

# LLI- GALL 46

**Evolució del  
processat de dades.**  
Des dels processos  
manuais fins el Big Data  
i els nous paradigmes.

Cesc Julbe  
Data Engineer Tech Lead a Roche

## RESUM

El valor de la dada ha anat creixent a les organitzacions i empreses a mesura que es consolidava la seva transformació cap a models centrats a utilitzar les noves tecnologies en l'anomenada era digital. No obstant això, han hagut de passar anys fins que s'ha posat de manifest aquest valor. Això ha estat possible, ja que els models de gestió i explotació de la dada han evolucionat i han permès formular preguntes «de negoci» cada cop més específiques a les quals s'ha pogut donar resposta. A mesura que s'obtenien aquestes respostes, es formulaven noves preguntes que requerien més i millors dades, impulsant millors sistemes per processar-les i sistemes cada cop més innovadors, eficients i escalables. Així, la volumetria de dades ha estat cada cop més gran i les eines per a explotar-les molt més sofisticades.

En aquest article farem un recorregut cronològic pels sistemes de gestió i explotació de la dada. Des dels incipients sistemes de *business intelligence* fins als sistemes més sofisticats de l'ecosistema big data, com Hadoop i Spark. Sobre aquest eix cronològic, anirem obrint derivades per presentar conceptes com SQL i NoSQL com a models per a l'emmagatzematge de dades, els models arquitecturals d'explotació de volums massius de dades, els paradigmes cloud, ja tan vigents a les organitzacions actuals per desplegar infraestructures de computació, i els models de governança de la dada, tan necessaris a l'hora de gestionar dades a escala estratègica. Com queda palès al llarg de l'article, tot allò que fa referència al processament i l'explotació de la dada està en constant evolució, de manera que introduïrem noves tendències en aquest àmbit, com ara *data fabric* i *data mesh*. L'article és una introducció a diferents conceptes tècnics presentats a alt nivell; no obstant això, s'hi inclouen múltiples referències que esperem que serveixin al lector per aprofundir, si cal, en els conceptes, tecnologies i paradigmes presentats.

PARUALES CLAU: ciència de dades, big data, *data lake*, *data fabric*, *data mesh*

## RESUMEN

El valor del dato ha ido creciendo en las organizaciones y empresas a medida que se consolidaba su transformación hacia modelos centrados en el uso de las nuevas tecnologías en la llamada era digital. Sin embargo, han tenido que pasar años hasta que se ha puesto de manifiesto ese valor. Eso ha sido posible gracias a que los modelos de gestión y explotación del dato han evolucionado y han permitido formular preguntas «de negocio» cada vez más específicas a las que se ha podido dar respuesta. A medida que se obtenían esas respuestas, se formulaban nuevas preguntas que requerían más y mejores datos, impulsando mejores sistemas para procesarlas y sistemas cada vez más innovadores, eficientes y escalables. Así, la volumetría de datos ha sido cada vez mayor y las herramientas para explotarlas mucho más sofisticadas.

En este artículo realizaremos un recorrido cronológico por los sistemas de gestión y explotación del dato. Desde los incipientes sistemas de *business intelligence* hasta los sistemas más sofisticados del ecosistema *big data*, como Hadoop y Spark. Sobre este eje cronológico, iremos abriendo derivadas para presentar conceptos como SQL y NoSQL como modelos para el almacenamiento de datos, los modelos arquitecturales de explotación de volúmenes masivos de datos, los paradigmas *cloud*, ya tan vigentes en las organizaciones actuales por desarrollar infraestructuras de computación, y los modelos de gobernanza de datos, tan necesarios para gestionar datos a escala estratégica. Como se refleja a lo largo del artículo, todo lo que hace referencia al procesamiento y explotación del dato está en constante evolución, de modo que introduciremos nuevas tendencias en este ámbito, como por ejemplo *data fabric* y *data mesh*. El artículo es una introducción a distintos conceptos técnicos presentados a alto nivel; sin embargo, se incluyen múltiples referencias que esperamos que sirvan al lector para profundizar, si es necesario, en los conceptos, tecnologías y paradigmas presentados.

PALABRAS CLAVE: ciencia de datos, *big data*, *data lake*, *data fabric*, *data mesh*

## RÉSUMÉ

La valeur de la donnée a augmenté progressivement dans les organisations et les entreprises au fur et à mesure que se consolidait sa transformation vers des modèles axés sur l'utilisation des nouvelles technologies dans ladite ère numérique. Cependant, il a fallu de nombreuses années avant que cette valeur se manifeste. Ceci a été possible grâce aux modèles de gestion et d'exploitation des données qui ont évolué et ont permis de formuler des questions «d'affaires» de plus en plus spécifiques auxquelles une réponse a pu être apportée. Au fil des réponses obtenues, de nouvelles questions apparaissaient et demandaient plus de données et de meilleure qualité, ce qui a promu de meilleurs systèmes pour les traiter, des systèmes toujours plus innovateurs, efficaces et évolutifs. Ainsi, la volumétrie des données est allée en augmentant et les outils pour les traiter sont devenus plus sophistiqués.

Dans cet article, nous ferons une revue chronologique des systèmes de gestion d'exploitation des données. Des premiers systèmes de *business intelligence* jusqu'aux systèmes les plus sophistiqués de l'écosystème *big data*, comme Hadoop et Spark. Sur cet axe chronologique, nous nous devrons pour présenter des concepts comme SQL et NoSQL en tant que modèles pour le stockage des données, les modèles architecturaux d'exploitation de volumes massifs de données, les paradigmes *cloud*, déjà bien en vigueur dans les organisations actuelles pour déployer des infrastructures computationnelles, et les modèles de gouvernance des données, si nécessaires pour gérer les données au niveau stratégique. Comme le reflète l'article, tout ce qui fait référence au traitement et à l'exploitation des données est en évolution constante, de sorte que nous introduirons de nouvelles tendances dans ce domaine, comme *data fabric* et *data mesh*. L'article est une introduction à différents concepts techniques présentés à haut niveau; cependant, nous y avons inclus de nombreuses références qui, nous espérons, serviront au lecteur pour approfondir, le cas échéant, les concepts, les technologies et les paradigmes présentés.

MOTS-CLÉS : sciences des données, *big data*, *data lake*, *data fabric*, *data mesh*

## ABSTRACT

The value of data has been growing in organisations and companies as their transformation towards models focused on using new technologies in the so-called digital era has been consolidated. However, it has taken years for this value to become apparent. This has been possible because data management and exploitation models have evolved and allowed increasingly specific "business" questions to be formulated and answered. As these answers were obtained, new questions were asked that required more and better data, driving better systems to process them and increasingly innovative, efficient and scalable systems. Thus, the volume of data has become ever greater and the tools to exploit it much more sophisticated.

In this article we will take a chronological look at data management and exploitation systems: from nascent business intelligence systems to the most sophisticated systems in the big data ecosystem, such as Hadoop and Spark. On this timeline, we will be opening derivations to present concepts such as SQL and NoSQL as models for data storage, architectural models for the exploitation of massive volumes of data, cloud paradigms – already so current in today's organisations for developing computing infrastructures – and data governance models, so necessary when managing data on a strategic scale. As is evident throughout the article, everything related to data processing and exploitation is constantly evolving, so we will introduce new trends in this area, such as *data fabric* and *data mesh*. The article is an introduction to various technical concepts presented at a high level; however, multiple references are included which we hope will help the reader to go deeper, if necessary, into the concepts, technologies and paradigms presented.

KEYWORDS: data science, big data, data lake, data factory, data mesh

## Introducció a la gestió de la dada

La necessitat de disposar d'informació i de tractar-la i transmetre-la va néixer fa molts anys, des de l'art rupestre, el primer llenguatge que permetia transmetre informació perdurable, fins a l'aparició i la perfecció de la paraula i el llenguatge, un mecanisme de comunicació molt més sofisticat que permetia la transmissió d'informació oral. Tanmateix, amb l'aparició de l'escriptura, la informació va esdevenir perdurable, interpretable i transmissible, i és aquí on podem identificar el moment zero en la gestió de la informació.

Jim Gray (Microsoft) ja anunciava les sis generacions en els sistemes de gestió de dades en l'article «Data Management: Past, Present, and Future» [1].

La generació inicial o zero és la generació que va cobrir les activitats més incipients de la gestió de la informació, entenen que es va iniciar aproximadament l'any 4000 aC, amb la troballa dels primers escrits a Sumèria. Els antics egipcis, cap al 300 aC, ja van intentar capturar totes les «dades» existents a la biblioteca d'Alexandria, la qual cosa es podria considerar un clar escenari de big data, i l'Imperi romà solia analitzar acuradament les estadístiques dels seus exèrcits amb la finalitat d'optimitzar l'eficiència militar. Aquesta primera generació zero va arribar ben bé fins a l'any 1900, aproximadament, i malgrat el llarguíssim període que cobreix, l'escriptura continuava sent escrita, i la seva gestió, manual.

La primera generació (1900-1955) va viure els primers processos de gestió automatitzada de la informació amb l'aparició de les anomenades *targetes perforades*. Empreses com IBM van fer grans desenvolupaments en la seva gestió. Com a exemple, l'any 1937, IBM tenia 32 premses treballant a Endicott (Nova York), que produïen fins a 10 milions de targetes perforades cada dia.<sup>1</sup>

En la segona generació (1955-1970) van aparèixer els primers ordinadors capaços de fer càlculs d'una certa complexitat, tot i que el focus és principalment incrementar la velocitat de processos que fins aleshores eren manuals. L'enginyeria de programari va esdevenir una nova disciplina, amb l'aparició de llenguatges com COBOL<sup>2</sup> i RPG.<sup>3</sup> Es processava informació, fos en targetes perforades o en cintes, fent tasques seqüencials en mode asíncron en processos que es podien executar de manera periòdica, però amb una escassa gestió automatitzada d'errors.

Grey defineix la tercera generació (1965-1980) com aquella en què els sistemes van esdevenir síncrons i això permetia saber-ne l'estat en temps real. Aquests sistemes, tanmateix, havien de resoldre un nou repte. Fins aleshores havien estat seqüencials i sense concurrència, però ara els qui accedien a un mateix recurs eren innumerables usuaris mitjançant els seus terminals. Per poder isolar les interaccions concurrents sobre les dades a les quals s'accedia, va aparèixer el concepte de transacció. Tanmateix, calia que la informació estigués organitzada de manera adequada. Així, els models de dades (maneres d'estructurar la informació) jeràrquics<sup>4</sup> i de xarxa<sup>5</sup> (*network data model*) van esdevenir els més populars. Tot i això, la navegació per aquests models era complexa i requeria un coneixement molt especialitzat. E. F. Codd ja va introduir el 1970 [2] un model de dades que semblava donar unes funcionalitats de navegació amb més potencial: el model de dades relacional.

La quarta generació (1980-1995) va estar dominada per la consolidació dels models relacionals i l'aparició del llenguatge SQL el 1985, que actualment és àmpliament utilitzat [3], [4].

Jim Grey, en el seu article, introduïa la cinquena generació (1996), en la qual els models relacionals s'escalaven per donar lloc a bases de dades distribuïdes, aplicacions client-servidor i el concepte de paral·lelisme. Aquesta generació ja tenia l'impacte d'internet i el potencial de l'ús de la xarxa va canviar la manera de pensar pel que fa a la gestió de la informació i el seu emplaçament físic. Val a dir que l'article va ser

reescrit el 1996, i és en aquest punt on prenem el relleu d'aquest article per fer un desenvolupament amb una certa cronologia de les diferents tendències, tecnologies i paradigmes en l'àmbit de la gestió i l'exploració de la informació que han anat apareixent a partir d'aleshores.

## Business intelligence

Que les dades tenien un valor en el procés de presa de decisions ja va quedar palès fa anys. L'octubre de 1958, Hans Peter Luhn, investigador d'IBM en aquell moment, va introduir el concepte «a *Business Intelligence System*» com l'habilitat d'aprendre la causalitat de fets que s'han esdevingut de manera que permetin prendre accions basant-s'hi. A aquests sistemes se'ls va anomenar DSS (*Decisions Suport Systems*) [5]. Però no va ser fins al 1989 que Howard Dresner, que seria analista de Gartner, va generalitzar el concepte d'intel·ligència de negoci (*Business Intelligence*, BI) com «els conceptes i mètodes per millorar la presa de decisions empresarials mitjançant l'ús de sistemes basats en fets de suport». I és que els sistemes operacionals van donar lloc a repositoris d'informació transaccional cada vegada més grans. I paral·lelament, el rendiment dels components computacionals havia evolucionat de manera inversament proporcional al seu cost, de manera que permetien disposar de sistemes de càlcul més potents a un preu menor.

Als anys 80, les arquitectures d'emmagatzemament de dades, des dels sistemes operacionals fins als sistemes analítics, es va anar sofisticant i va donar lloc als anomenats *datawarehouse*.

El *datawarehouse* és un repositori de dades centralitzat que integra les dades de les diferents fonts (sistemes operacionals i qualsevol altra font de dades que pugui contenir informació susceptible de tenir valor) per a finalitats analítiques. La integració de dades va requerir aplicar tècniques per transformar-les i tenir unes regles úniques i consistents en el repositori. Així, es van definir regles de qualitat, ja fos mitjançant regles de domini (camps formatats correctament, per exemple) o regles de negoci (les regles funcionals que requereix el cas de negoci). Aquesta integració va definir els processos anomenats ETL (*Extract, Transform and Load*) i podem dir que va aparèixer l'enginyeria de dades formalment.

En el *datawarehouse* cal que la informació estigui estructurada de manera que permeti una anàlisi ràpida. Així van aparèixer nous models de dades més enllà dels relacionals, específicament els anomenats *cubs* d'informació (*OnLine Analytical Processing*, OLAP) [6]. Simplificant la definició, aquests models es focalitzen a estructurar la informació en *arrays* multidimensionals,<sup>6</sup> de manera que tota la informació està relacionada amb les altres dimensions i es poden tenir diferents visions del cub, depenent de les dimensions que s'observen. Aquest model era una extensió del model relacional, molt adequat per a sistemes transaccionals, però no òptim per a anàlisis ràpides sobre dades amb múltiples relacions.

Tanmateix, un model relacional permet definir bones estructures OLAP i no són models excloents. Hi ha implementacions de models OLAP mitjançant motors relacionals com el ROLAP (*Relational OnLine Analytical Processing*). També hi ha la implementació no relacional: MOLAP (*Multidimensional OnLine Analytical Processing*) i HOLAP (*Hybrid OLAP*), que combina totes dues implementacions.

Aquesta preparació de dades amb finalitats analítiques farà possible el *Data Mining* (mineria de dades), una nova metodologia d'analitzar dades que consisteix a buscar tendències i patrons no visibles a primer cop d'ull o mitjançant una anàlisi estadística descriptiva,<sup>7</sup> que esdevindrà el que coneixem com a *Data Science* i aprenentatge automàtic.

1 [https://www.ibm.com/ibm/history/exhibits/vintage/vintage\\_4506VV2159.html](https://www.ibm.com/ibm/history/exhibits/vintage/vintage_4506VV2159.html)

2 [https://www.ibm.com/docs/en/SS6SG3\\_4.2.0/com.ibm.entcobol.doc\\_4.2/PGandLR/igy3lr50.pdf](https://www.ibm.com/docs/en/SS6SG3_4.2.0/com.ibm.entcobol.doc_4.2/PGandLR/igy3lr50.pdf)

3 <https://www.ibm.com/docs/es/i/7.1?topic=languages-rpg>

4 <https://www.ibm.com/docs/en/file-manager-for-zos/14.1?topic=overview-databases-segments>

5 <https://www.geeksforgoeks.org/network-model-in-dbms/>

6 Col·lecció d'elements en una sola estructura als quals s'accedeix mitjançant un índex. Un *array* multidimensional és un *array* d'*arrays*.

7 Una anàlisi descriptiva implica l'anàlisi de les variables, i mitjançant tècniques estadístiques com la mitjana, les distribucions estadístiques i les correlacions entre variables, es pot tenir una visió de present a passat de la mostra de dades analitzada.

## SQL i NoSQL

Als anys 90 del segle xx, amb la popularització d'internet augmenten els fluxos de dades de manera exponencial any rere any. L'immens flux d'informació combinat amb la varietat de tipus de dades procedents de moltes fonts diferents va donar lloc a bases de dades no relacionals que transcendien la rigidesa dels models relacionals, molt estrictes pel que fa a formats, tipus i relacions entre taules (basat en les transaccions). Aquests nous models s'anomenen NoSQL. Aquest acrònim el va utilitzar per primera vegada l'any 1998 Carlo Strozzi<sup>8</sup> mentre anomenava una nova base de dades «relacional» lleugera i de codi obert que no utilitzava SQL.

NoSQL es va desenvolupar inicialment per donar resposta a la gestió de les dades web, no estructurades i amb requisits de processament ràpid. I és que els models NoSQL solen ser la millor opció per a grans volums de dades no estructurats o heterogenis en comparació amb els models relacionals. La flexibilitat de les bases de dades NoSQL es basa principalment en la seva capacitat de desplegar-se de manera distribuïda, i això permet una millor escalabilitat horitzontal<sup>9</sup> fàcilment.

El teorema CAP, també conegut com a teorema de Brewer (en honor del seu desenvolupador, Eric Brewer), és un element important en la definició funcional de les bases de dades NoSQL. El teorema formula que una base de dades distribuïda no pot oferir simultàniament més de dues de les tres característiques següents:

- Coherència: les dades de la base de dades continuen sent coherents, fins i tot després d'executar una operació. Per exemple, després d'actualitzar un sistema, tots els consumidors observaran exactament les mateixes dades.
- Disponibilitat: el sistema està sempre disponible.
- Tolerància a la partició: encara que la comunicació entre els nodes de la xarxa distribuïda ja no sigui fiable, el sistema continuarà funcionant.

Brewer, de la Universitat de Califòrnia, va presentar la teoria la tardor de 1998, i es va publicar el 1999 com a Principi de CAP. Nancy Lynch i Seth Gilbert del Massachusetts Institute of Technology (MIT) van publicar una prova formal del concepte de CAP [7] el 2002.

Hi ha altres models de consistència que han anat evolucionant al llarg dels anys, com ACID (atomicitat, consistència, aïllament [en anglès, *isolation*] i durabilitat) creat el 1983 per Theo Härder i Andreas Reuter [8]. La majoria de bases de dades NoSQL, per principi, no poden garantir les propietats ACID, ja que en restringiria el seu potencial i són força contraposades a CAP.

Posteriorment, el terme BASE (*Basically Available Soft-state, Eventually-consistent*) [9] es va popularitzar com a alternativa a ACID, amb uns principis més «suaus», especialment centrats en la disponibilitat de dades. El model BASE, en general, es menys restrictiu que ACID en favor de la flexibilitat i la disponibilitat de dades, entenent flexibilitat com a sistema que és fàcilment escalable, sense esquemes i que permet canvis ràpids i de replicació fàcil.

<sup>8</sup> [http://www.strozzi.it/cgi-bin/CSA/tw7/l/en\\_US/NoSQL/Home%20Page](http://www.strozzi.it/cgi-bin/CSA/tw7/l/en_US/NoSQL/Home%20Page)  
<sup>9</sup> <https://www.geeksforgeeks.org/horizontal-and-vertical-scaling-in-databases/>

En termes generals, podem trobar les categories següents de bases de dades NoSQL:

- Emmagatzemament clau-valor [10], com Cassandra, HBase.
- Emmagatzemament basat en documents, com mongoDB.
- Bases de dades de grafs, com Neo4j.

Les bases de dades NoSQL permeten utilitzar un gran nombre d'atributs per a un sol element, mentre que les bases de dades relacionals es limiten a un sol atribut per mitjà d'una relació amb un element d'una altra taula. Més atributs requereixen més relacions, la qual cosa pot significar una complexitat important pel que fa al disseny. No obstant això, permeten aplicar rígides regles d'integritat que no podem garantir amb els models NoSQL (almenys no per a disseny).

## Supercomputació

L'evolució de les tècniques de processament de la informació ha anat, inevitablement, lligada a la millora dels recursos de computació. És necessari, doncs, analitzar en paral·lel com ha evolucionat la supercomputació durant aquest període de temps fins a la computació moderna. Seymour Cray [11], enginyer nord-americà, va ser pioner en el desenvolupament dels primers supercomputadors. El 1960 Cray va crear el CDC 1604, un dels primers ordinadors basats en transistors, i després va desenvolupar el CDC 6600 (1964), que utilitzava transistors de silici i podia arribar a tres megaflops<sup>10</sup> de potència de càlcul. Posteriorment, va arribar el 7600. Cray, durant aquesta dècada, va estar en competició constant amb IBM, que comercialitzava la família d'ordinadors 7030<sup>11</sup> i la família 7090.

A la dècada dels 70 i a la dels 80, va aparèixer el Cray-1 (1975), un dels supercomputadors més populars, i el va seguir el Cray Y-MP [12]. La capacitat de càlcul d'aquests ordinadors ja aconseguia 300 megaflops per processador. El Cray-2 (1985) comptava amb 8 processadors i tenia una capacitat de càlcul pròxima a 2 gigaflops. A la dècada dels 90, van aparèixer els supercomputadors amb centenars de processadors, amb l'arribada de fabricants japonesos com Fujitsu, amb el Numerical Wind Tunnel amb 167 processadors i prop de 100 gigaflops (1994), i Hitachi (1996), amb l'SR2201<sup>12</sup> i 600 gigaflops, amb 2.048 processadors, i Intel també va començar a establir-se com a referent amb l'Intel.

Amb l'entrada al nou segle, va aparèixer la computació a escala, que va incrementar la capacitat de processament de teraflops a petaflops i va evolucionar cap a la supercomputació tal com la coneixem avui dia. El paradigma de més processadors (escalat vertical) es va reemplaçar pel paradigma de més nodes més simples (escalat horitzontal) i es va entrar a l'era dels anomenats centres de supercomputació moderns, ja coneguts amb el terme HPC (*High Performance Computing*), també gràcies a la millora de les connexions de xarxa, que va permetre crear ordinadors «virtuals» d'enorme potència.

A casa nostra, al Barcelona Supercomputing Centre,<sup>13</sup> hi opera el MareNostrum, un dels ordinadors més potents del món. El 2004 va entrar en operacions el Mare Nostrum 1, amb una capacitat de càlcul de 42,35 teraflops. Una millora feta el 2006 (MareNostrum 2) en va incrementar la capacitat de càlcul a 94 teraflops, amb un increment del nombre de processadors de 4.812 a 10.240. El MareNostrum 3 (2012-2013) ja comptava amb 48.896 processadors i 3.056 nodes, i tenia una capacitat de càlcul d'1,1 petaflops. Finalment, el MareNostrum 4, operatiu des del 2017, ja disposa de 3.456 nodes i 165.888 processadors, i arriba a 13,9 petaflops.

<sup>10</sup> Unitat de mesura equivalent a un milió d'operacions de coma flotant per segon.  
<sup>11</sup> [https://www.ibm.com/ibm/history/exhibits/mainframe/mainframe\\_PP7030.html](https://www.ibm.com/ibm/history/exhibits/mainframe/mainframe_PP7030.html)  
<sup>12</sup> <https://www.hitachi.com/New/cnews/E/1996/960725B.html>  
<sup>13</sup> <https://www.bsc.es/>

Les llibreries i les eines per executar codi en entorns altament distribuïts també han anat evolucionant. Un exemple és MPI (*Message Passing Interface*), una llibreria per a arquitectures de computació paral·lela que permet la comunicació entre nodes en un clúster. Una implementació d'MPI es la popular Open MPI.

Com ja hem esmentat anteriorment, l'aparició de noves fonts i noves tipologies de dades que internet generava, altament heterogènies i voluminoses, van imposar nous requisits de processament, més focalitzats en la flexibilitat i la disponibilitat, que van donar lloc a l'aparició de noves tecnologies més assequibles i de desplegament fàcil. El paradigma de computació novament va canviar i es va iniciar l'era del big data. Els centres HPC han continuat operant per a projectes de computació complexa i de recerca, però la capacitat d'accedir a recursos de processat massiu s'ha generalitzat i ja no cal tenir accés a aquests entorns per dur a terme tasques de processament massiu, sinó que és relativament simple habilitar entorns de computació d'una certa capacitat usant *commodity hardware* o recursos al núvol, com ja comentarem més endavant.

L'evolució en els sistemes de BI i la capacitat d'emmagatzemar informació de manera distribuïda i la millora en els sistemes de computació (supercomputació) convergeixen en el que actualment coneixem com a big data.

## Big data

L'any 1998, Larry Page i Sergey Brin van dissenyar el motor de Google per cercar un lloc web específic [13] mentre processaven i analitzaven grans conjunts de dades en ordinadors distribuïts. Els principals punts d'interès del sistema eren l'escalabilitat, l'automatització i l'alt rendiment. I és que Page i Brin tractaven de resoldre la problemàtica que es plantejava en la cerca d'informació a internet, un dels primers casos de big data tal com l'entendem avui dia.

El 2001, l'analista Doug Laney [14], de META Group (ara Gartner), va definir el terme big data com el conjunt de tècniques i tecnologies per al tractament de dades en entorns de gran volum i varietat i en els quals la velocitat de resposta ha de ser ràpida. Aquesta definició es coneix popularment com les 3 V del big data (volum, velocitat i varietat). Avui dia, la definició de les 3 V ha estat amplificada amb algunes V més, com veracitat, valor o visualització, per exemple.

A finals del segle xx i especialment a començaments del xxi, hi havia diverses iniciatives orientades a gestionar els elevats volums de dades derivats de l'explosió d'internet.

El 2002, Doug Cutting i Mike Cafarella tractaven de resoldre el problema de la indexació de 1.000 milions de pàgines mitjançant una solució *open source* (Apache Nutch). Aquesta iniciativa va coincidir amb el model arquitectural de GFS (Google File System) [15], publicat per Google, per emmagatzemar grans volums de dades de manera distribuïda. A més, el 2004 Google també va publicar el paradigma MapReduce [16], la solució per processar grans volums de dades distribuïdes. Així, amb l'ajuda de Yahoo (2006) i basant-se en GFS i MapReduce, Cutting i Cafarella van desenvolupar un *framework* de codi obert per al processament de grans volums de dades, que van anomenar Hadoop.

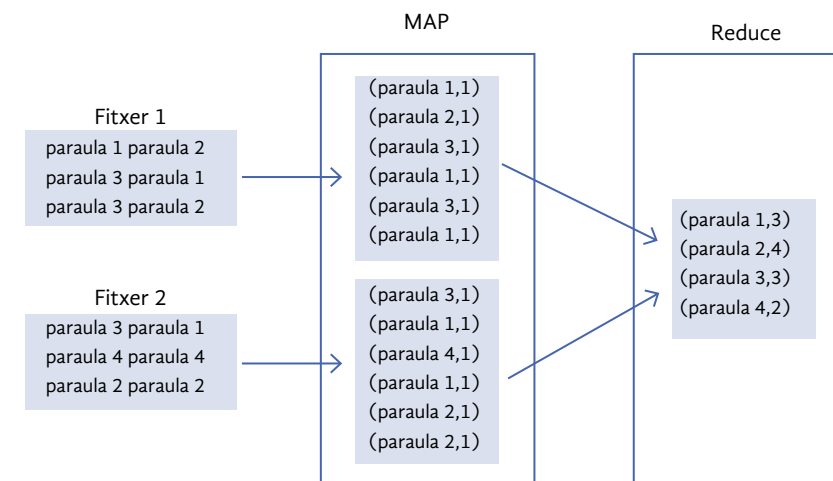
Yahoo va provar Hadoop en un clúster de 1.000 nodes l'any 2007. El 2008 es va llançar com a projecte de codi obert per a ASF (Apache Software Foundation) i es va provar en un clúster de 4.000 nodes. El 2009 es va utilitzar per indexar 1 PB de dades en menys de 17 hores, i al desembre del 2011 Apache Software Foundation va llançar Apache Hadoop versió 1.0.

## Hadoop

Hadoop és un conjunt de serveis destinats a facilitar la computació distribuïda amb dues característiques principals: (1) computació distribuïda transparent per a l'usuari i (2), ús de maquinari no especialitzat, allunyant-lo dels models de supercomputació en grans centres d'HPC. Com a pilar fonamental hi trobem MapReduce.<sup>14</sup>

Com el seu nom indica, MapReduce és un model de processament distribuït basat en dues etapes: un *Map*, que transforma d'1 a 1 qualsevol registre de dades, i un *Reduce*, que fa una agregació sobre la transformació *Map*. L'exemple més senzill és el comptador de paraules.

Com a exemple, considerem dos fitxers amb sis paraules cadascun, com els que s'observen a la figura. Cada fitxer conté un seguit de paraules (paraula 1, paraula 2...). Aquests fitxers podrien estar situats en ordinadors diferents.



Si volguéssim comptar quants cops apareix cada paraula aplicant el paradigma *MapReduce*, fariem el *Map*, on transformem cada paraula en l'anomenat parell «clau-valor». Cada paraula es compta a si mateixa un cop («paraula 1» esdevé «paraula 1,1», com es mostra a la figura). No hi cap lògica addicional ni es requereix encreuar informació entre fitxers ni entre paraules. És el *Reduce* el que pren tota la llista de paraules i suma tots els «uns» de cada paraula, de manera que el resultat esdevé una llista de paraules úniques com a clau i el nombre de cops que apareix, com a valor en aquest parell «clau-valor».

Aquest exemple és trivial. Però considerem que no tenim dos fitxers, sinó TB de dades repartides entre milers d'ordinadors. A més, els fitxers poden ser més complexos, dades no estructurades o semiestructurades sobre les quals s'ha de fer algun tipus d'agregació com la de l'exemple. El model encara seria vàlid, simplement que tractaria més dades.

Tot i això, Hadoop MapReduce presentava alguns problemes. El paradigma era senzill, però aquesta senzillesa feia que per a operacions més complicades fos difícil aplicar-lo, havent d'encadenar diversos passos MapReduce i generant dades intermèdies per tal de poder obtenir un resultat final. A banda d'això, per a cada un d'aquests processos intermedis calia llegir fitxers com a entrada i escriure fitxers com a sortida, de manera que el procés complet era molt lent.

<sup>14</sup> [https://hadoop.apache.org/docs/r1.2.1/mapred\\_tutorial.html](https://hadoop.apache.org/docs/r1.2.1/mapred_tutorial.html)

Entre altres serveis de l'ecosistema Hadoop, hi destaquem HDFS<sup>15</sup> (*Hadoop Distributed File System*), un sistema de fitxers distribuït que per a entorns de codi obert encara s'utilitza. Un altre servei que cal destacar és YARN<sup>16</sup> (*Yet Another Resource Negotiator*), una eina que gestiona recursos de computació en el clúster (nombre de CPU, memòria i generació de cues, entre d'altres), en el qual s'estan executant tasques de Hadoop.

Hadoop comptava amb més serveis, com Hive i Pig, i solucions compatibles, com Impala. Totes aquestes eines tractaven de resoldre un problema al voltant de MapReduce: el paradigma era senzill, però era difícil d'aplicar (calia escriure el codi en Java per utilitzar-lo i no tot es podia reduir a una cadena de *Map-Reducers*). Així doncs, aquestes eines afegien un nivell d'abstracció sobre MapReduce per poder treballar d'una manera més senzilla.

Les eines i els serveis de l'ecosistema Hadoop es van consolidar en les anomenades distribucions. Cloudera<sup>17</sup> és una companyia que es va fundar el 2008, impulsada per un grup de persones provinents de l'ecosistema tecnològic predominant en aquell moment: Google, Facebook, Yahoo i Oracle. Cloudera va comercialitzar una distribució de Hadoop, homogeneïtzant la gestió de tots els serveis. El 2011, Hortonworks<sup>18</sup> va ser fundada per Yahoo i oferia essencialment els mateixos serveis. Les dues companyies eren competència directa, fins que el 2018 Cloudera va comprar<sup>19</sup> Hortonworks.

Tanmateix, les limitacions de Hadoop van començar a impulsar propostes per superar-les. El 2009, Matei Zaharia [17], estudiant de Berkeley, desenvolupà un projecte anomenat Spark que va néixer amb l'objectiu de posar remei a les limitacions de MapReduce mitjançant una solució *open source*. El 2013, el projecte passà a formar part de l'Apache Software Foundation. Durant el 2013 i 2014, hi va haver diferents versions (*pre-releases*) de Spark, que deixaven entreveure que utilitzava un model de distribució molt avançat respecte a Hadoop, i finalment la versió 1.0 va arribar el maig del 2014.

Amb Hadoop, el concepte d'escalabilitat vertical (ordinadors cada cop més potents, amb més capacitat de càlcul, però amb la limitació física del mateix ordinador) perd força en favor del concepte d'escalabilitat horitzontal, que significa molts ordinadors més senzills connectats entre ells, que tenen un potencial gairebé infinit. Els centres HPC ja oferien escalabilitat horitzontal, però Hadoop democratitza el processat a gran escala.

## Apache Spark

Apache Spark és un motor de computació distribuït que unifica diverses funcionalitats analítiques en una sola solució, amb la qual cosa dona resposta a les limitacions de les eines de l'ecosistema Hadoop, la diversitat de serveis i la seva orquestració.

Spark defineix una col·lecció de dades abstracta anomenada RDD (*Resilient Distributed Dataset*) [18], que representa el conjunt de dades amb què es treballa. Sobre aquest conjunt de dades s'hi poden dur a terme transformacions (*Map*, *Reduce* i unes quantes més), i les dades també es poden combinar entre elles i s'hi pot definir una cadena de tasques (o *pipeline*) de processos d'extrem a extrem que transformaran les dades des de l'origen fins a la destinació. Aquesta cadena s'anomena DAG (*Directed Acyclic Graph*).

15 [https://hadoop.apache.org/docs/r1.2.1/hdfs\\_design.html](https://hadoop.apache.org/docs/r1.2.1/hdfs_design.html)

16 <https://hadoop.apache.org/docs/stable/hadoop-yarn/hadoop-yarn-site/YARN.html>

17 <https://es.cloudera.com/>

18 <https://www.cloudera.com/products/hdp.html>

19 <https://www.cloudera.com/about/news-and-blogs/press-releases/2018-10-03-cloudera-and-hortonworks-announce-merger-to-create-worlds-leading-next-generation-data-platform-and-deliver-industrys-first-enterprise-data-cloud.html>

Un RDD està format per blocs de dades, que són porcions físiques de les dades emmagatzemades en diferents nodes del nostre clúster, però des d'un punt de vista d'ús, l'RDD el podem entendre com una col·lecció de dades (text, nombres o objectes més complexos) sobre les quals es poden fer transformacions i accions, no gaire diferent d'un *array* en programació. La clau del model d'execució és el comportament *lazy loading*<sup>20</sup>, és a dir, no s'executa cap transformació fins que calgui accedir a les dades per visualitzar-les o consumir-les. Així, el DAG no s'executa fins que s'hagi d'accedir a les dades, optimitzant-lo perquè l'execució sigui el més eficient possible.

Spark és compatible amb els serveis ja existents de Hadoop. En versions posteriors, Spark va publicar un conjunt d'API (conjunts de llibreries especialitzades) per fer tasques avançades a sobre del *framework* original de Spark. D'aquestes API, cal destacar-ne dues: MLlib [19] i Spark SQL [20][21].

MLlib és una llibreria que permet desenvolupar processos de *machine learning* en entorns distribuïts i big data. Fins aleshores, les tasques de *machine learning* es desenvolupaven principalment amb llibreries de Python o R, però no estaven preparades per fer càlcul distribuït i depenien en gran manera de la capacitat de càlcul de l'ordinador en què s'executaven (escalabilitat vertical), però no estaven preparades per al càlcul distribuït, amb Spark, els models escalen horitzontalment.

Spark SQL és una llibreria que permet treballar amb dades distribuïdes utilitzant llenguatge SQL. Aquesta funcionalitat va anar guanyant popularitat, i és que abans de fer tasques d'anàlisi de dades, calia capturar-les, transformar-les, integrar-les i aplicar-hi regles de qualitat. Això és el que Spark SQL permet fer sense la necessitat de tenir una base de dades, només emmagatzemant les dades en els sistemes de fitxers distribuïts com HDFS. Aquesta API ha esdevingut essencial en els processos anomenats d'enginyeria de dades i ha canviat l'ecosistema d'especialització professional en el tractament de dades, amb una rellevància especial en l'enginyeria de dades, una de les especialitzacions amb més demanda actualment en el mercat laboral.

## Arquitectures big data

Apache Hadoop i Apache Spark van transformar la manera de processar dades en entorns big data, i a partir d'aquestes eines i de les seves capacitats van anar evolucionant les arquitectures necessàries per treballar amb grans volums de dades.

Els repositoris monolítics existents com els *datawarehouses* ja no eren prou flexibles i escalables per integrar dades tan heterogènies, de manera que va evolucionar un nou concepte: el *Data Lake*.

Els *Data Lakes* són àrees d'emmagatzematge consolidades i centralitzades per a dades en brut (no estructurades, semiestructurades i estructurades), extretes de diverses fonts, és a dir, dades que poden tenir valor. Se solen capturar dades per a casos d'ús específics, però és habitual que a partir d'un cas d'ús es puguin acabar descobrint noves preguntes i coneixements.

Un *Data Lake* no és només un repositori de dades desordenades, sinó que cal donar-li una estructura que permeti l'explotació de les dades. Típicament, un *Data Lake* està compost per un espai d'emmagatzematge, on es reben les dades «en brut», és a dir, tal com es capturen de les fonts. També hi ha un espai de dades ja homogeneïtzades i estandarditzades, però sense una lògica de negoci aplicada, que se solen

20 <https://spark.apache.org/docs/latest/rdd-programming-guide.html#rdd-operations>

identificar com a *curated*. A partir d'aquest espai intermedi, podem construir les capes d'explotació, molt orientades a la lògica de negoci, amb les agregacions i l'algorítmica que sigui necessària. El processament que transforma les dades per a totes les capes es coneix com a processament de dades en *batch*, en què els processos big data fan les tasques sobre totes les dades disponibles. Solen ser processos costosos en temps i recursos.

En emergir el big data també es presenta un nou escenari que tècnicament té implicacions importants: el processament de dades en temps real o *streaming*. Aquest tipus de processament ja feia temps que es treballava, però ara es volia aplicar a grans volums de dades, i això plantejava el dubte següent: com podem donar una resposta immediata a preguntes de negoci que requereixen l'ús de grans volums de dades?

Spark ofereix funcionalitats per tractar dades en *streaming*, de manera que habilita l'API Spark Streaming [22]. El seu funcionament es basa en la creació de petits paquets de dades que es processen per blocs o *micro-batch*. Així, Spark no treballa en *streaming* pur, és a dir, registre a registre. Alternativament, l'any 2011 es comença a desenvolupar Apache Storm,<sup>21</sup> una eina que processava dades en un *streaming* «pur», és a dir, registre a registre, tot i que la primera versió no va aparèixer fins al 2016. També, aquell mateix any aparegué Apache Flink,<sup>22</sup> un altre *framework* de processament de dades en *streaming*.

Tanmateix, es planteja una problemàtica addicional. Aquests *frameworks* processen les dades que reben, però cal capturar-les de les fonts que les generen i enviar-les allà on calgui per processar-les. Així, LinkedIn va crear el projecte Kafka, que es va convertir en *open source* el 2011 (Apache Kafka),<sup>23</sup> amb l'objectiu de capturar de manera distribuïda dades que es reben de fonts que les generen de forma contínua i anar-les enviant a diferents processos per gestionar-les, cosa que es coneix com a sistema de missatgeria.

Actualment, Kafka és una de les plataformes més utilitzades en els sistemes de baixa latència. Fem referència a baixa latència perquè, en realitat, quan parlem de dades en temps real abusem de l'expressió. Els sistemes de processament en *streaming* són sistemes que processen dades de manera contínua, però el temps real és quasi impossible d'assolir. Així doncs, en realitat els sistemes són sistemes que donen una resposta ràpida o de «baixa latència».

Com s'integren, però, els sistemes basats en grans *data lakes* i els sistemes de baixa latència? Els models d'arquitectura big data, doncs, es van començar a definir de manera que poguessin donar resposta a les dues casuístiques en una sola arquitectura. Nathan Marz [23] va proposar el 2011 una arquitectura genèrica que permetia unificar el processament en *batch* i en *streaming*, anomenada Lambda.

Aquesta arquitectura es basa en tres capes. La capa de processament en *batch*, amb totes les dades històriques del sistema; el processament de dades en *streaming*, per a la gestió de les dades que es van rebent de manera contínua, i una capa que aglutina dades de les dues capes esmentades per tenir-les sempre actualitzades, la *Serving Layer*. El sistema va computant les dades històriques en tot moment i, mentre aquest procés es porta a terme (pot trigar hores a completar-se), hi ha un procés més lleuger en *streaming* que va actualitzant les dades corresponents a la finestra de temps que el procés *batch* requereix, per tenir el sistema actualitzat en tot moment.

És una arquitectura que no està lligada a cap tecnologia i hi ha força implementacions utilitzant diferents eines. L'evolució dels sistemes va permetre definir arquitectures alternatives, com l'arquitectura Kappa

[24]. Aquesta arquitectura prescindeix de la capa de *batch* i basa el processament en l'acumulació de «versions» de les dades que va rebent en *streaming*. Aquesta arquitectura qüestiona la necessitat de la capa *batch* i focalitza la gestió de les dades en el temps real. Aquestes arquitectures són genèriques i cada organització fa implementacions *ad hoc* que hi estan basades. L'arquitectura Lambda sol ser més popular, principalment perquè no hi ha tants casos d'ús basats en la gestió de dades en *streaming*, però gairebé totes les organitzacions ja tenen grans repositoris de dades per integrar dades, la qual cosa ja és un *data lake* en si mateixa.

## Arquitectures cloud

Els sistemes big data ja estaven ben consolidats com les noves eines per al processament distribuït i requerien un clúster de computadors sobre els quals poguessin desplegar els serveis de computació distribuïda (Hadoop, Spark, etc.). Tot i això, calia la gestió de grans infraestructures, administració de sistemes i serveis amb l'esforç associat en temps, recursos i costos econòmics. I és que calia adquirir la infraestructura i les llicències de programari, a banda del personal especialitzat en la seva administració.

Així, l'any 2006 va aparèixer AWS<sup>24</sup> (Amazon Web Services) i presentà els primers serveis de computació *cloud*, òbviament limitats en aquell moment (S3 per a fitxers, SQS per a *events* i cues, i EC2 per a computació), però des d'aleshores han anat creixent i guanyant popularitat.

La transformació dels entorns de computació distribuïda cap al *cloud* ha estat fulgurant els últims cinc anys. Cada vegada més les companyies i organitzacions en general han anat migrant els seus entorns cap al núvol. I no només els que estan relacionats amb el big data, sinó tots els sistemes (bases de dades, instàncies per a diferents serveis i gairebé qualsevol mena de programari requerit).

Aquests serveis van permetre canviar el focus i les estratègies de tecnologies d'informació (IT) de les organitzacions, ja que són serveis administrats pel proveïdor, de manera que la gestió de la infraestructura pràcticament desapareix i només cal tenir un disseny d'arquitectura, tant de negoci com tecnològic, per dimensionar els sistemes.

En l'àmbit del big data, els proveïdors comencen a oferir eines com Spark i Hadoop de manera administrada encapsulades en serveis propis, com EMR (*Elastic Map Reduce*) d'AWS i AWS Kinesis com a alternativa a Kafka, per exemple. Les arquitectures big data es comencen a desplegar al núvol fent ús d'aquests serveis i amb un gran valor afegit, i és que els sistemes són escalables en pocs minuts, podent incrementar o disminuir la mida dels clústers gairebé sense inversió de temps ni recursos més enllà del cost econòmic del mateix servei, un fet impensable en instal·lacions propietàries dels maquinari (sovint anomenades *on-premise*).

A banda d'AWS, tant Microsoft amb Azure<sup>25</sup> com Google amb GCP<sup>26</sup> (Google Cloud Platform) també van començar a oferir serveis al núvol i actualment hi ha una llarga llista de proveïdors de serveis *cloud*, tot i que els principals continuen sent aquests tres, tal com mostra el gràfic de Synergy Research Group,<sup>27</sup> amb una quota de mercat del 65 % a finals del 2022.

21 <https://storm.apache.org/>

22 <https://flink.apache.org/>


23 <https://kafka.apache.org/>

24 <https://aws.amazon.com/>

25 <https://azure.microsoft.com/>

26 <https://cloud.google.com/>

27 <https://www.srgresearch.com/>



Més recentment, aquests models també han evolucionat per definir els mecanismes d'interoperabilitat entre sistemes que comparteixen dades, així com per definir els models de gestió sectorials, com, per exemple, els models de governança de dades per a l'àmbit de la salut.

Aquests models de govern també han posat de manifest la gran dificultat amb què les organitzacions es troben a l'hora de gestionar dades. L'heterogeneïtat i l'evolució orgànica de les organitzacions a mesura que acumulen dades han fet que cada domini de negoci acabi creant petits *data silos*, gestionats de manera independent, amb les dificultats que això comporta quan es volen aplicar regles homogènies i horitzontals a tota l'organització.

Aquests models organitzatius poden adoptar formes diferents: (1) un model centralitzat en què hi ha una unitat responsable de la gestió de la dada d'àmbit corporatiu; (2) un model descentralitzat en què cada unitat de negoci duu a terme una gestió independent; no cal dir que aquest model és el que s'adopta de manera natural si no hi ha una estratègia d'àmbit corporatiu i pot portar a molts desequilibris entre unitats de negoci, duplicitats d'esforços i costos, etc.; (3) un model federat, que sol ser el model recomanable (sempre depenent del cas), en què una unitat (anomenada típicament Oficina de la Dada) duu a terme una gestió transversal del model de govern, però hi ha la implicació de les unitats de negoci en la implementació del model.

Així, és un esforç compartit on hi ha representants del negoci amb coneixement de domini i responsables de l'àmbit de la dada.

Una de les organitzacions més rellevants en la definició de regles i polítiques de govern i gestió de la dada és DAMA<sup>29</sup> (*Global Data Management Community*). És una associació global sense ànim de lucre i independent dedicada a definir conceptes i pràctiques de gestió de la informació i les dades, i ofereix certificacions per a professionals que es volen formar en l'àmbit de la gestió avançada de la dada. DAMA defineix els àmbits de la governança de dades sobre dominis com arquitectura de dades, seguretat, metadades, qualitat de la dada o gestió de dades mestres entre d'altres. Per a cada àmbit es defineixen una sèrie de processos, basats inicialment en una anàlisi de maduresa per poder definir un model objectiu i un full de ruta de transformació de l'organització en un model *data-driven*.

No cal dir, doncs, que la gestió de la dada transcendeix el domini tecnològic i esdevé una peça clau en la definició estratègica de les organitzacions. Altres models i metodologies de govern s'han definit més enllà de DAMA. Aquestes se solen anomenar *Data Governance Playbook*, com la de Gartner.<sup>30</sup>

## Nous paradigmes

Amb la consolidació del big data i del concepte de *data lake*, les organitzacions se centren a dissenyar i desplegar grans infraestructures d'integració, processament i anàlisi de dades, escalables i ràpides, que d'alguna manera, amb polítiques de govern ben definides, redueixen la necessitat de gestió de dades descentralitzada que s'acostumava a produir, evitant que cada departament o unitat de negoci acabi definint un model de gestió propi amb la seva infraestructura IT i els ja esmentats *data silos*. Així i tot, això no ha acabat de ser ben bé així.

Cada ens de negoci sol tenir uns requisits diferents en les dades de què disposa. No és el mateix l'ús de dades d'àmbits comercials i vendes que les dades dels equips d'R+D sobre productes o projectes en desenvolupament o les dades de recursos humans. L'ús d'aquestes dades pot tenir finalitats molt diferents i pot estar subjecte a requisits legals i normatius també diferents. Així, amb la maduresa vers la dada de

## Governança de dades

Hem estat parlant de l'evolució en les tècniques i eines de processament de dades al llarg dels anys recents, però cal tenir en compte que en la gran majoria d'escenaris el gran repte és disposar de dades de qualitat. Els coneguts com a processos de transformació digital tenen en les dades i en el seu model de gestió i explotació un pilar fonamental. Aquests models de gestió han anat evolucionant al llarg dels anys a mesura que els casos de negoci basats en la seva explotació incrementaven la complexitat i l'exigència. És a dir, a mesura que es demana més a les dades, més qualitat s'espera que tinguin.

Adicionalment, la regulació i legislació entorn de la gestió de la dada també ha madurat a passos forçats durant l'última dècada, i cada vegada s'han imposat més requisits relatius a la seva privacitat i seguretat. L'any 2000 va ser la Llei orgànica de protecció de dades de caràcter personal (LOPD), d'àmbit espanyol, i en vigor des del 2018, i ja més evolucionat, el Reglament general de protecció de dades (RGPD), d'àmbit europeu.

Aquests requisits sobre la dada han donat lloc a models de govern per a la seva gestió més enllà dels aspectes purament tecnològics, i han nascut els anomenats models de governança de dades.

La governança de dades proporciona un enfocament global per administrar, millorar i aprofitar la informació d'una organització, generada típicament per moltes unitats de negoci i departaments, de manera que hi regeixin unes regles unificades sobre la seva qualitat (com ara estandardització i format, entre d'altres), metadades (la informació descriptiva de la dada que permet tenir-ne un coneixement), seguretat i alineament tecnològic. També cal poder donar traçabilitat a la gestió de la dada per poder tenir capacitat d'auditar-la, cosa que se sol conèixer com a *data lineage*.<sup>28</sup>

28 <https://www.ibm.com/topics/data-lineage>

29 <https://www.dama.org/>

30 <https://www.gartner.com/en/documents/3975624>



les organitzacions, cada unitat de negoci acaba tenint més empoderament sobre les dades que gestiona i l'ús que en vol fer (n'és el propietari), de manera que no és estrany que se segueixi produint la descentralització i la dispersió d'entorns de dades amb tecnologies diferents i models de gestió també diferents.

El 2019, Zhamak Dehghani va definir el concepte *data mesh* [25] mentre treballava a l'empresa de consultoria Thoughtworks.<sup>31</sup> En el model *data mesh* les dades s'organitzen al voltant dels propietaris de dominis de negoci i de les dades que produeixen. Aquestes dades, ben preparades, esdevenen *productes de dades*. Aquests productes s'han de proporcionar juntament amb els mecanismes necessaris per poder-los consumir, de manera que no és tan rellevant com s'implementa tècnicament el producte, sinó com s'hi accedeix. Això defineix una xarxa de productes de dades que són consumits per consumidors finals o per altres productes de dades i crea el *mesh*.

El producte de dades no és només la dada en si mateixa, sinó tots els processos necessaris per proveir-lo, és a dir, les fonts de dades que consumeix, els mitjans i els processos per integrar-les (ETL-ELT), els mitjans d'emmagatzemament i, finalment, els mitjans habilitats perquè sigui consumit (típicament una API o *Application Programming Interface*). Aquest producte ha de poder estar governat adequadament, amb manteniment i desplegament de noves versions si escau, amb la qual cosa apareix el nou concepte: el *DataOps*.<sup>32</sup> El model de generació de productes de dades és el que també entenem com a *Data Fabric*.<sup>33</sup>

Aquest paradigma allunya la necessitat de tenir un gran sistema analític que integri fonts de dades transaccionals en un *data lake* que proveeixi totes les respostes de les preguntes de negoci de manera transversal a l'organització, sinó que són les mateixes unitats de negoci les que generen els seus productes de dades perquè siguin consumits per la resta de l'organització. Val a dir que aquest model requereix un nivell elevat de maduresa organitzacional i cultural al voltant del valor de la dada, a més d'una organització altament alineada amb el model. Com a millors implementacions d'aquest model, podem esmentar alguns dels dominadors del món digital, com Netflix [26].

## Conclusions

Al llarg dels anys, els models de gestió de dades i les eines per desplegar-los i implementar-los han anat evolucionant a una velocitat vertiginosa. L'ecosistema de la dada fa tan sols vint anys era completament diferent de l'actual.

La dada ja es percep, excepte en alguns casos, com un actiu que cal gestionar. Però per tal d'aprofitar-ne el potencial, cal una estratègia sòlida i transversal (des de la seguretat i l'estructura de l'organització al voltant de la dada fins a l'elecció de les tecnologies correctes), però prou flexible per adaptar-se als canvis i als nous models, i sens dubte, un factor diferencial continua sent les persones i el canvi cultural relatiu al valor de la dada que cal impulsar internament.

L'explosió de la dada també ha transformat l'ecosistema professional a un nivell d'especialització difícilment imaginable fa uns quants anys. L'expert en el tractament de dades o mètodes numèrics tradicional era qui aglutinava una gran part de les tasques en la gestió de la dada, i els equips d'IT eren els que en gestionaven l'emmagatzemament. Aquests rols han derivat en altres perfils molt més especialitzats: el disseny d'arquitectures de dades el duu a terme l'arquitecte de dades, i el disseny dels sistemes de processament distribuït el fa l'arquitecte big data.

La integració de dades i el seu processament massiu han donat lloc a l'enginyeria de dades, una de les especialitzacions amb més demanda en el mercat professional,<sup>34</sup> fins i tot més que el científic de dades. I és que no totes les empreses i organitzacions tenen requisits de negoci que es resolguin amb models de *machine learning* o intel·ligència artificial, però gairebé totes necessiten l'accés a la dada i el seu tractament per a qualsevol cas de negoci. I, tanmateix, el científic de dades ara té un perfil molt més tecnològic, menys focalitzat en mètodes matemàtics i més avesat a utilitzar tecnologies capdavanteres, com les eines per al *deep learning*.

El futur probablement tendirà a fer madurar l'ús de la intel·ligència artificial en altres àmbits, més enllà dels casos en què actualment té més aplicabilitat (la visió artificial i els models de llenguatge), tot esperant que l'ús d'aquestes tecnologies tingui un retorn més tangible en els casos de negoci, i posant a produir els models de *machine learning* més enllà de les proves de concepte actuals, tan habituals en les organitzacions. Així, l'MLOps<sup>35</sup> és una altra tendència que les organitzacions més avançades en l'àmbit de la intel·ligència artificial estan adoptant, de la qual tindrem probablement una resposta en els pròxims cinc anys.

Fins aleshores, la realitat és que la gran majoria de les organitzacions encara estan en el procés de migració dels sistemes tradicionals monolítics *datawarehouses* per a intel·ligència de negoci a *data lakes* i big data al núvol, i avaluant proves de concepte en l'aplicació del *machine learning* a casos de negoci de petit abast.

<sup>31</sup> <https://www.thoughtworks.com/>

<sup>32</sup> [https://s3.amazonaws.com/eckerson/content\\_assets/assets/000/000/195/original/DataOps.pdf?1534882627](https://s3.amazonaws.com/eckerson/content_assets/assets/000/000/195/original/DataOps.pdf?1534882627)

<sup>33</sup> <https://www.gartner.com/smarterwithgartner/data-fabric-architecture-is-key-to-modernizing-data-management-and-integration>

<sup>34</sup> <https://www.linkedin.com/pulse/data-engineering-great-career-move-2022-saikat-dutta>

<sup>35</sup> <https://ml-ops.org/>

## Bibliografia

ARMBRUST, M.; XIN, R. S.; LIAN, C. [et al.] «Spark SQL: Relational Data Processing in Spark». *SIGMOD'15*, 2015, p. 1383-1394.

BRIN, S.; PAGE, L. «The Anatomy of a Large-scale Hypertextual Web Search Engine». *Computer Networks and ISDN Systems*. Núm. 30, 1998, p. 107-117. Stanford: Elsevier Science B.V. doi: 10.1016/S0169-7552(98)00110-X.

CODD, E. F. «A Relational Model of Data for Large Shared Databanks». *Communications of the ACM*. Vol. 13, num. 6, 1970, p. 377-387.

CODD, E. F.; CODD, S. B. y SALLEY, C. T. «Providing OLAP to user-analysts: An IT mandate», E. F. Codd and Associates, 1993, p. 1003.

CUNNINGHAM, J. «Netflix Data Mesh: Composable Data Processing - Justin Cunningham» [en línia]. 28 d'abril 2020. <[https://www.youtube.com/watch?v=TO\\_liN06jj4](https://www.youtube.com/watch?v=TO_liN06jj4)> [Consulta: 25, setembre, 2020].

DATE, C. J. «An Introduction to Database Systems». 6a edició, Addison Wesley, 1995.

DEAN, J.; GHEMAWAT, S. «MapReduce: Simplified Data Processing on Large Clusters». *Communications of the ACM*. Vol. 51, núm. 1, 2008, p. 107-113.

DEHGHANI, Z. «How to Move Beyond a Monolithic Data Lake to a Distributed Data Mesh». [martinFowler.com](http://martinfowler.com), 20 de maig, 2019; <<https://martinfowler.com/articles/data-monolith-to-mesh.html>>.

DEKA GANESH C. «BASE analysis of NoSQL database». *Future Generation Computer Systems* [en línia]. Vol. 52, 2015, p. 13-21. <<https://doi.org/10.1016/j.future.2015.05.003>>.

ENGLAND, C. «The Cray Y-MP EL: An overview». *Ressurrection*. Núm. 93, 2021.

GHEMAWAT, S.; GOBIOFF, H.; LEUNG S. «The Google File System». *ACM SIGOPS Operating Systems Review*. Vol. 37, núm. 5, 2003, p. 29-43.

GRAY, J. «Data Management: Past, Present, and Future». *IEEE Computer* Vol. 29, núm. 10, 1996, p. 38-46.

HAERDER, T.; REUTER, A. «Principles of Transaction-Oriented Database Recovery». *ACM Computer Surveys*. Vol. 15, núm. 4, 1983, p. 287-317.

HONGWEI, S. «Seymour Cray: The Father of World Supercomputer». *History Research*. Vol. 7, núm. 1, 2019, p. 1-6. <doi: 10.11648/j.history.20190701.11>.

IDREOS, S.; DAYAN, N.; QIN, W.; [et al.] «Learning Key-Value Store Design». *ArXiv*, 2019 <doi: abs/1907.05443>.

KEEN, P. G. W. «Decision support systems: a research perspective». Cambridge, Massachusetts: Center for Information Systems Research, Alfred P. Sloan School of Management, 1980.

KREPS, J. «Questioning the Lambda Architecture,» *O'Reilly.com* [en línia]. 2014. <[www.oreilly.com/ideas/questioningthe-lambda-architecture](http://www.oreilly.com/ideas/questioningthe-lambda-architecture)>.

LANEY, D. «3D Data Management: Controlling Data Volume, Velocity, and Variety», *META Group* [en línia]. Núm. 949, 2001.

LYNCH, N.; GILBERT, S. «Brewer's conjecture and the feasibility of consistent, available, partition-tolerant web services». *ACM SIGACT News*, Vol. 33, núm. 2, 2002, p. 51-59.

MARZ, N.; WARREN, J. *Big Data: Principles and best practices of scalable real time data systems*. Shelter Island: Manning Publications Co, 2015.

MELTON, J.; SIMON, A. R. «Understanding the New SQL: A Complete Guide». 1a edició. San Francisco: Morgan Kauffman, 1993.

MENG, X.; BRADLEY, J.; YAVUZ, B.; [et al.] «MLlib: Machine Learning in Apache Spark. *Journal of Machine Learning Research (JMLR)*». Núm. 17, 2016, p. 1-7.

XIN, R. S.; ROSEN, J.; ZAHARIA, [et al.] «Shark: SQL and Rich Analytics at Scale». *SIGMOD'13*, 2013.

ZAHARIA, M.; CHOWDHURY, M.; DAS, T.; [et al.] «Resilient Distributed Datasets: A Fault-Tolerant Abstraction for In-Memory Cluster Computing». *NSDI'12*, 2012.

ZAHARIA, M.; CHOWDHURY, M.; FRANKLIN, M. J.; [et al.] «Spark: Cluster Computing with Working Sets». *HotCloud'10*, 2010.

ZAHARIA, M.; DAS, T.; LI, H.; [et al.] «Discretized Streams: Fault-Tolerant Streaming Computation at Scale». *SOSP'13*, 2013.