

Régi anyag:

[https://docs.google.com/presentation/d/1\\_nmA1F4ag\\_O-qlJAE4TfVuyfLgSruZLW/edit?usp=sharing&oui d=110539736176923279178&rtpof=true&sd=true](https://docs.google.com/presentation/d/1_nmA1F4ag_O-qlJAE4TfVuyfLgSruZLW/edit?usp=sharing&oui d=110539736176923279178&rtpof=true&sd=true)

# □ Adatbázisok története és fejlődése

Relációs adatbázisoktól a NoSQL-en át a vektor adatbázisokig

## 1. Bevezetés

Az adatbázisok az informatikai rendszerek alapvető elemei, amelyek lehetővé teszik az adatok hatékony tárolását, visszakeresését, rendezését és módosítását. A modern világban hatalmas mennyiségű adat keletkezik másodpercenként, és ezek strukturált tárolása elengedhetetlen a döntéstámogatáshoz, automatizáláshoz és gépi tanuláshoz.

### Miért van szükség adatbázisokra?

- Az adatok szervezett tárolása lehetővé teszi azok gyors visszakeresését és elemzését.
- Több felhasználó egyidejűleg dolgozhat ugyanazon adatokkal (konkurens hozzáférés).
- Biztosítani lehet az **adatintegritást** és a **hozzáférés-ellenőrzést**.
- Az adatok rendszeres **mentése és visszaállítása** egyszerűbbé válik.
- Automatizált folyamatokhoz (pl. webalkalmazások, gépi tanulás) szükséges egy megbízható háttértároló.

Példa: Egy webshopban több ezer termék, rendelés és felhasználói adat van. Ezek kereshető tárolása adatbázis nélkül gyakorlatilag lehetetlen lenne.

### Adat vs. információ

- **Adat:** nyers tények, mért vagy rögzített értékek, amelyek még nem feltétlenül bírnak jelentéssel.
  - Példa: `42`, `2025-05-07`, `„Piros”`
- **Információ:** értelmezett adat, amely kontextusba helyezve új tudást jelent.
  - Példa: „42 éves a felhasználó”, vagy „A rendelés dátuma: 2025-05-07”

Az adat tehát az alap, amiből – megfelelő feldolgozással – információt nyerhetünk. Az adatbázis célja az adatok strukturált tárolása annak érdekében, hogy információvá alakíthassuk őket.

### Strukturált, félstrukturált és strukturálatlan adatok

- **Strukturált adat:**
  - Táblázatos formában rendezett, előre meghatározott sémával rendelkezik.
  - Példa: SQL adatbázisok, Excel-táblák, CRM rendszerek.
  - Jellemző: gyors kereshetőség, jól lekérdezhető.

- **Félstrukturált adat:**

- Nincs fix sémája, de tartalmaz címkéket vagy metaadatokat.
- Példa: XML, JSON, YAML fájlok, logok.
- Rugalmasabb, de nehezebb indexelni és lekérdezni.

- **Strukturálatlan adat:**

- Nincs formázása, nem egyértelmű a tartalma.
- Példa: szövegfájlok, képek, videók, e-mailek, hangfelvételek.
- Ezeket általában keresőmotorokkal vagy mesterséges intelligenciával lehet feldolgozni (pl. szöveg- vagy képelemzés).

Az adatbázisok fejlődése szorosan összefügg azzal, hogyan és milyen típusú adatokat akarunk hatékonyan kezelni.

## 2. Relációs adatbázisok (RDBMS)

A relációs adatbázisok az egyik legelterjedtebb adatbázis-típusok közé tartoznak. Az adatok táblákban (relációkban) tárolódnak, ahol minden tábla sorokból (rekordokból) és oszlopokból (mezőkből) áll. A relációs modell megbízható és jól definiált struktúrát biztosít az adatok kezeléséhez.

### Történet

- A relációs modellt **Edgar F. Codd** matematikus javasolta 1970-ben.
- A modell a halmazelméletre és a predikátumlogikára épül.
- A '70-es, '80-as években megjelentek az első RDBMS rendszerek: IBM System R, Ingres, Oracle.
- A **SQL (Structured Query Language)** nyelv szabványosítása nagyban hozzájárult az elterjedéséhez.

### Jellemzők

- **Adatszerkezet:** táblázatos (sorok és oszlopok).
- **Szigorú séma:** minden táblának előre meghatározott szerkezete van (mezőtípusok, kulcsok stb.).
- **Kapcsolatok:** táblák között idegen kulcsokon keresztül hozunk létre kapcsolatokat.
- **ACID tulajdonságok:**
  - **\*Atomicity\*** – a tranzakciók oszthatatlanok.
  - **\*Consistency\*** – az adatbázis érvényességi szabályai nem sérülnek.
  - **\*Isolation\*** – párhuzamos tranzakciók nem befolyásolják egymást.
  - **\*Durability\*** – a végrehajtott tranzakciók tartósan megmaradnak.

### Előnyök

- **Adatintegritás:** kulcsok, megszorítások és szabályok segítségével biztosítható.
- **Lekérdezhetőség:** a SQL nyelv rendkívül erős és kifejező eszköztárat ad.
- **Stabilitás és érettség:** hosszú távon kipróbált, optimalizált rendszerek.
- **Többfelhasználós működés:** jogosultságkezelés, tranzakciókezelés.

## Hátrányok

- **Skálázhatóság:** nagy adatmennyiség és sok párhuzamos felhasználó esetén nehezen osztható szét több gépre (horizontális skálázás).
- **Rugalmatlanság:** séma módosítása bonyolult lehet, különösen ha az adatstruktúra gyakran változik.
- **Strukturálatlan adatok kezelése:** szöveg, kép, videó típusú adatok kezelésére nem ideális.

## Népszerű relációs adatbázis-kezelő rendszerek (RDBMS-ek)

- **MySQL** – nyílt forráskódú, népszerű webalkalmazások körében (pl. WordPress).
- **PostgreSQL** – fejlett funkciók, szabványos SQL támogatás, objektum-orientált kiegészítések.
- **Oracle Database** – robusztus vállalati megoldás, fejlett biztonság és replikációs lehetőségek.
- **Microsoft SQL Server** – integráció Microsoft-technológiákkal, könnyű használat.

## Példa: Egyszerű SQL tábla és lekérdezés

Tábla: `diakok`

| id | nev         | szuletesi_ev |
|----|-------------|--------------|
| 1  | Kovács Anna | 2003         |
| 2  | Nagy Péter  | 2002         |

SQL lekérdezés:

```
SELECT nev FROM diakok WHERE szuletesi_ev < 2003;
```

Ez a lekérdezés visszaadja azoknak a diákoknak a nevét, akik 2003 előtt születtek.

## 3. NoSQL adatbázisok

A NoSQL adatbázisok a relációs modellek alternatívájaként jelentek meg, amikor az internetes alkalmazások, a Big Data és a valós idejű feldolgozások új követelményeket támasztottak az adatkezeléssel szemben. A „NoSQL” nem feltétlenül jelenti azt, hogy nem használható benne SQL, hanem inkább azt, hogy nem relációs modell alapján működik.

### Miért jelentek meg?

- Az adatok mennyisége gyorsan növekedett (pl. közösségi média, szenzoradatok).
- Az adatszerkezet egyre rugalmasabb lett – gyakran változó mezők, új attribútumok.
- Szükség volt **horizontális skálázásra** – sok szerver párhuzamos futtatása.
- Alkalmazásoknak nagy sebességre és alacsony késleltetésre volt szüksége.

## Jellemzők

- **Sémanélküli modell:** nincs előre rögzített mezőszerkezet.
- **BASE modell:**
  - \*Basically Available\* – mindig elérhető adatbázis
  - \*Soft state\* – az adat idővel változhat
  - \*Eventually consistent\* – idővel elérhető a konzisztencia (nem garantált azonnal)
- **Horizontálisan skálázható:** könnyen bővíthető több gépre.
- **Nagy teljesítmény:** ideális valós idejű alkalmazásokhoz.

## NoSQL típusok és példák

- **Dokumentum-orientált adatbázisok**
  - Minden rekord egy önálló dokumentum (pl. JSON formátumban).
  - Rugalmas szerkezet, ideális REST API-khoz.
  - Példa: **MongoDB**, CouchDB
- **Kulcs-érték tárolók**
  - Egyszerű szerkezet: kulcs → érték (mint egy szótár).
  - Nagyon gyors, kiváló gyorsítótárazásra.
  - Példa: **Redis**, Amazon DynamoDB
- **Oszlop-orientált adatbázisok**
  - Az adatok nem sorokban, hanem oszlopokban tárolódnak.
  - Hatékony analitikai feldolgozás nagy adattáblákon.
  - Példa: **Apache Cassandra**, HBase
- **Gráf adatbázisok**
  - Adatok és azok kapcsolatai gráfként ábrázolva (csomópontok és élek).
  - Nagyon hasznos hálózati elemzésekhez, pl. közösségi hálók, útvonalkeresés.
  - Példa: **Neo4j**, ArangoDB

## Előnyök

- Nagy teljesítmény, alacsony válaszidő.
- Könnyen skálázható horizontálisan.
- Rugalmas adatszerkezet – ideális gyorsan változó alkalmazásokhoz.
- Néhány esetben beépített replikáció, sharding, elosztott feldolgozás.

## Hátrányok

- Nincs szabványos nyelv (mint az SQL).
- Az adatintegritás és konzisztencia nem mindig garantált.
- Alkalmazásfejlesztéskor a logika egy része az adatbázis helyett a kódban jelenik meg.
- Komplex lekérdezések megvalósítása nehézkes lehet.

## Példa: MongoDB dokumentum

Egy MongoDB kollekcióban tárolt dokumentum példája:

```
{
  "_id": "u123",
  "nev": "Kiss János",
  "eletkor": 29,
  "cim": {
    "varos": "Budapest",
    "iranyitoszam": "1111"
  }
}
```

Egy lekérdezés: azokat a felhasználókat kérdezzük le, akik életkora nagyobb mint 25:

```
db.felhasznalok.find({ "eletkor": { "$gt": 25 } })
```

## 4. NewSQL adatbázisok

A NewSQL adatbázisok a relációs adatbázisok továbbfejlesztett változatai, amelyek célja, hogy megtartsák a klasszikus RDBMS rendszerek előnyeit (pl. SQL, ACID), ugyanakkor képesek legyenek a modern alkalmazások által megkövetelt **horizontális skálázásra** és **magas teljesítményre**, mint a NoSQL rendszerek.

### Miért jöttek létre?

- A vállalatok továbbra is igénylik a **strukturált, relációs adatsémát** és az **ACID** garanciákat.
- Ugyanakkor szükség van a **modern skálázhatóságra**, amit a NoSQL rendszerek nyújtanak.
- A cél: „**legyen meg a torta és együk is meg**” – relációs modell + felhőbarát architektúra.

### Jellemzők

- **Relációs modell:** táblák, kulcsok, SQL nyelv
- **ACID tranzakciók:** konzisztencia és megbízhatóság
- **Elosztott architektúra:** több szerveren futó adatbázis
- **Skálázhatóság:** automatikus sharding, load balancing
- **Magas rendelkezésre állás:** beépített replikáció, hibatűrés

### Előnyök

- Kombinálja a relációs adatbázisok előnyeit a NoSQL skálázhatóságával
- Alkalmas nagy forgalmú, üzletkritikus alkalmazásokhoz
- Használható ismerős SQL nyelvvel, nem igényel új tanulási görbét

## Hátrányok

- Bonyolultabb architektúra és üzemeltetés, mint egy egyszerű SQL adatbázisnál
- Még viszonylag fiatal technológia – kisebb ökoszisztéma, kevesebb szakember
- Néhány megoldás zárt forráskódú, kereskedelmi licenc alatt áll

## Példák

- **Google Spanner**
  - A Google saját globálisan elosztott relációs adatbázisa.
  - Világszintű szinkronizációval garantálja a konzisztenciát.
- **CockroachDB**
  - Nyílt forráskódú, elosztott relációs adatbázis.
  - Automatikus skálázás és replikáció.
  - PostgreSQL-kompatibilis SQL interfész.
- **VoltDB**
  - Főként valós idejű analitikára és tranzakciókra specializált.
  - Nagy sebesség, memóriabeli működés.

## Példa: CockroachDB SQL lekérdezés

```
CREATE TABLE felhasznalok (  
  id UUID PRIMARY KEY DEFAULT gen_random_uuid(),  
  nev TEXT NOT NULL,  
  regisztraltl TIMESTAMP DEFAULT now()  
);  
  
SELECT * FROM felhasznalok WHERE nev LIKE 'K%';
```

A fenti példa egy CockroachDB tábla létrehozását és egyszerű lekérdezését mutatja be, PostgreSQL-kompatibilis SQL nyelven.

## 5. Vektor adatbázisok

A vektor adatbázisok új generációs adatbázis-rendszerek, amelyek a mesterséges intelligencia és a gépi tanulás elterjedésével váltak népszerűvé. Céljuk nem strukturált adatok – például szövegek, képek, hangok – jelentés szerinti keresése, amelyet az ún. \*embedding\* (beágyazott vektorreprezentáció) segítségével valósítanak meg.

### Miért van rájuk szükség?

- A hagyományos adatbázisok nem alkalmasak jelentésalapú keresésre.
- Az LLM-ek, képfeldolgozók, hangfelismerők vektorokat állítanak elő, amelyek geometriailag

összehasonlíthatók.

- Példa: „melyik másik dokumentum tartalmilag hasonlít ehhez a kérdéshez?”

## Hogyan működik?

- Az objektumokat (pl. szöveg, kép) **embedding**-gé alakítjuk egy neurális háló segítségével.
- Az így kapott vektorokat egy vektoradatbázis tárolja.
- Keresés során szintén vektort képezünk, majd megkeressük a **legközelebbi** (használatos: k-NN – \*k Nearest Neighbors\*) vektorokat.
- A hasonlóságot általában **koszinusz-hasonlóság**, **euklideszi távolság** vagy más metrika alapján számítják.

## Jellemzők

- Nincs klasszikus SQL – speciális API vagy Python/REST kliensek használatosak.
- Beépített **indexelési módszerek** a gyors kereséshez (pl. HNSW, IVF, PQ).
- Gyors és hatékony **nagy dimenziójú adatok** keresése.

## Előnyök

- Jelentésalapú keresés – szöveg vagy kép jelentésének megértése
- Ideális LLM-alapú rendszerekhez, mint pl. kérdés-válasz vagy dokumentumkeresés
- Kiváló teljesítmény nagy adathalmazokon is

## Hátrányok

- Nem hagyományos adatmodell – nem tárol klasszikus táblákat, kapcsolatokkal
- A „miért kaptuk ezt a találatot?” kérdésre nehezebb választ adni (black-box jelleg)
- A pontosság függ az embedding minőségétől és a választott metrikától

## Népszerű vektor adatbázisok

- **FAISS** (Facebook AI Similarity Search) – nagy teljesítményű, Python-könyvtárként is elérhető
- **Milvus** – nyílt forráskódú, skálázható, GPU-t is támogató vektor DB
- **Weaviate** – REST API + GraphQL támogatás, integrált gépi tanulási pipeline
- **Pinecone** – felhőalapú, egyszerűen használható szolgáltatás
- **Chroma** – egyszerű integráció LangChain/RAG rendszerekhez

## Példa: vektoros keresés szövegek között

1. Szöveg → embedding: `“Milyen magas a Mount Everest?”` → `[0.12, -0.45, ..., 0.33]` 2. A vektoradatbázisban tárolt több ezer dokumentum embeddingje közül kiválasztjuk a legközelebbit:

```
query_vector = model.encode("Milyen magas a Mount Everest?")
results = vector_db.search(query_vector, top_k=5)
```

3. Eredmény: olyan dokumentumokat kapunk, amelyek tartalmilag legközelebb állnak a kérdéshez – még akkor is, ha szó szerint nem egyeznek meg.

## 6. Tendenciák és jövőkép

- Multimodális adatbázisok (szöveg + kép + struktúrált adatok)
- Hybrid keresés: SQL + vektoros keresés együtt
- AI-native rendszerek: LLM + adatbázis integráció (pl. LangChain)

## 7. Összefoglaló táblázat

| Típus            | Terméknevek                               | Előnyök                                                  | Hátrányok                                             |
|------------------|-------------------------------------------|----------------------------------------------------------|-------------------------------------------------------|
| Relációs (RDBMS) | MySQL, PostgreSQL, Oracle                 | Stabil, jól definiált séma, SQL támogatás, ACID garancia | Nehezen skálázható, rugalmatlan struktúra             |
| NoSQL            | MongoDB, Redis, Cassandra, Neo4j          | Rugalmas séma, jól skálázható, gyors lekérdezések        | Gyenge konzisztencia, nincs egységes lekérdezőnyelv   |
| NewSQL           | CockroachDB, Google Spanner, VoltDB       | ACID + skálázhatóság, SQL-kompatibilitás                 | Bonyolultabb architektúra, kisebb ökoszisztéma        |
| Vektor           | FAISS, Milvus, Weaviate, Pinecone, Chroma | Jelentésalapú keresés, AI integráció, gyors k-NN keresés | Nem klasszikus lekérdezések, nehezebb magyarázhatóság |

## 8. Példa

Az alábbi példák bemutatják, hogyan tér el az adatok kezelése a különböző adatbázistípusokban. A példák egyszerűek, mégis jól szemléltetik az eltérő adatmodelleket és lekérdezési módokat.

### 1. Relációs adatbázis: SQL példa (PostgreSQL)

Tábla létrehozása:

```
CREATE TABLE diakok (  
  id SERIAL PRIMARY KEY,  
  nev TEXT NOT NULL,  
  szulesesi_ev INTEGER  
);
```

Adatok beszúrása:

```
INSERT INTO diakok (nev, szulesesi_ev)  
VALUES ('Kiss Anna', 2002), ('Nagy Péter', 2001);
```

Lekérdezés: ki született 2001 előtt?

```
SELECT nev FROM diakok WHERE szulesesi_ev < 2001;
```



## 2. NoSQL példa: MongoDB dokumentum és lekérdezés

Dokumentum beillesztése:

```
db.diakok.insertOne({
  nev: "Kiss Anna",
  szuletesi_ev: 2002
});
```

Lekérdezés: azok a diákok, akik 2001 előtt születtek:

```
db.diakok.find({ szuletesi_ev: { $lt: 2001 } });
```

## 3. Vektor adatbázis példa: FAISS keresés (Python)

Tegyük fel, hogy szövegeket átalakítunk vektorokká egy nyelvi modell (pl. `sentence-transformers`) segítségével, majd ezekben keresünk.

Embedding előállítás (példa):

```
from sentence_transformers import SentenceTransformer
import faiss
import numpy as np

model = SentenceTransformer('all-MiniLM-L6-v2')
dokumentumok = ["A kutya ugat.", "A macska nyávog.", "Az autó gyors."]

vektorok = model.encode(dokumentumok)
index = faiss.IndexFlatL2(vektorok.shape[1])
index.add(np.array(vektorok))
```

Keresés hasonló szöveg alapján:

```
kerdes = "Melyik állat nyávog?"
kerdes_vektor = model.encode([kerdes])
_, eredmények = index.search(np.array(kerdes_vektor), k=1)

print("Legjobban illeszkedő dokumentum:", dokumentumok[eredmények[0][0]])
```

Eredmény:

From:  
<https://edu.iit.uni-miskolc.hu/> - Institute of Information Science - University of Miskolc

Permanent link:  
[https://edu.iit.uni-miskolc.hu/tanszek:oktatas:muszaki\\_informatika:adattarolas\\_adatbazisok?rev=1746601049](https://edu.iit.uni-miskolc.hu/tanszek:oktatas:muszaki_informatika:adattarolas_adatbazisok?rev=1746601049)

Last update: 2025/05/07 06:57

