Memóriaadatbázisok

Marton József

marton@db.bme.hu
BME-TMIT

Adatbázisok elmélete VITMMA13
2019. április 2.

Miről lesz szó?

- Memóriaadatbázisokról általában
  - Alapelv, kontraszt a ,,hagyományossal”
  - Előnyök, erősségek
  - Hátrányok (?), nehézségek
- Szervezés
  - Kommunikáció
  - ACID D betűje
  - Fizikai szervezés, lekérdezésvégrehajtás
- Megvalósítások

DBMS: a kezdetek

Az 1960-as évek hardverei

- Egy mag, egyetlen CPU
- Kevés memória
- Diszk-alapú adatbázistárolás
- A diszk lassú

DBMS: a kezdetek

Az 1960-as évek hardverei

- Egy mag, egyetlen CPU
- Kevés memória
- Diszk-alapú adatbázistárolás
- A diszk lassú

Válaszok

- Ütemező algoritmusok
- Buffer-kezelési algoritmusok
- Fizikai szervezés: B*-fa, Heap, vödrös hash
- A diszk lassú

DBMS: overhead

Mérés: OLTP-ben a CPU-idő felhasználása

- buffer pool: 34%
- latch kezelés: 14%
- zárkezelés: 16%
- naplózás: 12%
- keresési kulcsok összehasonlítása: 16%

DBMS: overhead

Mérés: OLTP-ben a CPU-idő felhasználása

- buffer pool: 34%
- latch kezelés: 14%
- zárkezelés: 16%
- naplózás: 12%
- keresési kulcsok összehasonlítása: 16%
- érdemi munka: 7%

In: OLTP THROUGH THE LOOKING GLASS, AND WHAT WE FOUND THERE; SIGMOD, pp. 981-992, 2008.

Adathozzáférés DBMS-ben

- Az ábrán: DRDB
  - piros nyilak: üzenetátadás
  - zöld nyilak: adatáramlás
  - a szaggatott keret átlépése a futási környezetváltás
- kliens-szerver modell
- osztott memória alapú adatelérés

  durva hozzáférés szabályozás

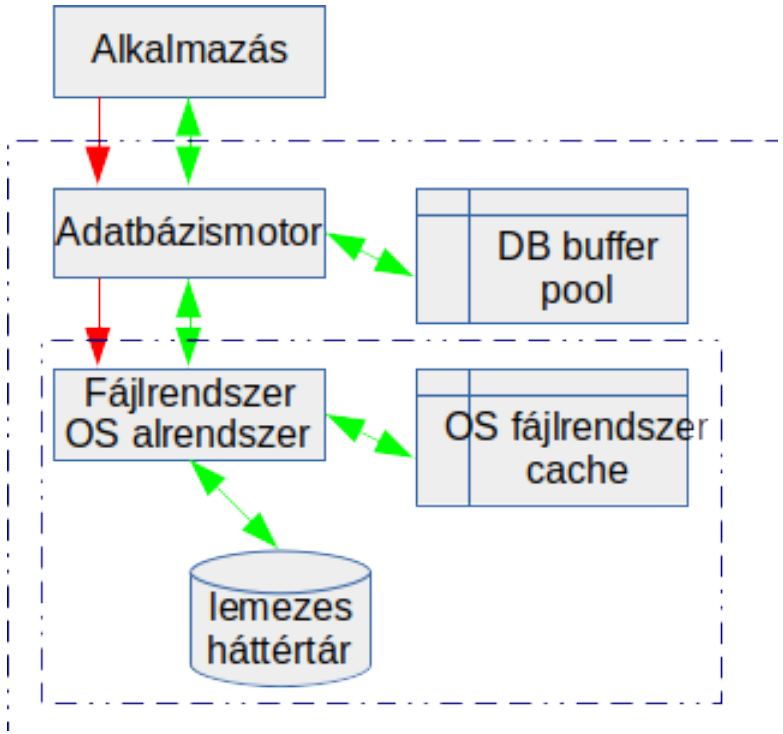

Memóriaadatbázis: alapelv

Memóriaadatbázis-rendszer (IMDB) (In-Memory DataBase)

- az adatok elsődleges példánya a fizikai memóriában
- DRDB: az elsődleges példány diszken van (Disk-Resident DataBase)

  mondjuk inkább úgy: blokkos tárolón (vö. SSD)

Az alapelv létjogosultsága

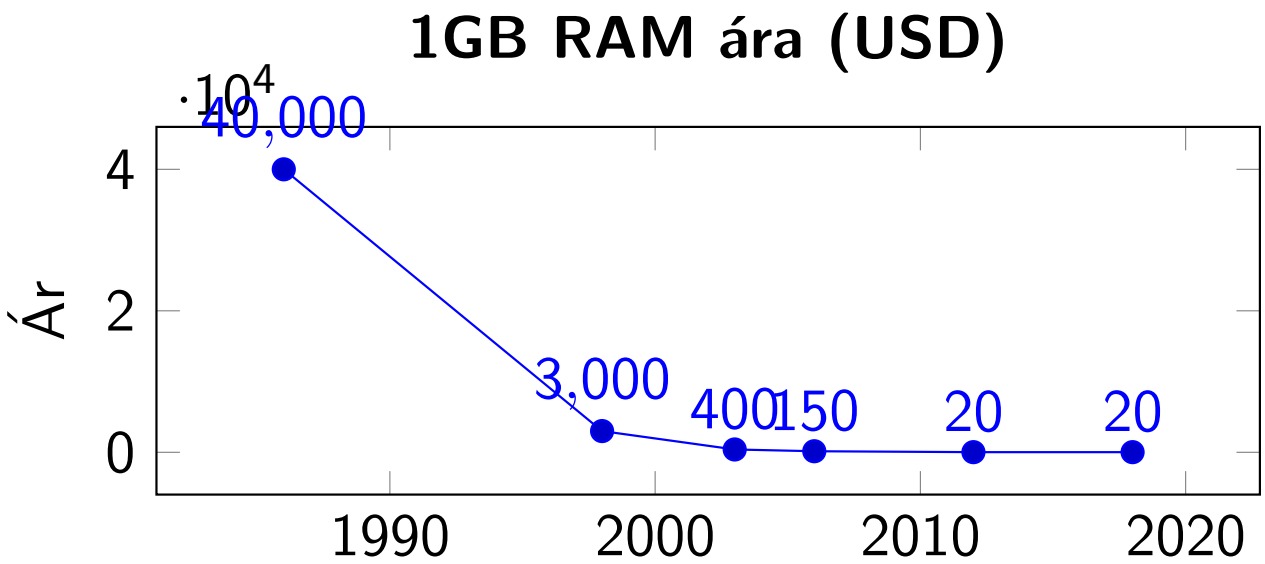

- Sok és olcsó RAM

  OLTP, OLAP rendszerek számára
- Opció: adatbázis particionálása IMDB és DRDB részre
  - automatikusan vagy kézzel konfigurált módon
  - az adatok migrációja a két rendszer között

IMDB használatának előnyei

- gyorsabb adatelérés, tranzakció-feldolgozás

  akár hard real-time alkalmazások
- egyes esetekben egyszerűbb alkalmazás-logika

  diszk-IO alrendszer eliminálása
- saját adatszerkezetek helyett kész komponens

  olcsóbb fejlesztés, olcsóbb termék

IMDB: hátrányok, nehézségek

- bizonyos esetekben bonyolultabb alkalmazás-logika
  - tartósság biztosítása
  - biztonsági mentések szervezése
- a rendszer indulásakor fel kell tölteni az adatbázist
  - mentésből, fejállomásról letöltve vagy on-line adatgyűjtésből
  - segédstruktúrák online felépíthetők
- Megéri-e: előnyök vs. hátrányok: a konkrét feladat határozza meg

IMDB: megvalósítási kihívások

- optimalizált adatszerkezetek
  - a fizikai memória véletlen elérését kihasználják
  - zárkezelés, tranzakciók ütemezése
  - megfelelő granularitású zárak
- tartósság
  - HW támogatás: elemes RAM, hálózaton szinkronizáló RAM-kártyák
  - memrisztor (RRAM: Resistive random-access memory)
  - szinkron vagy aszinkron naplózás
  - nem követelmény

Vajon IMDB-nek minősül?

- egyedi alkalmazás saját adatszerkezetekkel
- hagyományos DBMS úgy, hogy
  - nagy fájlrendszer cache az operációs rendszerben
  - nagy buffer pool
  - adatfájlok RAM-diszken

Tranzakciós tulajdonságok I.

Szemben a DRDB-nél megismertekkel, az IMDB rendszerekben:

- A – atomicitás
  - nincs markáns különbség
  - gyorsabb tranzakciók, magasabb zár-granularitás
- C – konzisztencia
  - nincs markáns különbség
- I – izoláció
  - sorosítható helyett valódi soros ütemezés
  - környezetváltások: a processzor-cache, mint környezet
- D – tartósság

Tranzakciós tulajdonságok II. A tartósság

Az adatbázisba ,,írt" adatok ,,megmaradnak"

- diszk: passzív
- memória: aktív
  - tápfeszültség kimaradásakor törlődik
  - elemmel támogatott RAM
- bithiba – modul meghibásodások
  - ECC (vö: diszkek: RAID)
  - modultöbbszörözés
- naplózás (és persze mentések)

Tranzakciós tulajdonságok III. A naplózás

- ... de hova?
  - diszkre: már megint diszkIO
  - stable memory
    kicsi, nagy megbízhatóságú memória-megoldás
  - memrisztor
    amikor elérhető lesz, de még drága
- ... de mikor?
  - írási műveletkor azonnal
  - tranzakció kommitjakor
  - még később?!
  - ún. durable commit (Oracle TimesTen)

Tranzakciós tulajdonságok III. Durable commit

Table: durable commit hatása a tranzakciófeldolgozási kapacitásra

select/insert/update	70/15/15	40/30/30	20/40/40
tartós kommit	100%	52%	38%
nem tartós kommit	918%	714%	626%

- A mérés a tptBm benchmark eredményeit mutatja
- Mérési környezet: AMD Athlon64 3000+ (1809 MHz) CPU, GiB RAM, 7200 rpm fordulatú Seagate Barracuda UltraATA 100-as diszk, Debian Linux 3.1 amd64 OS, TimesTen 6.0.2-es, 64 bit

Index adatszerkezetek I. Hash és B*-fa

- Hash-alapú segédstruktúrák
  - kiterjeszthető hash
  - többszintes hash
- B*-fa (IMDB-hez lassú?)

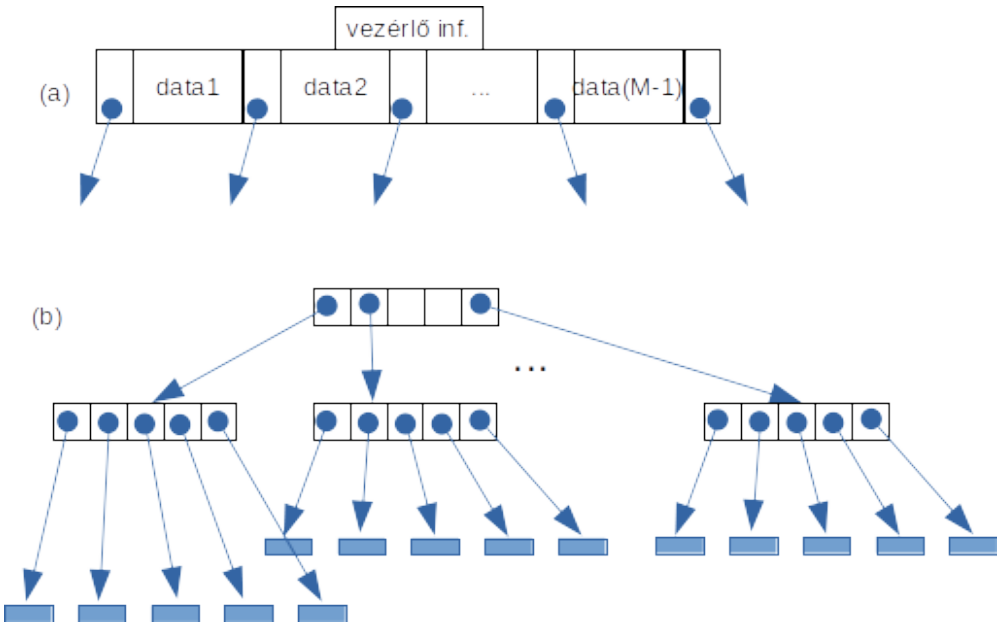

Figure: B*-fa: (a) egy B-fa csomópont, (b) egy B-fa

Index adatszerkezetek II. Az AVL-fa

- AVL-fa
  - bináris keresőfa AVL-tulajdonsággal
  - gyors navigáció
  - gyenge memóriakihasználás
- Az ábrán:

  (a) egy AVL-fa csomópont

  (b) egy AVL-fa

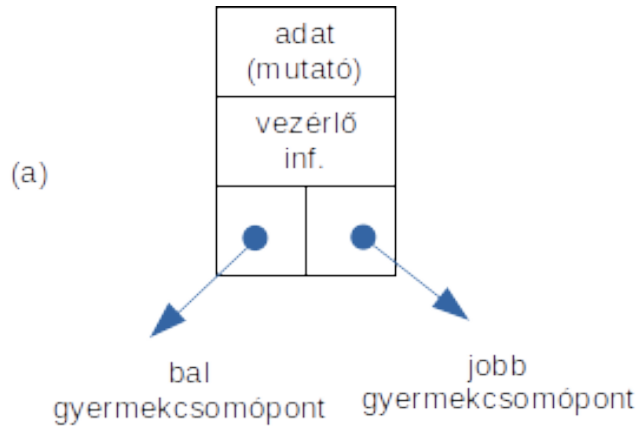

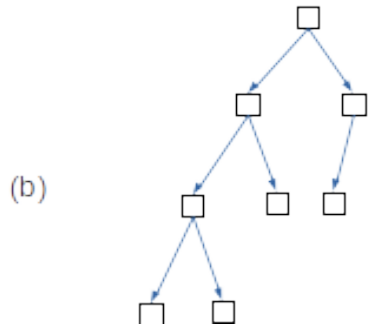

Index adatszerkezetek III. Az T-fa

- B*-fa és AVL-fa előnyei összegyúrva
  - gyors navigáció
  - jó memóriakihasználás
- Az adatok tárolása
  - adat maga
  - mutató
  - m + adat része (pkT-fa)
- Az ábrán:

  (a) egy csomópont

  (b) egy T-fa

  (c) elemek helye a fában

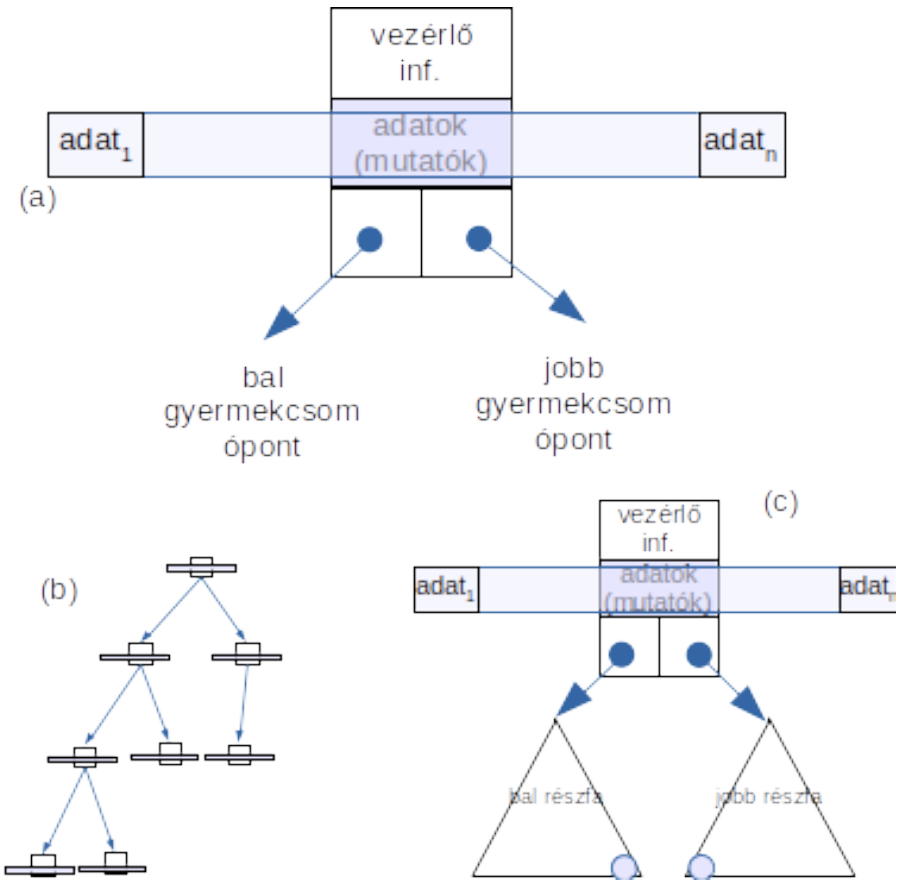

Relációk tárolása

- rekordok vagy mutatók tömbje
- idegen kulcsok követésének (illesztés) támogatása
  - avagy ,,előreszámított (fél)illesztések”
  - DRDB: klaszterezés
  - IMDB: a kulcs értéke helyett mutató

Lekérdezésvégrehajtás

- Vetítés, szelekció

  sokszor olcsóbb az eredményreláció leírójának módosítása és on-the-fly számítás, mint a tényleges számítás
- Illesztések

  I. a mutatók követéséről írottakat
- Költség
  - DRDB: tipikusan az eredmény kiírásának költségét nem számoljuk (miért?), de
  - IMDB: a saját címtér miatt nem mindig merül fel

Architektúra: partícionálás

- ha a teljes adatbázis IMDB-ben nem
  - megoldható v.
  - racionális
- Hibrid megoldás
  - tiszta IMDB
  - in-memory cache
  - DRDB

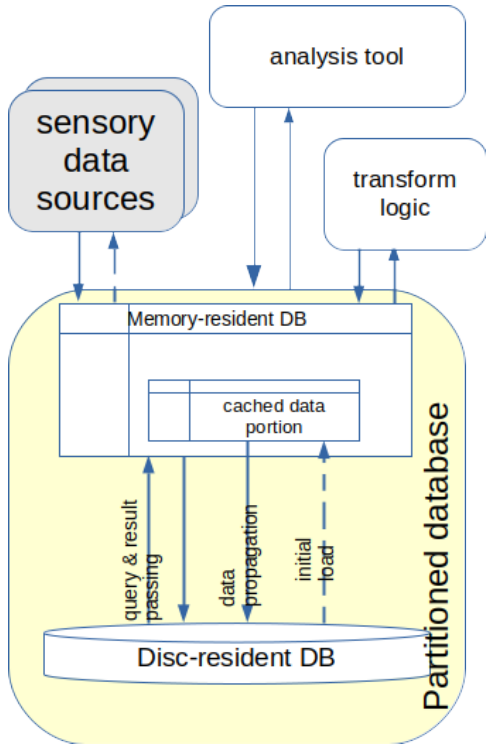

Az ábrán: az elemzőeszközök a partícionált adatbázishoz csatlakoznak, amíg az adatforrások friss adatai közvetlenül az IMDB részbe érkeznek, hogy minél hatékonyabb lehessen az előfeldolgozásuk.

Ha nincs IMDB I.

- RAM-diszk
- HW-tuning
- memóriatuning: buffer-pool kezelési policy
  - Keep
  - recycle
  - standard

Ha nincs IMDB II. Oracle Database In-Memory

- oszloporientált
- tömörítés, kibontás nélküli keresés
- IMCU indexelés, szótár
- SIMD támogatás
- hash-join Bloom filter segítségével

További olvasnivaló: Oracle blog: Getting started w/ Database In-Memory:

- Elméleti jellegűek: Part IV: joinok, Part V: aggregáció
- Üzemeltetés/technológiai jellegűek: Part I: bekapcsolás, Part II: betöltés, Part III: lekérdezések, Part VI: lekérdezésenkénti be/kikapcsolás

Bloom filter illusztráció

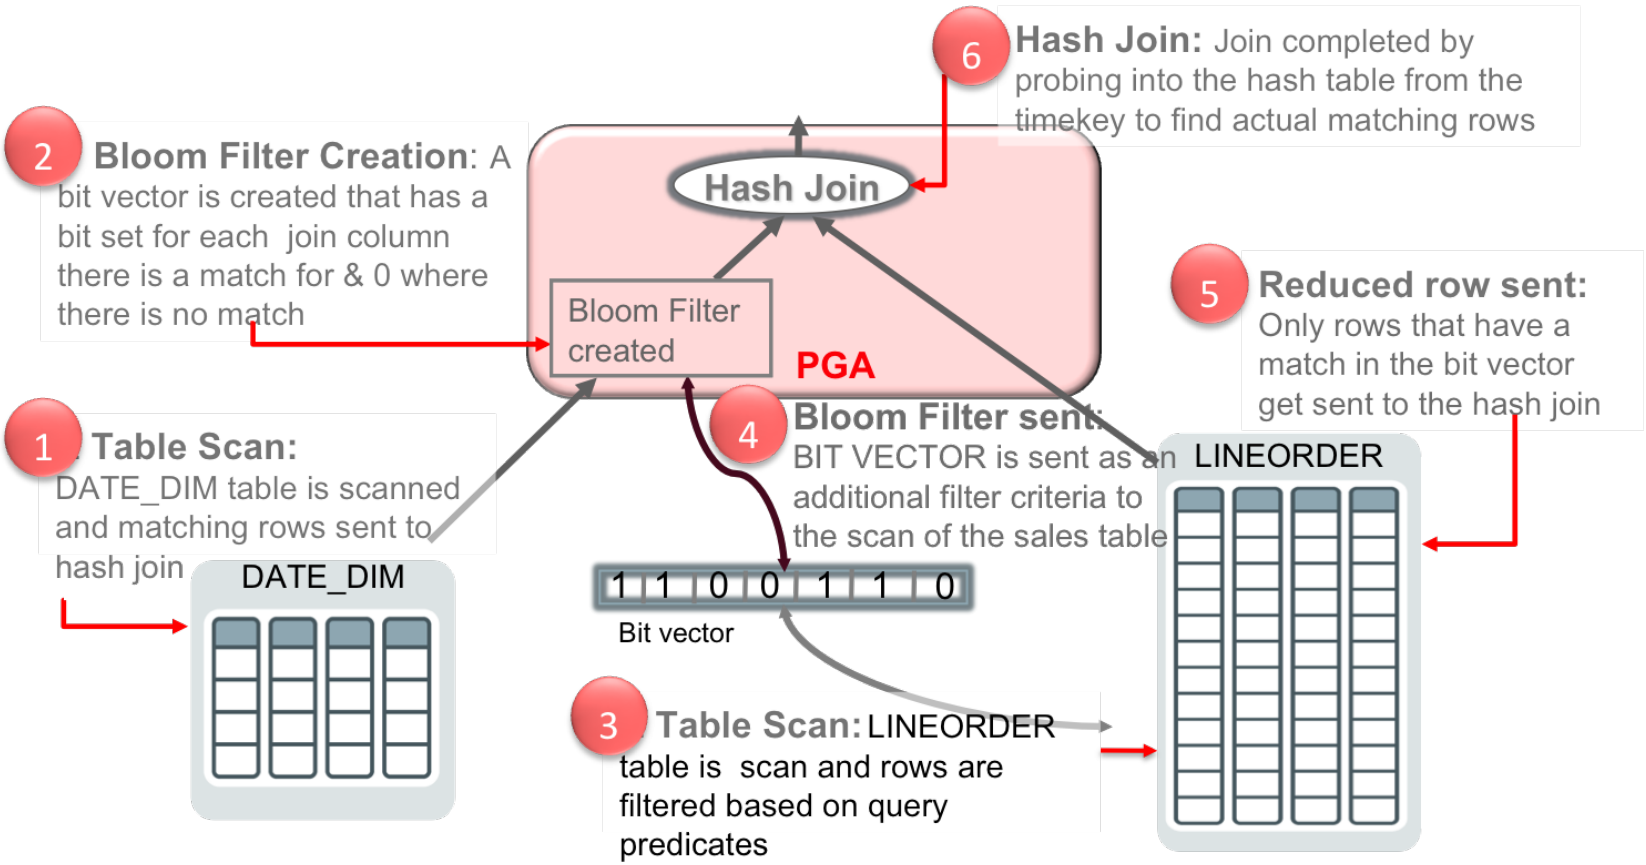

Ábra forrása: Oracle blog: Database In-Memory, Part IV - Joins

Megvalósítások I.

- Peloton
- Oracle TimesTen
- SAP Hana
- MySQL memory engine

Megvalósítások II. Peloton

- önmenedzselő
- MI alapú optimalizáció
- non-volatile memória támogatás
- zármentes MVCC
- latch-mentes Bw-fa indexek
- PostgreSQL protokol-kompatibilitás

További infó: pelotondb.io