IN2090 – Databaser og datamodellering

08 – Typer og skranker

Leif Harald Karlsen
leifhka@ifi.uio.no

Universitetet i Oslo

Databasers typesystem

- De fleste relasjonelle databaser har et strengt typesystem
- Alle kolonner må ha en tilhørende type, og kun verdier av denne typen kan legges i kolonnen
- I tillegg har man som regel mange funksjoner man kan bruke for å manipulere verdier
- Også disse har en type-signatur som angir lovlig type til variable og typen til returnerte verdier
- I dag: se nærmere på hvilke typer vi har i PostgreSQL, hvlike funksjoner vi kan bruke på dem, og typenes oppførsel

Hvilke datatyper har vi

- PostgreSQL har mange innebygde typer, se:

  `https://www.postgresql.org/docs/current/datatype.html`
- De mest brukte er:
  - Numeriske typer
  - Strengtyper
  - Dato- og tidstyper
  - Boolean
  - Array
- Merk at man også kan lage egne typer (utenfor pensum)
- Man kan også lage egne funksjoner (også utenfor pensum)

SQL-standarden vs. RDBMSer

- Noen typer er en del av SQL-standarden, men mange vanlig brukte typer er ikke
- Også mange funksjoner på SQL-standary-typer som ikke selv er en del av standarden
- Likevel stor likhet mellom ulike RDBMS, ofte kun syntakiske forskjeller

Casting

- Dersom vi skriver `'1'` er dette en utypet literal for databasen
- Databasen forsøker så å *caste* denne verdien til det den brukes som
- Så dersom vi har tabellene `person(id int)` og `notes(note text)` vil

```
INSERT INTO person VALUES ('1');
INSERT INTO notes VALUES ('1');
```

  vil den første bli en `int` mens den andre `text`
- Vi kan også *caste* ekplisitt, og det er flere måter å gjøre det på
  - Med `::` – `'1'::int`
  - Med `cast`-nøkkelordet – `cast('1' AS int)`
  - Eller å sette typen først – `int '1'`
- Merk: Vi skriver alltid inn utypede litteraler til databasen, enten caster den eller så caster vi

Numeriske typer

Vi har følgende numeriske typer[1]:

Name	Storage Size	Description	Range
smallint	2 bytes	small-range integer	-32768 to +32767
integer	4 bytes	typical choice for integer	-2147483648 to +2147483647
bigint	8 bytes	large-range integer	-9223372036854775808 to +9223372036854775807
decimal	variable	user-specified precision, exact	up to 131072 digits before the decimal point; up to 16383 digits after the decimal point
numeric	variable	user-specified precision, exact	up to 131072 digits before the decimal point; up to 16383 digits after the decimal point
real	4 bytes	variable-precision, inexact	6 decimal digits precision
double precision	8 bytes	variable-precision, inexact	15 decimal digits precision
smallserial	2 bytes	small autoincrementing integer	1 to 32767
serial	4 bytes	autoincrementing integer	1 to 2147483647
bigserial	8 bytes	large autoincrementing integer	1 to 9223372036854775807

Større presisjon fører til høyere forbruk av lagringsplass og bergninger/spørringer tar lengre tid.

[1] `https://www.postgresql.org/docs/current/datatype-numeric.html`

Numeriske typer – Funksjoner og operatorer

Har de fleste vanlige matematiske funksjoner og operatorer, se:

`https://www.postgresql.org/docs/11/functions-math.html`

Numeriske typer: eksempel-spørring

Ønsker å pakke bestilte varere i bokser, så vil finne 3. roten av antall bestilte varer for de som er bestilt, samt ca. pris avrundet til nærmeste heltall på det som er bestilt.

```
SELECT product_name,
       ceil(power(units_on_order, 1.0/3)) AS box_size,
       round(unit_price * units_on_order) AS ca_price
FROM products
WHERE units_on_order > 0;
```

Streng-typer

Vi har følgende strengtyper[2]:

Name	Description
`character varying(n)`, `varchar(n)`	variable-length with limit
`character(n)`, `char(n)`	fixed-length, blank padded
`text`	variable unlimited length

- Insetting av strenger som er lengre enn `n` i kolonner med type `varchar(n)` eller `char(n)` gir error
- `text` er ikke en del av SQL-standarden, men nesten alle RDBMS implementerer en slik type
- I PostgreSQL er det ingen fordel å bruke `varchar(n)` eller `char(n)` med hensyn på effektivitet eller minne
- Bruk `varchar(n)` eller `char(n)` kun som skranker (begrense lovlig lengde)

[2] `https://www.postgresql.org/docs/current/datatype-character.html`

Streng-typer – Funksjoner og operatorer

- SQL-standarden har noe rar syntaks for en del streng-manipulering
- For eksempel:
  - `position(sub in str)` finner posisjonen til `sub` i `str`
  - `substring(str from s for e)` finner substrengen i `str` som starter på indeks `s` og slutter på `e`
- Postgres støtter disse, men har mer naturlige varianter, f.eks.:
  - `strpos(str, sub)`, samme som `position`-uttrykket over
  - `substr(str, s, e)`, samme som `substring`-uttrykket over
- Ellers, se følgende for vanlige strengmanipulerings-funksjoner

  `https://www.postgresql.org/docs/11/functions-string.html`

Strengtyper: eksempel-spørring

Lag en pen melding på formen ”Product [name] costs [price] per [quantity]” men hvor ”glasses” er byttet ut med ”jars”.

```
SELECT replace(prod_desc, 'glasses', 'jars') AS prod_desc
FROM (
  SELECT format('Product %s costs %s per %s',
                product_name,
                unit_price,
                quantity_per_unit) AS prod_desc
  FROM products
) AS t;
```


Tidstyper

Vi har følgende tidstyper[3]:

Name	Storage Size	Description	Low Value	High Value	Resolution
`timestamp [ (p) ] [ without time zone ]`	8 bytes	both date and time (no time zone)	4713 BC	294276 AD	1 microsecond
`timestamp [ (p) ] with time zone`	8 bytes	both date and time, with time zone	4713 BC	294276 AD	1 microsecond
`date`	4 bytes	date (no time of day)	4713 BC	5874897 AD	1 day
`time [ (p) ] [ without time zone ]`	8 bytes	time of day (no date)	00:00:00	24:00:00	1 microsecond
`time [ (p) ] with time zone`	12 bytes	time of day (no date), with time zone	00:00:00+1459	24:00:00-1459	1 microsecond
`interval [ fields ] [ (p) ]`	16 bytes	time interval	-178000000 years	178000000 years	1 microsecond

hvor `p` er antall desimaler for sekunder.

[3] `https://www.postgresql.org/docs/current/datatype-datetime.html`

Formater for datoer

Datoer

Example	Description
1999-01-08	ISO 8601; January 8 in any mode (recommended format)
January 8, 1999	unambiguous in any `datestyle` input mode
1/8/1999	January 8 in `MDY` mode; August 1 in `DMY` mode
1/18/1999	January 18 in `MDY` mode; rejected in other modes
01/02/03	January 2, 2003 in `MDY` mode; February 1, 2003 in `DMY` mode; February 3, 2001 in `YMD` mode
1999-Jan-08	January 8 in any mode
Jan-08-1999	January 8 in any mode
08-Jan-1999	January 8 in any mode
99-Jan-08	January 8 in `YMD` mode, else error
08-Jan-99	January 8, except error in `YMD` mode
Jan-08-99	January 8, except error in `YMD` mode
19990108	ISO 8601; January 8, 1999 in any mode
990108	ISO 8601; January 8, 1999 in any mode
1999.008	year and day of year
J2451187	Julian date
January 8, 99 BC	year 99 BC

Formater for tid

Tid

Example	Description
`04:05:06.789`	ISO 8601
`04:05:06`	ISO 8601
`04:05`	ISO 8601
`040506`	ISO 8601
`04:05 AM`	same as 04:05; AM does not affect value
`04:05 PM`	same as 16:05; input hour must be <= 12
`04:05:06.789-8`	ISO 8601
`04:05:06-08:00`	ISO 8601
`04:05-08:00`	ISO 8601
`040506-08`	ISO 8601
`04:05:06 PST`	time zone specified by abbreviation
`2003-04-12 04:05:06 America/New_York`	time zone specified by full name

Tidstyper – Funksjoner og operatorer

- Man kan bruke + og − mellom tidstyper, f.eks.:

```
date '2001-09-28' + interval '1 hour' = timestamp '2001-09-28 01:00:00'
date '2001-09-28' - interval '1 hour' = timestamp '2001-09-27 23:00:00'
date '2001-09-28' + 7                 = date '2001-10-05'
```

- Tilsvarende som for strengtyper har SQL noe rar syntaks for å manipulere tidstyper
- Man bruker `extract(part from value)` for å hente ut `part`-delen av `value`
- For eksempel:

```
extract(hour from timestamp '2001-02-16 20:38:40') = 20
extract(year from timestamp '2001-02-16 20:38:40') = 2001
extract(week from timestamp '2001-02-16 20:38:40') = 7
```

- Man kan også bruke `date_part(part, timestamp)`, f.eks.:

```
date_part('hour', timestamp '2001-02-16 20:38:40') = 20
date_part('year', timestamp '2001-02-16 20:38:40') = 2001
date_part('week', timestamp '2001-02-16 20:38:40') = 7
```


Tidstyper – Andre funksjoner og operatorer

- Man har også funksjoner som gir dagens dato, ol.
- For eksempel vil `now()` gi et `timestamp` med nåværende tidspunkt
- Mens `current_date` er en konstant som inneholder dagens dato
- For å lage en dato kan man også bruke `make_date(year int, date int, day int)`
- For tidstyper kan man også bruke `OVERLAPS` mellom par, f.eks.:

```
SELECT (DATE '2001-02-16', DATE '2001-12-21') OVERLAPS
       (DATE '2001-10-30', DATE '2002-10-30');
Result: true
```

- Ellers, se

  `https://www.postgresql.org/docs/11/functions-datetime.html`

Tidstyper: eksempel-spørring

Finn gjennomsnittlig tid fra bestilling av en ordre til den må være levert, i perioden fra 1997 frem til nå.

```
SELECT avg(required_date::timestamp - order_date::timestamp) AS ship_to_req
  FROM orders
 WHERE (order_date, required_date) OVERLAPS (make_date(1997, 01, 01), now());
```


Array-typen

- Av og til kan det være nyttig å relatere elementer til lister av ting, uten å lage en ny tabell
- For dette kan man bruke arrays
- Typen til arrays er typen til de indre elementene etterfulgt av `[]`, f.eks. `int[]` er en array av heltall
- Arrays i PostgreSQL lages slik: `'{1,2,3}'` og `'{hello, hei, hi}'`
- Merk: Kun fnutter ytterst
- Bruk dobbel-fnutt dersom inder elementer inneholder komma, parenteser, el.
- Eller lages slik: `ARRAY[1,2,3]` eller `ARRAY['hello', 'hei', 'hi']`

Array-typen – Funksjoner og operatorer

- Et element i arrayen kan hentes ut som i andre språk, f.eks. `a[3]` henter ut 3. element fra `a`
- MERK: Indeksene her starter på 1, og ikke 0 som i Python/Java
- Man kan også hente ut deler av en array, f.eks. `a[2:4]` returnerer en ny array bestående av 2., 3., og 4. element fra `a`
- `array_length(a)` returnerer lengden til arrayen `a`
- Man kan konkatenere to arrayer med `||` (akkurat som strenger)
- F.eks. `'{1,2,3}' || '{4,5,6}' = '{1,2,3,4,5,6}'`
- Kan bruke `a && b` for å sjekke overlap mellom arrayene `a` og `b` (om de har et element felles)
- Kan bruke `a @> b` for å sjekke om `a` inneholder alle elementene til `b`
- Ellers, se

  `https://www.postgresql.org/docs/11/functions-array.html`

Andre nyttige typer

PostgreSQL støtter også

- XML
- JSON
- Bitstrenger
- Nettverks-adress-typer
- Geometriske typer
- ...

Extensions

- Utvidelser av databasen kalles *extensions*
- Disse er pakker som kan inneholde nye typer, funksjoner, ol.
- Utvidelser installeres og slettes som alt annet i databasen, altså med `CREATE` og `DROP`

```
CREATE EXTENSION <navn>;

DROP EXTENSION <navn>;
```

- Spørringer gjøres fortsatt med vanlig SQL

Extensions – Eksempler

- PostGIS[4] for romlig data (punkter, linjer, polygoner, geografiske objekter, osv.)

- PipelineDB[5] for strømmer av data

PIPELINEDB

[4] https://postgis.net/
[5] https://www.pipelinedb.com/

Check-skranker

- Hittil har vi sett på følgende varianter av skranker:
  - `UNIQUE`
  - `NOT NULL`
  - `PRIMARY KEY`
  - `REFERENCES`
  - typer
- I dag skal vi se på en annen generell og nyttig skranke, nemlig `CHECK`
- `CHECK` lar oss bruke et generelt uttrykk for å avgjøre om verdier kan settes inn i kolonnen eller ikke
- For eksempel, med

```
CREATE TABLE students (
  sid int PRIMARY KEY,
  name text NOT NULL,
  birthdate date CHECK (birthdate < date '2000-01-01')
);
```

kan man kun legge inn studenter med fødselsdato før år 2000.

- Merk: Man kan fortsatt sette inn `NULL`

Eksempel: Database for et forum – Modell

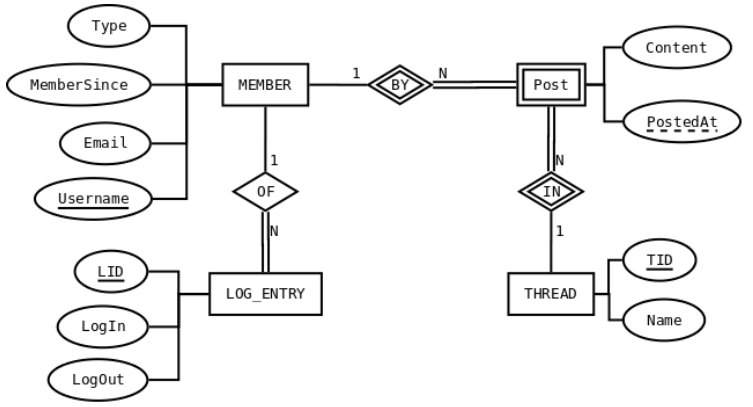

Eksempel: Database for et forum – Realisering (1)

```
CREATE SCHEMA forum;

CREATE TABLE forum.member (
    username text PRIMARY KEY
        CHECK (NOT username LIKE '% %'),
    mail text NOT NULL
        CHECK (mail ~ '^([a-zA-Z0-9_\-\.]+)@([a-zA-Z0-9_\-\.]+)\.([a-zA-Z]{2,5})$'),
    member_since date NOT NULL
        CHECK (member_since <= current_date),
    type text NOT NULL
        CHECK (type = 'normal' OR type = 'admin')
);
```


Eksempel: Database for et forum – Realisering (2)

```
CREATE TABLE forum.threads (
    tid int PRIMARY KEY,
    name text NOT NULL
);

CREATE TABLE forum.posts (
    tid int REFERENCES forum.thread(tid),
    username text REFERENCES forum.member(username),
    posted_at timestamp NOT NULL
        CHECK (posted_at <= now()),
    content text NOT NULL,
    CONSTRAINT post_pk PRIMARY KEY (tid, username, posted_at)
);
```


Eksempel: Database for et forum – Realisering (3)

```
CREATE TABLE forum.log_entry (
    lid int PRIMARY KEY,
    username text REFERENCES forum.member(username),
    log_in timestamp NOT NULL
        CHECK (log_in <= now()),
    log_out timestamp
        CHECK (log_out > log_in)
);
```


Eksempel: Database for et forum – Realisering (4)

```
CREATE VIEW forum.logged_in AS
SELECT m.username, now() - l.log_in AS time_logged_in, m.mail
FROM forum.member AS m
     INNER JOIN forum.log_entry AS l ON (m.username = l.username)
WHERE l.log_out IS NULL;
```

Eksempel: Database for et forum – Realisering (5)

```
CREATE VIEW forum.dash_board AS
SELECT
    (SELECT count(*)
     FROM forum.logged_in) AS active_users,

    (SELECT count(*)
     FROM forum.log_entry
     WHERE (log_in, log_out)
           OVERLAPS
           (current_date::timestamp, (current_date + 1)::timestamp)) AS logins_today,

    (SELECT count(*)
     FROM forum.threads AS t
          INNER JOIN forum.posts AS p
          ON (t.tid = p.tid)) AS total_posts,

    (SELECT count(*)
     FROM forum.threads AS t
          INNER JOIN forum.posts AS p
          ON (t.tid = p.tid)
     WHERE (posted_at, posted_at)
           OVERLAPS
           (current_date::timestamp, (current_date + 1)::timestamp)) AS posts_today;
```