Performante Verarbeitung großer Datenbanken am praktischem Beispiel

Thomas Lehmann – 08.09.2015, Dresden

Agenda

1. Technische Rahmenbedingungen
2. Theoretische Grundlagen
3. Verschiedene Probleme am praktischen Beispiel

Allgemeine Anmerkungen

- Keine vorgefertigten Universallösungen
- Möglichkeiten der Oracle Datenbank aufzeigen
- Individuelle Entscheidung / Abstimmung notwendig
- Seiteneffekte im Auge behalten

Technische Rahmenbedingungen

- Programmlogik in der Datenbank (PL/SQL-Code)
- Serielle Programmabarbeitung
- Hohes Datenvolumen
- Wiederkehrende Prozesse

- Leistungsstarke Serverhardware (CPU, IO, Memory)
- Optimale Ressourcennutzung ???

Oracle Database Appliance → Robotron EDM Appliance

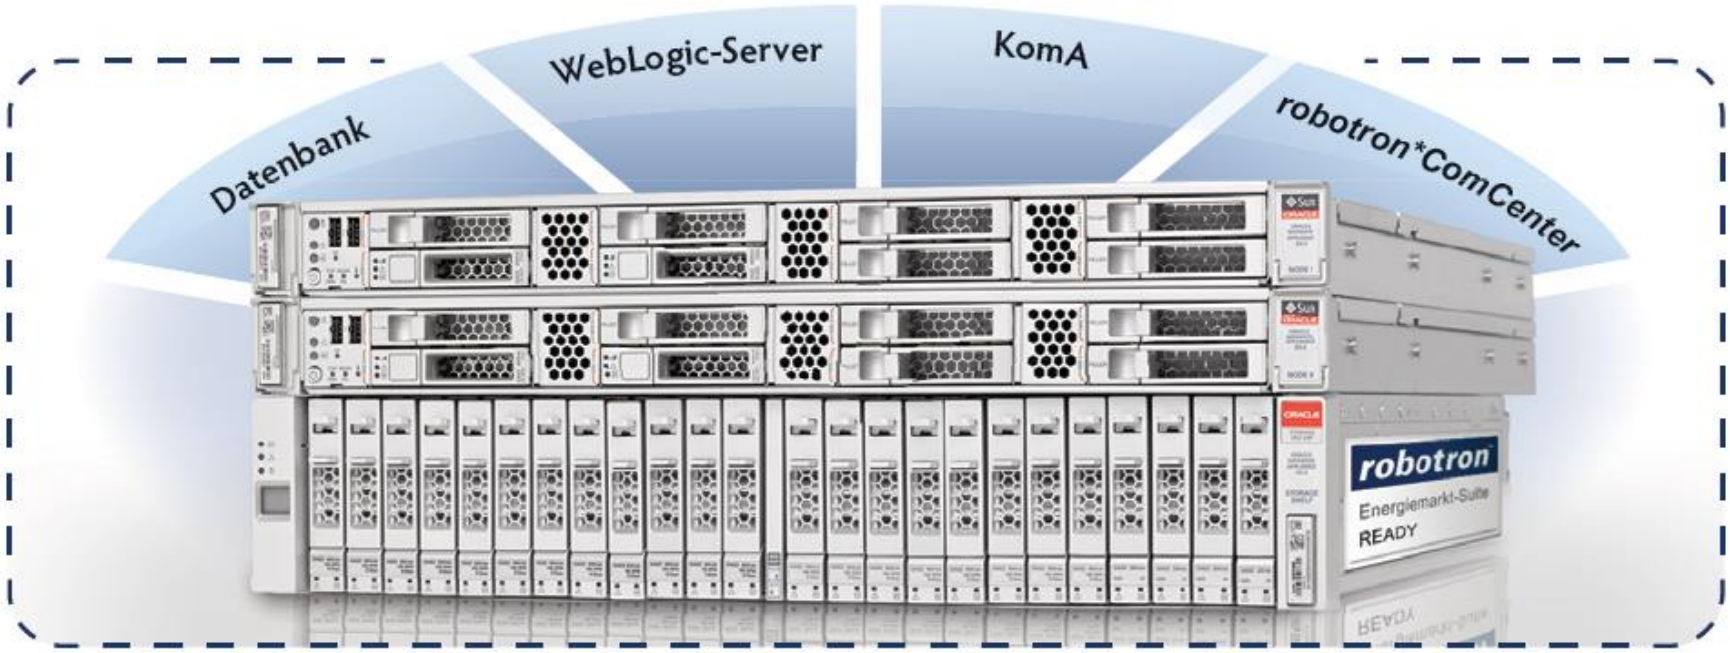

Zertifizierte Hard- und Software-
Komplettlösung für den Betrieb der Robotron-Energiemarkt-Suite

Theroretische Grundlagen

- Wie gelangen Daten in die Datenbank ?
  - Tools
  - Tabellenlayout
  - Statistiken
- Wie können DML-Operationen auf großen Datenmengen durchgeführt werden ?
  - DML / CTAS ?
  - Row / Set-Based ?

External tables

- Voraussetzung: strukturierte Daten
- Einfach einzurichten aber statisch
- Empfehlenswert bei Initialbeladungen / Entladungen oder wiederkehrenden Prozessen
- Zugriff auf DB-Server
- Steuerung über DDL-Statement

- Beispiel

External tables

```
CREATE TABLE imp_std_csv_data (
  INT_ID VARCHAR(10),
  ID VARCHAR(10),
  name VARCHAR(200),
  name2 VARCHAR(200),
  plz VARCHAR(10),
  ort VARCHAR(200),
  strasse VARCHAR(200),
  region VARCHAR(10),
  met_code VARCHAR(50)
  )
  ORGANIZATION EXTERNAL (TYPE ORACLE_LOADER DEFAULT DIRECTORY extern_data_dir
                ACCESS PARAMETERS (FIELDS TERMINATED BY ';')
                LOCATION ('data01.csv'));
```

External tables

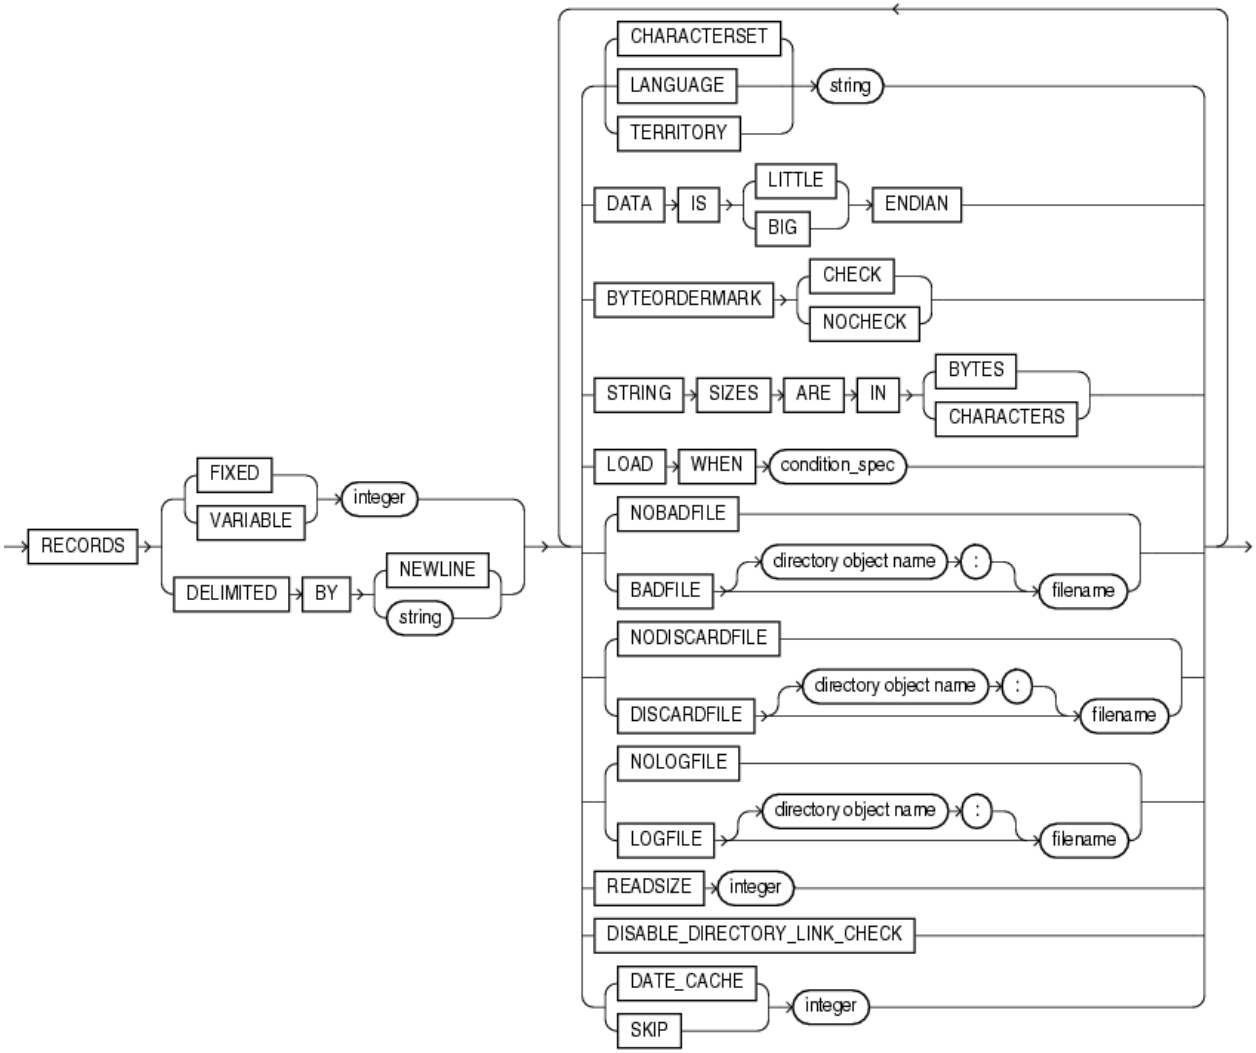

SQL Loader

- Voraussetzung: strukturierte Daten
- Einfach einzurichten
- Keine Festen Dateinamen
- Empfehlenswert bei wiederkehrenden Prozessen
- Zugriff über SQL Net
- Steuerung über Control File

- Beispiel

External Tables vs. SQL Loader

- External Tables:
  - Datentransformation beim Laden
  - Parallelisierung
  - NLS-Einstellung der Datenbank
  - Performanter

- SQL Loader:
  - Remotezugriff
  - Zusätzliche Indizierung der Staging Table
  - NLS-Einstellung des Clients

Statistiken & Indizes

- Massenbeladung wenn Möglich ohne Indizes / Trigger
- Anlegen der Indizes nach Beladeprozess

- Aktualisierung der Statistiken (evtl. inkrementell)
- Besonderheit der Histogramme

- Beispiele

Statistiken

- DBMS_STATS.GATHER … STATS

```
DBMS_STATS.GATHER_TABLE_STATS (
   ownname          VARCHAR2,
   tabname          VARCHAR2,
   partname         VARCHAR2 DEFAULT NULL,
   estimate_percent NUMBER   DEFAULT to_estimate_percent_type
                                        (get_param('ESTIMATE_PERCENT')),
   block_sample     BOOLEAN  DEFAULT FALSE,
   method_opt       VARCHAR2 DEFAULT get_param('METHOD_OPT'),
   degree           NUMBER   DEFAULT to_degree_type(get_param('DEGREE')),
   granularity      VARCHAR2 DEFAULT GET_PARAM('GRANULARITY'),
   cascade          BOOLEAN  DEFAULT to_cascade_type(get_param('CASCADE')),
   stattab          VARCHAR2 DEFAULT NULL,
   statid           VARCHAR2 DEFAULT NULL,
   statown          VARCHAR2 DEFAULT NULL,
   no_invalidate    BOOLEAN  DEFAULT  to_no_invalidate_type (
                                 get_param('NO_INVALIDATE')),
   force            BOOLEAN DEFAULT FALSE);
```

`method_opt` Accepts either of the following options, or both in combination:

- `FOR ALL [INDEXED | HIDDEN] COLUMNS [size_clause]`
- `FOR COLUMNS` [size clause] column|attribute [size_clause] [,column|attribute [size_clause]...]

`size_clause` is defined as `size_clause := SIZE {integer | REPEAT | AUTO | SKEWONLY}`
`column` is defined as `column := column_name | (extension)`

- `integer` : Number of histogram buckets. Must be in the range [1,254].
- `REPEAT` : Collects histograms only on the columns that already have histograms.
- `AUTO` : Oracle determines the columns to collect histograms based on data distribution and the workload of the columns.
- `SKEWONLY` : Oracle determines the columns to collect histograms based on the data distribution of the columns.
- `column_name` : name of a column
- `extension` : can be either a column group in the format of (`column_name`, `colume_name` [, ...]) or an expression

The default is `FOR ALL COLUMNS SIZE AUTO`. The default value can be changed using the SET_DATABASE_PREFS Procedure, SET_GLOBAL_PREFS Procedure, SET_SCHEMA_PREFS Procedure and SET_TABLE_PREFS Procedure.

Partitionierung

- Aufteilung von Tabellen und Indizes
- Transparent für die Anwendung

- Verbesserung der Abfrageperformance
- Beschleunigung von Wartungsvorgängen

- Lizenzkosten beachten
- Evtl. zusätzliche Wartungsaufgaben

- Beispiele

Parallelisierung

- PL/SQL Code läuft auf einer CPU Core
- → keine Skalierungsfähigkeit
- → sequentielle Abarbeitung

- → langlaufende Aktionen parallelisieren

- Row-By-Row → Bulk Operations → Parallelisierung

Parallelisierung, Partitionierung und Komprimierung

- Optimale Ressourcenausnutzung durch Parallelisierung
- Achtung: Keine Überbeanspruchung
- → Customizingmöglichkeiten im Code/Layout vorsehen

- Aufteilung der Daten durch Partitionierung
- Performancegewinn vs. Maintenance

- Verringerung des Datenbestandes durch Komprimierung
- Verringerung Lesezugriffe (Tagesgeschäft, Betrieb)

- Hinweis: Lizenzkosten im Auge behalten

Row Bases vs. Set Based

- „eCount-Krankheit“: Verarbeitungsschritte Row Based
- (Nachvollziehbare Gründe: Trigger, Mandanten, komplexe Logik)
- Langsamste Verarbeitung innerhalb der Datenbank

- Oracle beherrscht JOINS - Performant und Skalierbar !

Row Bases vs. Set Based

- Problem: 1 GB große Tabelle mit ca. 3 Mio Datensätzen soll ein Update erfahren, bei dem:
  - IDs < 300.000 → Region ‚SN‘
  - IDs < 400.000 → Region ‚NRW‘
  - IDs < 500.000 → Region ‚BY‘
  - IDs >500.000 → Region ‚BL‘

Zusammenfassung

- Wachsende Datenmengen
- Wachsende Anforderungen
- Leistungsstarke Hardware

- Optimale Auslastung der Ressourcen
- Maximale Performancesteigerung durch Code / Designanpassungen
- Supportabteilung lässt sich gern in Designphasen einbinden

Thomas Lehmann
Senior Systemberater Support

Tel: +49 351 25859 2782

Fax: +49 351 25859 3696

thomas.lehmann@robotron.de