LMU KLINIKUM DER UNIVERSITÄT MÜNCHEN
CAMPUS INNENSTADT
INSTITUT FÜR NOTFALLMEDIZIN UND MEDIZINMANAGEMENT

ORACLE 12c
AUTOMATIC BIG TABLE CACHE

Markus Geis

18.11.2015

AGENDA

- **INM**
- **automatic big table cache**
  - **Technik**
  - **Einrichtung**
  - **erste Erfahrungen**
  - **Zusammenfassung / Fazit**

INM

- Institut für Notfallmedizin und Medizinmanagement
  - Teil des Klinikums der Universität München (LMU)
- Qualitätsmanagement in der Notfallmedizin und im Rettungswesen
- Interdisziplinäre Forschungseinrichtung
- DWH: 2 MIO Rettungsdienst-Daten / pro Jahr Verarbeitung medizinischer- / GEO- Daten
- www.inm-online.de

AUSGANGSSITUATION

- Betrieb eines 12c 3 Knoten Clusters (12.1.0.2 EE)
  -> 3 Cluster-DB‘s mit ca. 3TB / 1.200 DB-Usern
- Netapp Metro Cluster
- Shared Disk Spaces sind über NFS eingebunden (kein ASM)
- Optionen:
  - Partioning
  - Spatial (Routenberechnung und Geo-Analysen)

AUSGANGSSITUATION

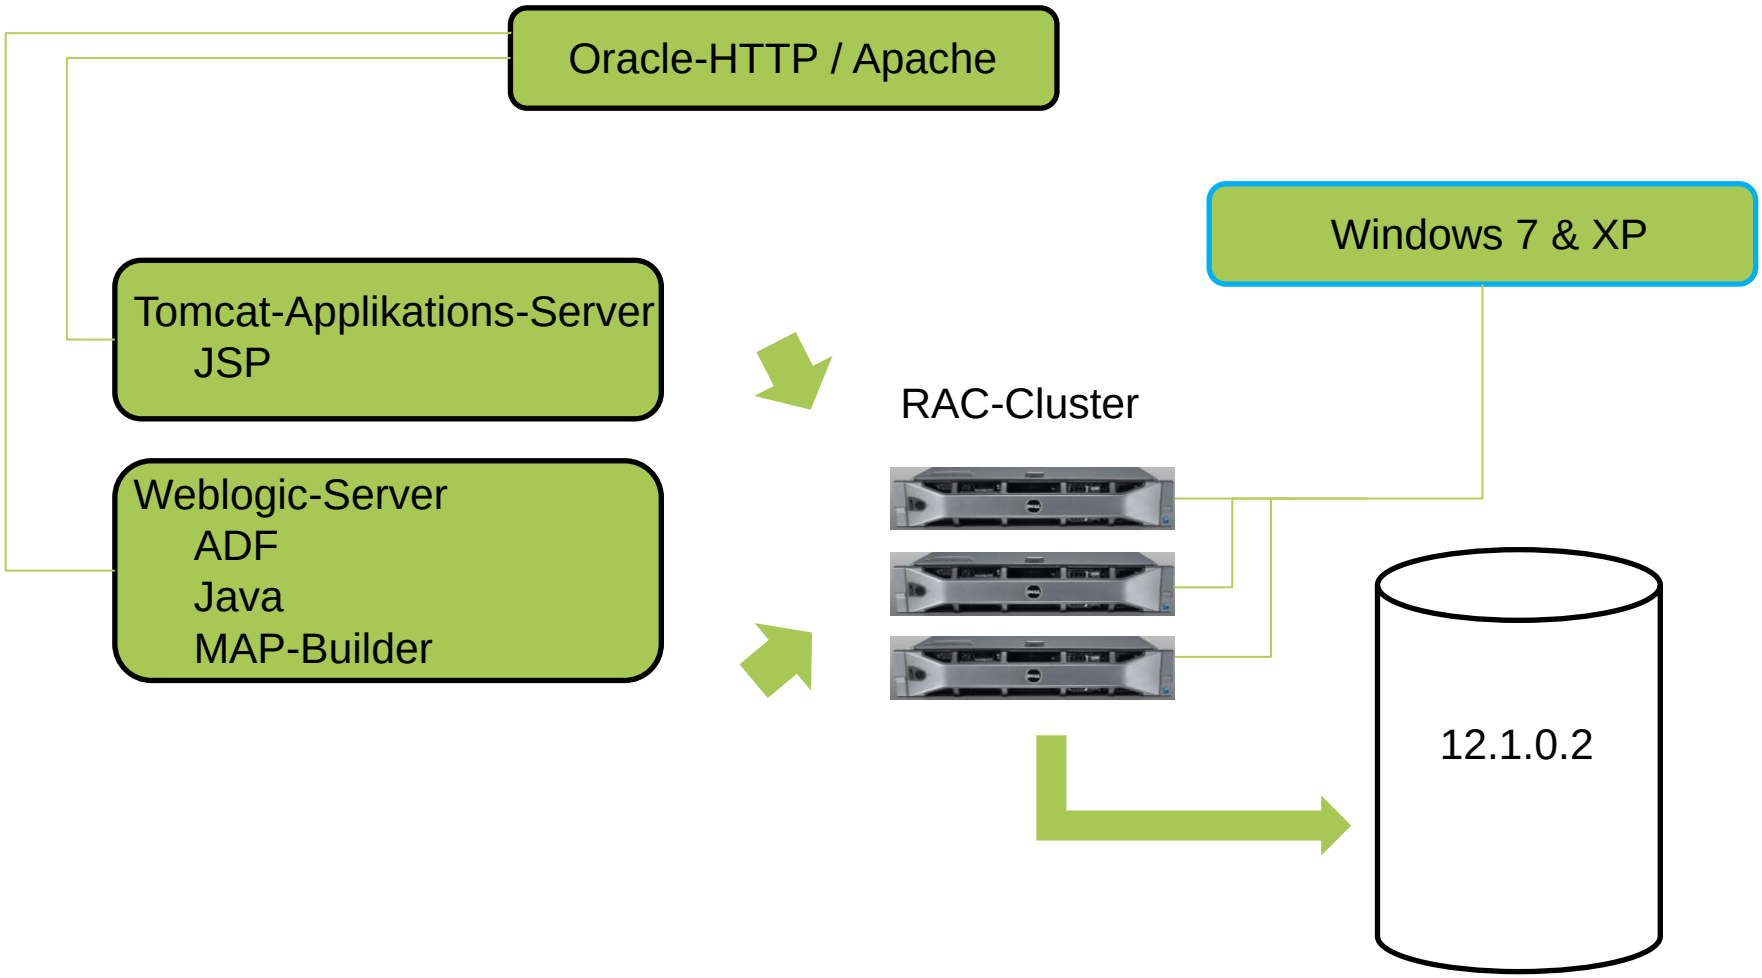

AUTOMATIC BIG TABLE CACHE

- Teil der Oracle „inMemory“ Initiative
- verfügbar ab der Version 12.1.0.2
- Feature (Poor Man’s In-Memory Caching)
- in allen Edition verfügbar:
  - SI (EE): bei sequentiellen Abfragen (PX)
  - RAC / (EE): nur parallel-query

AUTOMATIC BIG TABLE CACHE

- Performance der DB wird durch den CACHE bestimmt
  - der Zugriff auf die DB-Daten sollte über den CACHE realisiert werden (DB-Blöcke)
  - Plattenzugriffe sollten vermieden werden
- Datenmengen werden größer
- wichtige/unwichtige Daten

AUTOMATIC BIG TABLE CACHE

- bisherige Technologie für die Verarbeitung großer Tables (Full Table Scans)
  - direct path read
    - _small_table_threshold
  - COMPRESSED
  - PARTIONING

AUTOMATIC BIG TABLE CACHE

- direct path read
  - liest große Tables bei einem FULL-TABLE-SCAN direkt unter Umgehung des BUFFER-Caches aus den Data-Files in die PGA des Users
  - BUFFER-Cache wird nicht geflutet
  - Nachteil: select immer von der Platte

AUTOMATIC BIG TABLE CACHE

- _small_table_threshold (Schwellenwert):
  beschreibt eine Table als „SMALL“
  - HIDDEN
  - eine Table gilt als SMALL, bei einer Größe < 2% des buffer-caches
  - Infos werden über den DB-BLOCK-BUFFER zur Verfügung gestellt
  - Info wird auch später für den „automatic big table cache“ benötigt

AUTOMATIC BIG TABLE CACHE

- _small_table_threshold (Anzahl Blöcke)

```
SELECT a.ksppinm,b.ksppstvl ,c.ksppstvl,a.ksppdesc
FROMx$ksppi a ,x$ksppcv b ,x$ksppsv c
WHEREa.indx = b.indx AND a.indx = c.indx
AND a.ksppinm LIKE '/_%' escape '/'
and a.ksppinm like '_small%'
ORDER BY 1
```

PARAM	SESSIONVAL	INSTANCEVAL	DESCR
_small_table_threshold	76943	76943	lower threshold level of table size for direct reads

- gv$sgainfo (Buffer Cache Size 26306674688 bytes ca.26GB)
- 76.943*DB-Block (8K)/DB-Buffer-CACHE ca. 2%
- Größe der SMALL-Table in der INM-Umgebung: ca. 600 MB

AUTOMATIC BIG TABLE CACHE

- bisheriges CACHE-Verhalten des DB-BLOCK-BUFFERS:
  - LRU (last recently used)-> Algorithmus
  - LRU-Liste verwaltet den CACHE (DB-BUFFER)
  - bei vollem CACHE, werden die am längsten nicht genutzten Blöcke aus dem CACHE entfernt, um Platz für neue Blöcke zu schaffen
  - **Problem:** wichtige Objekte/Blöcke können so aus dem CACHE herausfallen (Abfragen werden langsam / lesen von Disk)

AUTOMATIC BIG TABLE CACHE

- bisheriges CACHE-Verhalten des DB-BLOCK-BUFFERS:
  - COLD- / HOT-AREA
  - Blöcken werden in der Mitte der LRU-Liste eingefügt
  - Je nach Nutzungsfrequenz wandern die Blöcke in den COLD oder HOT Bereich
  - bei Platzbedarf fallen dann mit der Zeit Blöcke aus dem CACHE heraus

AUTOMATIC BIG TABLE CACHE

- eine Möglichkeit in der Vergangenheit, um das Herausfallen von Objekten aus dem CACHE zu verhindern -> KEEP-Mechanismus
- bestimmte Tables konnten in den Hauptspeicher gepinnt werden
- es war eine Technologie für kleine Tables
- es konnten keine „Partitionen“ angesprochen werden
- der Workload spielte keine Rolle / die Technik wurde durch den Administrator bestimmt

AUTOMATIC BIG TABLE CACHE

- **Automatic big table cache: „ABTC“**
  - die Technologie soll verhindern, daß oft genutzte Objekte aus dem CACHE herausfallen
  - der „*workload*“ soll die bestimmende Größe für das CACHE-Verhalten sein
  - ein bestimmter Teil des DB-Block-Buffers wird für diese Technologie reserviert (bis 90%)

AUTOMATIC BIG TABLE CACHE

- Wie berechnet sich der Workload?
  - Algorithmus, welcher über die Häufigkeit des Zugriffes bestimmt ob und wie ein Objekt (z.B. Table) in den CACHE geladen wird und dort verbleibt
  - Oracle bezeichnet dies als “temperature”
  - je höher die “temparture” desto eher verbleiben die Objekte im CACHE
  - Es werden nur große Tables gemessen;
    keine kleinen Tables -> _small_table_threshold

AUTOMATIC BIG TABLE CACHE

- **zwei Einstellungen für die Aktivierung:**

```
ALTER SYSTEM SET db_big_table_cache_percent_target=55;
ALTER SYSTEM SET compatible='12.1.0.2.0‘
```

- RAC-Cluster: „parallel query“ eingeschaltet (automatic / adaptive)

```
ALTER SYSTEM SET PARALLEL_DEGREE_POLICY=AUTO;
```

- single instance : auch Verarbeitung von sequentiellen Abfragen

UPGRADE 12C – TECHNIK

- Es können folgende Objekte in den „ABTC“ geladen werden:

OBJEKTE	OBJECT-TYPE (v$bt_scan_obj)
Table	TABLE PARTITION
Table-Partition	TABLE SUBPARTITION
Index	INDEX
Index-Partition	INDEX SUBPARTITION

AUTOMATIC BIG TABLE CACHE - TECHNIK

- Zwei SYS-Views für die Verwaltung des “ABTC”:
  - Single-Instance
    - V$BT_SCAN_CACHE -> CACHE-Infos
    - V$BT_SCAN_OBJ_TEMPS -> Objekte im “ABTC”
  - RAC:
    - gV$BT_SCAN_CACHE
    - gV$BT_SCAN_OBJ_TEMPS

AUTOMATIC BIG TABLE CACHE – TECHNIK

- **Beispiel: Platzbedarf und Infos über den „ABTC“**

```
SELECT bt_cache_alloc, bt_cache_target, object_count, memory_buf_alloc
FROM v$bt_scan_cache;
```

BT_CACHE_ALLOC	BT_CACHE_TARGET	OBJECT_COUNT	MEMORY_BUF_ALLOC
.400005755	40	3	50685

```
SELECT * from gV$BT_SCAN_CACHE
```

INST_ID	BT_CACHE_ALLOC	BT_CACHE_TARGET	OBJECT_COUNT	MEMORY_BUF_ALLOC
2	0,550005216490914	55	204	1706599
1	0,550000710281341	55	2563	1659568
3	0,550000788577281	55	234	1732373

AUTOMATIC BIG TABLE CACHE – TECHNIK

- **Objekte im „ABTC“:**

```
SELECT distinct obj.object_name,ts.name ts_name,subobject_name,object_type,
temperature,policy, (cached_in_mem*8192)/1024/1024 cached_mb, dataobj# , btt.inst_id
FROM gv$tablespace ts,gv$bt_scan_obj_temps btt,dba_objects obj
WHERE ts.ts# = btt.ts#
AND obj.object_id = DATAOBJ#
order by  temperature desc, dataobj# ;
```

OBJECT_NAME	TS_NAME	SUBOBJECT_NAME	OBJECT_TYPE	TEMPERATURE	POLICY	CACHED_MB	DATAOBJ#	ID
ILS_EINSATZMITTEL	ARLIS_DATA	RDB_303	TABLE PARTITION	405000	MEM_ONLY	64,4140625	1251086	2
ARLIS_DATA	ARLIS_DATA	ED_2012_RDB_303	TABLE SUBPARTITION	9813	MEM_ONLY	44,7109375	1029063	3
ARLIS_DATA_FA_EDAT	ARLIS_INDEX	ED_2008_RDB_302	INDEX SUBPARTITION	2000	MEM_ONLY	1,3671875	1046850	1

AUTOMATIC BIG TABLE CACHE - TECHNIK

- im RAC werden die Objekte /oder dessen Fragmente über die Nodes verteilt
- jeder Node verwaltet seinen CACHE
- im Gegensatz zu „cache-fusion“ werden keine Blöcke/Daten über den interconnect übertragen (nur Ergebnisse von entfernten Knoten über PX erzeugt und übertragen)
- bei: PARALLEL_FORCE_LOCAL=TRUE (interconnect / PX bleiben auf einer Instance)
- Objekte können dann mehrfach auf den Instanzen allokiert werden

AUTOMATIC BIG TABLE CACHE - TECHNIK

```
SELECT  distinct obj.object_name,ts.name ts_name,subobject_name,object_type,
   temperature,policy, (cached_in_mem*8192)/1024/1024 cached_mb, dataobj# , btt.inst_id
   FROM gv$tablespace ts,gv$bt_scan_obj_temps btt,dba_objects obj
   WHERE ts.ts# = btt.ts#
   AND obj.object_id = DATAOBJ#
   and subobject_name='ED_2013_RDB_501'
   order by  obj.object_name,btt.inst_id
```

OBJECT_NAME	SUBOBJECT_NAME	OBJECT_TYPE	TEMPERATURE	POLICY	CACHED_MB	DATAOBJ#	INST_ID
ARLIS_DATA	ED_2013_RDB_501	TABLE SUBPARTITION	2000	MEM_ONLY	130,3203125	1058127	1
ARLIS_DATA	ED_2013_RDB_501	TABLE SUBPARTITION	1000	MEM_ONLY	130,3203125	1058127	2
ARLIS_DATA	ED_2013_RDB_501	TABLE SUBPARTITION	60250	MEM_ONLY	130,3203125	1058127	3

AUTOMATIC BIG TABLE CACHE – TECHNIK

- **Ausprägungen des „ABTC“ (POLICY)**

MEM_ONLY	Objekt wird komplett im Cache gehalten
MEM_PART	Teile des Objektes werden im CACHE gehalten
DISK	Objekt wird komplett von DISK gelesen

OBJECT_NAME	TS_NAME	TEMPERATURE	POLICY	CACHED_MB
ARLIS_DATA_FIRMA_P_O_IDX	ARLIS_INDEX	2000	DISK	0
ARLIS_DATA_FIRMA_P_O_IDX1	ARLIS_INDEX	2000	MEM_PART	1,2578125
DM_TG_RDS_BODEN	ARLIS_DATA	26563	MEM_ONLY	888,8046875

AUTOMATIC BIG TABLE CACHE - TECHNIK

```
SQL> select object_count from V$BT_SCAN_CACHE;
OBJECT_COUNT
------------
0

SQL> set autotrace on
SQL> select count(*) from scott.t1;
COUNT(*)
--------
2000000

Execution Plan
---------------
Plan hash value: 227768458
----------------------------
|Id | Operation           | Name         | Rows  | Cost (%CPU)| Time     |
-------------------------------------------------------------------------------
|0 | SELECT STATEMENT     |              | 1     | 211 (6)    | 00:00:01 |
|1 | SORT AGGREGATE       |              | 1     |            |          |
|2 | INDEX FAST FULL SCAN | SYS_C0011355 | 2565K | 211 (6)    |00:00:01  |
-------------------------------------------------------------------------------
Statistiken
------------------------
947    recursive calls
0      db block gets
11489  consistent gets
4191   physical reads
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

```
select object_count from V$BT_SCAN_CACHE;

OBJECT_COUNT
------------
1

select ts#,dataobj#,policy from V$BT_SCAN_OBJ_TEMPS;

TS#    DATAOBJ# POLICY
-------------------------
196612   96464  MEM_ONLY

select owner,object_name,object_type
from dba_objects
where data_object_id=96464;

OWNER OBJECT_NAME OBJECT_TYPE
-----------------------------
SCOTT T1          TABLE
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

```
select count(*) from scott.t1;

Execution Plan
----------------------------
Plan hash value: 227768458
----------------------------
| Id | Operation          |         Name | Rows | Cost (%CPU)| Time |
-------------------------------------------------------------------------
| 0 | SELECT STATEMENT    |              | 1    | 211 (6)| 00:00:01 |
| 1 | SORT AGGREGATE      |              | 1    |        |          |
| 2 | INDEX FAST FULL SCAN| SYS_C0011355 | 2565K| 211 (6)| 00:00:01 |
-------------------------------------------------------------------------

Statistiken
------------------------
3911 consistent gets
0    physical reads
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

```
select /*+ full(t1) */ count(*) from scott.t1;
COUNT(*)
————-
2000000

Elapsed: 00:00:00.03
Execution Plan
----------------------------
Plan hash value: 3724264953
----------------------------
|Id | Operation         | Name | Rows  | Cost (%CPU)| Time     |
-------------------------------------------------------------------
|0 | SELECT STATEMENT  |      | 1     |    596 (33)| 00:00:01 |
|1 | SORT AGGREGATE    |      | 1     |            |          |
|2 | TABLE ACCESS FULL| T1   | 2565K | 596 (33)   | 00:00:01 |
-------------------------------------------------------------------

Statistiken
-----------------------
7883 consistent gets
0    physical reads
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Messungen INM:**
  - Problem: Testumgebung (neuer Test jeweils nach ein paar Tagen Normalbetrieb)
  - 55% „ABTC“ bei ca. 26 GB DB-BLOCK-BUFFERS
  - regelmäßige einzelne selects auf eine Table „distanz_matrix“ mit ca. 1,6 MRD Rows, um den Cache und die Maschine zu belasten (12c mit ABTC)
  - Restart der Statments jeweils nach PLUS einem Tag
  - Table mit Partitionen und SUB-Partitionen
  - SIZE: 22,6 GB / 30,5 MIO Rows

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Select-INM:**
- Test: 29.10.2015:

```
SELECT distinct obj.object_name,ts.name ts_name,subobject_name,object_type,
   temperature,policy, (cached_in_mem*8192)/1024/1024 cached_mb, dataobj# , btt.inst_id
   FROM gv$tablespace ts,gv$bt_scan_obj_temps btt,dba_objects obj
   WHERE ts.ts# = btt.ts#
   AND obj.object_id = DATAOBJ# order by  temperature desc, dataobj# ;
```

OBJECT_NAME	TS_NAME	SUBOBJECT_NAME	OBJECT_TYPE	TEMPERATURE	POLICY	CACHED_MB	DATAOBJ#	INST_ID
ARLIS_DATA	**ARLIS_DATA**	ED_2013_RDB_308	TABLE SUBPARTITION	56250	MEM_ONLY	43,4609375	1058112	3
ARLIS_DATA	ARLIS_DATA	ED_2013_RDB_505	TABLE SUBPARTITION	56250	MEM_ONLY	59,8359375	1058114	3
ARLIS_DATA	ARLIS_DATA	ED_2013_RDB_206	TABLE SUBPARTITION	56250	MEM_ONLY	63,90625	1058116	3
ILS_EINSATZMITTEL	ARLIS_DATA	RDB_303	TABLE PARTITION	17010	MEM_ONLY	69,3203125	1251086	2
ILS_EINSATZMITTEL	ARLIS_DATA	RDB_314	TABLE PARTITION	16010	MEM_ONLY	400,984375	1251097	2

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Messungen INM:**

```
select /*+ full(t1) */  distinct to_char(einsatz_datum,'dd.mm.yyyy') TAG, count(*)
from oracle.arlis_data t1
where einsatz_datum >=to_date('01.01.2013','dd.mm.yyyy')
and  einsatz_datum < to_date('01.01.2014','dd.mm.yyyy')
and firma=308
group by to_char(einsatz_datum,'dd.mm.yyyy')


TAG          COUNT(*)
---------- ----------
23.10.2013        157
22.10.2013        140
09.05.2013         97
…
365 Zeilen ausgewählt.

Abgelaufen: 00:00:05.17
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Messungen INM:**

```
Ausführungsplan
----------------------------------------------------------
Plan hash value: 1211467257
-------------------------------------------------------------------------------------------------------------
| Id  | Operation                | Name       | Rows  | Bytes | Cost (%CPU)| Time     | Pstart| Pstop |
-------------------------------------------------------------------------------------------------------------
|   0 | SELECT STATEMENT         |            |   365 |  4380 |  1260   (4)| 00:00:01 |       |       |
|   1 |  HASH GROUP BY           |            |   365 |  4380 |  1260   (4)| 00:00:01 |       |       |
|   2 |   PARTITION RANGE SINGLE|            | 62513 |   732K|  1249   (3)| 00:00:01 |    16 |    16 |
|   3 |    PARTITION LIST SINGLE|            | 62513 |   732K|  1249   (3)| 00:00:01 |   KEY |   KEY |
|   4 |     TABLE ACCESS FULL    | ARLIS_DATA | 62513 |   732K|  1249   (3)| 00:00:01 |   401 |   401 |
-------------------------------------------------------------------------------------------------------------


Statistiken
----------------------------------------------------------
      55359  consistent gets
        362  physical reads
```

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Messungen INM:**
  - Nutzung von Partitioning in Kombination mit “ABTC”
  - Partition reduziert Datenmenge erheblich
  - “ABTC” hält die Partition durch den errechneten workflow im CACHE

AUTOMATIC BIG TABLE CACHE - TECHNIK

- **Messungen INM / Zeitverlauf:**

```
select count(*), firma, kfzart
from oracle.arlis_data
group by firma, kfzart
```

Statement	12.1.0.2 / SI / ohne ABTC	11gCluster	12c Cluster + parallel /ABTC
2	00:00:20.64	00:05:39.64	00:00:13.67
			00:00:18.31 (Tage später)
			00:00:26.97 (Tage später)

AUTOMATIC BIG TABLE CACHE – ERSTE ERFAHRUNGEN

- einfach einzurichten / keine Änderung an DB-Strukturen u. Applikationen
- besonders gut für partitionierte Tables verwendbar
- bei Simulationsberechnungen mit wiederkehrenden SQL-Abfragen auf gleiche Table-Partitionen
- der workload bestimmt den Inhalt des CACHES
- es benötigt einige Zeit, damit sich der „workload" richtig einpendelt
- erheblicher Performance-Gewinn in unserer Umgebung
  z.B. Procedure vor „ABTC" 45 Minuten / jetzt 12 Minuten
- produktiv seit ca. 3 Monaten

VIELEN DANK FÜR IHRE AUFMERKSAMKEIT

ANSPRECHPARTNER:

Markus Geis

Klinikum der Universität München

INM - Institut für Notfallmedizin
und Medizinmanagement

Telefon: 089 / 4400-57101

E-Mail: markus.geis@med.uni-muenchen.de

Internet: www.inm-online.de