Análisis de enfoques:

¿cómo comparar peras con manzanas?

Bases de Datos No Relacionales

Instituto de Computación, FING, UdelaR

Preliminares

Una Base de Datos (BD) es una colección organizada de datos.

Los Sistemas de Gestión de Bases de Datos (DBMS) son programas que permiten el almacenamiento, modificación y extracción de datos de la BD.

Podemos clasificar y caracterizar a los DBMS según varios aspectos.

Algunos aspectos para clasificar sistemas de gestión de datos

- Modelos de datos
- Lenguajes de consulta e interfases
- Modelos de consistencia y soporte a transacciones
- Arquitectura de datos y de cómputo
- Modelos de despliegue y estrategia comercial

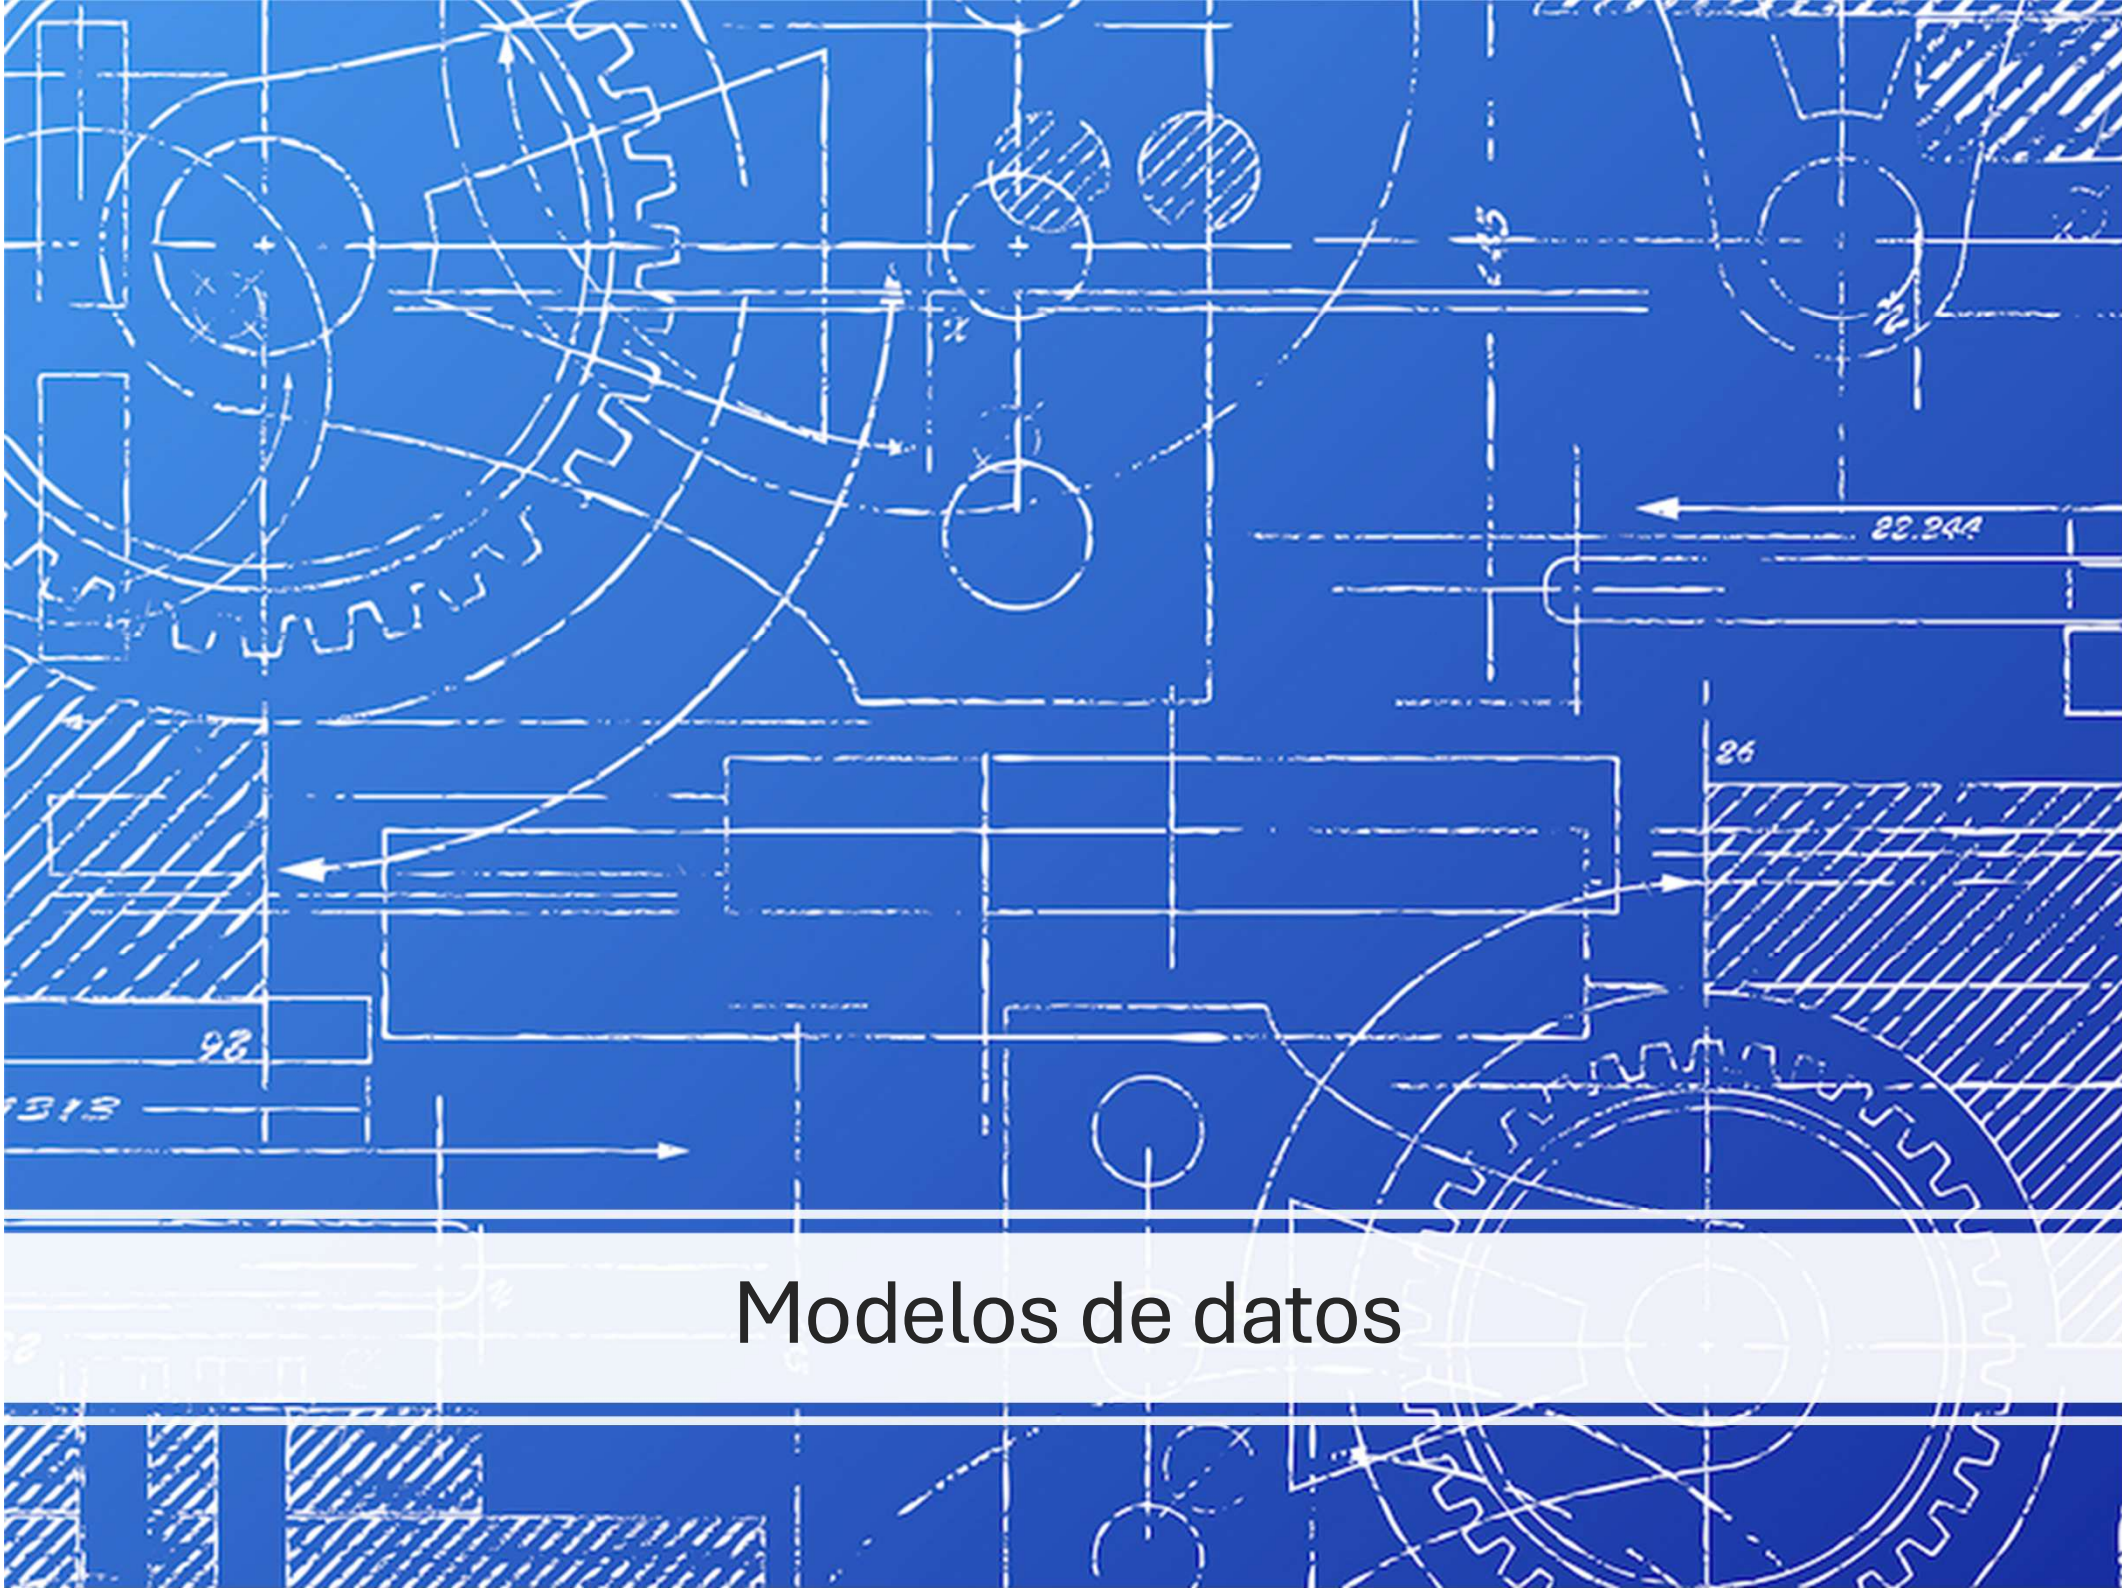

Modelos de datos

Modelos de datos

Son **lenguajes** usados para especificar y manipular BDs y permiten expresar:

- **Estructuras:** Elementos de los problemas.
- **Restricciones:** Reglas que deben cumplir los datos para que la BD sea considerada válida.
- **Operaciones:** Insertar, borrar y consultar la BD.

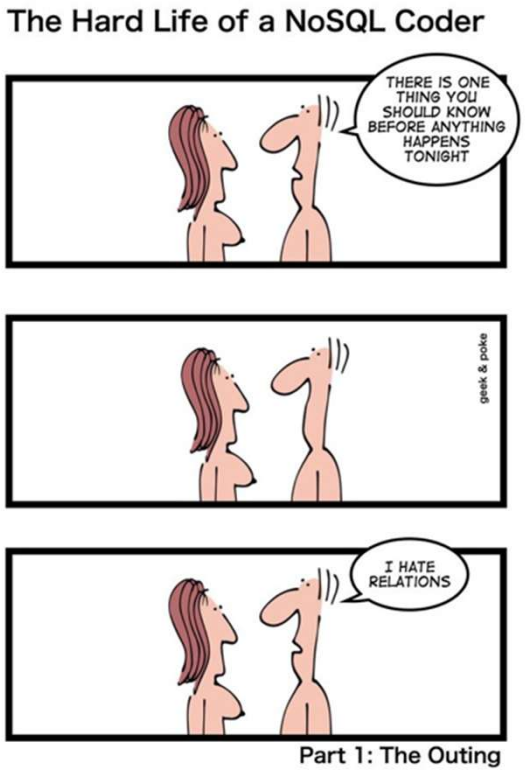

http://geek-and-poke.com/geekandpoke/2011/12/7/the-hard-life-of-a-nosql-coder.html

Modelos de datos (2)

Los modelos de datos pueden tener diferentes niveles de abstracción.

- Modelos conceptuales: Representan la realidad **independientemente** de la implementación de la BD
- Modelos lógicos: abstracción que implementa el DBMS
- Modelos físicos: estructuras de datos que implementa y usa el DBMS para almacenar los datos

Ejemplos en el caso relacional

Modelo conceptual: modelo Entidad-Relación

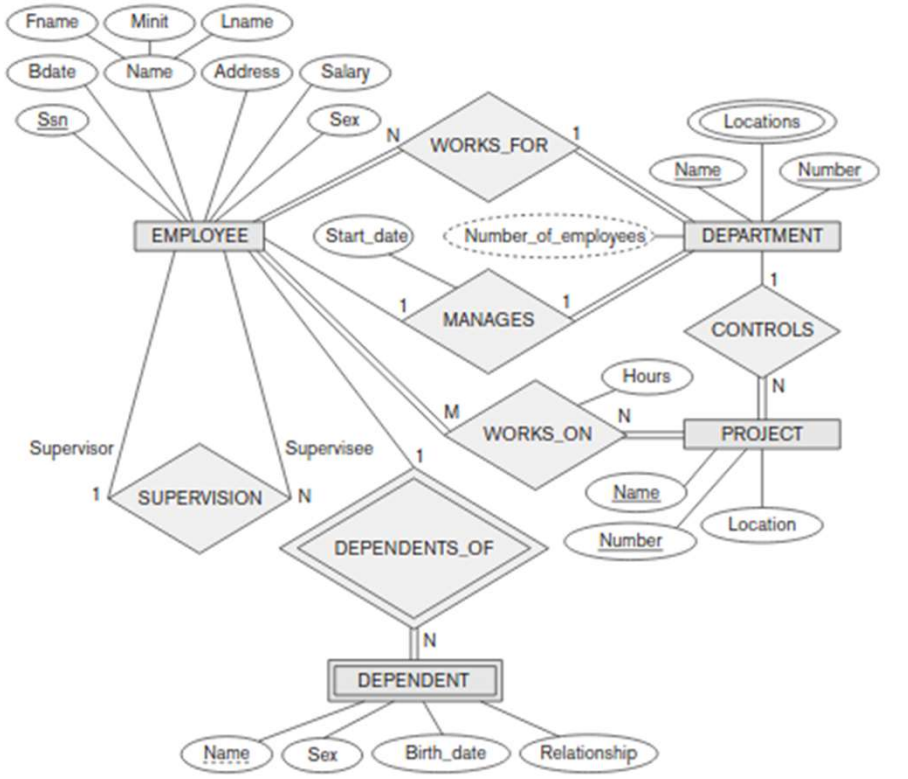

Figure 3.2
An ER schema diagram for the COMPANY database. The diagrammatic notation is introduced gradually throughout this chapter and is summarized in Figure 3.14.

Ejemplos en el caso relacional

Modelo lógico: modelo relacional (tablas, restricciones, etc)

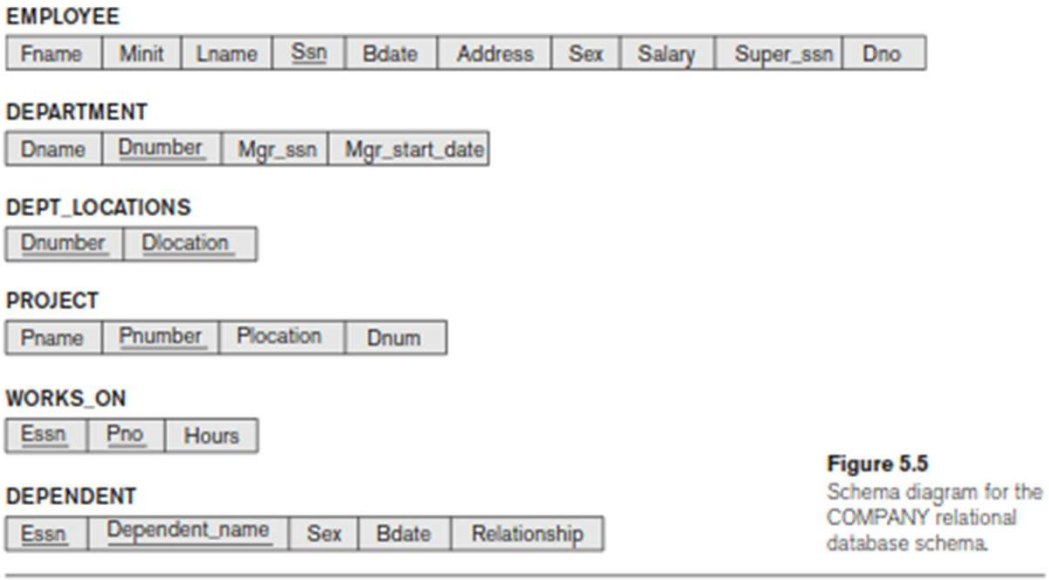

Figure 5.5
Schema diagram for the COMPANY relational database schema.

Ejemplos en el caso relacional

Modelo físico: registros, árboles B, tablas de hash

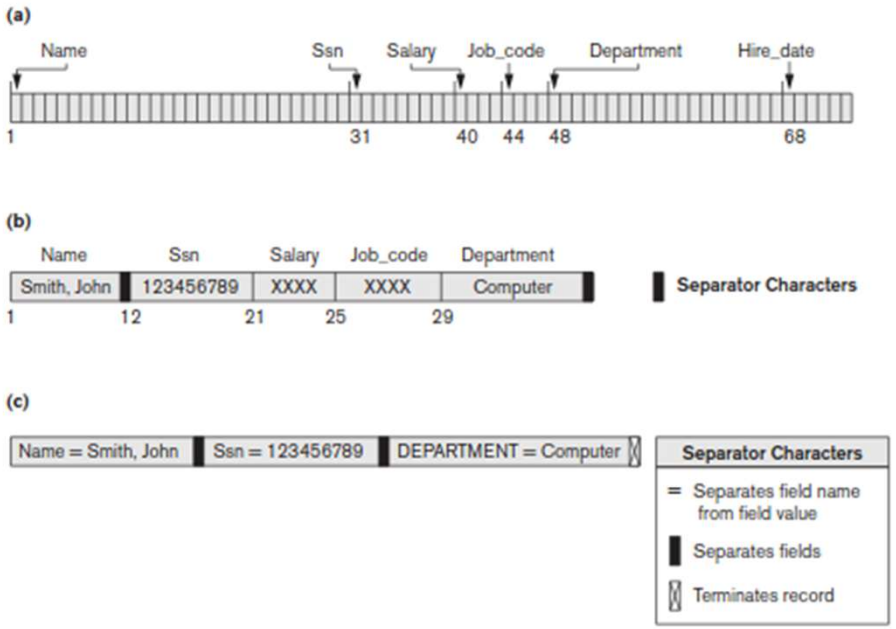

Figure 16.5
Three record storage formats. (a) A fixed-length record with six fields and size of 71 bytes. (b) A record with two variable-length fields and three fixed-length fields. (c) A variable-field record with three types of separator characters.

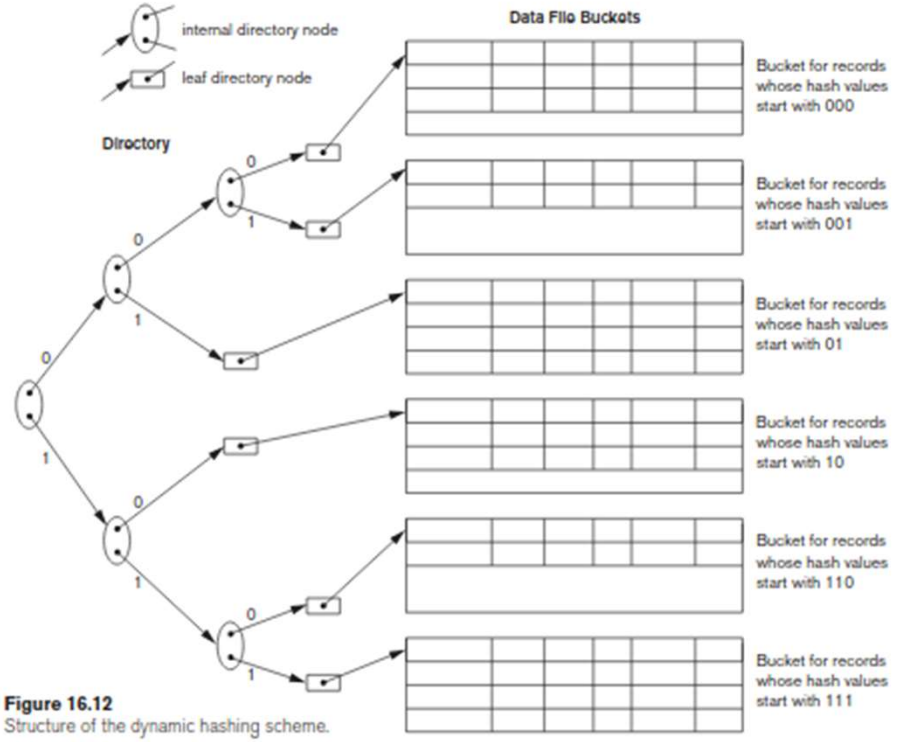

Figure 16.12
Structure of the dynamic hashing scheme.

¿y que pasa fuera del modelo relacional?

- Poco foco en el modelado conceptual 😳
- Muchos modelos lógicos, pero no siempre formalmente especificados: (ej el modelo **documental,** el modelo de **property graphs** para bases de datos de grafos)
- Gran diversidad en las implementaciones (modelos físicos)

SQL

Relational

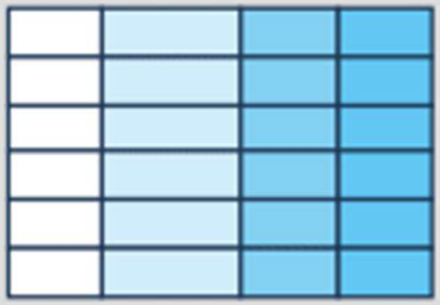

Analytical (OLAP)

NoSQL

Key-Value

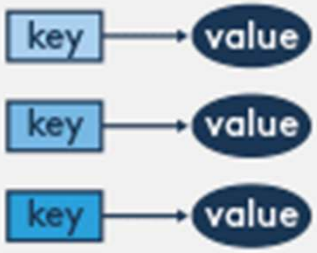

Column-Family

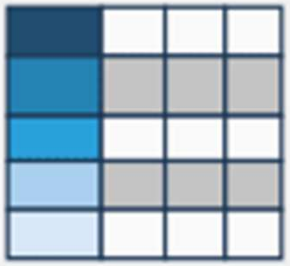

Graph

Document

Lenguajes de consulta e interfases

Pieter Brueghel the Elder (1526/1530–1569) Tower of Babel – 1563

En los RDBMS

- SQL es un estándar desde 1982
- Cada fabricante de RDBMS implementa variantes, pero las diferencias son sutiles.
- Casi todos los lenguajes de programación tienen bibliotecas y abstracciones (ej: JDBC en Java)

Query 0. Retrieve the birth date and address of the employee(s) whose name is 'John B. Smith'.

```
Q0:   SELECT   Bdate, Address
      FROM     EMPLOYEE
      WHERE    Fname = 'John' AND Minit = 'B' AND Lname = 'Smith';
```

En los sistemas no relacionales hay mucha **diversidad**:

APIs y lenguajes de consulta
falta de estándares
Muchos brindan posibilidad de ejecutar consultas SQL-like

LA PORTABILIDAD ENTRE PRODUCTOS ES MUY DIFICIL

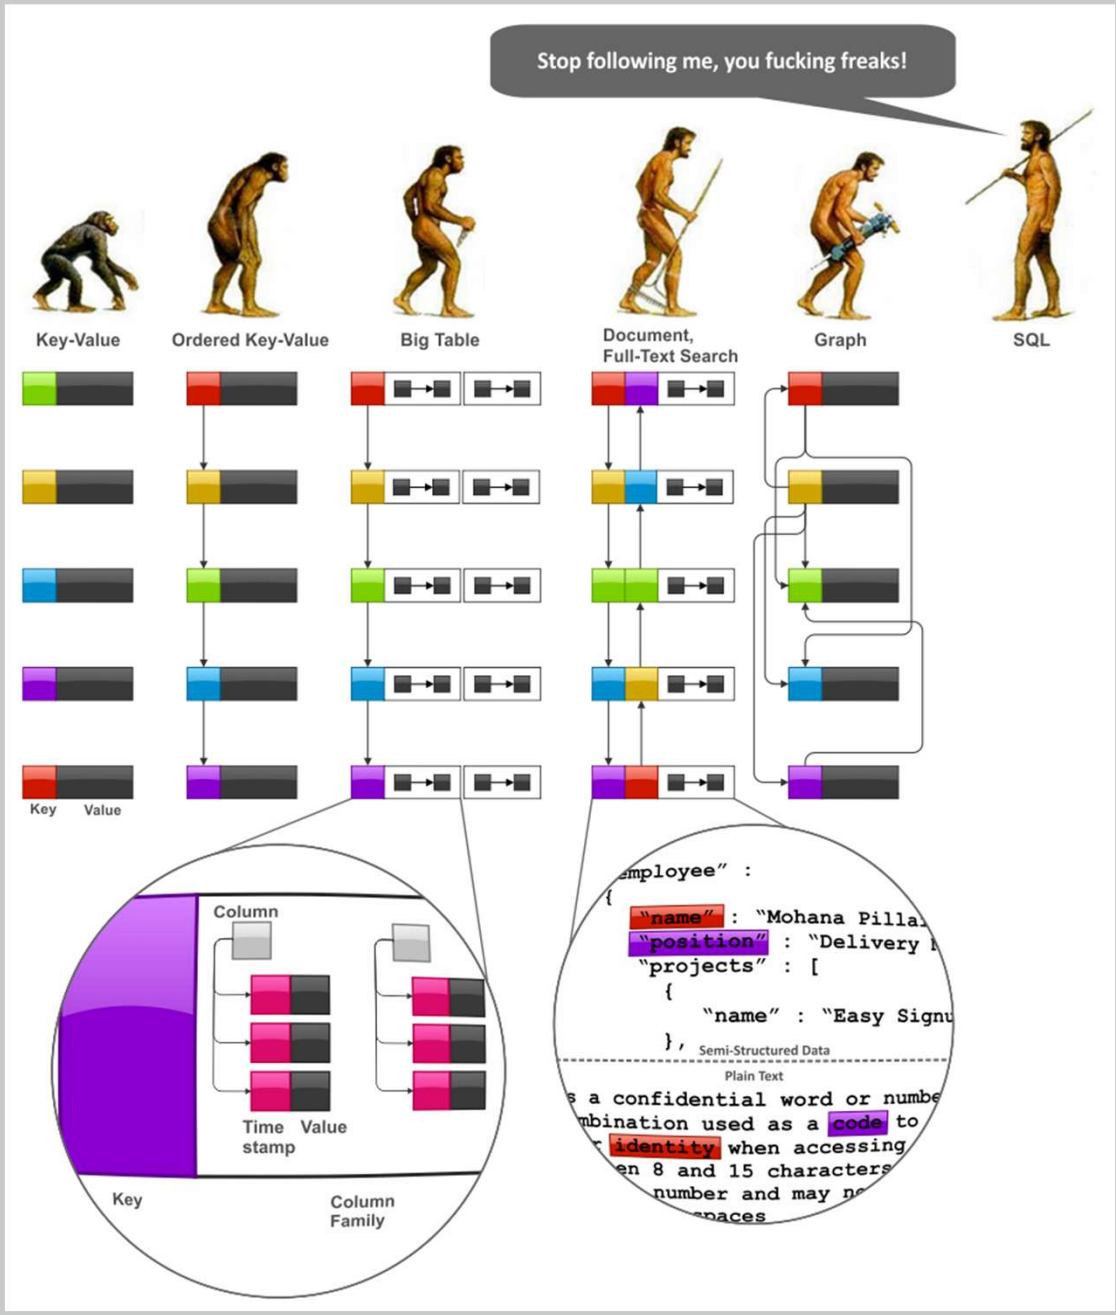

Consistencia y soporte a transacciones

Consistencia y transacciones en RDBMS

La noción de consistencia estricta implica que toda instancia de la BD satisface una serie de **restricciones** (ej: restricciones de clave primaria, clave foránea, etc)

Las operaciones sobre la BD garantizan que van de un estado consistente a otro estado consistente.

Esto se implementa con **transacciones** (soporte a acceso **concurrente**)

¿qué pasa en los sistemas noSQL?

Se define una nueva noción de consistencia.

CAP Theorem

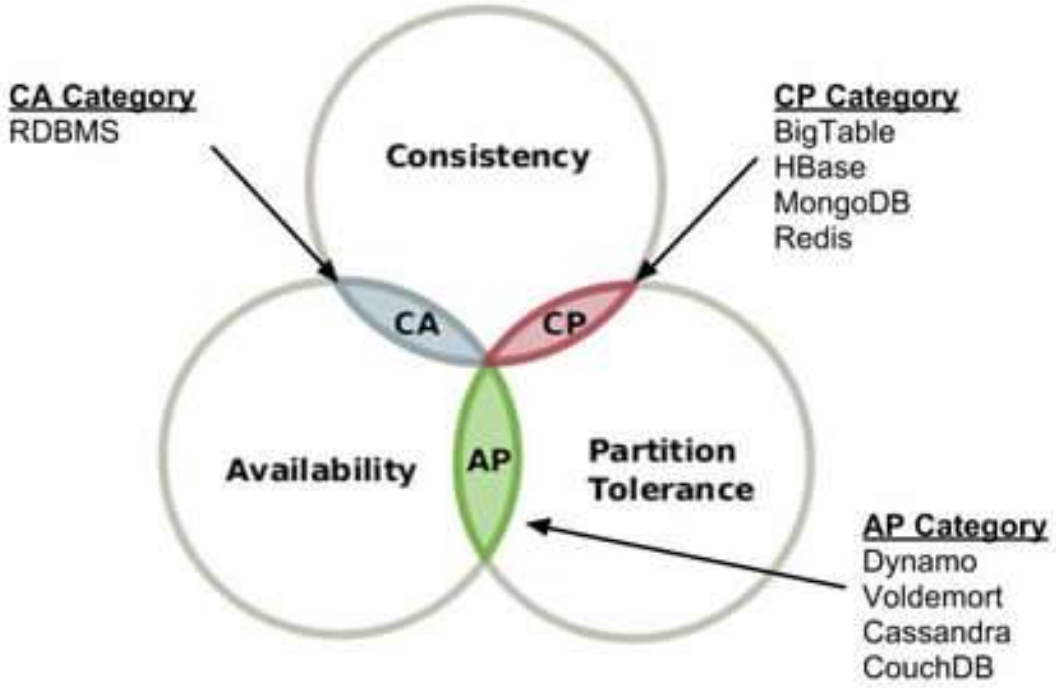

Brewer, E. A. (2000, July). Towards robust distributed systems. In *PODC* (Vol. 7, No. 10.1145, pp. 343-477).

¿qué pasa en los sistemas noSQL?

Diferentes enfoques plantean estrategias diferentes:

- Consistencia estricta (típicamente via locks)
- *Eventual consistency* [1]
- Consistencia ajustable (ej: Dynamo DB)
  - En algunos casos puede requerir de mecanismos de resolución de conflictos

[1] Vogels, W. (2009). Eventually consistent. Communications of the ACM, 52(1), 40-44.

Arquitectura de datos y de cómputo

Estrategias para la escalabilidad

scale up

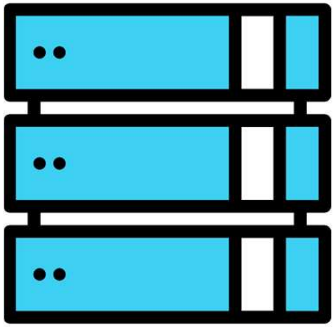

La misma solución en una máquina más grande

scale out

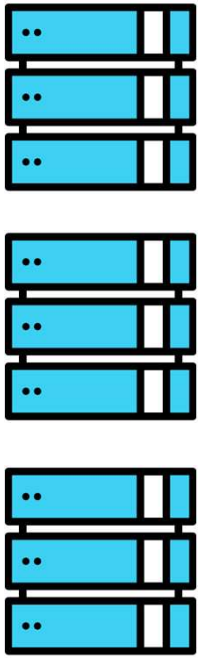

Una nueva solución que **distribuye** el cómputo, los datos, o ambos en varias máquinas

La escalabilidad es la propiedad de un sistema para gestionar un volumen de trabajo cada vez mayor.

Scale out en RDBMs

Arquitectura *share everything*

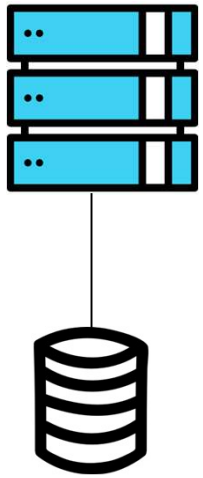

Arquitectura *share disk*

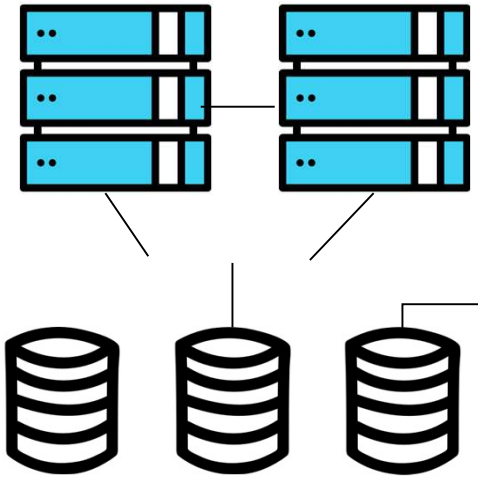

EJ: Oracle RAC

Arquitectura *share nothing*

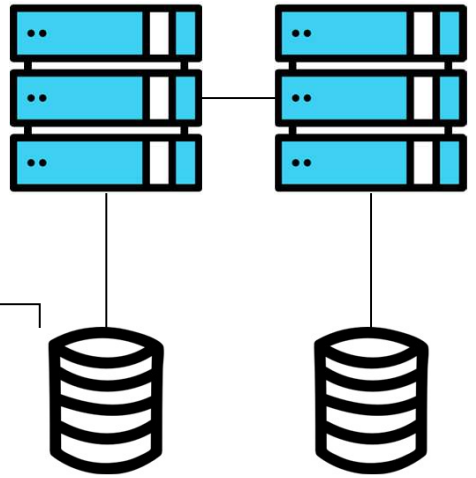

EJ: sharded MySQL

Algunos problemas difíciles de gestionar

- *Shared-disk*:
  - Gestión de los caches de cada nodo (*cache coherency*)
- *Shared-nothing*:
  - ACID sobre varios nodos (2PC)
  - Balance de carga (datos y cómputo)
  - La caída de un nodo implica pérdidad de datos (salvo q tenga redundancia)

¿qué pasa en los sistemas noSQL?

- Disponibilidad vs Consistencia
  - Teorema CAP
- Uso de *commodity-hardware*
  - Decenas de miles de nodos!
- Necesidad de resiliencia:
  - Los nodos fallan, el sistema debe recuperarse

¿qué pasa en los sistemas noSQL?

Hay al menos tres familias de estrategias para el particionamiento de datos

- *Sharding* por clave (y variantes) (ej: MongoDB)
- Un master que sabe donde colocar los datos (ej: Hadoop, HDFS y Hbase)
- Distribución via funciones de hash (ej: Amazon Dynamo)

Modelos de despliegue y de negocio

Modelos de despliegue

Despliegue en la Nube:

- Nube Pública: Utiliza recursos de terceros, como Amazon Web Services (AWS), Microsoft Azure o Google Cloud Platform (GCP).

- Nube Privada: Infraestructura de TI dedicada a una sola organización, con mayor control y seguridad.

- Nube Híbrida: Combina recursos de nube pública y privada para optimizar costos y flexibilidad.

- Nube Comunitaria: Infraestructura compartida por varias organizaciones con intereses o necesidades comunes.

Despliegue en Premisas (On-Premises):

- La base de datos se instala y gestiona en los propios servidores de la organización

Cloud computing

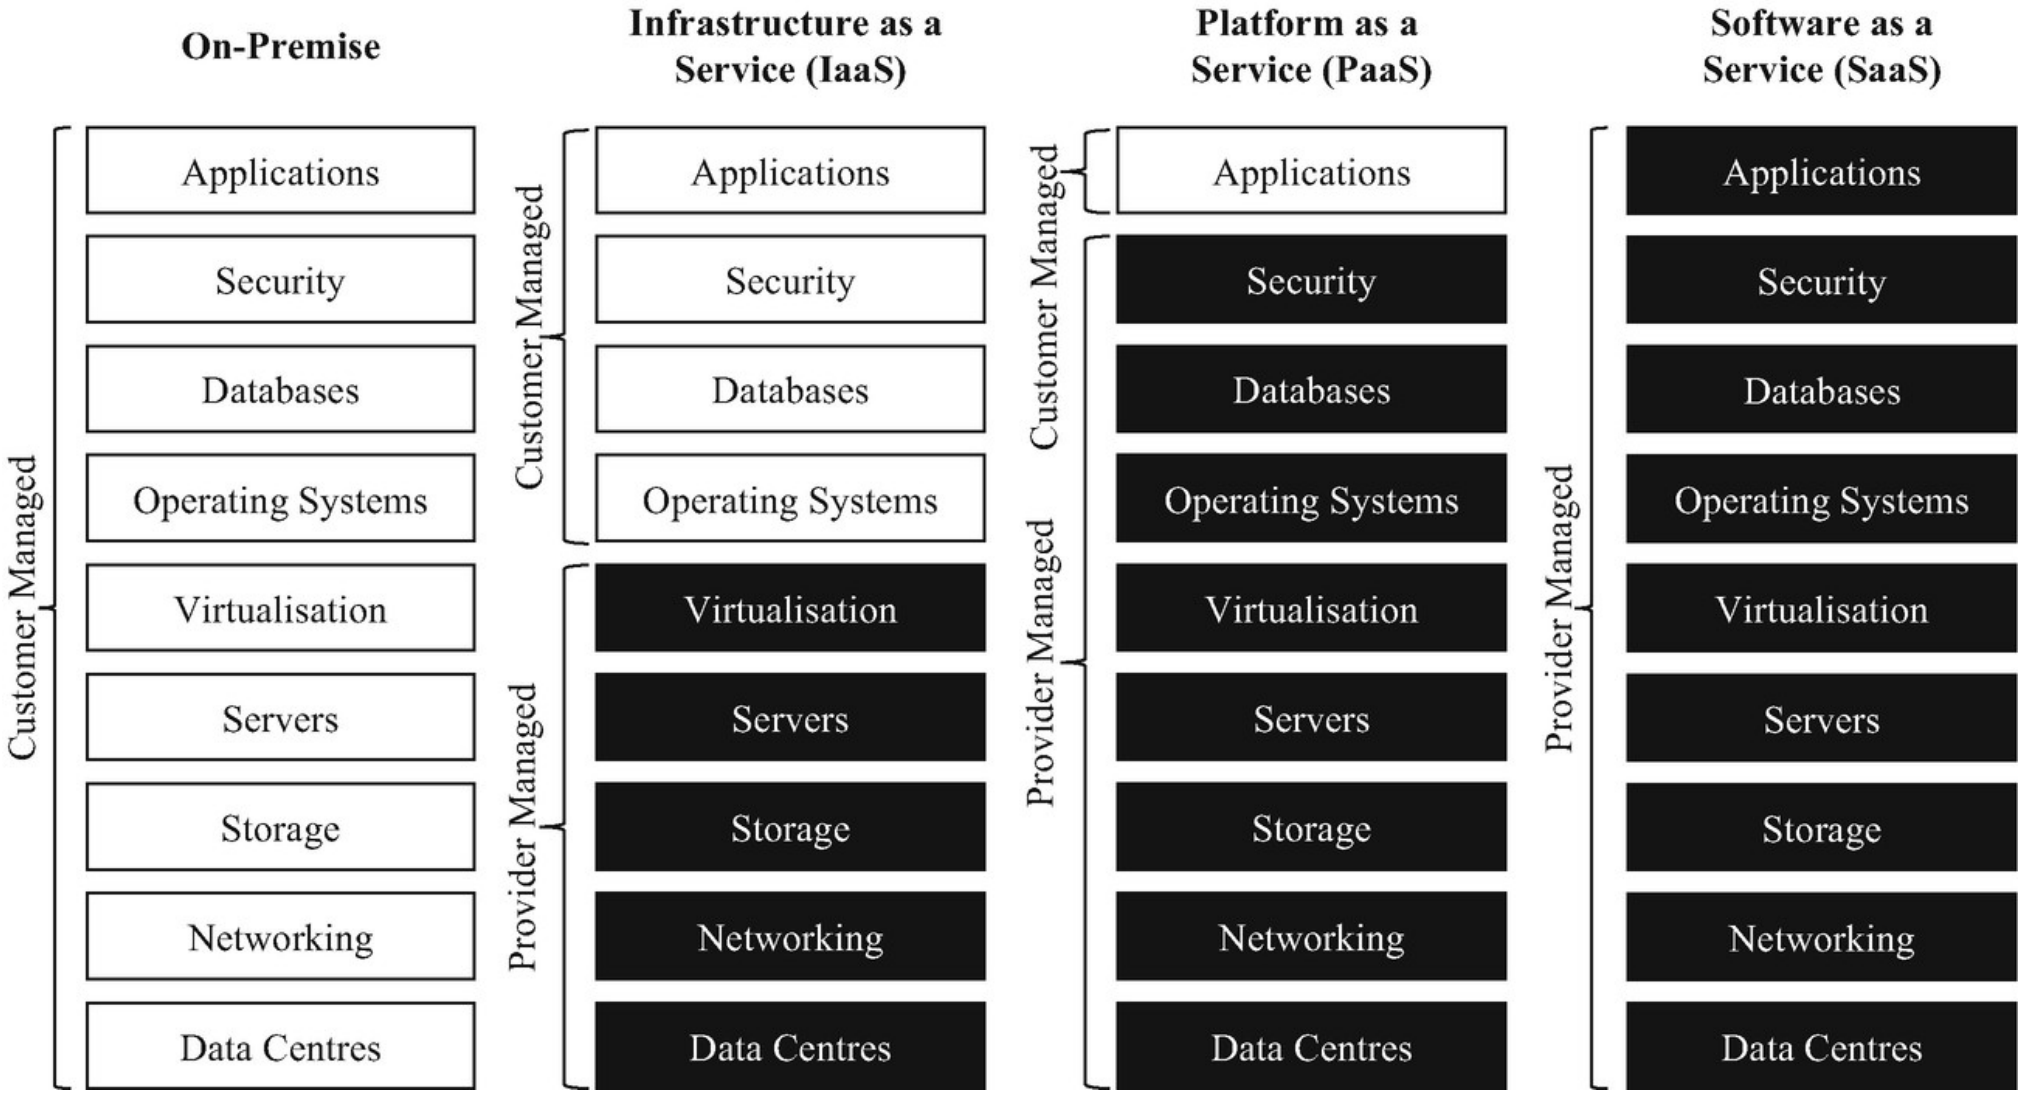

By Rosati, Pierangelo; Lynn, Theo - https://link.springer.com/chapter/10.1007/978-3-030-43198-3_2/figures/1
https://link.springer.com/book/10.1007/978-3-030-43198-3, Public Domain,
https://commons.wikimedia.org/w/index.php?curid=148159724

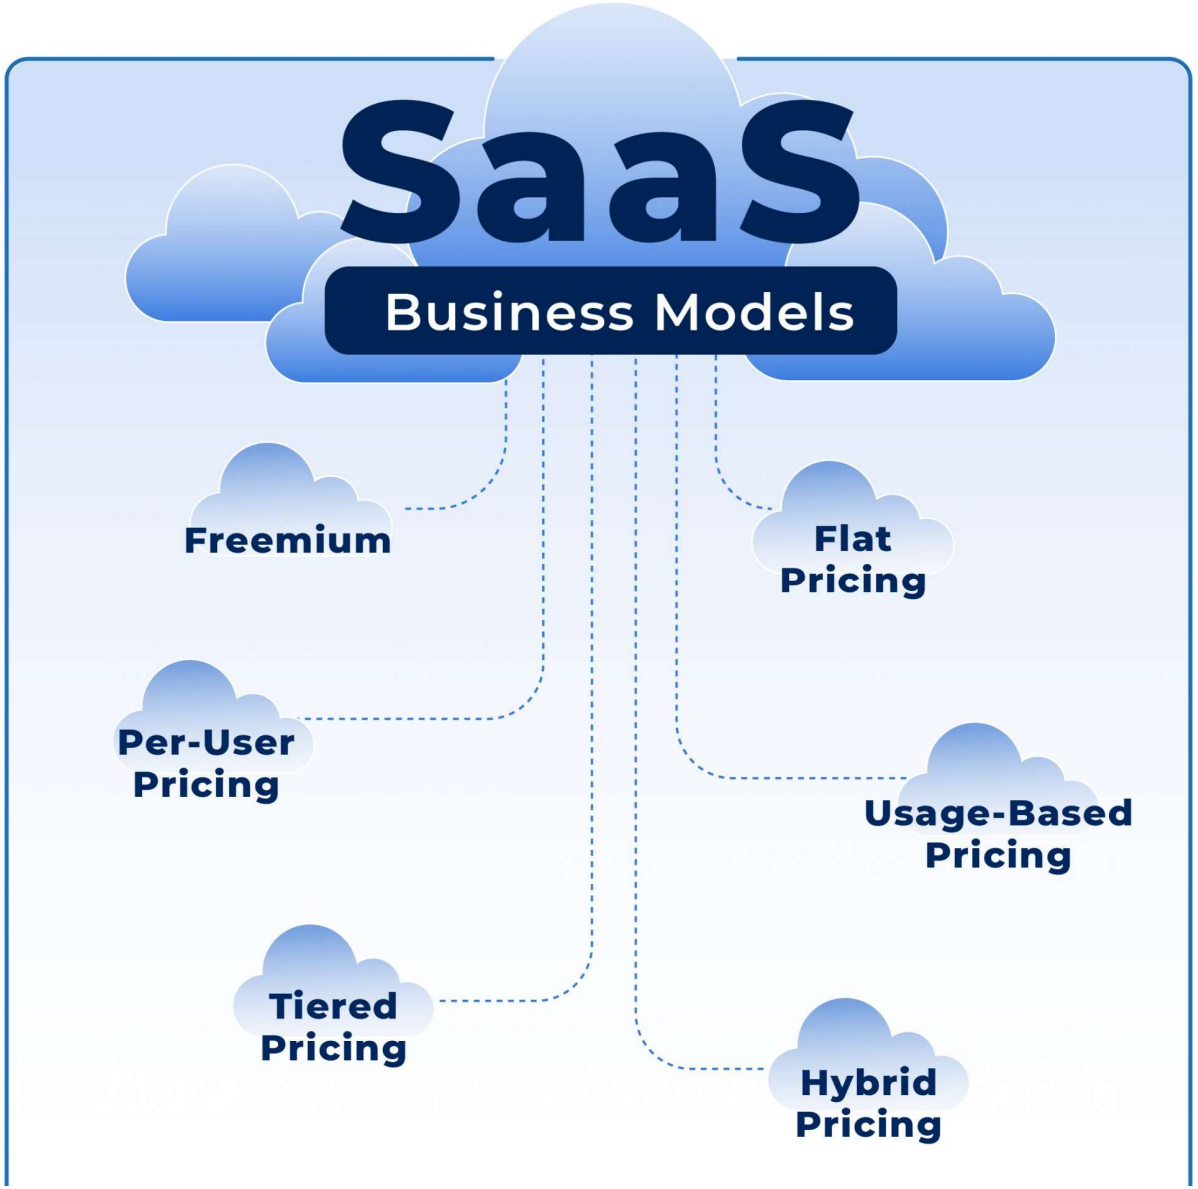
SaaS
Business Models
Freemium
Flat Pricing
Per-User Pricing
Usage-Based Pricing
Tiered Pricing
Hybrid Pricing

Resumiendo

- Decidir cual es la estrategia adecuada para cada caso no es sencillo!!!
- Hay varios factores que inciden:
  - ¿qué modelo de datos se ajusta a cada problema?
  - Formas de interacción sobre los mismos, portabilidad, capacidades de los equipos de desarrollo
  - Características de los datos (volumen, naturaleza, volatilidad, etc)
  - Arquitecturas y formas de despliegue (on-premises, on-cloud, etc.)
  - $$$