ISO
SQL: Structured Query Language

Prof. dr. Paul De Bra

Gebaseerd op:
Database System Concepts, 5th Ed.
©Silberschatz, Korth and Sudarshan

SQL: query taal "met woorden"

- doel: intuitieve query taal
  - gebruikt Engelse woorden: *select*, *from*, *where*
  - is meer declaratief: je beschrijft de vraag en niet de berekening van het antwoord
  - beschikbaar in (bijna) alle database systemen
  - veel "toeters en bellen" die we in ISO niet bestuderen
  - het "data definitie" deel slaan we in ISO ook over
  - leunt aan bij wat computers goed kunnen (geen verzamelingen, beperkte data types zoals verschillende soorten getallen en strings)

voor andere datatypes: BLOBs

- wat we niet in SQL kunnen weergeven moeten we BLOBs gebruiken: **b**inary **l**arge **ob**jects
  ze hebben verder … geen betekenis

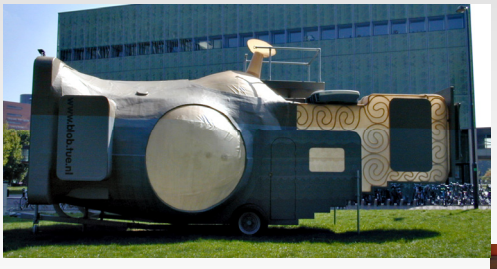

de SQL basis query structuur

- een typische SQL query ziet er als volgt uit:
  select A_1, A_2, ..., A_n
  from r_1, r_2, ..., r_m
  where P
  - A_i is een attribuut
  - R_i is een relatie (tabel)
  - P is een logisch predicaat.
- het resultaat betekent:

$$\prod_{A_1, A_2, \ldots, A_n}(\sigma_P(r_1 \times r_2 \times \ldots \times r_m))$$

- de query werkt op een instantie en produceert een nieuwe (virtuele) tabel-instantie

voorbeeld:

- geef het rekeningnummer en saldo van alle rekeningen bij het filiaal "Perryridge"
  - in de algebra was dit:
    $\Pi_{account\_number,\ balance}(\sigma_{branch\_name="Perryridge"}(account))$
  - in SQL wordt dit:

    select *account_number, balance*
    from *account*
    where *branch_name* = "Perryridge"
  - merk op dat dit bijna leest als Engels: "select the *account number* and *balance* of the *accounts* where the *branch name* is "Perryridge"

SQL: variaties op de *select* clausule

- een sterretje geeft aan dat er geen projectie is (dat alle attributen behouden blijven):

  select *
  from *loan*
- in de **select** clausule mag *gerekend* worden (+, –, ∗, /) met attributen en constanten
  - de vraag:

    select *loan_number, branch_name, amount* ∗ 100
    from *loan*

  geeft een tabel die lijkt op *loan* maar met alle bedragen maal 100.

de *where* clausule

- de **where** clause geeft een voorwaarde aan *per rij* uit de tabel (of cartesisch product)
  - komt helemaal overeen met het selectie-predicaat uit de relationele algebra.
  - we gebruiken **and**, **or**, **not** en haakjes, en we schrijven <>, <= en >= in plaats van ≠, ≤ en ≥.
  - we mogen ook in de **where** clausule rekenen:

    select *loan_number*
    from *loan*
    where *amount / 100* > 10

de *where* clausule: bijzondere gevallen

- SQL kent een **between** vergelijking:
  - **select** *loan_number*
    from *loan*
    where *amount* **between** 90000 **and** 100000
- SQL kent *string* operaties:
  - %: stelt eender welke string voor
    vb: **where** branch **like** '%idge%'
  - _: stelt eender welk (enkel) teken voor
    vb: **where** *customer_name* **like** '_. De Bra'
    selecteert De Bra met eender welke voorletter.
  - alleen exacte string vergelijking kan met "=".

de *from* clausule

- de **from** clausule bevat de relaties waarvan het cartesisch product genomen wordt.
  - vb: geef klant-naam, leningnummer en leningbedrag van alle klanten met leningen bij het filiaal Perryridge:

    select *customer_name, borrower.loan_number, amount*
    from *borrower, loan*
    where *borrower.loan_number = loan.loan_number*
    and *branch_name* = 'Perryridge'

  - merk op dat we dezelfde impliciete hernoeming gebruiken als bij de relationele algebra

expliciete hernoeming

- naast impliciete hernoeming kent SQL ook expliciete hernoeming van tabellen en van attributen: de **as** clausule:

  old-name **as** *new-name*

- geef klant-naam, leningnummer en leningbedrag van alle klanten met leningen bij het filiaal Perryridge en noem het *loan_number* om tot *loan_id*:
  select *customer_name, b.loan_number* **as** *loan_id, amount*
  from *borrower* **as** *b, loan* **as** *l*
  where *b.loan_number = l.loan_number*
- we noemen een hernoemde tabel ook *tupel variabele*

hernoeming (vervolg)

- voorbeeld met nodige hernoeming:
  geef de namen van alle filialen met grotere "assets" dan een filiaal in Brooklyn:

  select *T.branch_name*
  from *branch* **as** *T, branch* **as** *S*
  where *T.assets > S.assets*
  and *S.branch_city* = 'Brooklyn'

  - "groter… dan een filiaal in Brooklyn" betekent niet hetzelfde als "groter… dan elk filiaal in Brooklyn".

verzamelings-operaties

- de operaties ∪, ∩, – uit de relationele algebra heten in SQL **union**, **intersect**, en **except**.
  - de queries die moeten gecombineerd worden moeten tussen haakjes staan
  - hoewel SQL in het algemeen een "probleem" heeft met het elimineren van dubbele tupels gebeurt dat elimineren bij union, intersect en except altijd automatisch (zodat er geen vergissingen ontstaan)

verzamelings-operaties

- geef alle klanten met een rekening of een lening (of allebei):

  (**select** *customer_name* **from** *depositor*)
  union
  (**select** *customer_name* **from** *borrower*)

- geef alle klanten met een rekening en een lening:

  (**select** *customer_name* **from** *depositor*)
  intersect
  (**select** *customer_name* **from** *borrower*)

- geef alle klanten met een rekening maar geen lening:

  (**select** *customer_name* **from** *depositor*)
  except
  (**select** *customer_name* **from** *borrower*)

opgaven

- we stellen dezelfde queries als bij de relationele algebra, op de database van opgave 2.1:

  employee (*person_name*, *street*, *city*)

  works (*person_name*, *company_name*, *salary*)

  company (*company_name*, *city*)

  manages (*person_name*, *manager_name*)

  de sleutels hebben hierbij belang!

opgaven

- Stel volgende vragen in SQL:
  1. geef de namen van alle bedienden die wonen in Eindhoven
  2. geef de namen van alle bedienden die niet in Eindhoven wonen
  3. geef de namen van alle bedienden die zichzelf als manager hebben
  4. geef de naam van de managers met een salaris van meer dan 100.000
  5. geef de naam van de bedienden met een manager met een salaris van meer dan 100.000

opgaven

- Stel volgende vragen in SQL:
  6. geef de namen van de bedienden die meer verdienen dan hun manager
  7. geef de naam van de bedrijven die gevestigd zijn in een stad waar nog een ander bedrijf gevestigd is
  8. geef de namen van alle bedienden die wonen in de stad waar ze werken
  9. geef de namen van alle bedienden die wonen in een andere stad dan hun manager
  10. geef de naam van de bedrijven die gevestigd zijn in een stad waar geen enkele bediende van dat bedrijf woont

opgaven

- Stel volgende vragen in SQL:
  11. geef de naam van bedienden wiens manager voor een ander bedrijf werkt dan zij zelf
  12. geef de namen van de bedrijven die werknemers hebben die in Eindhoven wonen
  13. geef de namen van de bedrijven die geen werknemers hebben die in Eindhoven wonen
  14. geef de naam van de bediende met het hoogste salaris
  15. geef de naam van de manager met het hoogste salaris

terugvertaling naar het Nederlands

- **select** e.person_name
  from employee **as** e, manages **as** m employee **as** me
  where e.person_name = m.person_name
  and m.manager_name = me.person_name
  and e.city = me.city

- (**select** c.company_name **from** company as c)
  except
  (**select** c.company_name
  from company **as** c, works **as** w, employee **as** e
  where e.person_name = w.person_name
  and e.city = c.city)

geneste of *ingenestelde* queries

- in SQL kunnen queries binnen andere queries worden gebruikt
- *subqueries* worden o.a. gebruikt om $\in$ en $\notin$ uit te drukken (met **in** en **not in**):
  - geef de klanten met een rekening maar geen lening:

```
select customer_name
from depositor
where customer_name
  not in
  (select customer_name
   from borrower )
```

```
( select
customer_name
from depositor )
except
(select
customer_name
from borrower )
```


waarom geneste queries?

- bij een geneste query kunnen in de subquery attributen uit hoofd- en subquery worden gebruikt:
  - geef de klanten met een rekening waarop het saldo hoger is dan het bedrag van elk van hun leningen:

```
select customer_name
from depositor as d, account as a
where d.account_number = a.account_number
  and customer_name not in
( select customer_name
  from borrower as b, loan as l
  where b.loan_number = l.loan_number
  and l.amount >= a.balance )
```


meer mogelijkheden…

- dit lijkt op dezelfde vraag…
  - maar is dit echt dezelfde query?

```
select customer_name
from depositor as d
where customer_name not in
( select b.customer_name
  from borrower as b, loan as l , account as a
  where d.account_number = a.account_number
  and b.loan_number = l.loan_number
  and l.amount >= a.balance )
```


meer mogelijkheden, meer fouten…

- dit lijkt opnieuw op dezelfde vraag…
  - maar wat betekent deze query?

```
select customer_name
from depositor as d
where customer_name not in
( select b.customer_name
  from borrower as b, loan as l ,
       depositor as dd,  account as a
  where d.customer_name = dd.customer_name
  and dd.account_number = a.account_number
  and b.loan_number = l.loan_number
  and l.amount >= a.balance )
```


scoping regels

- in de subquery mag worden verwezen naar de hoofdquery, maar niet omgekeerd
  - wat is er fout in de volgende query?

```
select customer_name
from depositor as d, account as a
where d.account_number = a.account_number
  and d.customer_name = b.customer_name
  and customer_name not in
( select customer_name
  from borrower as b, loan as l
  where b.loan_number = l.loan_number
  and l.amount >= a.balance )
```


verzamelingen vergelijken: *some*

- we kunnen =, <>, >, >=, <, <= met **some** gebruiken (**in** is hetzelfde als **= some**):
  - geef de (namen van) klanten met een rekening waarvan het saldo groter is dan het bedrag van een van hun leningen:

```
select customer_name
from depositor as d, account as a
where d.account_number = a.account_number
  and balance > some
  ( select amount
    from borrower as b, loan as l
    where b.customer_name = d.customer_name
      and b.loan_number = l.loan_number )
```

  - **verschil (in Engels) tussen "some" en "any" !!**

some : beperkt gebruik

- je mag alleen een attribuutwaarde met een subquery vergelijken.
  - dit is OK:
    select *account_number*
    from *account*
    where *balance* **>** **some** (**select** *amount*
    from *loan*)
  - dit is **niet OK**:
    select *customer_name*
    from *depositor* **as** *d*, *account* **as** *a*
    where *d.account_number* = *a.account_number*
    and some *balance* **>** (**select** *amount*
    from *loan*)

exacte betekenis van *some*

- F <comp> **some** $r \Leftrightarrow \exists\, t \in r$ zodat (F <comp> t)
  waarbij <comp> $<,\ \leq,\ >,\ \geq,\ =,$ of $\neq$ is

(5 < **some** {0, 5, 6}) = waar (lees: 5 < sommige waarden in de tabel)

(5 < **some** {0, 5}) = onwaar

(5 = **some** {0, 5}) = waar

(5 ≠ **some** {0, 5}) = waar (want 0 ≠ 5)

(= **some**) ≡ **in** maar, (≠ **some**) ≢ **not in**

verzamelingen vergelijken: *all*

- we kunnen =, <>, >, >=, <, <= met **all** gebruiken (**not in** is hetzelfde als **<> all**):
  - geef de (namen van) klanten met een rekening waarvan het saldo groter is dan de bedragen van al hun leningen:
    select *customer_name*
    from *depositor* **as** *d*, *account* **as** *a*
    where *d.account_number* = *a.account_number*
    and *balance* **>** **all**
    (**select** *amount*
    from *borrower* **as** *b*, *loan* **as** *l*
    where *b.customer_name* = *d.customer_name*
    and *b.loan_number* = *l.loan_number*)
  - **vergelijk (in Engels) “all” en “any” !!**

exacte betekenis van *all*

- F <comp> **all** $r \Leftrightarrow \forall\, t \in r$ (F <comp> t)

(5 < **all** {0, 5, 6}) = onwaar

(5 < **all** {6, 10}) = waar

(5 = **all** {4, 5}) = onwaar

(5 ≠ **all** {4, 6}) = waar (want 5 ≠ 4 en 5 ≠ 6)

(≠ **all**) ≡ **not in**
maar, (= **all**) ≢ **in**

test of een subquery-resultaat leeg is

- een **exists** clausule geeft de waarde **waar** terug als de subquery een niet-leeg resultaat oplevert.
- **exists** $r \Leftrightarrow r \neq \emptyset$
- **not exists** $r \Leftrightarrow r = \emptyset$
- **select** *customer_name*
  from *borrower* **as** *b*
  where not exists
  (**select** *
  from *depositor* **as** *d*
  where *d.customer_name* = *b.customer_name*)

Opgaven

- Stel volgende vragen in SQL:
  1. geef de namen van klanten die een rekening hebben die ze niet gemeenschappelijk hebben met iemand anders
  2. geef de namen van klanten die geen rekening gemeenschappelijk hebben met iemand anders
- Wat betekent de volgende query:
  3. select balance
     from account
     where balance > all
     (select amount
     from loan, borrower, customer
     where loan.loan_number = borrower.loan_number
     and borrower.customer_name = customer.customer_name
     and customer_city = ‘Eindhoven’)

aggregatie-functies in SQL

- je kunt een “berekening” uitvoeren over de waarden van een attribuut uit verschillende tupels
  - **avg** berekent het gemiddelde (van getallen)
  - **sum** berekent de som (van getallen)
  - **min** neemt het minimum (van getallen, of alfabetisch eerste bij strings)
  - **max** neemt het maximum (van getallen, of alfabetisch laatste bij strings)
  - **count** telt het aantal elementen in de tabel of het “groepje”
- de berekening werkt op een lijst, niet een verzameling (dus dubbels blijven behouden)

voorbeeld van aggregatie

- geef de som van de saldi van alle rekeningen bij filialen uit Eindhoven:
  - **select sum**(*balance*)
    from *account* **as** *a*, *branch* **as** *b*
    where *a.branch_name* = *b.branch_name*
    and *b.branch_city* = ‘Eindhoven’
- geef de naam van de klant(en) met de hoogste lening:
  - **select** *customer_name*
    from *borrower* **as** *b*, *loan* **as** *l*
    where *b.loan_number* = *l.loan_number*
    and *l.amount* **in**
    (**select max**(*amount*)
    from *loan*)

aggregatie kan ook in een subquery

- geef de klanten die meer dan 10000 aan saldo hebben op al hun rekeningen samen
  - **select** *d.customer_name*
    from *depositor* **as** *d*
    where 10000 < **some**
    (**select sum**(*a.balance*)
    from *depositor* **as** *dd*, *account* **as** *a*
    where *dd.account_number* = *a.account_number*
    and *dd.customer_name* = *d.customer_name*)

opletten met scoping regels!

- geef de klanten, samen met het totaal van de saldi op hun rekeningen
  - **select** *d.customer_name*, **sum**(*a.balance*)
    from *depositor* **as** *d*
    where *a.account_number* **in**
    (**select** *a.account_number*
    from *depositor* **as** *dd*, *account* **as** *a*
    where *dd.account_number* = *a.account_number*
    and *dd.customer_name* = *d.customer_name*)
- dit is dus fout: *a* wordt gebruikt buiten de scope van de subquery!

groepjes vormen met *group by*

- geef de klanten, samen met het totaal van de saldi op hun rekeningen
  - **select** *d.customer_name*, **sum**(*a.balance*)
    from *depositor* **as** *d*, *account* **as** *a*
    where *d.account_number* = *a.account_number*
    group by *d.customer_name*
  - we zetten (zie **from** en **where**) klanten en *hun* rekeningen eerst naast elkaar
  - we maken dan groepjes van rijen die bij eenzelfde klant horen
  - we tonen dan de klant en de som van de saldi, berekend per groepje

groepjes selecteren met *having*

- geef de klanten, samen met het totaal van de saldi op hun rekeningen, als dat totaal groter is dan 10000.
  - **select** *d.customer_name*, **sum**(*a.balance*)
    from *depositor* **as** *d*, *account* **as** *a*
    where *d.account_number* = *a.account_number*
    group by *d.customer_name*
    having sum(*a.balance*) > 10000
  - **where** werkt op afzonderlijke tupels
  - **having** werkt op groepjes van tupels

opgaven

- Stel de volgende vragen in SQL:
  1. geef de klanten met twee of meer rekeningen (doe dit met en zonder **group by**)
  2. geef klanten met meer leningen dan rekeningen
- Wat betekent volgende query:
  3. **select sum**(*a.balance*)
     from *account* **as** *a*, *depositor* **as** *d*, *customer* **as** *c*
     where *a.account_number* = *d.account_number*
     and *d.customer_name* = *c.customer_name*
     and *c.customer_city* = 'Eindhoven'

opgaven (employee database, opg. 2.1)

16. geef (de namen van) de bedrijven waar geen enkele manager werkt.
17. geef de steden waar geen enkele manager woont.
18. geef (de namen van) de bedienden die meer verdienen dan elke manager.
19. geef (de namen van) de bedienden die meer verdienen dan elke manager die bij het bedrijf van die bediende werkt.
20. geef (de namen van) de bedrijven die alleen maar bedienden uit de vestigingsplaats van het bedrijf hebben.

opgaven (employee database, opg. 2.1)

21. geef (de naam van) de manager met het hoogste salaris.
22. geef (de naam van) de bedrijven waar bedienden werken met een manager met het hoogste salaris.
23. geef (de naam van) de bedrijven waar de managers met het hoogste salaris werken.
24. maak een lijst van bedrijfsnamen met per bedrijf het gemiddelde salaris bij dat bedrijf.
25. maak een lijst van (de namen van) de bedrijven waar het gemiddelde salaris hoger is dan 20.000, en geef per bedrijf dat gemiddelde salaris.

opgaven (employee database, opg. 2.1)

26. maak een lijst van (de namen van) de bedrijven waar het gemiddelde salaris hoger is dan 20.000.
27. maak een lijst van bedrijfsnamen met per bedrijf de totale salarislast van dat bedrijf.
28. maak een lijst van bedrijven met per bedrijf het aantal personeelsleden.
29. geef de stad waar de meeste managers wonen.
30. maak een lijst van steden met per stad het aantal personeelsleden bij bedrijven die in die stad gevestigd zijn.
31. maak een lijst van steden met per stad het aantal personeelsleden (van bedrijven uit de database) dat in die stad woont.