Fragmentierung sinnvoll sind und warum!

# Bereichsfragmentierung: Beispiel

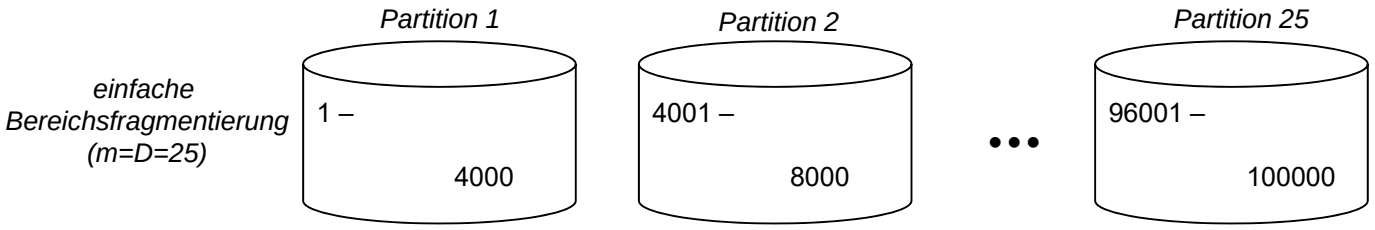


- Beispiel: Kontoaufteilung über VA Kontonummer
  - Exact-Match-Anfragen gehen auf 1 Rechner
  - Bereichsanfragen auf VA werden auf minimale Rechnerzahl begrenzt
  - Relationen-Scans gehen auf alle Rechner
- aber: 1 Fragment pro Rechner (m=D) beschränkt auch Parallelisierung / Lastbalancierung für Bereichsanfragen
- Verbesserung durch größere Anzahl von Fragmenten (m > D)
  -> verfeinerte Bereichsfragmentierung

# Verfeinerte Bereichsfragmentierung

- Ansatz: erhöhe Fragmentanzahl, so dass relevante Fragmente im Mittel $p_{opt}$ Rechnern zugeordnet werden können
  - K = Kardinalität der Tabelle
  - s = mittlere Selektivität der Bereichsanfragen, $0 \leq s \leq 1$
  - $p_{opt}$ : optimaler Parallelitätsgrad für durchschnittliche Bereichsanfrage
  - wähle: $m = p_{opt} / s$ (Fragmentgröße: $K/m = K * s / p_{opt}$
- Beispiel: CARD (KONTO) = 100.000, Verteilattribut KTONR, s=0.05, $p_{opt}$ = 10, D=25

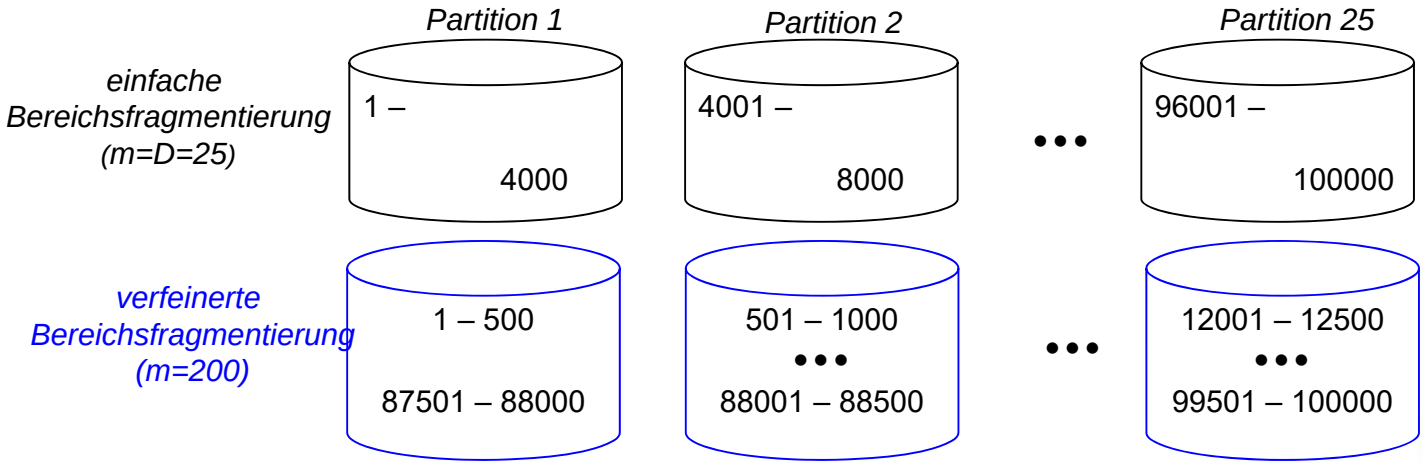




# Mehrdimensionale Bereichsfragmentierung

- Ziel: Unterstützung von Exact-Match- und Bereichsanfragen auf mehreren Attributen
- Beispiel: Zwei Anfragetypen

**A:** SELECT * FROM PERS WHERE NAME = :Z

**B:** SELECT * FROM PERS WHERE GEHALT BETWEEN [:X,:Y]

- Hash- und Bereichsfragmentierung können nur 1 Anfragetyp unterstützen (für andere sind alle Rechner involviert)
- mehrdimensionale Bereichsfragmentierung erlaubt, beide Anfragetypen auf Teilmenge der Fragmente zu beschränken

9 Rechner
36 Fragmente

| *Name* \ *Gehalt* | < 20K | < 50K | < 70K | < 90 K | < 120K | ≥ 120K |
|---|---|---|---|---|---|---|
| A-D | 1 | 1 | 4 | 4 | 7 | 7 |
| E-H | 1 | 1 | 4 | 4 | 7 | 7 |
| I-L | 2 | 2 | 5 | 5 | 8 | 8 |
| M-P | 2 | 2 | 5 | 5 | 8 | 8 |
| Q-S | 3 | 3 | 6 | 6 | 9 | 9 |
| T-Z | 3 | 3 | 6 | 6 | 9 | 9 |

# Mehrdimensionale Fragmentierung für Data Warehouses

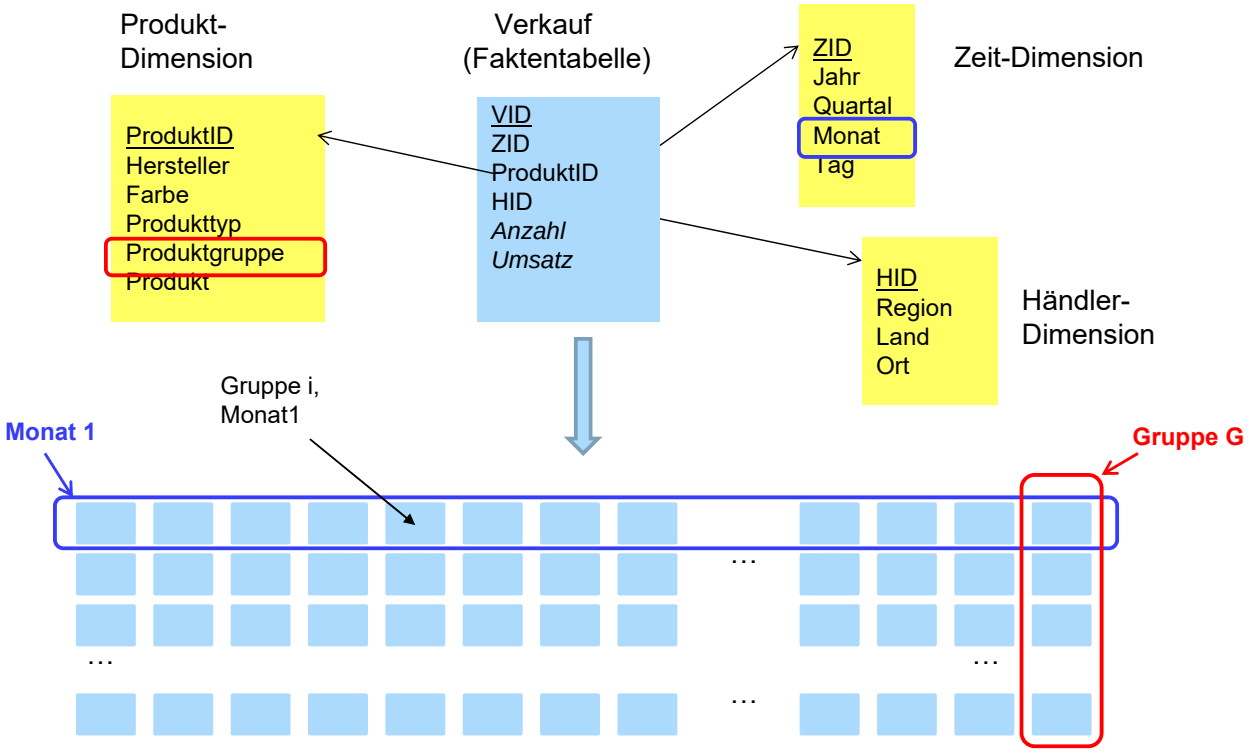


- abhängige Fragmentierung der Faktentabelle über mehrere Dimensionsattribute
  - Fragment Pruning für alle Anfragen auf den Fragmentierungsdimensionen
  - hierarchische Dimensionen: Eingrenzung auch oberhalb/unterhalb des Fragmentierungsattributs



# DB2 für LUW: Datenallokation (SN)

- 3-stufige Vorgehensweise
  - DISTRIBUTE BY HASH - Tabellen-Partitionierung zwischen Knoten
  - PARTITION BY RANGE – partitionsinterne Fragmentierung von Tabellen
  - ORGANIZE BY DIMENSIONS – Clustering innerhalb von Fragmenten (mehrdimensionales Clustering, MDC)

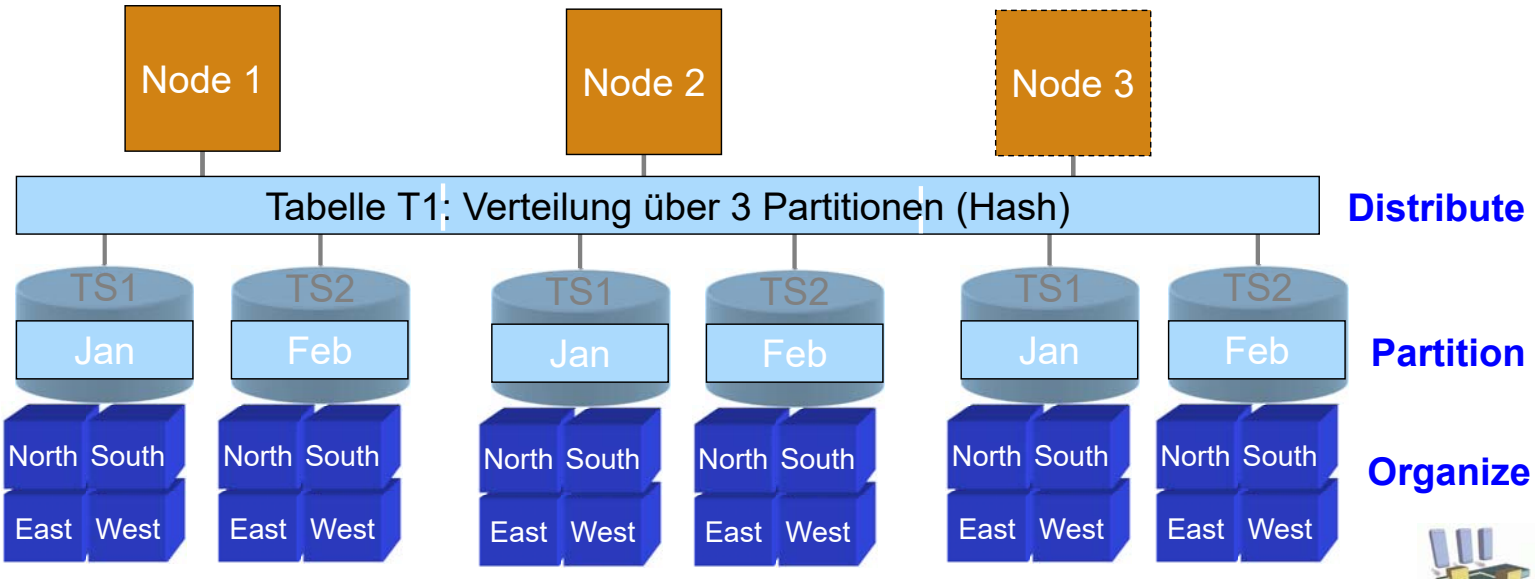

# Allokation von Fragmenten

- Allokation: Partitionenbildung durch Rechnerzuordnung der Fragmente (SN)
  - Festlegung des Verteilgrades D
  - "gleichmäßige" Aufteilung der m Fragmente unter D Rechnern: (statische) Lastbalancierung
  - analoge Partitionierung von Indexstrukturen

- Balancierung der Zugriffshäufigkeit von Partitionen
  - Round Robin-Zuordnung der Fragmente
  - (gierige Heuristik) bei stark unterschiedlichen Fragment-Zugriffshäufigkeiten:
    - ordne Fragmente gemäß Zugriffshäufigkeiten
    - solange noch Fragmente aufzuteilen, wähle das nächste Fragment mit der höchsten Zugriffsfrequenz aus
    - ordne es dem bis dahin am geringsten ausgelasteten Knoten (Partition) zu

# Allokation: Beispiel

| Fragment | F1 | F2 | F3 | F4 | F5 | F6 | F7 | F8 |
|---|---|---|---|---|---|---|---|---|
| Zugriffshäufigkeit | 100 | 600 | 400 | 150 | 200 | 500 | 400 | 50 |

D=4: R1 R2 R3 R4

Round Robin:

Greedy:

# 4. Datenallokation in VDBS und PDBS

- Fragmentierung und Allokation
- Fragmentierungsvarianten
  - horizontale / vertikale /hybride Fragmentierungen
- Verteilungstransparenz
- Datenallokation für Shared Nothing PDBS
  - Verteilgrad
  - Varianten der horizontalen Fragmentierung
    - Round Robin, Hash-Fragmentierung
    - Bereichsfragmentierung: einfach, verfeinert
    - mehrdimensionale und mehrstufige Fragmentierung
  - Allokation der Fragmente
- Datenallokation für Shared Storage / Shared Everything
- NoSQL Datenallokation
  - Consistent Hashing
  - MongoDB

# Datenverteilung bei SE und SS

- wesentliche Unterschiede gegenüber SN
  - Festlegung der Datenverteilung bezieht sich nur auf Externspeicher, nicht auf Prozessoren
  - Datenallokation hat keinen Einfluss auf Kommunikationshäufigkeit
  - größere Freiheitsgrade für Verarbeitungsparallelität
  - Indexallokation kann unabhängig von Tabellenallokation gewählt werden
- großes Lastbalancierungspotential (Parallelitätsgrad, Ausführungsort)

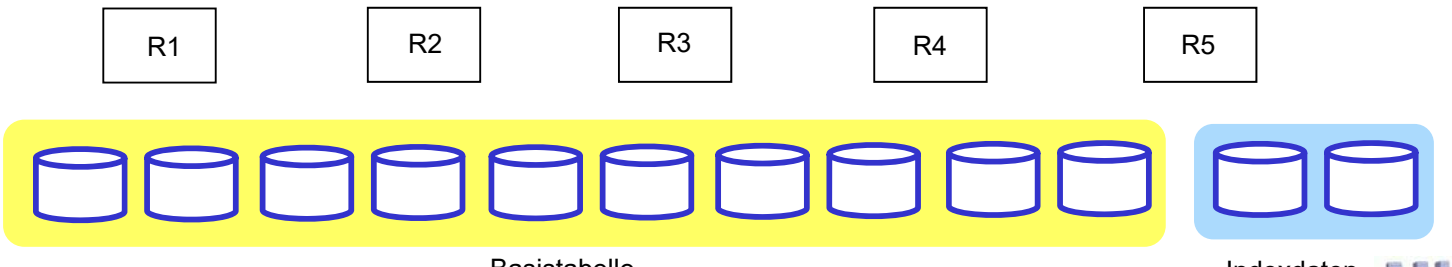

# SE/SS-Datenallokation (2)

- Ansatz zur Bestimmung des Verteilgrades
  - breites Declustering zur optimalen Abdeckung von Relationen-Scans
  - selektivere Anfragen bzw. Anfragen im Mehrbenutzerbetrieb können dennoch mit geringerer Parallelität bearbeitet werden

- Fragmentierung analog SN möglich, z. B. über Hash- oder Bereichspartitionierung
  - reduzierter Datenraum für Anfragen auf Verteilattribut
    - Beispiel: Bereichspartitionierung von Relation R auf Attribut A ($D_R$=20)

      A: (1 - 10.000; 10.001 - 20.000; 20.001 - 30.000; ... 190.001 - 200.000)

    - Anfrage *Select MAX (B) FROM R*
      *WHERE A > 70.000 AND A <= 110.000*

    - parallele Ausführung mit 4 (2, 1) Teilanfragen ohne Plattenengpässe

# Partitionierung in Oracle (SE, SS)

- Range - partition by predefined ranges of continuous values
- Hash - partition according to hashing algorithm applied by Oracle
- Composite - e.g. range-partition by key1, hash sub-partition by key2
- List - partition by lists of predefined discrete values

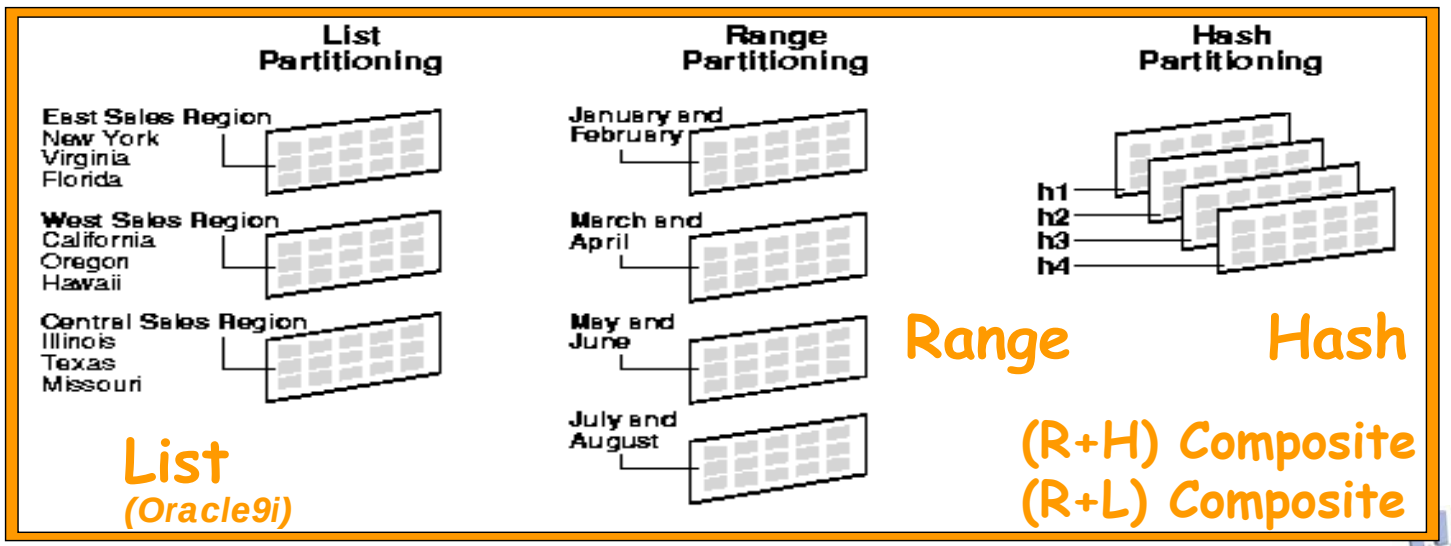

# Beispiel: Oracle Range-Partitionierung

```
CREATE TABLE Telefonat (Datum DATE, KdNr NUMBER, Dauer NUMBER)
  PARTITION BY RANGE(Datum)
     (PARTITION vor_2024 VALUES
          LESS THAN TO_DATE('01-JAN-2024', 'DD-MON-YYYY'),
      PARTITION in_2024 VALUES
          LESS THAN TO_DATE('01-JAN-2025', 'DD-MON-YYYY'),
      PARTITION nach_2024 VALUES LESS THAN MAXVALUE) ;
```

| Datum | KdNr | Dauer |
|---|---|---|
| 2023-05-15 | 1 | 45 |
| 2023-07-21 | 2 | 215 |
| 2024-01-16 | 1 | 200 |
| 2024-10-16 | 3 | 20 |
| 2025-03-07 | 2 | 50 |

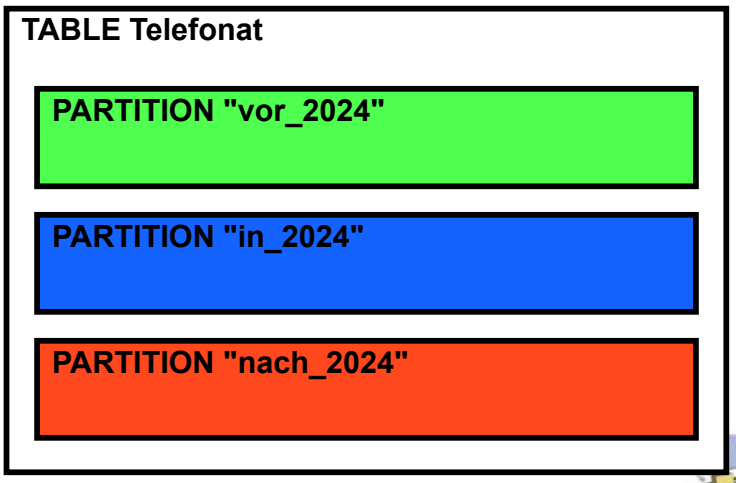




# Datenallokation in NoSQL Stores

- hohe Skalierbarkeit und Verfügbarkeit (durch Datenreplikation) auf Shared-Nothing-Architekturen
  - Key Value Stores und Erweiterungen (BigTable/Hbase, Cassandra, …)
  - Document Stores (MongoDB u.a.)
- vorrangige Nutzung von Hash-Fragmentierung auf Key-Attribut
  - schneller Zugriff für Key-Operationen
  - gute Lastbalancierung
  - keine Unterstützung für komplexe Queries oder Intra-Query-Parallelität
- Bereichsfragmentierung u.a. in BigTable/Hbase und MongoDB
- zu lösende Probleme
  - Anpassung der Datenverteilung nach Ausfall / Hinzunahme von Knoten (-> Consistent Hashing)
  - automatische Bestimmung der Bereichsfragmentierungen („Auto-Sharding“)

# Consistent Hashing

- Nutzung u.a. in Dynamo, Cassandra, Voldemort, Redis
- Prinzip
  - gleichartige Hash-Abbildung von Knoten-Ids und Objekt-Keys auf ringförmigen Wertebereich von 0 .. $2^m$-1
  - Objekt mit Key x wird Knoten zugeordnet, dessen Ring-Position h(x) als nächstes (im Uhrzeigersinn) h(x) folgt
- Änderungen in Knotenzahl betreffen nur Daten eines Knotens
  - Beispiele: Wegfall Knoten B, Hinzunahme Knoten D
  - geringerer Umverteilungsaufwand gegenüber komplettem Re-Hashing
- ungünstige Lastbalancierung möglich, v.a. nach Knotenausfall
  -> Einführung virtueller Knoten

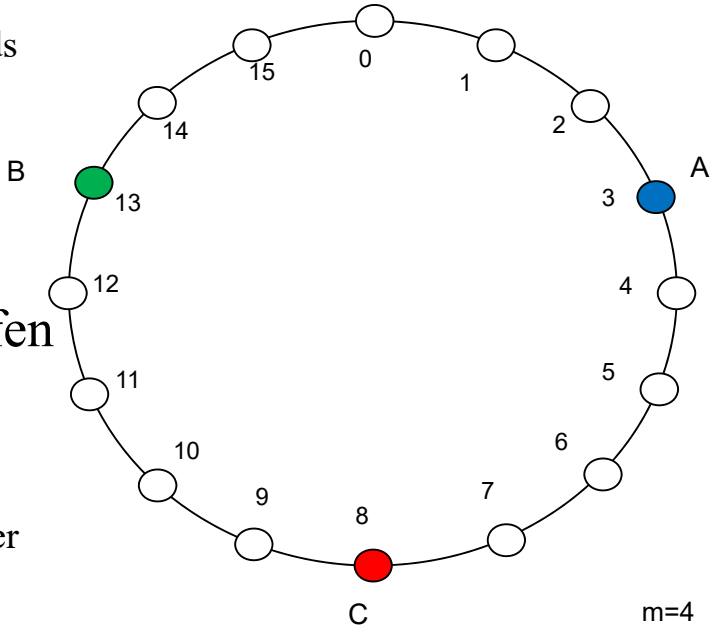

# Consistent Hashing mit virtuellen Knoten

- jeder physische Knoten wird durch *k* virtuelle Knoten repräsentiert
  - *k* Zuständigkeitsbereiche pro Knoten
- Änderung in Knotenzahl führt zu guter Lastbalancierung bei begrenzter Umverteilung
  - Beispiel: Ausfall Knoten B

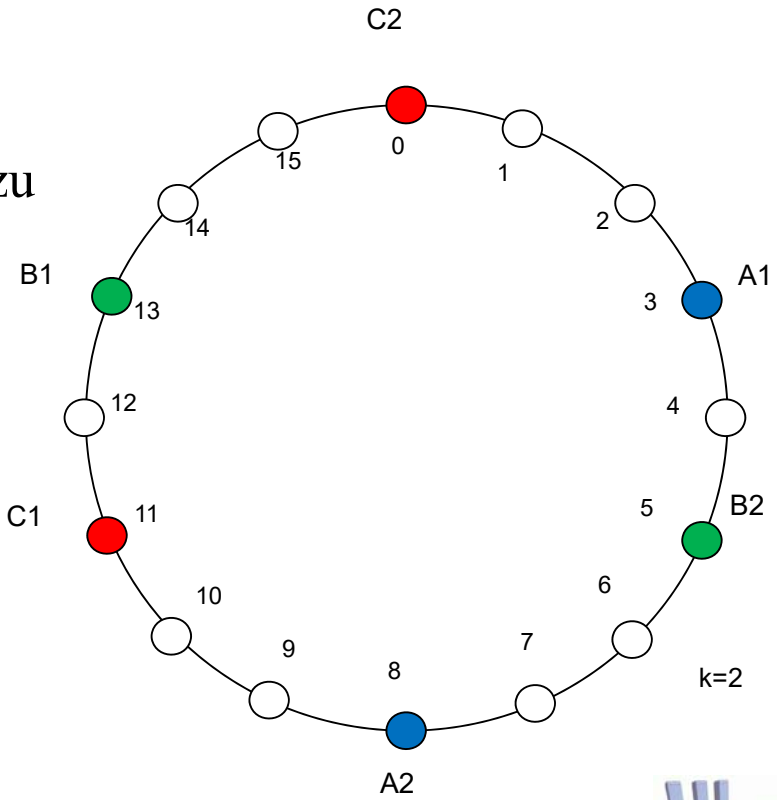

# MongoDB Auto-Sharding

- MongoDB: schemalose Speicherung von JSON-Dokumenten
- DB = mehrere Kollektionen von Dokumenten
  - einfache Anfragesprache
  - Map/Reduce-Unterstützung
  - kein ACID
- horizontale Bereichspartitionierung einer Dokumentenkollektion über Shard-Key
  - Shard-Key einfach oder zusammengesetzt, muss für jedes Dokument existieren
  - automatische Zuordnung von Dokumenten zu Fragmenten ("Chunks") maximaler Größe, z.B. 64 MB
  - automatische Anpassung der Fragmentierung / Datenallokation
- replizierte Datenspeicherung

```
{
   "Herausgeber": "Mastercard",
   "Nummer": "1234-5678-9012-3456",
   "Währung": "EURO",
   "Inhaber": {
            "Name": "Mustermann",
           "Vorname": "Max",
           "männlich": true,
           "Hobbys": [ "Reiten", "Lesen" ],
           "Kinder": [],
            "Partner": null        }
}
```

# MongoDB Grobarchitektur

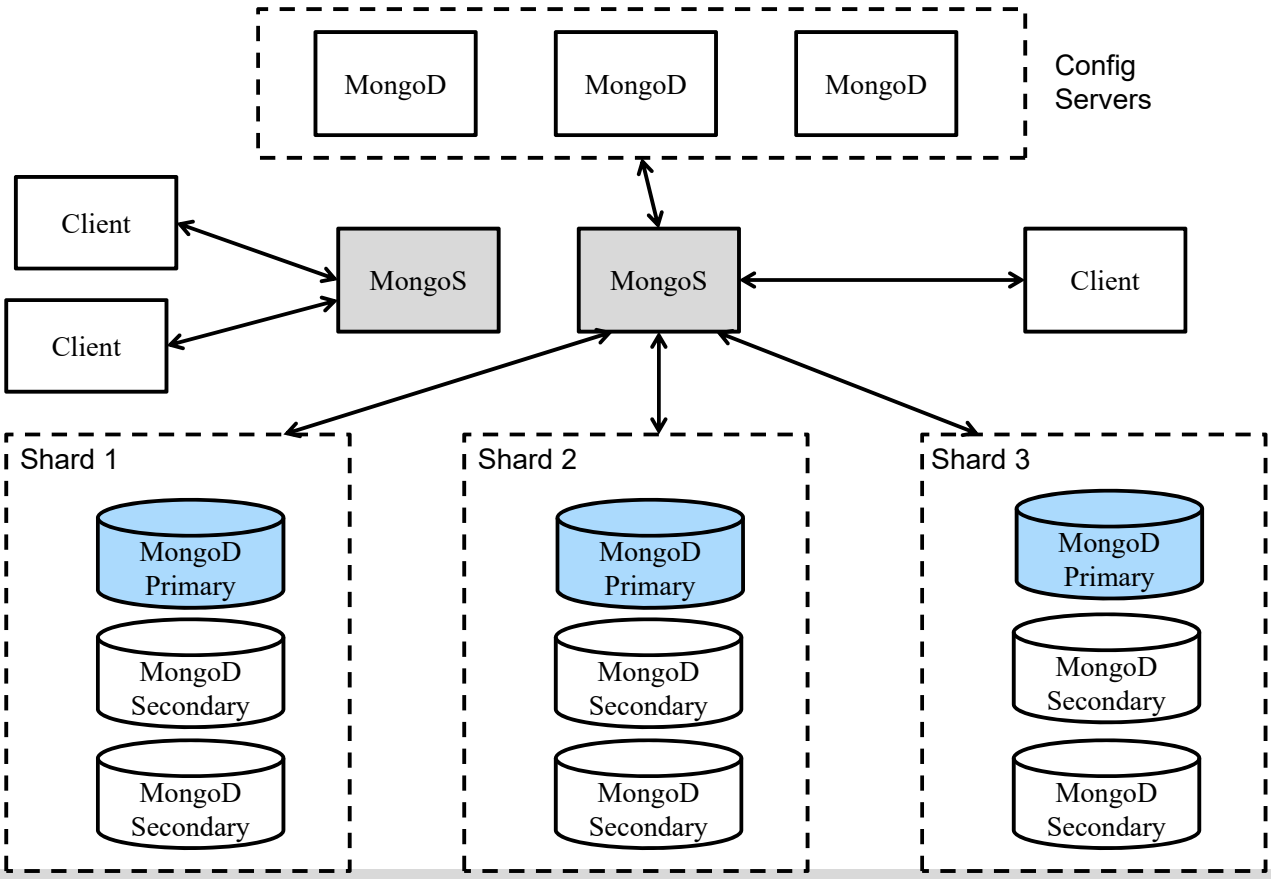

# MongoDB: Auto-Sharding (2)

- kontinuierliche Verfeinerung der Fragmentierung bei wachsenden Datenmengen
  - zunächst 1 Fragment (Chunk) für Wertebereich ( $-\infty$, $+\infty$)
  - Splitten des Fragments in zwei Fragmente bei Übersteigen der max. Größe
  - rekursive Fortsetzung bis alle Fragmente unter max. Größe bleiben
  - gleichmäßige Aufteilung der Fragmente unter den Knoten

- dynamische Anpassung der Datenallokation
  - Splitting von Fragmenten, die durch Einfügungen max. Größe übersteigen
  - Anzahl von Fragmenten pro Knoten darf nur bis zu einem Schwellwert abweichen
  - ansonsten asynchrone Migration von Fragmenten vom Knoten mit den meisten zu dem mit den wenigsten Fragmenten (durch *Balancer-Prozess*)

# Zusammenfassung

- Datenpartitionierung: Fragmentierung + Allokation der Fragmente
- Hauptziele der Fragmentierung
  - Reduzierung des Verarbeitungsumfangs
  - Reduzierung des Kommunikationsaufwandes / Unterstützung von Lokalität in VDBS
  - Unterstützung von Parallelität (v.a. wichtig für PDBS)
- Parallele DBS basieren auf horizontaler Fragmentierung
  - hohe Flexibilität durch Bereichsfragmentierung und Varianten
  - mehrdimensionale Fragmentierung: Eingrenzung des Verarbeitungsumfangs hinsichtlich mehrerer Attribute
- Datenallokation: Zuordnung der Fragmente zu Knoten
  - Bestimmung von Verteilgrad und Auswahl der Knoten
  - wesentlich für Lastbalancierung
- SE/SS: Datenallokation bezüglich Externspeicher mit erhöhter Flexibilität
- NoSQL Stores: 1-dimensionale Hash- oder Bereichspartitionierung
  - keine Intra-Query-Parallelität
  - automatische Anpassung der Datenallokation (Consistent Hashing, Auto-Sharding)