




Corsi di preparazione concorsi interni - ruolo tecnico

Metodologie e strumenti per l'analisi dei dati
– Advanced Analytics






Big Data & Data Science

Business intelligence vs. advanced analytics

	BUSINESS INTELLIGENCE	ADVANCED ANALYTICS
Answers the questions:	<ul style="list-style-type: none"> ■ What happened? ■ When? ■ Who? ■ How many? 	<ul style="list-style-type: none"> ■ Why did it happen? ■ Will it happen again? ■ What will happen if we change x? ■ What else does the data tell us that we never thought to ask?
Includes:	<ul style="list-style-type: none"> ■ Reporting (KPIs, metrics) ■ Automated monitoring and alerting (thresholds) ■ Dashboards ■ Scorecards ■ OLAP (cubes, slice and dice, drilling) ■ Ad hoc query ■ Operational and real-time BI 	<ul style="list-style-type: none"> ■ Statistical or quantitative analysis ■ Data mining ■ Predictive modeling ■ Multivariate testing ■ Big data analytics ■ Text analytics

40 ZETTABYTES

[43 TRILLION GIGABYTES]
of data will be created by
2020, an increase of 300
times from 2005



**6 BILLION
PEOPLE**
have cell phones



WORLD POPULATION: 7 BILLION

Volume SCALE OF DATA

It's estimated that
2.5 QUINTILLION BYTES
[2.3 TRILLION GIGABYTES]
of data are created each day



2020

2005

Most companies in the
U.S. have at least
100 TERABYTES
[100,000 GIGABYTES]
of data stored

The New York Stock Exchange
captures

**1 TB OF TRADE
INFORMATION**
during each trading session



Velocity ANALYSIS OF STREAMING DATA

Modern cars have close to
100 SENSORS
that monitor items such as
fuel level and tire pressure



By 2016, it is projected
there will be

**18.9 BILLION
NETWORK
CONNECTIONS**

- almost 2.5 connections
per person on earth



The FOUR V's of Big Data

From traffic patterns and music downloads to web history and medical records, data is recorded, stored, and analyzed to enable the technology and services that the world relies on every day. But what exactly is big data, and how can these massive amounts of data be used?

As a leader in the sector, IBM data scientists break big data into four dimensions: **Volume**, **Velocity**, **Variety** and **Veracity**.

Depending on the industry and organization, big data encompasses information from multiple internal and external sources such as transactions, social media, enterprise content, sensors and mobile devices. Companies can leverage data to adapt their products and services to better meet customer needs, optimize operations and infrastructure, and find new sources of revenue.

By 2015
4.4 MILLION IT JOBS
will be created globally to support big data,
with 1.9 million in the United States



As of 2011, the global size of
data in healthcare was
estimated to be

150 EXABYTES

[161 BILLION GIGABYTES]



Variety DIFFERENT FORMS OF DATA

**30 BILLION
PIECES OF CONTENT**

are shared on Facebook
every month




By 2014, it's anticipated
there will be

**420 MILLION
WEARABLE, WIRELESS
HEALTH MONITORS**

4 BILLION+
HOURS OF VIDEO

are watched on
YouTube each month



400 MILLION TWEETS

are sent per day by about
200 million monthly active users



1 IN 3 BUSINESS LEADERS

don't trust the information
they use to make decisions



Poor data quality costs the US
economy around

\$3.1 TRILLION A YEAR




**27% OF
RESPONDENTS**

in one survey were unsure of
how much of their data was
inaccurate

Veracity UNCERTAINTY OF DATA

Defining Big Data

- **Gartner:** High-volume, high-velocity, and/or high-variety information assets that require new forms of processing to enable enhanced decision-making, insight discovery and process optimization.
- **IBM:** Datasets whose size is beyond the ability of typical database software tools to capture, store, manage, and analyze.
- **NY Times:** Shorthand for advancing trends in technology that open the door to a new approach to understanding the world and making decisions.
- **McKinsey:** Large pools of data that can be brought together and analyzed to discern patterns and make better decisions



Artificial Intelligence


Any technique which enables computers to mimic human behavior.

Machine Learning

Subset of AI techniques which use statistical methods to enable machines to improve with experiences.


Deep Learning

Subset of ML which make the computation of multi-layer neural networks feasible.



Hype Cycle Analytics & BI

Hype Cycle for Analytics and Business Intelligence, 2019



Big Data in Banca d'Italia



29^a Conferenza (EC)² su “Big Data Econometrics with Applications”

Apertura dei lavori del Direttore Generale della Banca d’Italia
e Presidente dell’IVASS

Salvatore Rossi

Roma, 13 Dicembre 2018

Appare sempre più chiaro, tuttavia, che i *big data* potrebbero segnare la fine dell’econometria così come la conosciamo. La raccolta di dati provenienti dai *social media* ha generato basi di dati sui comportamenti e sulle interazioni degli agenti economici che, ancorché non strutturate, presentano un’ampiezza e una complessità senza precedenti. Tutto ciò si sta rivelando una miniera d’oro in termini di informazione economica.

La Banca d’Italia, in ragione della molteplicità delle funzioni che svolge, segue con estrema attenzione l’evoluzione delle piattaforme *big data*. Queste saranno oggetto di un seminario organizzato in collaborazione con la Banca dei Regolamenti Internazionali il prossimo 15 gennaio qui a Roma.

Negli ultimi anni abbiamo fatto passi avanti nel nostro percorso di apprendimento. Abbiamo coniugato competenze economiche, econometriche, statistiche e informatiche per lavorare con dati in continua crescita in termini di volumi, eterogeneità e velocità. Li abbiamo utilizzati per stimare la disoccupazione e l’inflazione, per migliorare le nostre previsioni economiche, per misurare il clima di fiducia di consumatori e imprese.

L'authority. Il vice dg Fabio Panetta: sui social per monitorare le attese di inflazione

Bankitalia vigila anche su Twitter: «Faro sulla fiducia dei depositanti»

Davide Colombo

ROMA

■ Alla strumentazione tradizionale utilizzata da Bankitalia per misurare le aspettative di inflazione o valutare la fiducia dei risparmiatori si aggiungono ora i Big data e il monitoraggio diretto dei social network. Lo ha annunciato ieri il vice direttore generale, Fabio Panetta nel suo intervento di saluto

anche per analisi di impatto delle politiche economiche o per

IL TREND

La Banca d'Italia ha costituito un proprio team sui Big data che include statistici, economisti e informatici per affrontare analisi innovative

(qui il riferimento di Panetta è stato all'enorme volume di dati granulari raccolto dal Ssm sui singoli prestiti degli istituti oppure sulla rendicontazione statistica del mercato monetario giornaliero da parte del Sistema europeo di banche centrali e sui depositi commerciali previsti dal regolamento europeo sulle infrastrutture di mercato).



WIRED.it

Sezioni ▾

Wired Health ▾

□ Gallery ▾

▶ Video



HOT TOPIC CAMBRIDGE ANALYTICA DEPOSITO NUCLEARE APPLE GUIDA AUTONOMA CASO SKRIPAL GOOGLE HOME FACEBOOK XYLELLA...

VEDI TUTTI ▶



di Pietro Deragni
26 MAR, 2018

La Banca d'Italia studia i nostri tweet per prevedere l'inflazione

Bankitalia ha un team digitale che monitora i social media per prevedere gli effetti sulla fiducia dei consumatori e sui prezzi degli immobili. Analisi anche sulla stabilità finanziaria



Il commento

Banca d'Italia suona la sveglia su Big Tech e Big Data

di **Daniele Manca**

Siamo abituati a parlare dell'Italia come un Paese immobile. E sicuramente lo siamo in molti settori. Ma a giudicare dal workshop organizzato dalla Banca d'Italia sui Big Data, qualcosa si sta muovendo sul fronte dell'innovazione. Di

modificando e influenzando i comportamenti. Il 40% delle persone nel nostro Paese hanno accesso al conto bancario, e molti ormai acquistano, attraverso lo smartphone. Utilizzando i dati che noi depositiamo sulle varie piattaforme e tramite l'intelligenza artificiale, le big tech sono in grado di analizzare e indicare comportamenti e aspettative dei consumatori. Cosa che le banche dovranno imparare in fretta a fare. Basta guardare a come si sono mossi i nuovi attori nel sistema dei pagamenti da PayPal alle nuove nate Satispay ma

SUPTECH - ANALISI ESPOSTI

Progetto 908-P0691

Classe 2 - Priorità 804



GPDp

GARANTE
PER LA PROTEZIONE
DEI DATI PERSONALI

Dipartimento Tutela della clientela ed educazione finanziaria
SERVIZIO TUTELA INDIVIDUALE DEI CLIENTI


Realizzazione di un'applicazione, denominata EspTech, a sostegno delle attività di ricerca e indagine conoscitiva sugli esposti privatistici pervenuti alla Banca e di identificazione precoce di fenomeni emergenti d'interesse per la vigilanza.

Parere alla Banca d'Italia sullo schema di regolamento concernente il trattamento dei dati personali effettuato nell'ambito della gestione degli esposti - 24 febbraio 2022 [9751895]

VEDI ANCHE [Newsletter del 14 marzo 2022](#)

[doc. web n. 9751895]

Parere alla Banca d'Italia sullo schema di regolamento concernente il trattamento dei dati personali effettuato nell'ambito della gestione degli esposti - 24 febbraio 2022



L'iniziativa soddisfa esigenze nell'ambito **FinTech**.



Studio: dal 1 gennaio 2020 al 15 giugno 2020

Realizzazione: dal 1 luglio 2020 al 31 luglio 2021

ALCUNE INIZIATIVE IN CORSO

Migrazione delle basi dati CERVED/CEBIL e CSDB - (studio di progetto in corso)	Archiviazione delle basi dati CEBIL e CSDB su piattaforma <i>Big Data</i>
Creazione di un archivio INPS - (realizzazione in corso)	Archiviazione dell'archivio INPS su piattaforma <i>Big Data</i>
Caricamento dati PATSTAT su piattaforma <i>Big Data</i> - (realizzazione in corso)	Archiviazione su piattaforma <i>Big Data</i> (<i>Data Science Lab</i>) dei dati sui brevetti europei del database PATSTAT
Realizzazione piattaforma tecnologica per <i>Artificial Intelligence</i> e <i>Machine Learning</i> - (realizzazione in corso)	Introduzione di <i>tools</i> per <i>data science</i>
Introduzione strumenti di <i>graph analysis</i> in RADAR - (realizzazione in corso)	Soluzioni innovative di <i>graph analysis</i> e di analisi visuale
Progetto di sfruttamento del patrimonio informativo della Tesoreria - (realizzazione in corso)	Utilizzo del <i>Data Lake</i> come piattaforma di archiviazione dei dati e di sfruttamento con tecniche avanzate di data science

DIPARTIMENTO VIGILANZA BANCARIA E FINANZIARIA

SERVIZIO SUPERVISIONE BANCARIA 1

▶ AUTOMAZIONE VERIFICA FAP (908-P0693) P ↔

70

SERVIZIO ISPETTORATO VIGILANZA

▶ FINDINGS AUTOMATION (911-P0015) P F

71

SERVIZIO SUPERVISIONE BANCARIA 2


▶ CORPORATE GOVERNANCE ANALYSIS (911-P0016) P F

72

Sperimentazioni di **tecnologie di frontiera**:

- Sperimentazione di algoritmi e modelli di *machine learning*
 - Studio e applicazione delle tecnologie di *automated reasoning* e dei *knowledge graph*
 - Sostegno allo sviluppo di servizi in ambito finanziario ad alto contenuto tecnologico
-
- Realizzazione di un prototipo per l'euro digitale, nell'ambito della fase di *investigation* sulla CBDC europea avviata e coordinata dalla BCE
 - Sperimentazione di soluzioni DLT per offrire servizi condivisi per la produzione di dati statistici a livello europeo (iniziativa IReF)
 - Sperimentazione di soluzioni per l'interoperabilità di TIPS con altre infrastrutture di mercato (TIPS-HashLink, Buna, progetto Nexus)

Enterprise Architecture View



Big Data Platforms


"Big data platform generally consists of big data storage, servers, database, big data management, business intelligence and other big data management utilities. It also supports custom development, querying and integration with other systems. The primary benefit behind a big data platform is to reduce the complexity of multiple vendors/solutions into a one cohesive solution. Big data platform are also delivered through cloud where the provider provides an all inclusive big data solutions and services." [source: Techopedia]



Benefici delle piattaforme BD


- Gestire volumi elevati di dati a costi ridotti e con alte prestazioni (date lake, data staging, archiving, streaming, EDW extension, etc.)
- Superare le limitazioni prestazionali dei db relazionali
- Abilitare analisi e applicazioni di nuova tipologia (p.e. text analytics, machine learning)

PIATTAFORMA INTEGRATA + Sicurezza




Schema on-read

Schema On-Write	Schema On-Read
Structured Data	Un-Structured Data
OLTP & OLAP systems	Big Data & NoSQL systems
Heavy ETL tool's role in staging and moving data	Very low ETL tool involvement
Modification of data model is costly	Schema is just a structured file, can be switched dynamically
Works well in small data sets.	Ideal for large volumes of data
User knows exactly what he/she is looking for	User is exploring the data without predefined questions



Open Source Is Here to Stay — Technologies Adopted by Data Science Teams




Data Science Deconstructed




Where to Put the Data Scientists?

Data Scientists @ LOBs




Data Scientists @ IT



Data Scientists as Separate BU




Scattered Experts



- Business Intimacy
- Knowledge Sharing
- Agility
- Cross-Functional View
- Proximity to Process and Data

Data Science Lab/CoE



Source: "Organizational Principles for Placing Data Science and Machine Learning Teams," (G00325989)

DS = Data Science; LOB = Line of Business

Taming the «Wild West» of Big Data



Issues

- **Data scientists waste time on DevOps work.** Data scientists are precious, highly paid people, yet they often must spend 25% of their time dealing with DevOps tasks like installing packages and moving files between machines.
- **Data scientists waste time duplicating effort and reinventing the wheel.** Beyond individual data scientists wasting time on DevOps, entire teams can waste time pursuing projects that reinvent the wheel or don't build upon past organizational knowledge, because that past work was siloed and undiscoverable.
- **Important business processes become dependent on unreliable infrastructure.** Data scientists will often set up scheduled jobs to run on their own local machines, or operate shared servers as "lab" or "dev" machines.
- **Compute costs can become excessive and uncontrolled.** Unlike BI, data science involves computationally intensive techniques, which demand high-powered machines and specialized resources like GPUs. Especially in a cloud environment, data scientists in the wild west can unintentionally burn thousands of dollars a month by leaving expensive machines running unnecessarily.
- **High-value intellectual property is improperly secured.** Predictive models and analyses can encapsulate insights key to competitive advantage, and that work is often scattered throughout network drives, wikis, or Sharepoint sites.

Solution

- **Self-service infrastructure**, so data scientists can do exploratory data analysis and model development without configuring and using their own compute resources. The data science platform encompasses compute resources—as well as the languages, packages and tools necessary for modern data science work—with controls and reporting around resource usage to administer or attribute costs.
- **Ways to deploy, productionize or operationalize finished models**, instead of driving data scientists to set up shadow systems. This includes deploying models to power scheduled jobs, reports, APIs or dashboards in one place. The data science platform also provides a consistent baseline of non-functional requirements (security, HA, etc.) and a catalog that offers transparency into assets and utilization across the enterprise.
- **Governance, collaboration and knowledge management** around all the artifacts created in the process of the research and deployment work described above.


REALIZZAZIONE DI UN ENTERPRISE DATA LAKE ORIENTATO AI DATI STATISTICI

Progetto 908-P0875

Classe 2 - Priorità 688

Dipartimento Economia e statistica
SERVIZIO RILEVAZIONI ED ELABORAZIONI STATISTICHE

Realizzazione di un "Enterprise Data Lake" orientato ai dati statistici che consenta l'archiviazione di basi dati di grandi dimensioni anche con caratteristiche eterogenee (es. dati strutturati, testi, social data) e che faciliti le attività di integrazione e sfruttamento da parte degli utenti tramite metodi e strumenti tipici della data science.



L'iniziativa è stata inserita per la prima volta in Portafoglio.



Studio: dal 1 aprile 2022 al 30 settembre 2022

- Studio di fattibilità Data lake
- GdL principi di Data Governance

TAKEAWAYS

- Differenza tra applicazioni transazionali e informative
- La funzione informatica presidia non solo le basi dati operative e le relative applicazioni, ma anche gli sfruttamenti diretti da parte dell'utente, attraverso la creazione di DW e reportistica predefinita e la disponibilità agli utenti di ambienti evoluti di sfruttamento.
- Il perimetro dei dati oggetto di analisi e la tipologia di analisi si ampliano costantemente e rapidamente → Big Data, AI/ML, ecc.
- Per evitare il «wild west» dei Big Data, sono necessari nuovi strumenti tecnologici e nuovi presidi organizzativi, di sicurezza e di governance. → nuove iniziative ML framework e Data Lake