

on

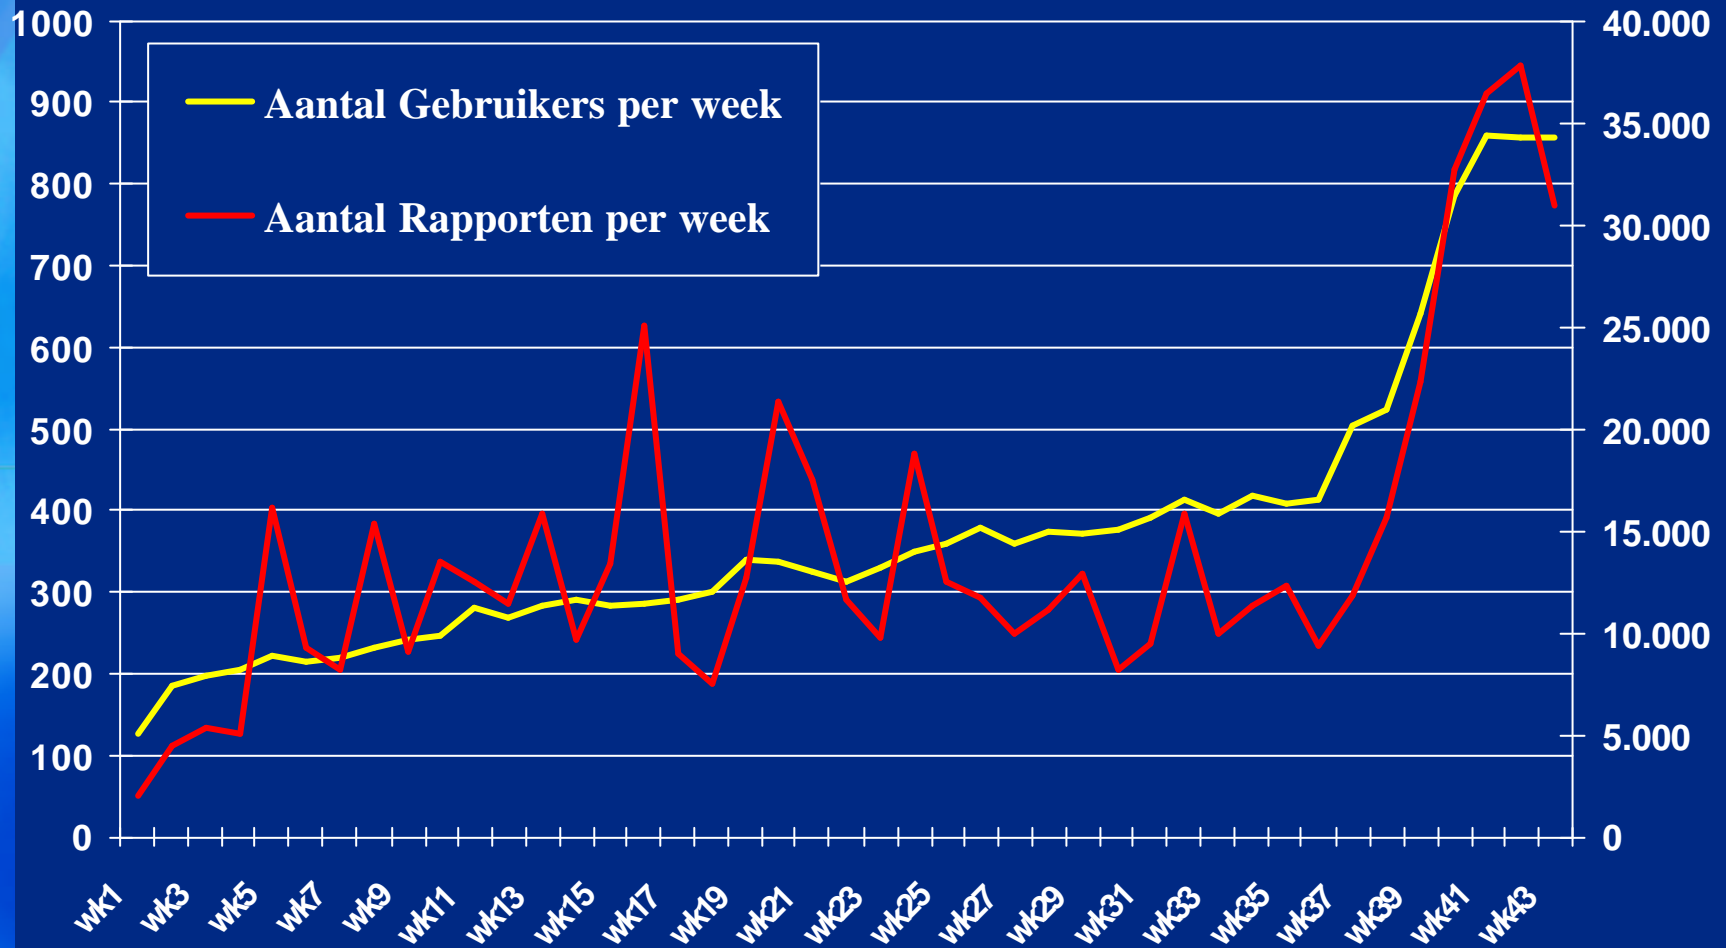
Albert Heijn

Enterprise Data Warehouse

Het PALLAS project



AH-datawarehouse project Pallas in 2003





AH-DWH presentatie OGH

- de businesscase van 1999
- algemene architectuur
- tooling, hardware, sizing
- koffie
- backup & recovery
- datamodellen. TR, staging, Datamart
- databaseontwerp. opslag, partitioning, indexing, data proximity, analyze
- werken met veel data



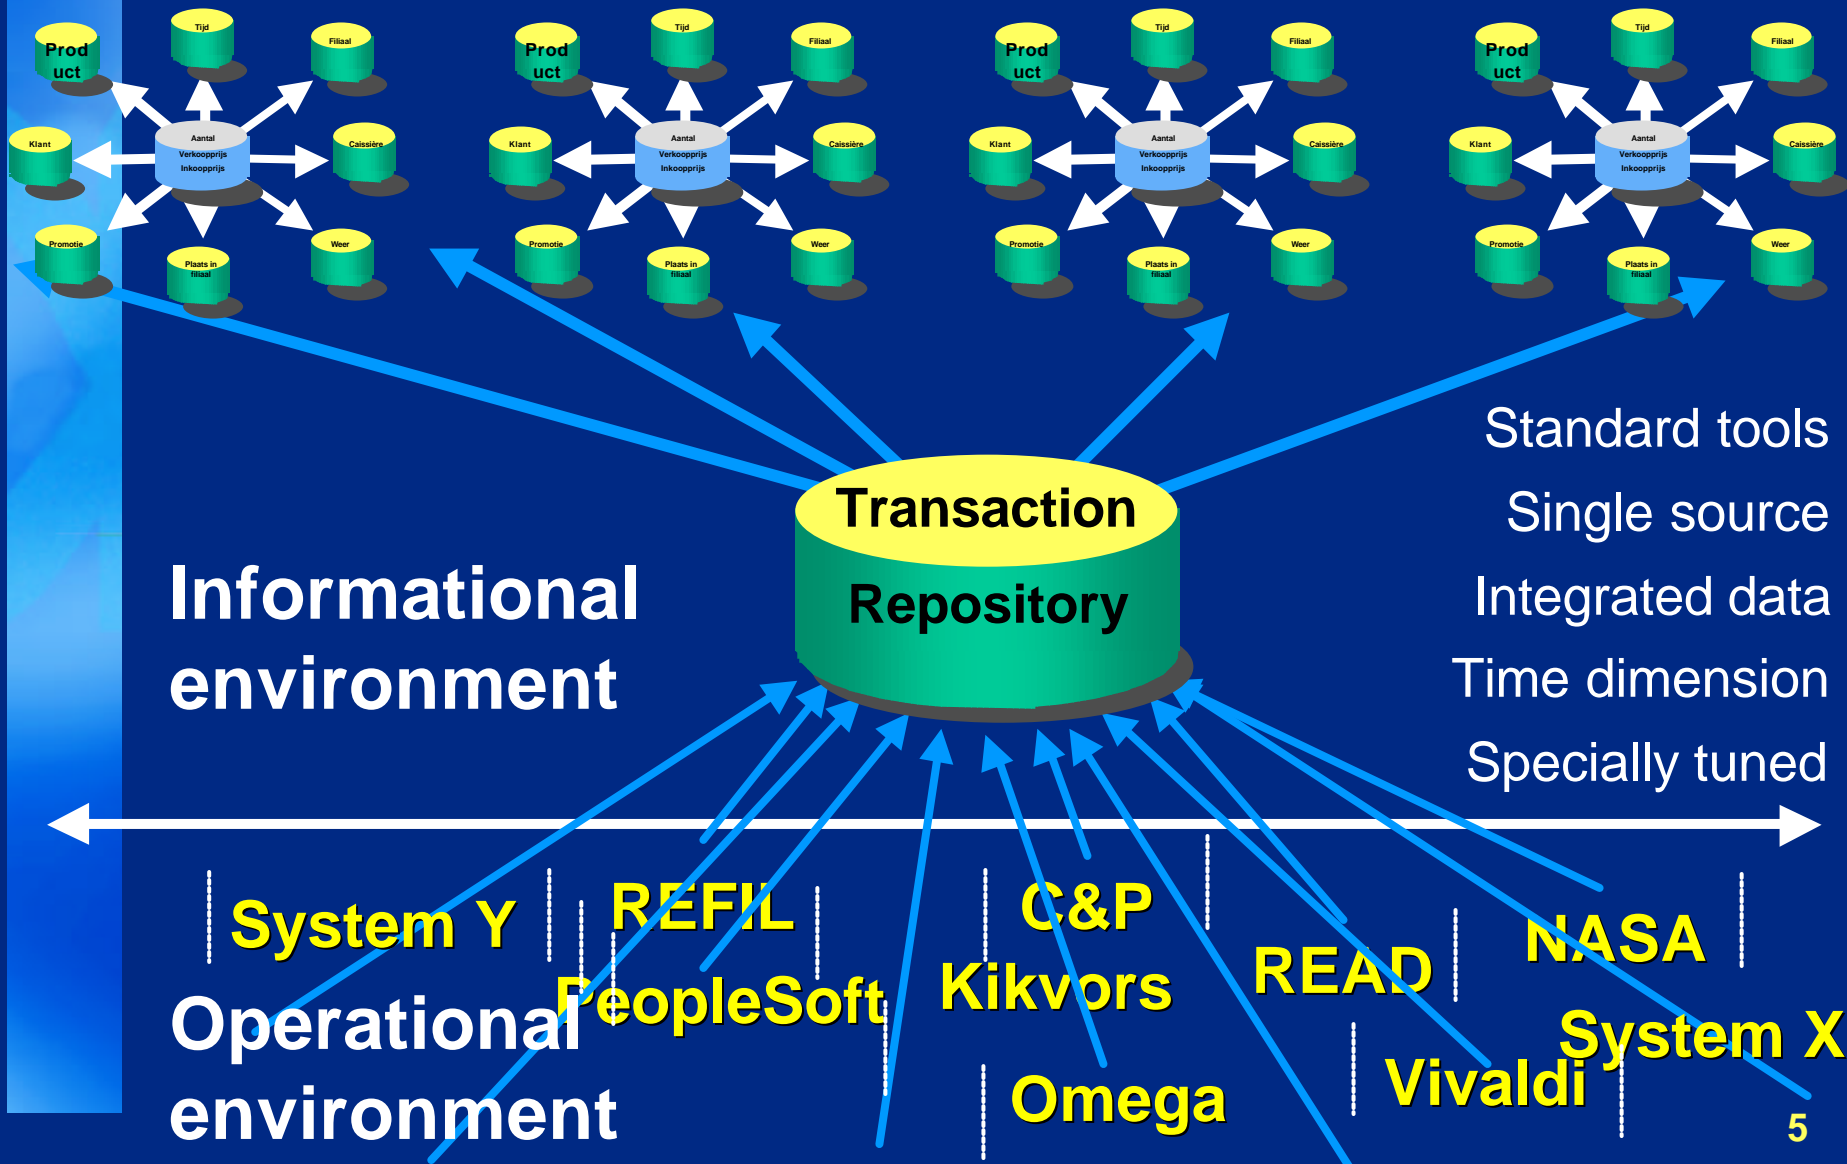
businesscase : outset 1999 / 2000

- Defensief :
 - Management info uit diverse bronnen.
 - Te duur

- Offensief :
 - Differentiatiestrategie ondersteunen
 - POS data en winkelniveau centraal ontsluiten
 - Herbruikbaar model / techniek

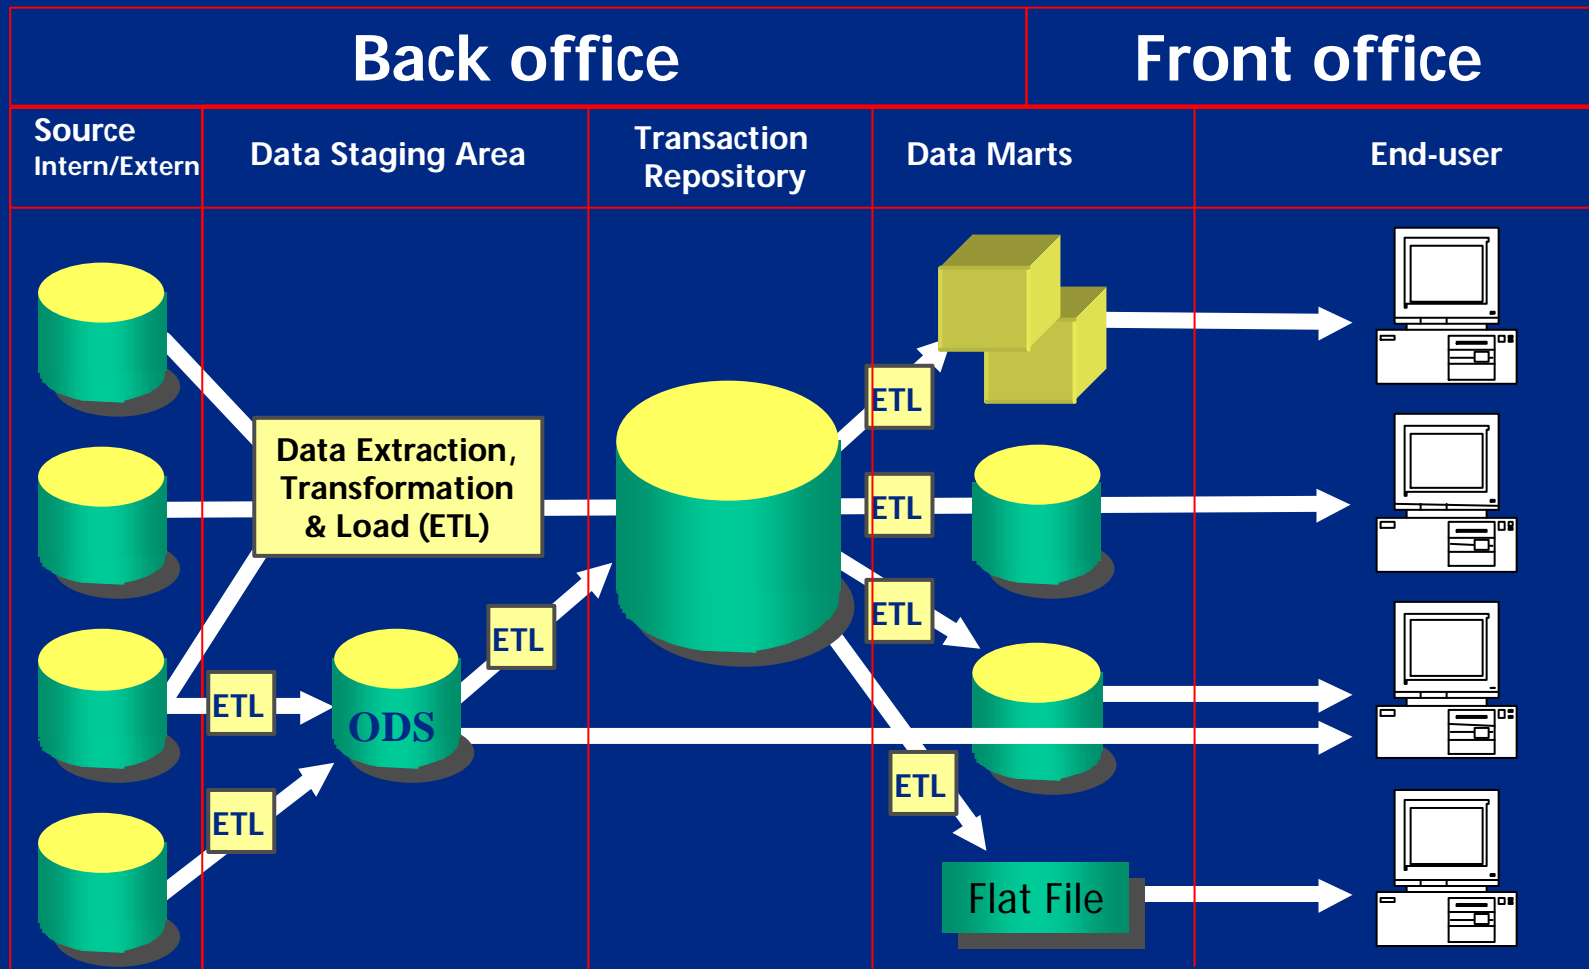


Informational versus Operational *The Enterprise Data Warehouse*



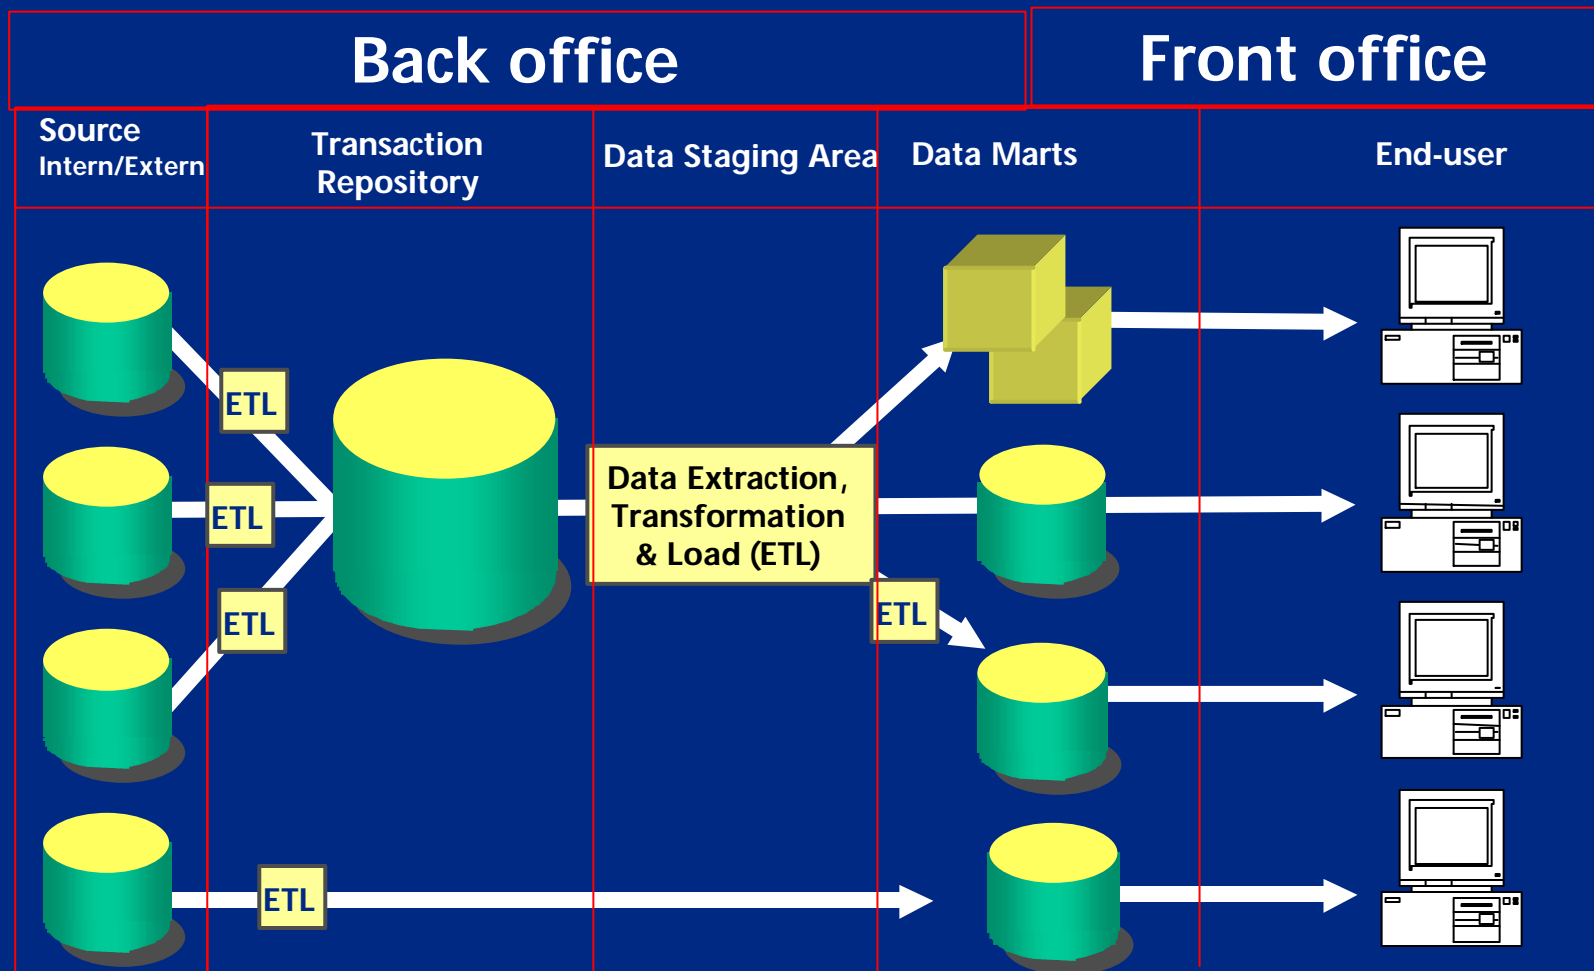


Pallas Basic Architecture





Pallas Basic Architecture






Fasering Pallas project

- 2000 EDOG non-tr datamart 150 GB
- 2001 TR opbouw start
- 2001 Gall datamart
- 2002 Sales Day datamart 1e fase
- 2002 Essbase meerdere cubes
- 2002 Bonuskaart datamart
- 2002 Sales Day datamart 2e fase
- 2003 Warehouse Execution datamart
- 2003 Rosie filiaal datamart
- 2003 1000-plus named users..



Hardware en Tools

- Hardware **IBM S80 AIX, Ess disks**



- RDBMS **Oracle 8.1.7 Partitioning**



- ETL-Tool **PowerCenter 6.2**



- End-user tool Reporting **MicroStrategy 7.2**

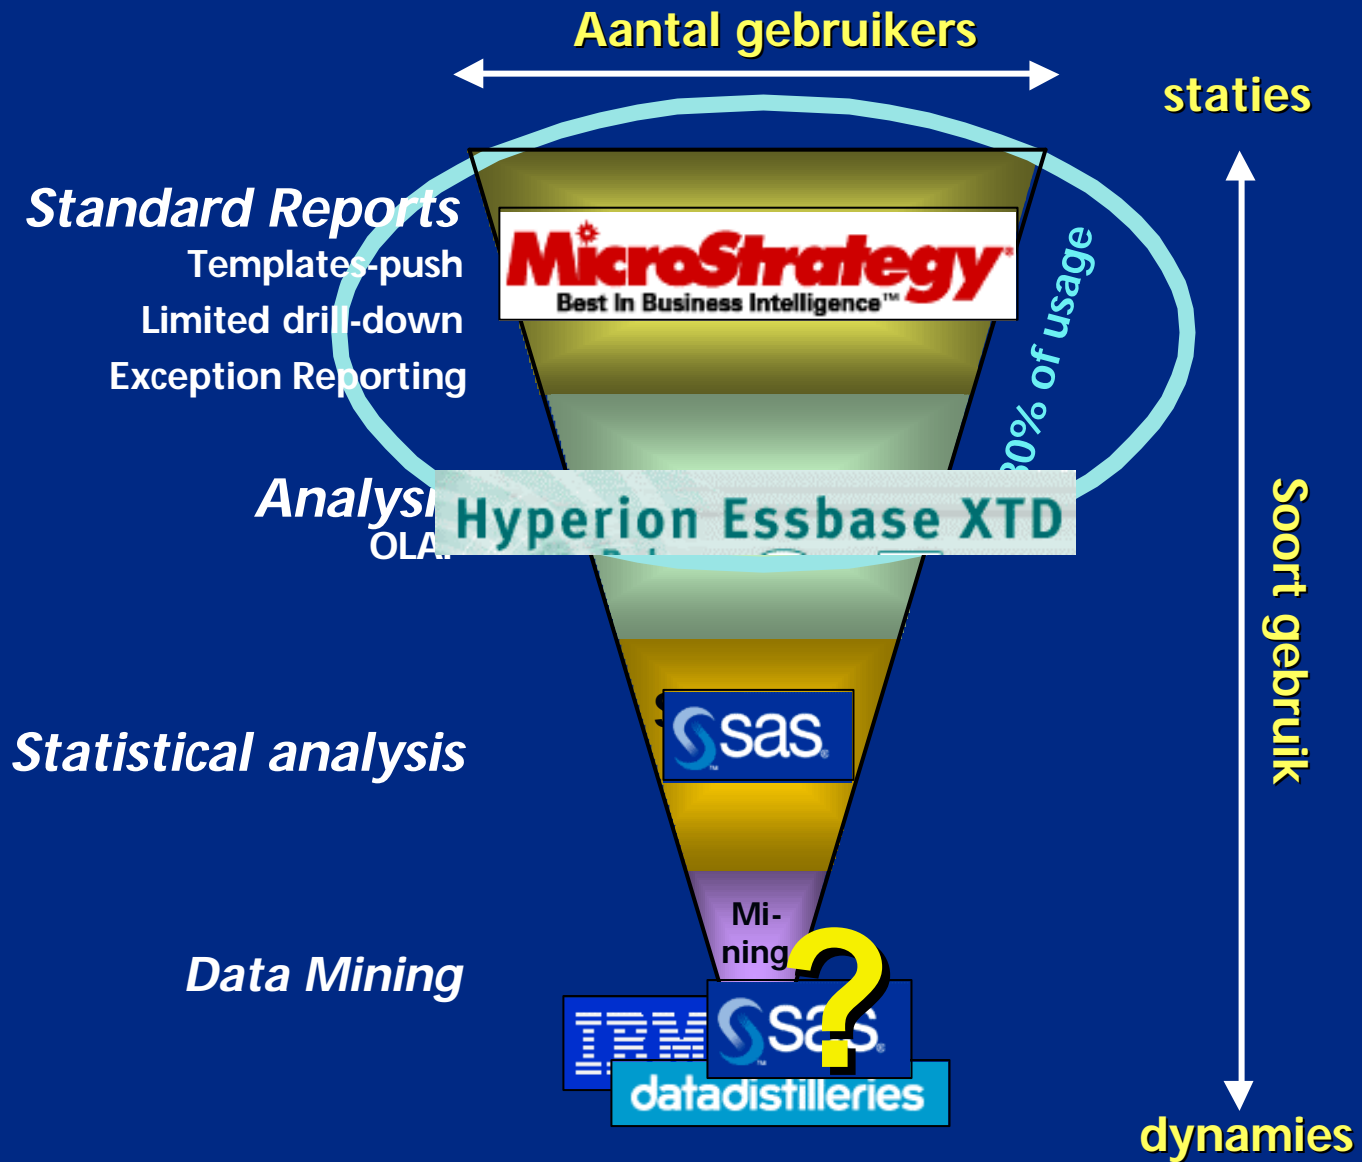


- End-user tool Analyse **Hyperion Essbase 6.1**





Functionele as – end-user tools





Hardware

- 2000
 - 1 IBM S80 : 12 maal 450 Mhz + 16 GB
 - 1 ESS 384 maal 18 GB disks (5 TB)
 - 2 NT servers 400 Mhz 500 Mb

- 2003
 - 1 IBM S80 : 24 maal 450 Mhz + 32 GB
 - 1 IBM S80 : 12 maal 450 Mhz + 16 GB
 - 1 IBM S85 : 8 maal 700 Mhz + 16 GB
 - 1 IBM P670 : 8 maal 850 Mhz + 16 GB
 - 2 EMC met 36 GB disks (12 TB)
 - 8 NT servers 750 Mhz 2Gb
 - backup : 2 IBM 3494 tape robots
 - 2 IBM H80's TSM servers.



Data Warehouse - disk volume



Spool, temp, overhead space

Data Mart - Customer Loyalty

Replacement MarketExpert; Basket Analyses, eCommerce
Customer Receipt data mart (customer-store-item-time), 6 months history
Customer Week data mart (customer-store-miac-week), 9 months history

Data Mart - Essbase

Solution for SAS, Delta AA

Spool, temp, overhead space

Data Mart - SalesDay


Powerplay, SAS Replacement
POS+dimensions, item-store-day-in promo y/n
history: two year+current year

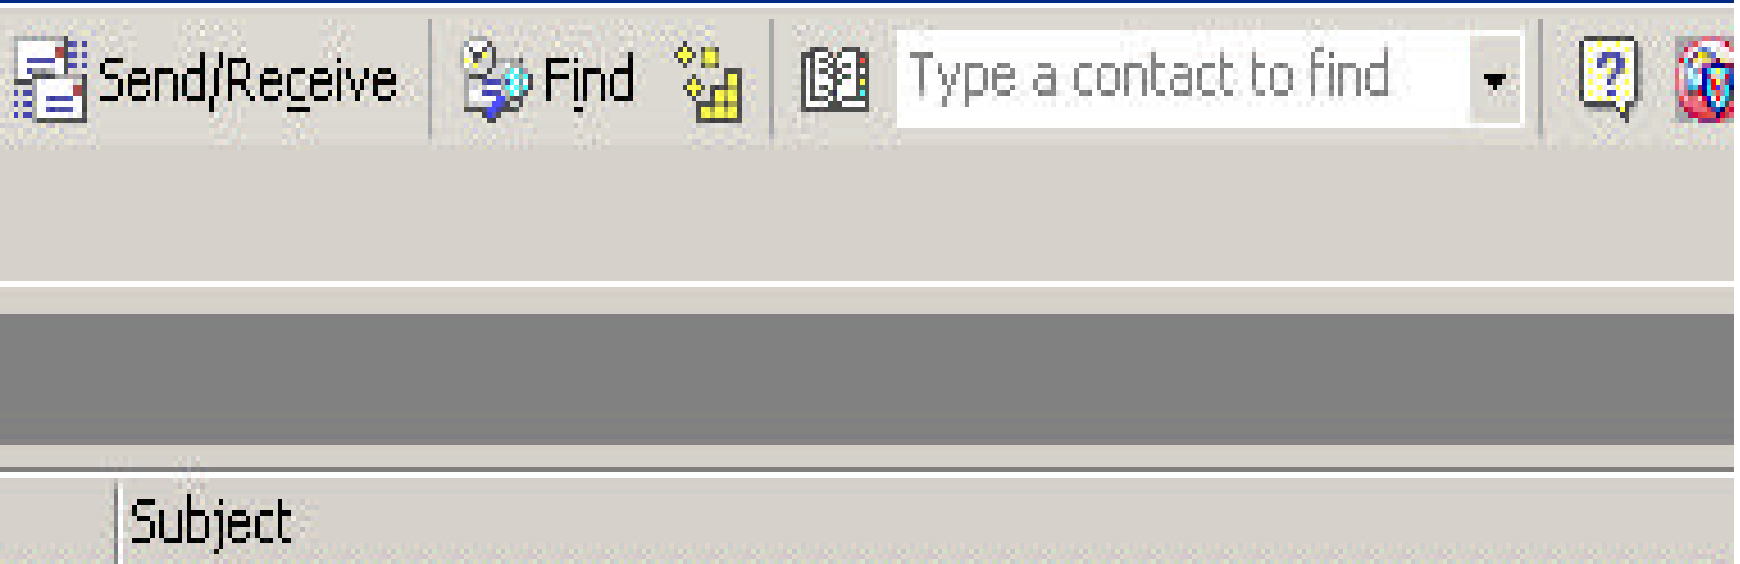
OTA, Backup issues

Spool, temp, overhead space

Transaction Repository POS

POS+dimensions, 6 months history, archiving 5 years
receipt line level, 64 million lines per week

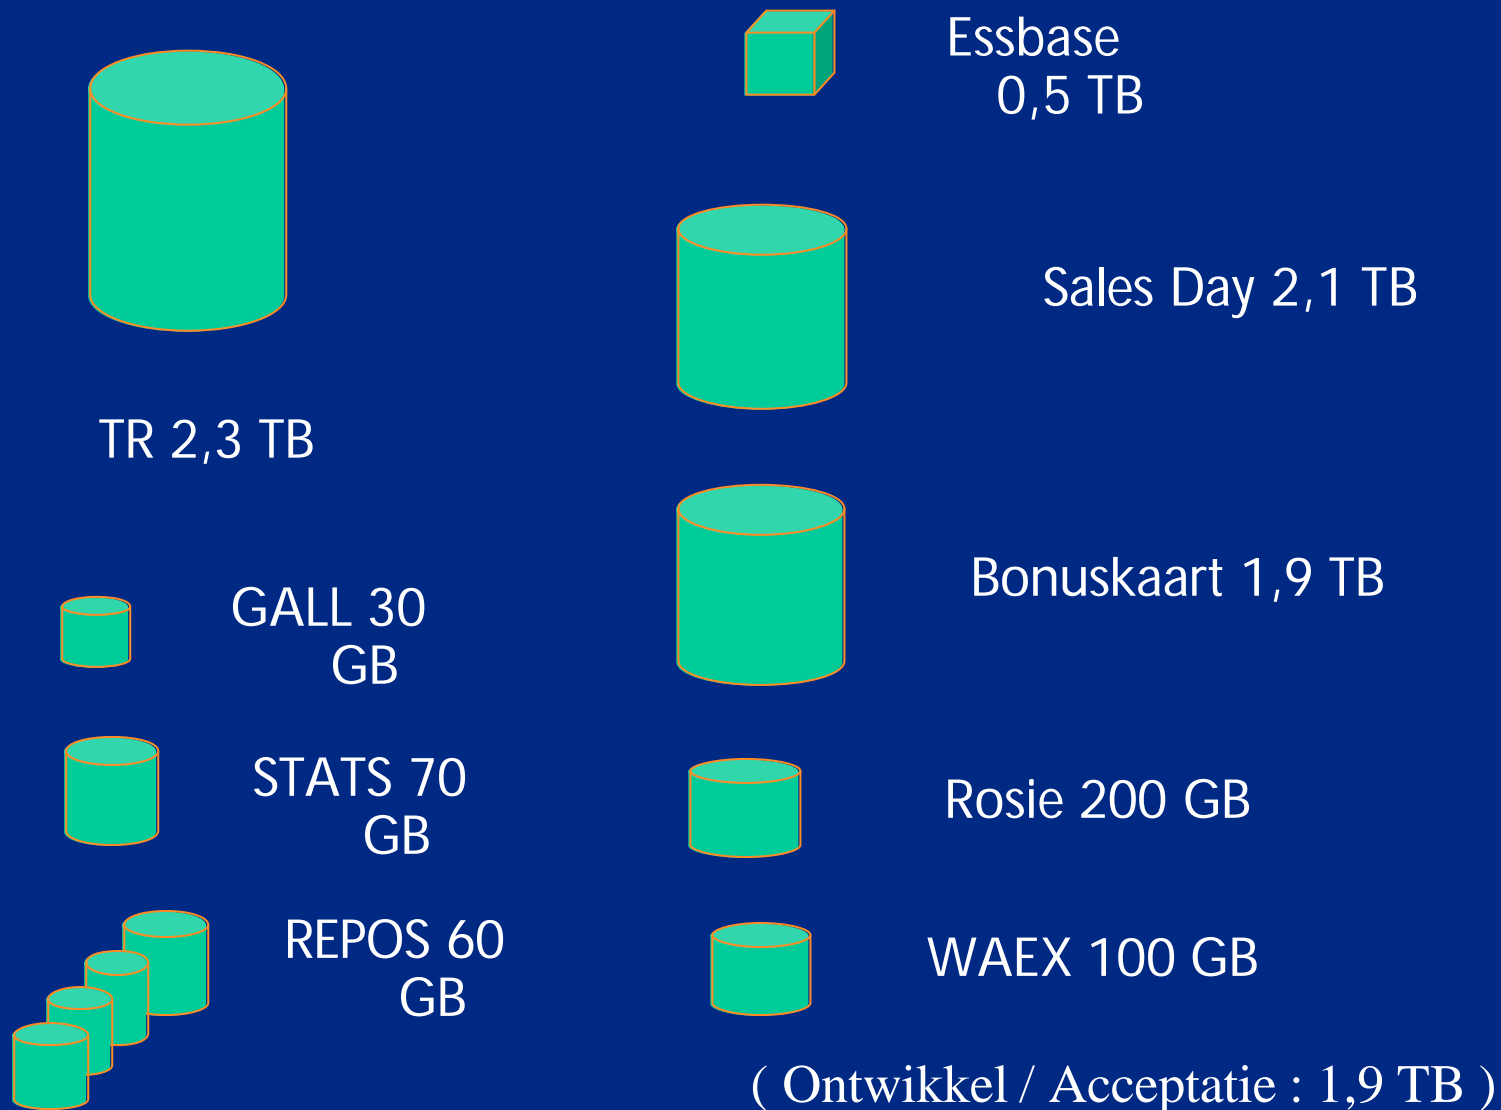




Now Add Three Full Inches to Your Datawarehouse !!



Pallas databases per mid 2003



Koffie ?!



Backup and Recovery

- Draaien in archivelog !
- Ad Hoc Maintenance operaties draaien vaak nologging
- Oracle Rman
- 80 tot 85% van het datavolume is Read Only
- RW : 5 maal per week INCR1/2 + 1 maal per week INCRO (alles dus skip RO)
- RO : todo list bepalen middels handgeschreven sync van de controlfile met de rman catalog. 4 maal p wk INCRO.
- Separaat Gbit-eth theoretisch max is 450 GB / uur maar nu ligt dat op 85 GB /uur
- Recovery : werkt. Partiele restores..



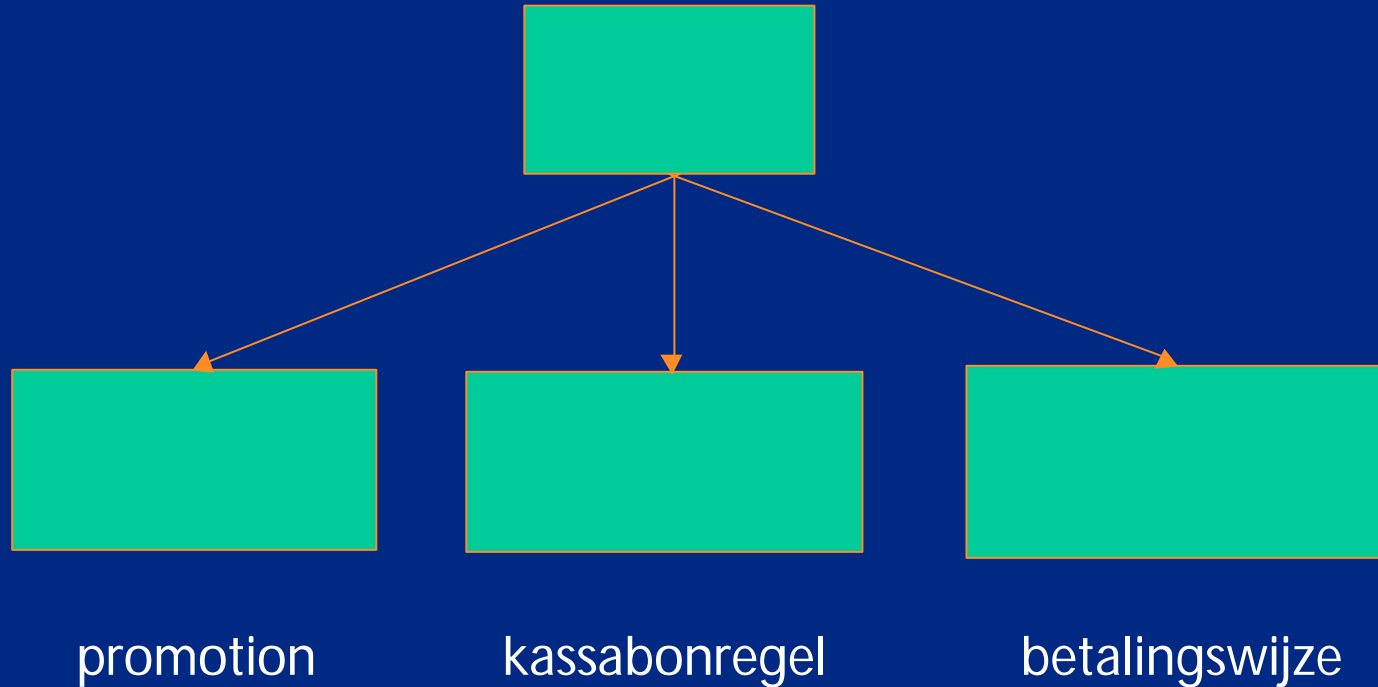
Datamodellen : TR 1

- corporate datamodel maakt direct aansluiten mogelijk
- dreiging UDM
- 3 NF time variant
- vrijwel geen indexes
- vrijwel geen PK's
- bewaar dimension history.
- uitgebreide DSA, maar aan de "achterkant" !




Datamodellen : TR 2

Kassabon header





Datamodellen : Data Staging




“prejoined” partitioned hulptabellen op
partition key $\text{mod}(\text{day}, 28)$

plus 7 hulptabellen



Datamodellen : Data Staging




“prejoined” partitioned hulptabellen op
partition key $\text{mod}(\text{day}, 20)$

plus 7 hulptabellen

Toevoegen “delta”

Plus 43 hulptabellen.....





■ Fact-tables

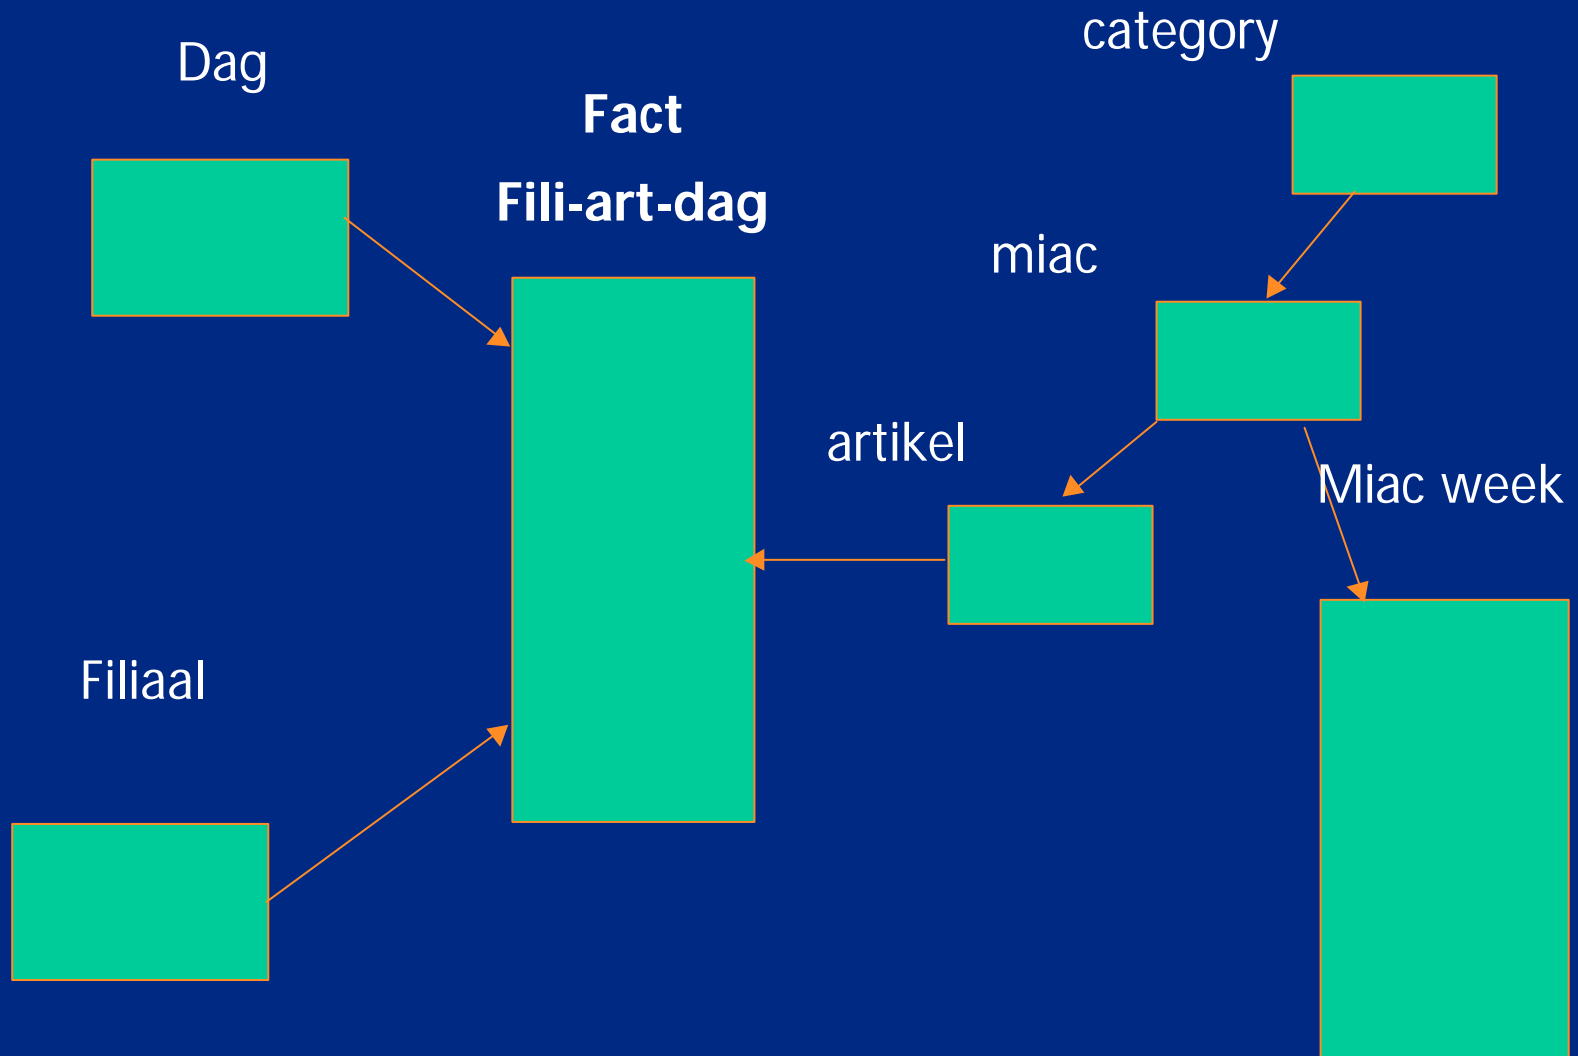
- vrij veel aggregaten
- onze aggregaten zijn niet altijd technisch
- de moeder van alle fact-tables is opgestaan

■ conformed dimensions

- straightforward
- snowflaked + platgeslagen



Datamodellen : Datamarts 2 Sales Day





Datamodellen : Datamarts 3 Sales Day

Fili miac week



Fili art week



Fili art dag



Art dag





Datamodellen : Datamarts 3 Sales Day

Select art, omzet from
fili art dag,
filiaal, artikel where 2
weken, miac = 297
en filiaal niet een
franchiser

(lees 8 GB)

Fili miac week



Fili art week



Fili art dag



Art dag





Datamodellen : Datamarts 3 Sales Day

Franchise indicator in
de fact-table

Fili miac week



Fili art week



Fili art dag



Frai art dag

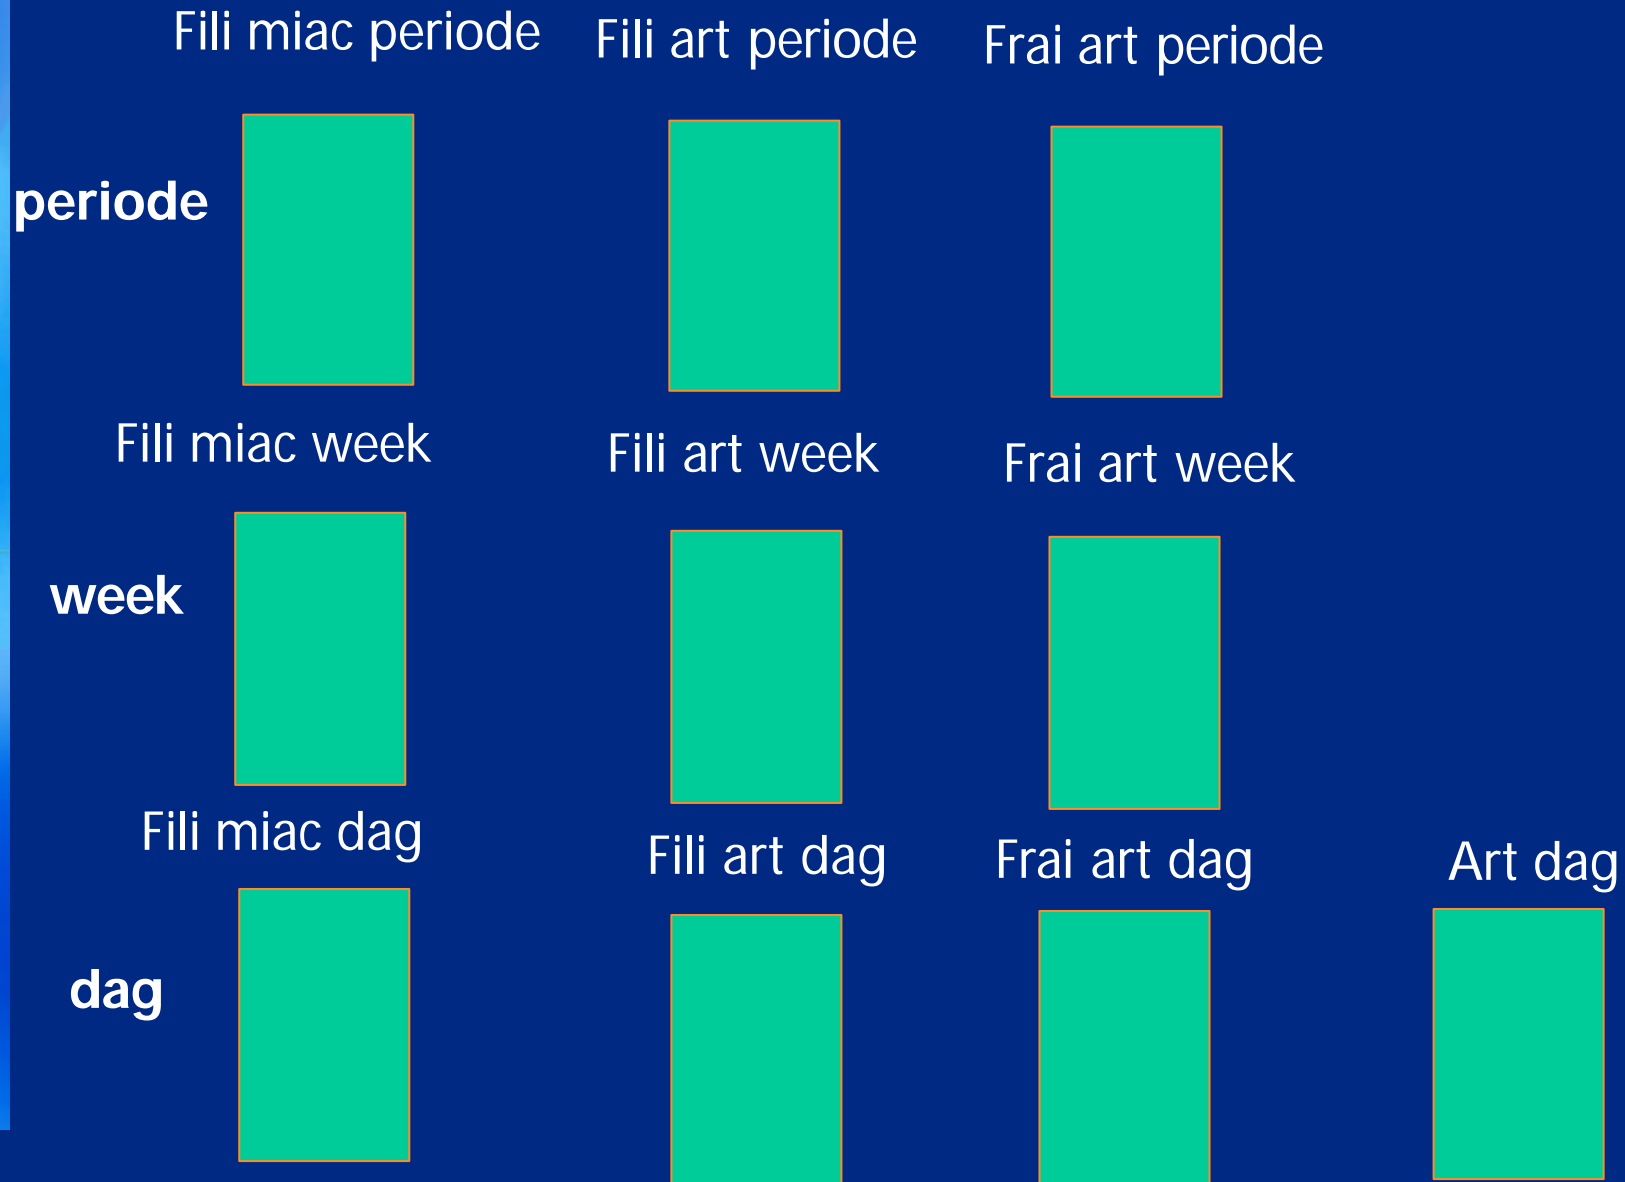


Art dag





Datamodellen : Datamarts 3 Sales Day





Datamodellen : Datamarts 4 Bonuskaart





Database ontwerp : opslag

- Basis : “ Stop defragmenting and ..”
- Autoextendable locally managed uniform size tablespaces.
- Slechts twee uniform sizes : 128k en 4m.
- Geen enkel object heeft dus eigen storage clause.
- Partitioned data in periode (28 dagen) tablespaces.
- maximale datafile size 9 GB (ivm backup-pool)
- Naamgeving tablespaces :
 - partitions : TRAS_2003PD10_01
 - klein TREP0101 / TREP0102 (resp. tables / indexes)
 - groot TREP0201 / TREP0202



Database ontwerp : partitioning

- Partition table alleen als > 5GB (maintenance..)
- Altijd range op dag of week of periode
- Sterke focus op partition elimination (between !)
- Let op de verschillen tussen plan en uitvoering.
- Nog steeds : Eens per jaar maak-nieuwe-partitions-feest !!
- Doorzetten naar acceptatie via dblink
- Archiveren : exchange, RO, transport, backup, drop.



Database ontwerp : indexing

- Bij mij doen ze het niet altijd..
- Lijn lijkt : hoe groter de tabel hoe moeilijker
- Wij hebben op enkele cruciale plaatsen sorted indexen op fact tables.
- 9i
- Doe geen updates op data met usable bitmap-indexes



Database ontwerp : data proximity

- Pre-sorting kan factoren (4-200) versnelling bereiken als verbeteren van SQL en indexes onmogelijk lijkt.
- ```
select count(distinct(block)) from (select dbms_rowid.rowid_block_number(ROWID) block
```
- ```
from trak_0911_sorted
```
- ```
where exists
```
- ```
(select 1 from CULO_ARTIKEL a14 where a14.MIAF_ID = 1507 and arti_id = a14.id))
```



Database ontwerp : analyse

- Nu : dbms_stats direct na laden, en tevens periodiek
- op basis gather stale
- pluggen van hulptabel statistics
- plannen voor pluggen van alle statistics
- Scalzo : number of rows = 20.000 voldoet prima.



Werken met zeer veel data.

- Rules of thumb voor werk met heel veel data :
 - eerst nederlands, dan sql, dan denken en dan andere sql.
 - maak operatie voorspelbaar.
 - 10 kleine sorts zijn samen sneller dan 1 grote.
 - De sum over (de union over de output van 10 kleine sorts) is sneller dan 1 grote sort. Of niet ?
 - Een 24 CPU machine is single user sneller, dan als JOUW queries elkaar in de weg zitten. Want Oracle heeft maar 1 temp-tablespace. Oh nee, per user.



Aanrader :

- Bert Scalzo : Oracle DBA Guide to data warehousing and star schemas.