



Cenni di Piattaforme di Supporto Clustered per Applicazioni Big Data

Università di Bologna
CdS Laurea Magistrale in Ingegneria Informatica
I Ciclo - A.A. 2013/2014

Corso di Sistemi Distribuiti M Scenari di Applicazioni Big Data e Sfide Tecnologiche Aperte per loro Supporto

Docente: Paolo Bellavista
paolo.bellavista@unibo.it

<http://lia.deis.unibo.it/Courses/sd1314-info/>
<http://lia.deis.unibo.it/Staff/PaoloBellavista/>



Data & Data & Data & Management

Centralità dei dati e della gestione di dati

Molti sistemi sono sempre più costituiti e caratterizzati da **enormi moli di dati da gestire**, originati da **sorgenti altamente eterogenee** e con **formati altamente differenziati**, oltre a **qualità estremamente eterogenea (qualità dei dati)**

Esempi tipici:

- ❑ Sistemi distribuiti a larga scala
- ❑ Sistemi mobili
- ❑ Sistemi embedded e Internet of things
- ❑ Sistemi cloud

Tipiche aree applicative:

- ❑ Scenari **smart city**
- ❑ Applicazioni **social**
- ❑ Large-scale **streaming** information
- ❑ Data center e **high-performance computing**
- ❑ **Sistemi e servizi mobili**



Big Data: anche le Aspettative sono Big...

Mercato e investimenti in tematiche Big Data

- ❑ 6.3 billion of USD 2012
 - ❑ 48.3 billion of USD 2018
- atteso **incremento di 45% per anno**
sia da parte di investimenti pubblici che privati

Overall ICT industry market in 2020

- ❑ 5 trillion of USD 2020

Guidato e spinto da piattaforme per Mobile broadband, Social business, servizi Cloud e Big Data management&analytics

Anche grande sforzo EU

Diverse iniziative nel framework **Horizon 2020**, anche connesse alle tematiche **Open and Linked data** (soprattutto dati PA, ...)

Forse Private Public Partnership (PPP) emergente nei prossimi mesi...



All-Data Vision (non solo Big Data)

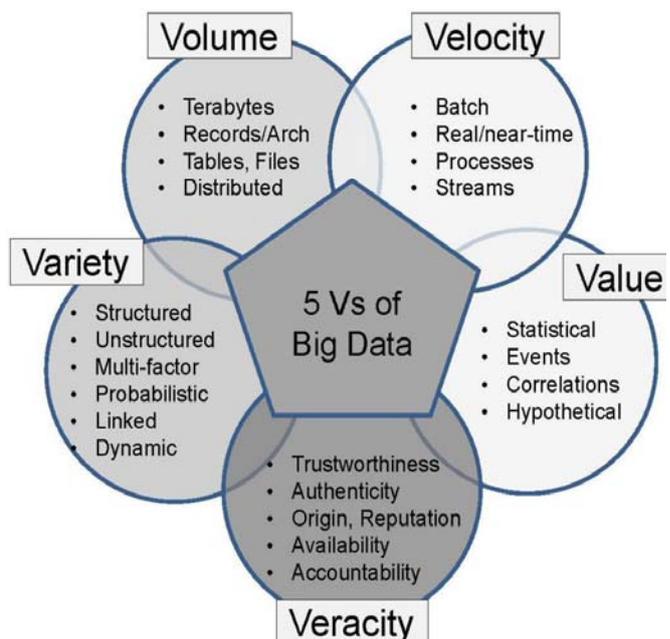
Sistemi informativi richiedono una **visione quality-aware** che possa organizzare e rendere efficiente l'intero **data lifecycle**

5 V per il nuovo processamento e trattamento dei dati

- ❑ **V**olume of Data
- ❑ **V**ariety of Data
- ❑ **V**elocity
- ❑ **V**alue
- ❑ **V**eracity

6 V includendo anche

- ❑ **V**ariability





All-Data Service and Management

Sistemi informativi moderni richiedono **gestione quality-aware e processing workflow ottimizzato** per produrre **nuovi servizi e incrementare data value**

Visione di base unificante: **full set di servizi per arricchire e accompagnare l'intero data lifecycle**

- Modelli, strutture e tipologie di dato
- Data Collection
- Data Processing
- Inferenza e attachment automatico di metadati
- Information Sharing
- Information Maintenance
- Information Archiving
- Information Protection



All-Data Service and Management

Piattaforme integrate e innovative per All-data service richiedono nuovi meccanismi, algoritmi, protocolli e strategie da investigare, anche in aree tecnologiche nuove

- Nuove metodologie, processi e strumenti**
- Causality/correlation sui dati**
- Stream processing**
- Visual Analytics
- Real-time Analytics**
- Sicurezza e data quality (QoS)**
- Mantenimento e archiviazione dei dati
- Nuove architetture hardware e di storage



Big Data: Aree Applicative



- Telephony**
 - CDR processing
 - Social analysis
 - Churn prediction
 - Geomapping
- Stock market**
 - Impact of weather on securities prices
 - Analyze market data at ultra-low latencies
- Law Enforcement, Defense & Cyber Security**
 - Real-time multimodal surveillance
 - Situational awareness
 - Cyber security detection
- Fraud prevention**
 - Detecting multi-party fraud
 - Real time fraud prevention
- e-Science**
 - Space weather prediction
 - Detection of transient event
 - Synchrotron atomic research
- Other**
 - Manufacturing
 - Text Analysis
 - Who's Talking to Whom?
 - ERP for Commodities
 - FPGA Acceleration
- Transportation**
 - Intelligent traffic management
- Smart Grid & Energy**
 - Transactive control
 - Phasor Monitoring Unit
- Health & Life Sciences**
 - Neonatal ICU monitoring
 - Epidemic early warning system
 - Remote healthcare monitoring
- Natural Systems**
 - Wildfire management
 - Water management



Sicurezza e Law Enforcement (1)

- Video sorveglianza, comunicazioni, recording di chiamate (sia voce che email), ..
- Milioni di messaggi al secondo con **bassa densità di dati critici**
- Identificazione di **pattern e relazioni** fra sorgenti di informazioni dal volume imponente e molto numerose

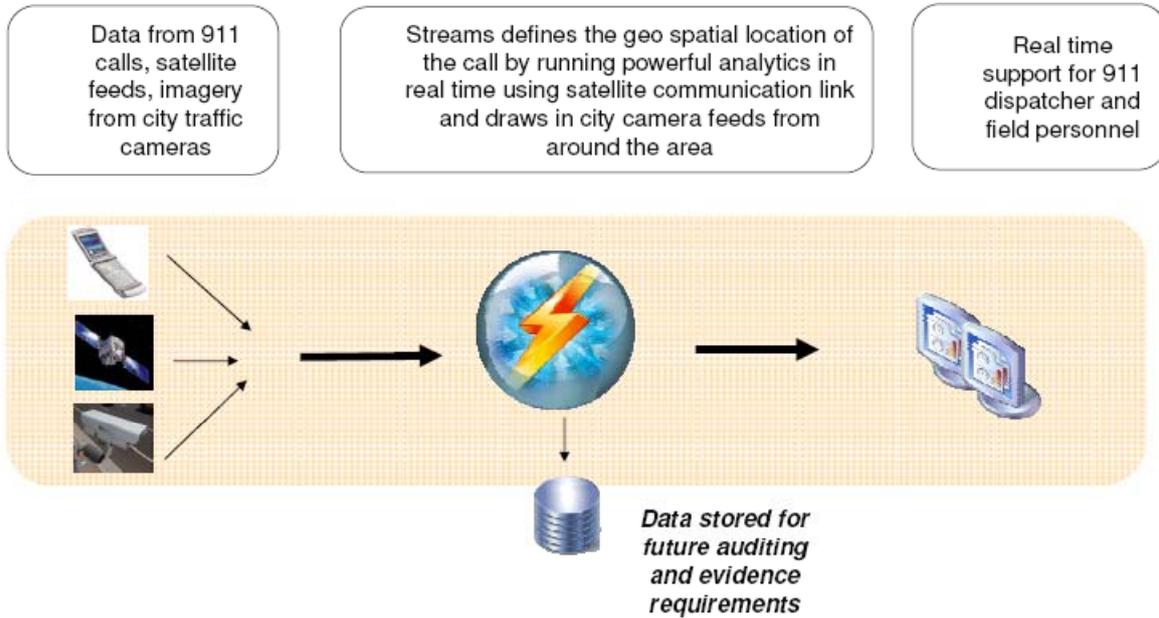


Ad es. US Government e IBM per high-performance analytics ad **alta scalabilità** su **multimedia stream "in motion" di tipo eterogeneo**



Sicurezza e Law Enforcement (2)

Government and Law Enforcement: e911 Support



Forme Avanzate di Customer Relationship Management (1)

Non solo riconoscimento di **problemi comuni** e reperimento info per **determinati utenti/classi di utenti**, ma anche **trend emergenti e "sentiment analysis"**

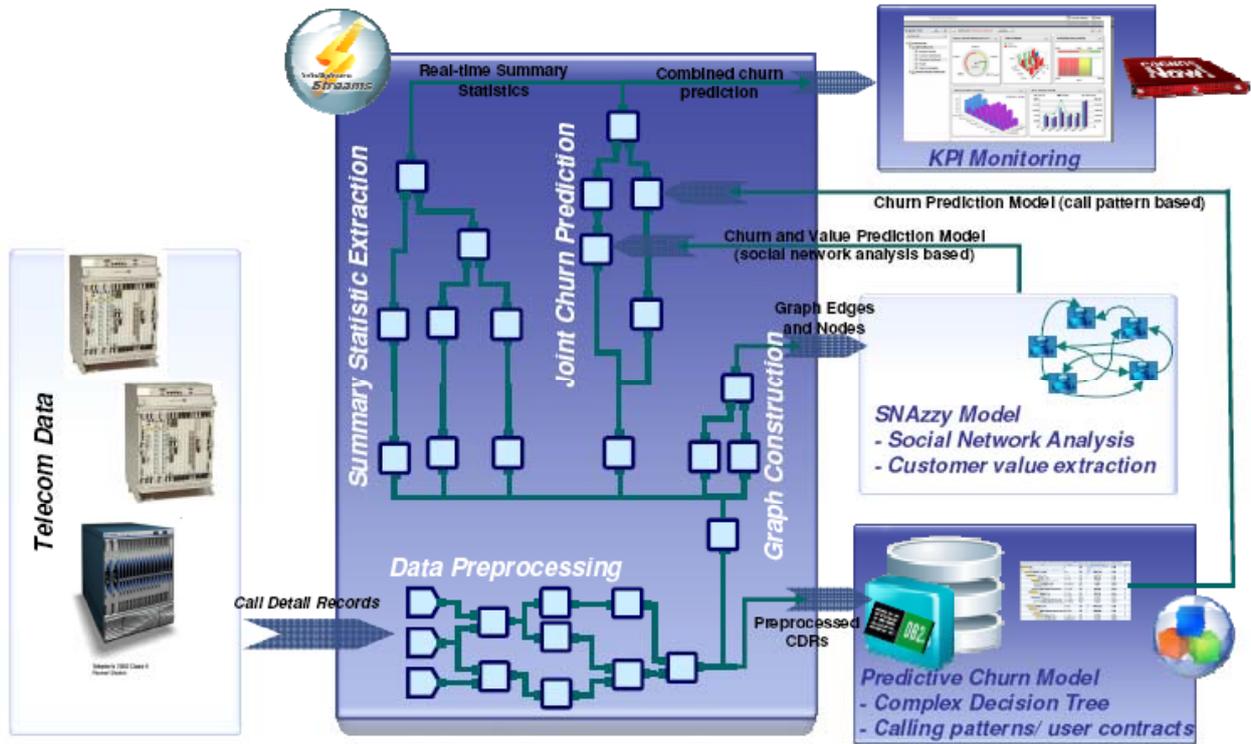
Analysis of Call Detail Records for Customer Retention





Forme Avanzate di Customer Relationship Management (2)

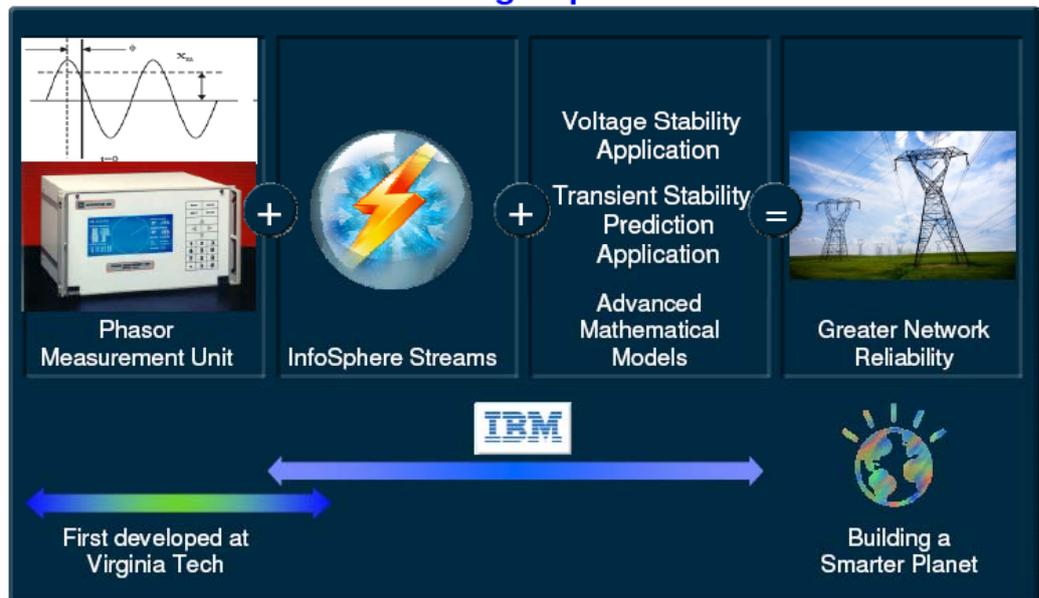
Telephony Architecture



Integrazione e Ottimizzazione Smart Grid (1)

- ❑ Concetto emergente di **smart grid**
- ❑ Anche microgenerazione di energia e difficoltà di storage

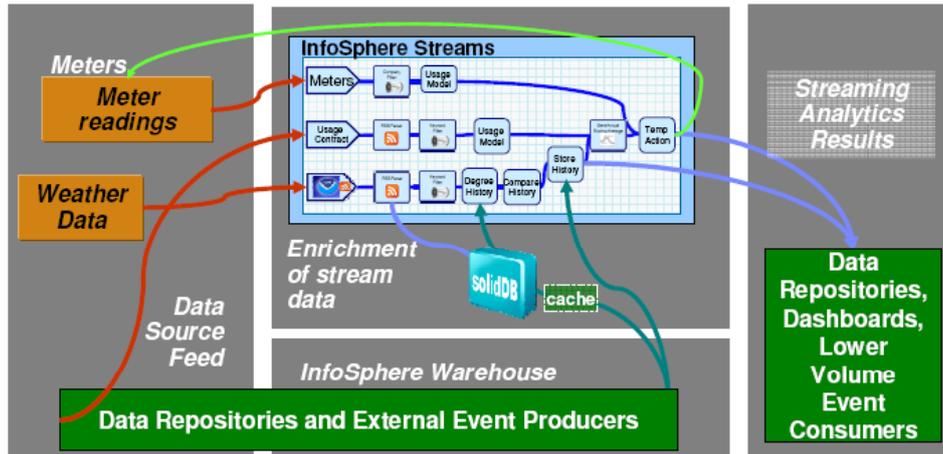
Smart Electric Grid Monitoring to prevent black outs



Importanza della possibilità di inserire **metadata di correlazione** sui flussi in elaborazione

Smarter Utilities

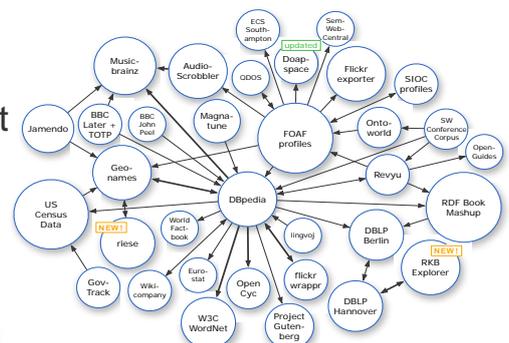
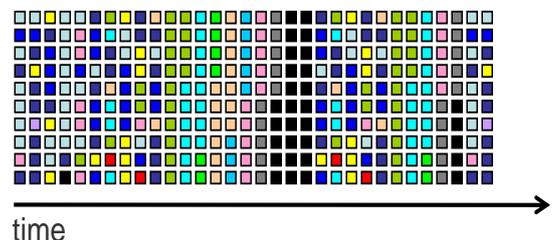
- Analysis of data from multiple sources
- Real-time decisions – lower voltage on hot days



Molte Aree Tecnologiche Coinvolte

Enormi moli di dati, quasi sempre eterogenei, e spesso in **real-time streaming** che devono essere monitorati, con gestione spesso **urgente di situazioni critiche o comunque di interesse**

- ❑ Acquisizione dati da sensori
 - Eterogeneità
- ❑ Tecnologie data streaming
 - Dati statici/dinamici
 - Identificazione e gestione
- ❑ Semantic Web e tecnologie sem. lightweight
 - Linked and Open Data

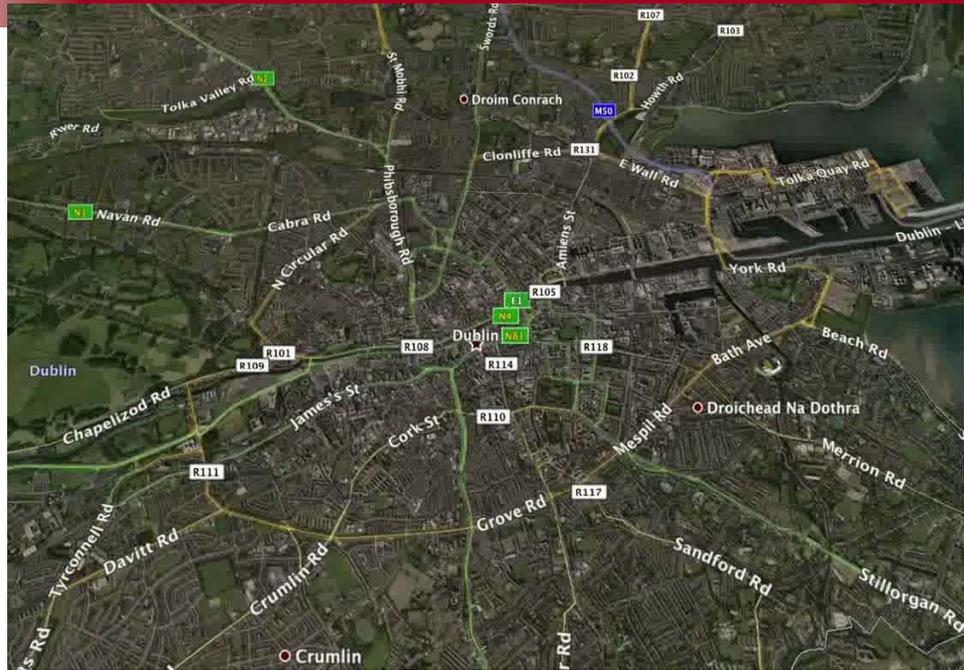




Data Streaming from a Smart City

Sorgenti:

- ❑ Biciclette
- ❑ Noise control
- ❑ Pollution control
- ❑ Punti di interesse
- ❑ Bus
- ❑ Video-camere

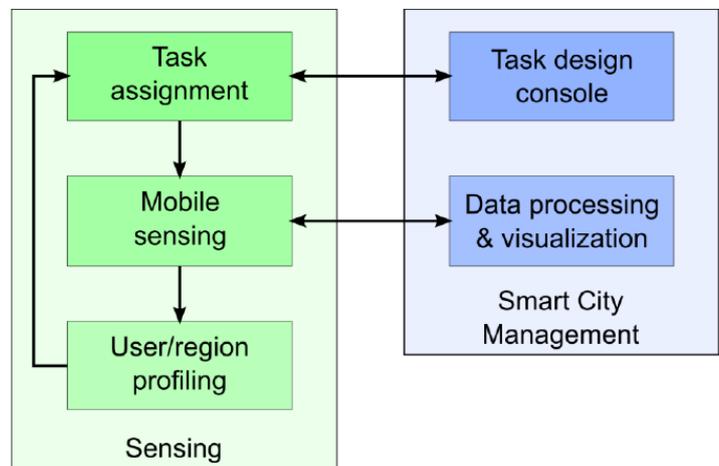


Analisi di alcune tipologie di sorgenti dati dalla città di **Dublino**, per monitorare *con focus variabile alcuni punti di interesse via “selected activated cameras”*

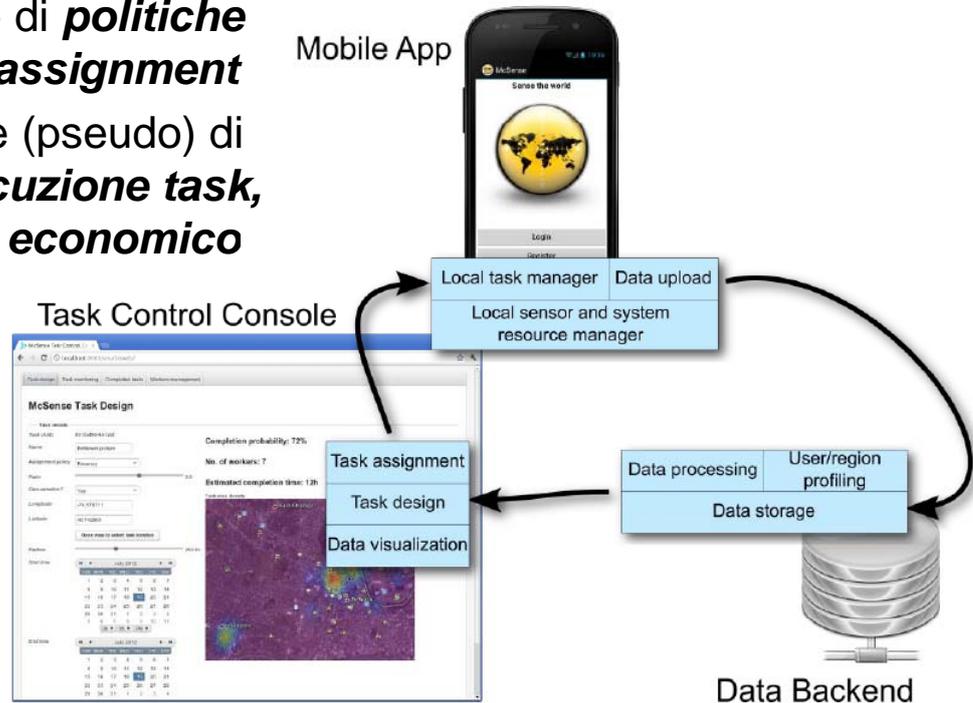


ParticipAction: Crowdsensing

- ❑ Collaborazione con NJIT
- ❑ Disponibilità di buon gruppo di terminali Android e utenti per sperimentazione (300)
- ❑ Monitoring e crowdsensing per smart city
- ❑ **Assegnamento “smart” di task partecipativi**, anche con micro-incentivi economici



- Determinazione e sperimentazione di **politiche smart per task assignment**
- Ottimizzazione (pseudo) di **affidabilità esecuzione task, latenza e costo economico**



Automobili sono esempio potente di **sensori mobili autonomi** e che si possono **coordinare** in modo **lazy** sfruttando comunicazioni wireless



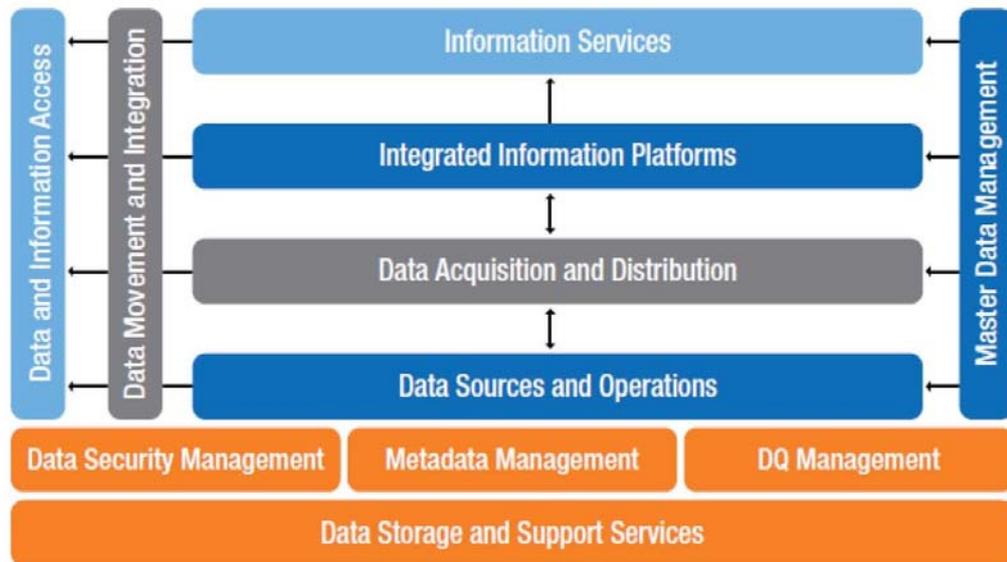
- Automobili operano **sensing opportunistico** nell'ambiente urbano e mantengono dati localmente
 - **Disseminazione collaborativa di metadati** basata su decisioni locali
 - Possibilità di **comportamenti emergenti** per soddisfare **requisiti application-specific** (ad es. completezza query, tempo risposta, overhead, ...)
- Vedi progetto EU FP7 COLOMBO



Sforzi di Standardizzazione Industriale

Standardizzazione industriale almeno delle **architetture emergenti** nelle piattaforme di supporto

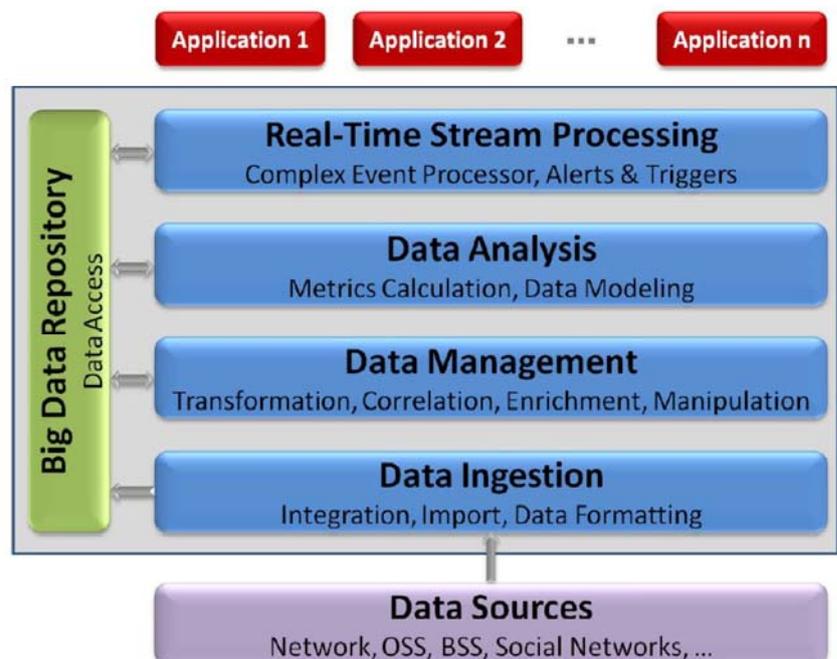
Open Data Center Alliance (ODCA) **for Information as a Service (InfoaaS)**



Sforzi di Standardizzazione Industriale

□ Architettura TMF per Big Data Analytics

□ Strumenti innovativi di analytics per accesso rapido ed efficiente

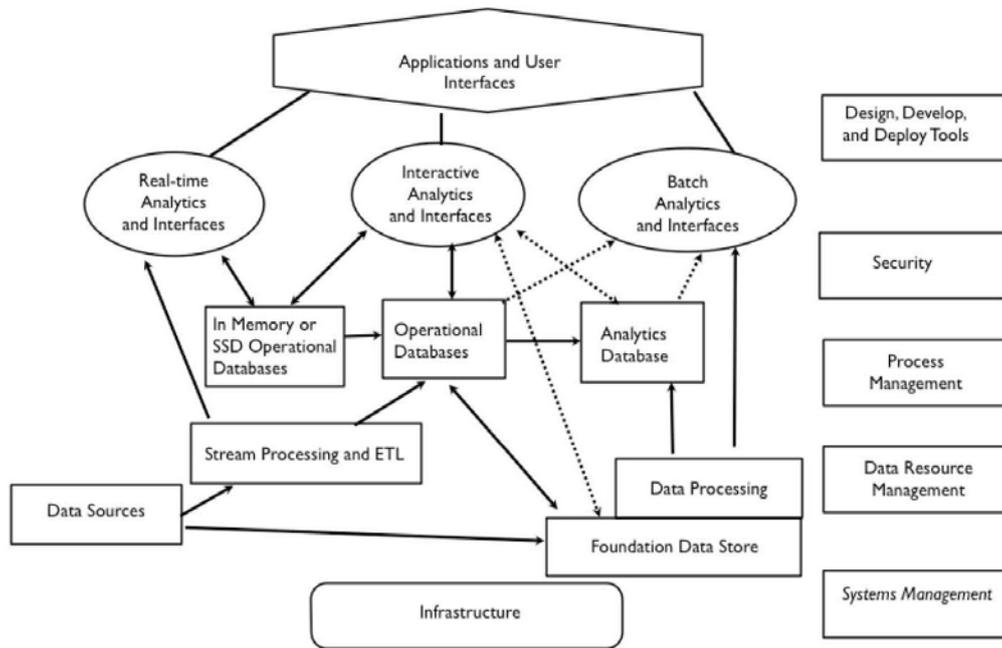




Sforzi di Standardizzazione Industriale

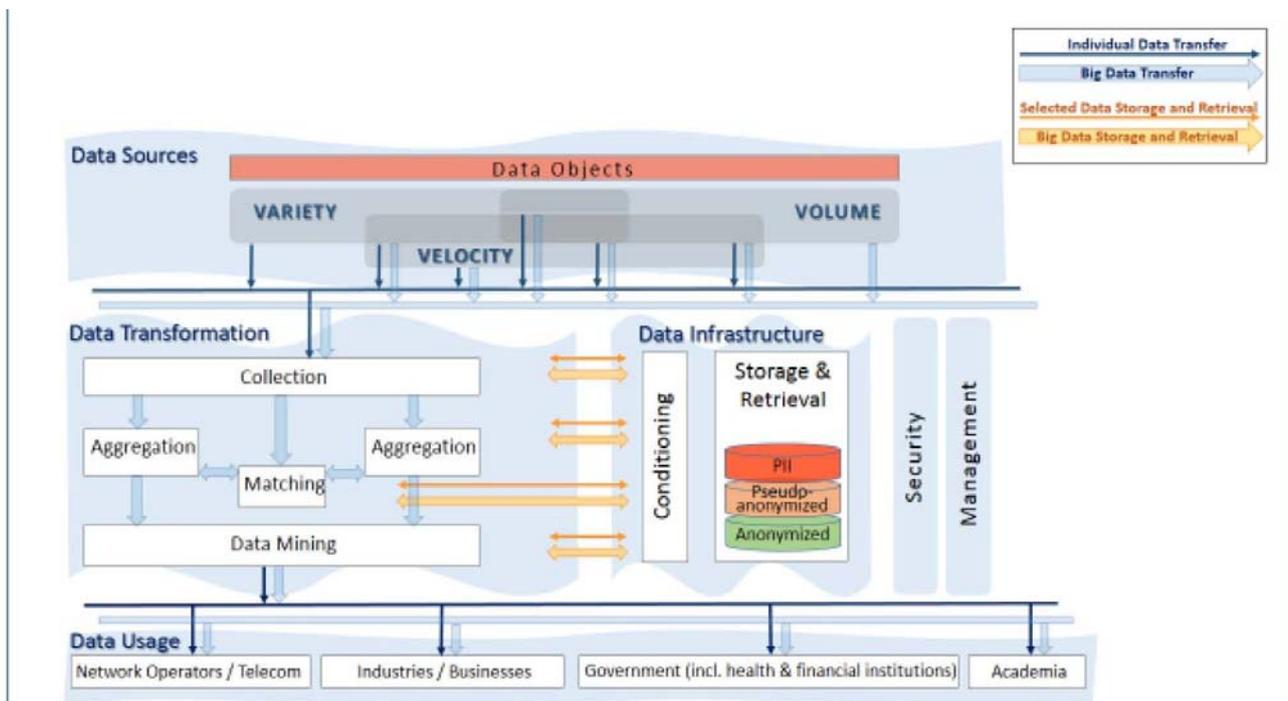
Architettura di riferimento **NIST**

Distinzione fra real-time, interactive e batch



Sforzi di Standardizzazione Industriale

Ovviamente anche Microsoft...

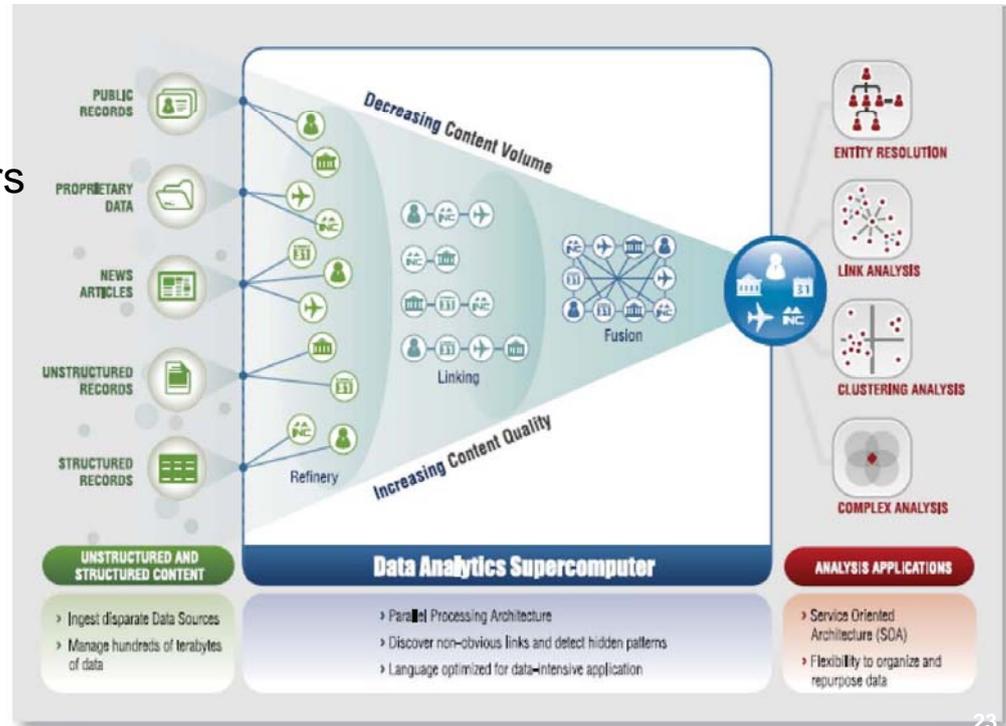




Sforzi di Standardizzazione Industriale

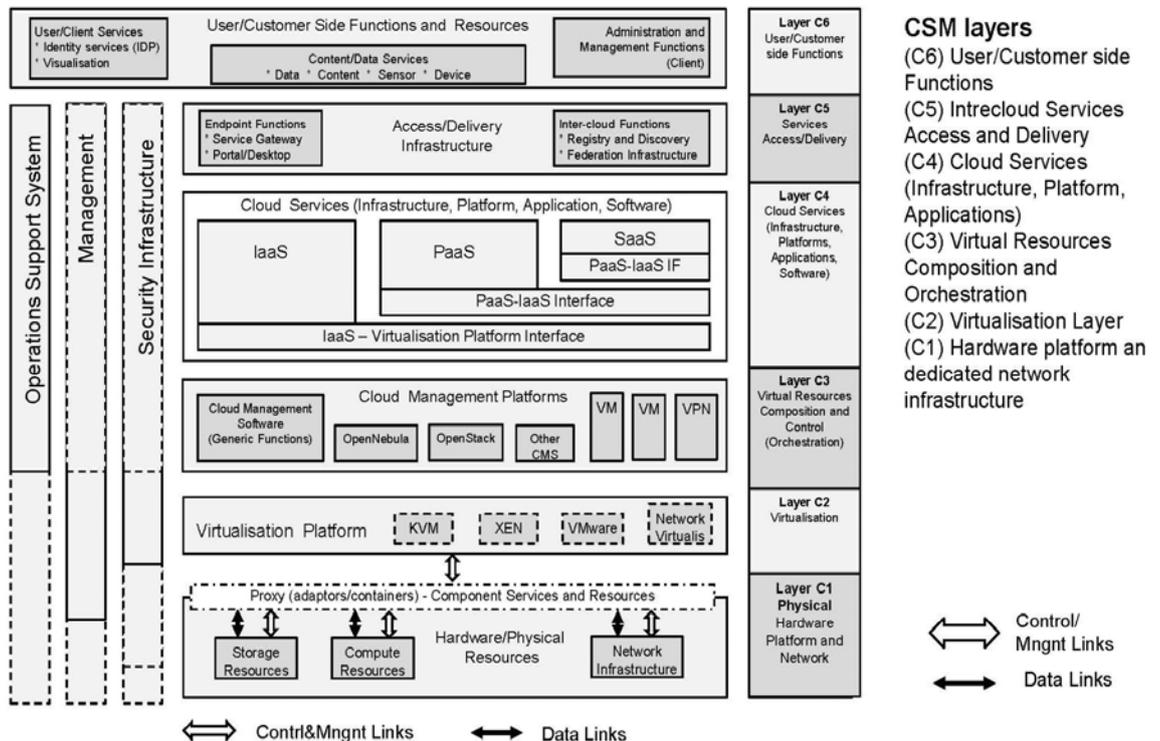
Architettura
Lexis per Data
Analytics
Supercomputers

Idea di **riduzione volumi e incremento qualità**



Sforzi di Standardizzazione Industriale

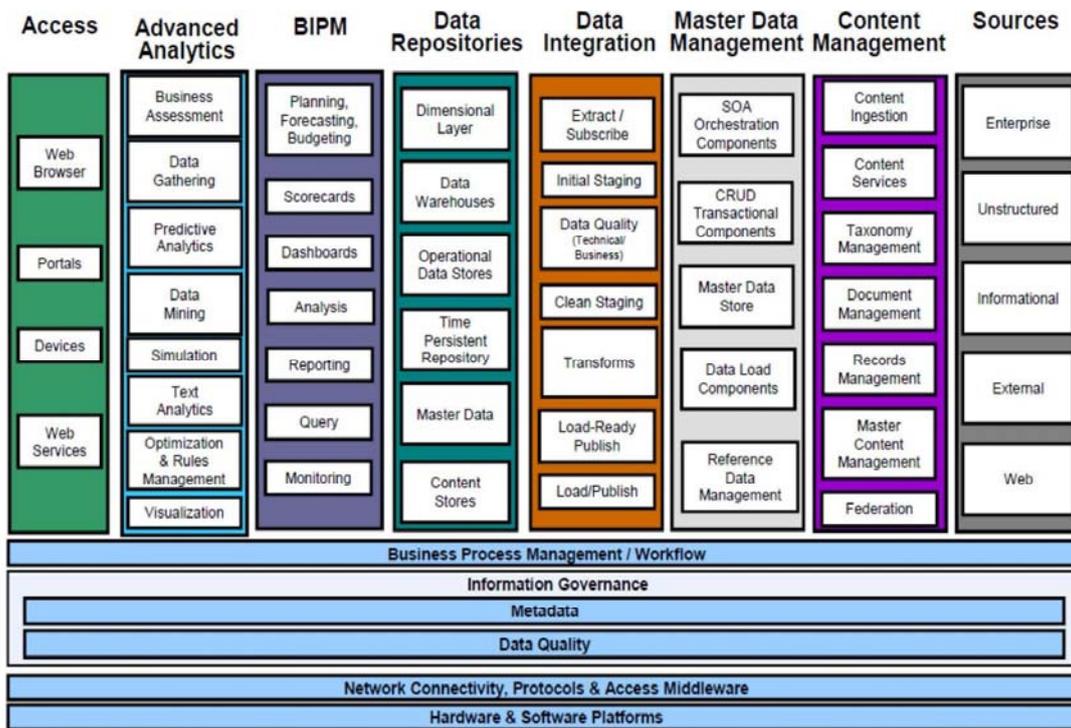
Ovviamente anche **cloud integration...**





Sforzi di Standardizzazione Industriale

E ovviamente anche **IBM**... - IBM Reference Architecture



25

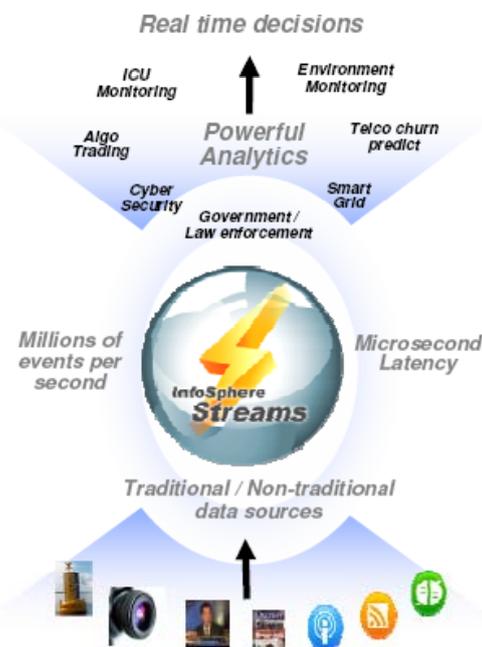


IBM InfoSphere Streams

IBM InfoSphere Streams v2.0

A platform for real-time analytics on BIG data

- **Volume**
 - Terabytes per second
 - Petabytes per day
- **Variety**
 - All kinds of data
 - All kinds of analytics
- **Velocity**
 - Insights in microseconds
- **Agility**
 - Dynamically responsive
 - Rapid application development





Perché InfoSphere Streams

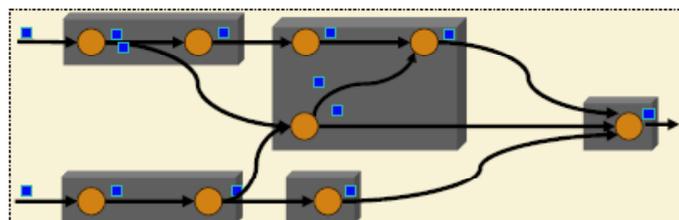
Differenze rispetto a sistemi di data analytics più tradizionali (non big-data-oriented):

1. Orientato ad applicazioni che richiedono **on-the-fly processing, filtering e analisi di flussi** di dati
 - ❑ Sensori (ambientali, industriali, video sorveglianza, GPS, ...)
 - ❑ Log file di server network/Web/application
 - ❑ Dati di transazioni ad alto rate: transazioni finanziarie, chiamate telefoniche, ...
2. **Criteri**
 - ❑ Messaggi processati in **isolamento o in finestre limitate**
 - ❑ Sorgenti includono **dati non tradizionali** (spaziali, immagini, ...)
 - ❑ Sorgenti **eterogenee** in termini di connettività, datarate, requisiti di processamento, ... con problematiche di integrazione
 - ❑ Datarate e volumi richiedono risorse computazionali su **nodi di processamento multipli**, troppo grandi per **approcci store-and-mine**
 - ❑ Tempi di risposta con **latenze dell'ordine sub-ms**



Scalable Stream Processing

- ❑ **Modello di programmazione per definire grafi dataflow** costituiti da datasource (input), operatori e sink (output)
- ❑ Controllo più o meno automatico per **fusione di operatori in Processing Element (PE)**
- ❑ **Infrastruttura** per supportare composizione e runtime di applicazioni stream processing **scalabili** a partire da questi componenti
- ❑ Deployment e supporto runtime su nodi x86/PowerPC, anche ad alte prestazioni (ad es. IBM Blade)





Applicazione Streams

Applicazione Streams come **grafo diretto**, **possib. ciclico**, di operatori connessi da streams

Istanza

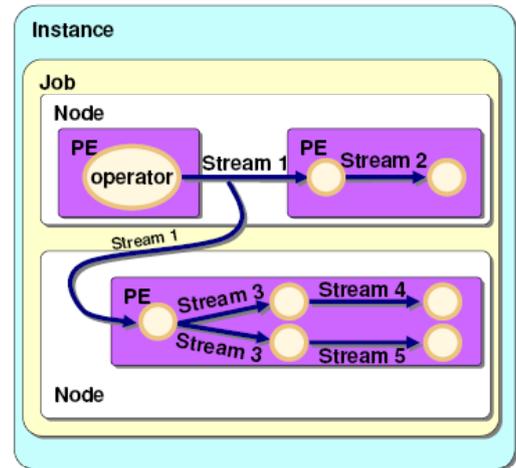
- Istanziamento runtime di InfoSphere Streams che esegue su uno o più nodi
- Collezione di componenti e servizi

PE

- Unità di esecuzione fondamentale che è eseguita da una istanza
- Può incapsulare un singolo operatore o diversi operatori "fused"

Job

- Una applicazione Streams di cui è fatto il deployment su una istanza
- Consiste di uno o più PE



Streams: Development View

Operatore

Building block fondamentale per Streams Processing Language. Operatori processano dati chiamati Streams e possono generare nuovi stream

Stream

Una **sequenza infinita di tuple strutturate**. Possono essere consumate da operatori o in modo singolo o attraverso la definizione di una finestra

Tupla

Lista strutturata di attributi e dei loro tipi

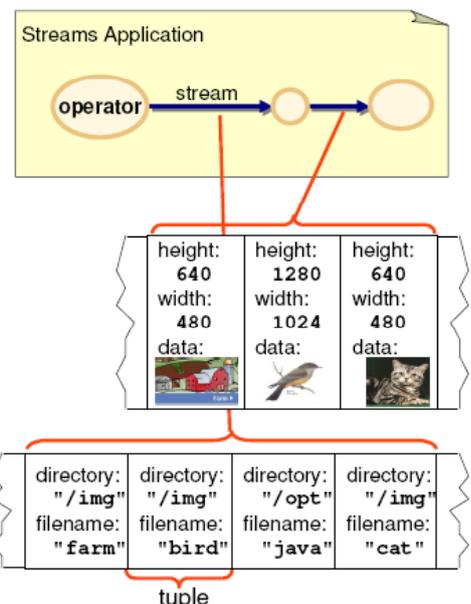
Stream type

Specifica del nome e del tipo per ogni attributo in una tupla

Finestra

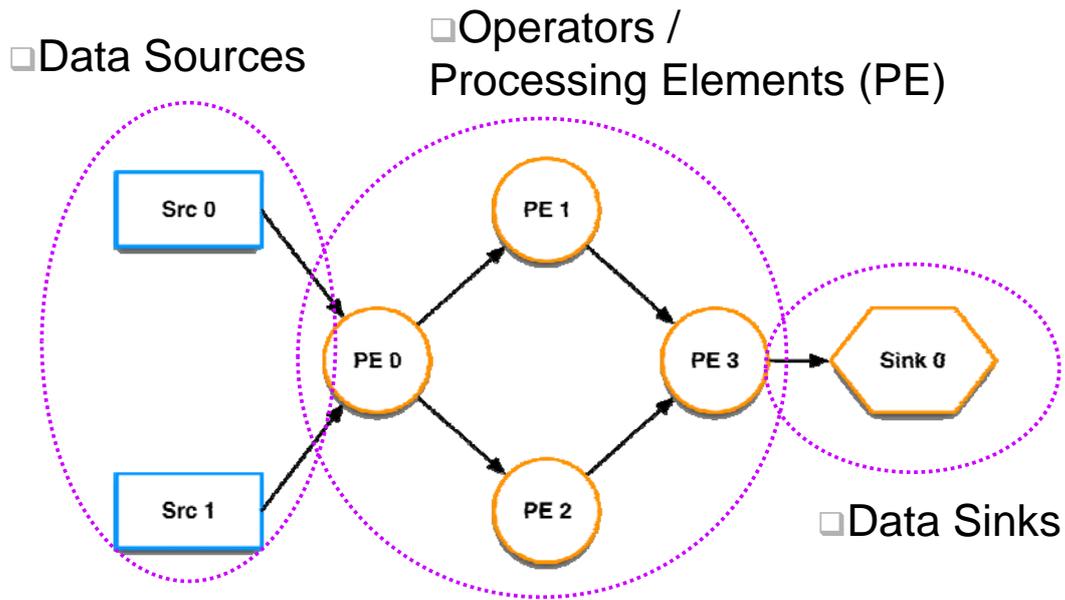
- **Gruppo finito e sequenziale** di tuple in un flusso
- Basata su contatori, tempo, valore di attributi o punctuation mark

Development View





Streams Processing Model: Flow Graph



Ambiente di Sviluppo e Runtime Integrato

IBM InfoSphere Streams

Agile Development Environment



- Eclipse IDE
- Streams Live Graph
- Streams Debugger

Distributed Runtime Environment



- Clustered runtime for near-limitless capacity
- RHEL v5.3 and above, CentOS v6.0 and above
- x86 & Power multicore hardware
- Ethernet & InfiniBand

Sophisticated Analytics with Toolkits & Adapters



- Toolkits
 - Database
 - Mining
 - Financial
 - Standard
 - Internet
- Big Data (HDFS)
 - Text
 - User-defined
- Over 50 samples



Le Origini del Modello...

Da dove traggono origine **modello e successo** dell'approccio?
Probabilmente il “padre storico” di impatto industriale è il progetto **Apache Hadoop**

- ❑ **Framework open source** di larga scala, con Yahoo! Come principale contributor
- ❑ Dedicato a finalità di **processing scalabile, distribuito e data-intensive**
- ❑ Migliaia di nodi e PB di dati
- ❑ Supporta applicazioni sotto free license
- ❑ 3 sottoprogetti principali
 - Hadoop Common (package di facilities comuni)
 - **Hadoop Distributed File System (HDFS)** – high throughput
 - **MapReduce** – framework per processing distribuito di grandi insiemi di dati su cluster



MapReduce

MapReduce è **modello di programmazione e framework software** sviluppato originariamente da Google (paper 2004)

Obiettivo: semplificare il processamento di enormi moli di dati **in parallelo su cluster di grandi dimensioni di commodity hw**, in modo affidabile e fault-tolerant

Processamento deve avvenire su:

- ❑ **Dati NON STRUTTURATI** (filesystem)
- ❑ Dati strutturati (db)



Hadoop Distributed File System (HDFS)

Prende ispirazione da **Google file system**

❑ **Scalabile, distribuito, portabile, scritto in Java per framework Hadoop**

❑ HDFS può essere parte di cluster Hadoop o file system distribuito standalone general-purpose

❑ HDFS cluster è costituito da:

➢ NameNode che gestisce i **metadata** del file system

➢ DataNode che memorizzano i veri dati

❑ Memorizza file di grandi dimensioni in **blocchi distribuiti** sul cluster

❑ Affidabilità e fault-tolerance tramite **replicazione su nodi multipli**

❑ Progettato specificamente per deployment su hw low-cost

Hadoop può lavorare su qualsiasi file system distribuito ma sfrutta **conoscenza di località per ottimizzazione**, quindi HDFS particolarmente adatto



Hadoop Cluster

Un tipico cluster Hadoop integra **funzionalità MapReduce e HDFS**

❑ **Architettura master/slave**

❑ Master contiene

➢ Job tracker (MapReduce – responsabile scheduling dei job task, monitoraggio slave, ri-esecuzione job con fallimenti)

➢ Task tracker (MapReduce)

➢ NameNode (HDFS)

➢ DataNode (HDFS)

❑ Nodi slave includono

➢ Nodo Task tracker (MapReduce – esegue i task sotto coordinamento del master)

➢ DataNode (HDFS)



MapReduce (1)

Codice usualmente scritto in Java, altri linguaggi supportati tramite Hadoop Streaming API

Due passi fondamentali:

Map step

- ❑ Nodo master riceve input del problema e lo divide in **sotto-problemi più piccoli**, distribuiti verso i nodi worker. **Quando e come è possibile?**
- ❑ Nodi worker possono farlo a loro volta (**struttura gerarchica ad albero multi-livello**)
- ❑ Un worker risolve problema “piccolo” e riporta sotto-risultato al master

Reduce Step

- ❑ Nodo master **raccoglie risposte ai sottoproblemi** e li combina in modo predefinito per ottenere la risposta complessiva



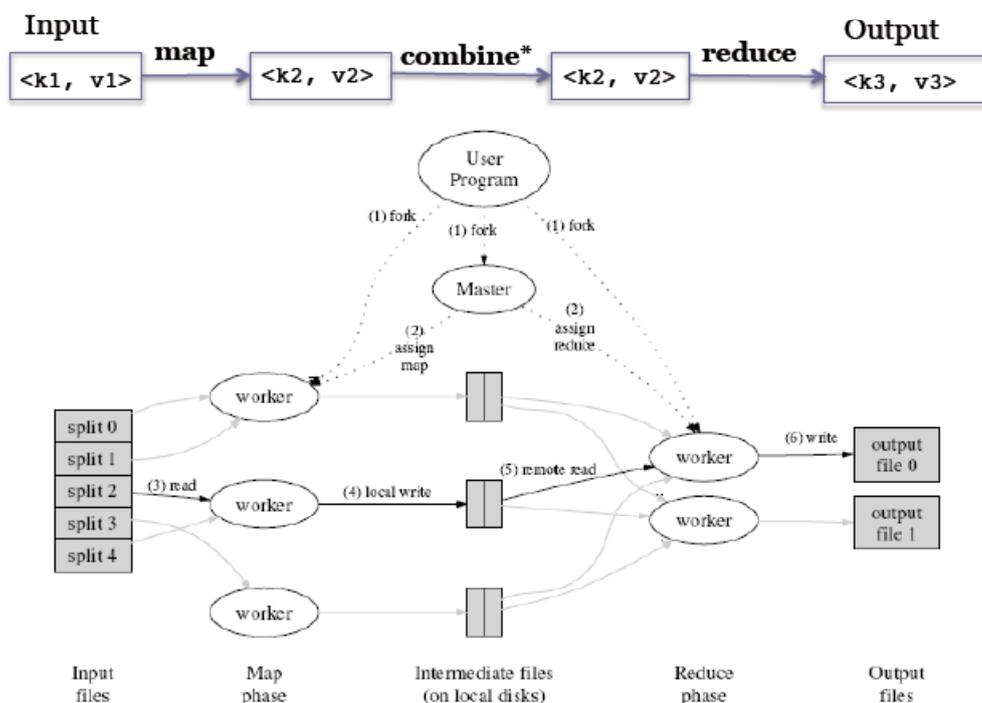
MapReduce (2)

Funzionalità core e come è gestito il flusso dati fra gli step di Map e Reduce:

- ❑ **Input reader** – divide input in chunk di **misura appropriata**, che vengono assegnati a una funzione Map
- ❑ **Funzione Map** – mappa file data **verso coppie <key, value>** più piccole e di utilizzo intermedio
- ❑ **Funzione Partition** – trova il **reducer appropriato** data la chiave key
- ❑ **Funzione Compare** – input per Reduce è preso dall’output intermedio di Map e riordinato in accordo a Compare
- ❑ **Funzione Reduce** – prende valori intermedi e processa soluzione parziale restituita al framework
- ❑ **Output writer** – scrive risultati su file di output

Funzionalità core e come è gestito il flusso dati fra gli step di Map e Reduce (continua):

- ❑ **Un Job MapReduce controlla l'esecuzione**
 - Divide dataset di input in **chunk indipendenti**
 - Chunk indipendenti sono processati da task Map **in parallelo**
- ❑ Il framework riordina gli output dei Map
- ❑ Un task MapReduce raccoglie l'output e svolge il ruolo di reduce & combine
- ❑ Sia input che output del job sono memorizzati nel file system integrato in Hadoop
- ❑ **Il framework gestisce tutte le problematiche di scheduling**
 - Monitoraggio e ri-esecuzione di task con fallimenti/guasti





MapReduce (5)

Esempio semplicissimo: WordCount per contare occorrenze di OGNI PAROLA su un set di file di ingresso

2 file di ingresso:

file1 = "hello world hello
moon"

file2 = "goodbye world
goodnight moon"

3 operazioni:

Map

Combine

Reduce

MAP

First map:

```
< hello, 1 >  
< world, 1 >  
< hello, 1 >  
< moon, 1 >
```

Second map:

```
< goodbye, 1 >  
< world, 1 >  
< goodnight, 1 >  
< moon, 1 >
```

COMBINE

First map:

```
< moon, 1 >  
< world, 1 >  
< hello, 2 >
```

Second map:

```
< goodbye, 1 >  
< world, 1 >  
< goodnight, 1 >  
< moon, 1 >
```

REDUCE

```
< goodbye, 1 >  
< goodnight, 1 >  
< moon, 2 >  
< world, 2 >  
< hello, 2 >
```



MapReduce Scheduling (1)

Hadoop scheduling di default per i job è **FIFO**

Alternative = **capacity e fair**

Capacity scheduler

- Sviluppato da Yahoo!
- Job **sottomessi a code e prioritizzati (priorità statica o dinamica?)**
- Code con **allocazione di una frazione** della capacità totale delle risorse disponibili
- Risorse libere** sono allocate alle code in aggiunta alla loro capacity totale nominale
- Nessuna preemption**



MapReduce Scheduling (2)

Fair scheduler

- ❑ Sviluppato da Facebook
- ❑ Migliora tempi di risposta per **job “piccoli”**
- ❑ Job sono raggruppati in **insiemi detti Pool**
- ❑ Ad ogni Pool è assegnata una **quota minima garantita**
- ❑ La capacità in eccesso è divisa fra i job
- ❑ A default i job non categorizzati (uncategorized) vanno nel Pool di default. I Pool devono specificare il loro **numero minimo di risorse desiderate di tipo map e resource**, e un limite sul numero dei loro job in esecuzione



Limiti di Hadoop e altri Approcci

- ❑ Come effettuare la determinazione di **chunk indipendenti e sotto-problemi indipendenti?**
- ❑ Anche MapReduce **più adatto a batch processing**, meno a stream processing
- ❑ Approccio non “dramatically novel” – vedi tradizione del calcolo distribuito e parallelo

Anche di conseguenza, estremo fermento nell’ambito piattaforme di stream processing. Non solo IBM InfoSphere Streams:

- ❑ Storm - <http://www.slideshare.net/nathanmarz/storm-11164672>
- ❑ Apache S4 - <http://www.slideshare.net/alekbr/s4-stream-computing-platform>
- ❑ YARN (Yet Another Resource Negotiator) per maggiore scalabilità su MapReduce - <http://www.slideshare.net/AdamKawa/apache-hadoop-yarn-simply-explained>
- ❑ Apache Samza (LinkedIn) - <http://www.slideshare.net/blueboxtraveler/apache-samza>



Alcune attività di ricerca svolte nel settore Big Data e Distributed Stream Processing da UNIBO:

- ❑ **Quasit** (streaming graph con indicazioni/requisiti di qualità di servizio e integrazione con OMG DDS)
- ❑ Collaborazione con **IBM Dublin Smarter Cities Lab**
- ❑ Collaborazione con **UTA e Numerex**
- ❑ Bilanciamento e tradeoff dinamico di **qualità di servizio e garanzie di fault tolerance tramite replicazione adattiva** (vedi qualche dettaglio nel seguito...)



Fault-Tolerance in Distributed Stream Processing Systems (DSPS)

- ❑ Numero crescente di applicazioni hanno la necessità di gestire, trasformare e analizzare Big Data Stream in modo scalabile ed efficace:
 - Monitoring
 - Crowdsensing
 - Healthcare
 - Web 2.0
 - Transportation
 - Finance
- ❑ **Applicazioni DSPS devono eseguire per sempre e senza interruzione**
 - **Guasti sono sicuri** (hardware o software)
 - Su larga scala, affidabilità peggiora (maggior numero di possibili punti di failure)
- ❑ **Nostro claim: DSPS hanno bisogno di fronteggiare guasti efficientemente in dipendenza da requisiti application-specific**
 - Ad es. una soluzione di social messaging ha diversi requisiti di qualità di una applicazione per personal healthcare



Fault-Tolerance in DSPS

Consistency

Availability

- ❑ Failure detection
- ❑ Replacement dei componenti con fallimenti, ad es. PE
- ❑ Idealmente fail-over istantaneo per evitare crescite di latenza

- ❑ Mascherare gli effetti dei guasti sull'output applicativo
- ❑ Semantica di processamento tuple
- ❑ Gestione di componenti stateful
- ❑ Idealmente processamento delle tuple exactly-once

Cost

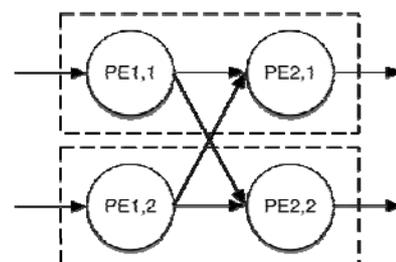
- ❑ Runtime cost: costo di mantenimento fault-tolerance in assenza di guasti
- ❑ Fail-over cost: costo per gestione fallimenti
- ❑ Ovviamente obiettivi di minimizzazione costi



Review di Tecniche di Fault-Tolerance

Active Replication

- ❑ **Due repliche fisiche** in esecuzione **per ogni PE** nel grafo di flusso
- ❑ Mantengono il loro **stato consistente** tramite processamento dello stesso input
- ❑ Solo la copia primaria emette le tuple di output verso le repliche downstream
- ❑ In caso di guasto del primario, il secondario può immediatamente fare take over (**latenza minima**)
- ❑ **100% runtime overhead**
- ❑ **Consistenza forte**
- ❑ Esempi: **Borealis**¹ o **Flux**²

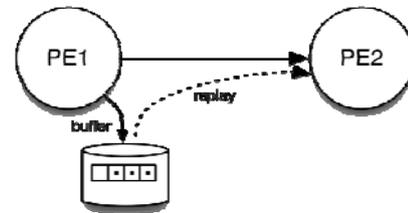


¹ M. Balazinska, et al.: Fault Tolerance in the Borealis Distributed Stream Processing System. ACM Trans. Database Syst. 33 (1), 2008

² M.A. Shah, et al.: Highly available, fault-tolerant, parallel dataflows. Proc. of the ACM SIGMOD Conference, 2004

Upstream Backup

- ❑ Tuple di output sono **memorizzate** “*somewhere upstream*” per ogni PE (ad es. dai predecessori o sorgenti)
- ❑ In caso di guasto, si avvia un PE con fresh state
- ❑ Tutte le **tuple bufferizzate sono replayed**
- ❑ **Latenza molto alta**: tuple devono essere replayed
- ❑ **Basso runtime overhead** (basso costo storage)
- ❑ **Consistenza forte**
- ❑ Esempi: Storm³ o Hwang et al.⁴

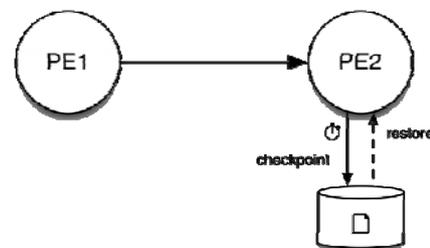


³ Storm project Web Site. Available at: <http://storm-project.net/>, last visited 25 Sep. 2013

⁴ J.-H. Hwang, et al.: High Availability Algorithms for Distributed Stream Processing. In Proc. of 21° ICDE Conf., Tokyo, Japan, 2005

Checkpointing

- ❑ **Stato dei componenti è periodicamente checkpointed** su storage permanente
- ❑ In caso di guasto, un PE è riavviato recuperando lo stato checkpointed
- ❑ **Bassa latenza** perché lo stato checkpointed è usualmente molto più piccolo dello storico tuple
- ❑ **Basso runtime overhead**
- ❑ **Possibile perdita di info** in caso di guasti
- ❑ Esempi: Streams⁵ o Apache S4⁶



⁵ G. Jacques-Silva, et al.: Language level checkpointing support for stream processing applications. In Proc. Of DSN'09 Conf., Lisbon, 2009

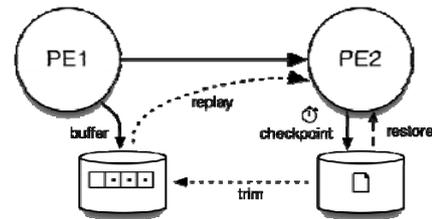
⁶ L. Neumeyer, et al: S4: Distributed Stream Computing Platform. In Proc. Of. ICDMW'10 Conf., Sydney, Australia, 2010



Review di Tecniche di Fault-Tolerance

Checkpointing + Upstream Backup

- ❑ **Stato di componenti è periodicamente checkpointed** su storage permanente
- ❑ **Tuple “non afferenti” ai checkpoint sono backed up** su nodi upstream
- ❑ **Latenza maggiore** rispetto a checkpointing ma minore rispetto a upstream backup puro
- ❑ **Basso runtime overhead**
- ❑ **Consistenza forte**
- ❑ Esempi: Apache Samza⁷ o Google MillWheel⁸



⁷ C. Riccomini: Samza: Real-time Stream Processing at LinkedIn. International Software Dev. Conf. Qcon, San Francisco., 2013

⁸ T. Akidau, et al.: MillWheel: Fault-Tolerant Stream Processing at Internet Scale. Proc. of the VLDB Conf., Trento, 2013



Review di Tecniche di Fault-Tolerance

Trade-off fra

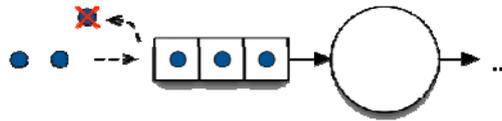
- ❑ **Recovery time (latenza)**
quanto tempo richiesto per una applicazione per tornare attiva e di nuovo funzionante?
- ❑ **Garanzie di consistenza**
quale effetto dei guasti sullo stato dei componenti e sull'output dell'applicazione?
- ❑ **Costo Runtime**
quale runtime overhead per la soluzione di fault-tolerance?

Technique	Latency	Consistency	Cost
Active Replication	Very Low	Strong	High
Upstream Backup	Very High	Strong	Low
Checkpointing	Low	Weak	Low
Checkpointing + Upstream Backup	High	Strong	Low



Gestione Cost-effective di Variazioni di Carico

- ❑ Molti flussi di dati real-world sono caratterizzati da **variabilità della dinamica di input**, ad es. modifiche improvvise di datarate
 - Ad es. picchi di traffico in real-time monitoring di reti veicolari
- ❑ **Carico si modifica fortemente in modo dinamico** su sistemi di stream processing
 - Buffering di tuple alle porte input dei PE
 - Perdita di dati
- ❑ Altro **trade-off** fra **latenza** (buffering) e **consistenza** (tuple dropping)



Gestione di Variazioni di Carico

- ❑ **Over-provisioning**
Allocare staticamente risorse sufficienti per gestire picchi di carico
- ❑ **Back-pressure**
Rallentare componenti di processing (possibilmente fino alla sorgente)
- ❑ **Load-shedding**
Invece di fare dropping casuale di tuple, cercare di scartare le tuple a **minore importanza**
- ❑ **Dynamic PE Relocation**
Muovere i componenti di processing da nodi overloaded a **nodi sotto-utilizzati**

	Latenza	Perdita Dati	Costo
Over-provisioning	Bassa	Nessuna	Alto
Back-pressure	Alta	Nessuna*	Basso
Semantic Load Shedding	Bassa	Sì	Basso
Dynamic PE relocation	Dipende	Nessuna	Dipende



Load-Adaptive Active Replication (LAAR)

Punto aperto a livello di ricerca

è possibile riutilizzare temporaneamente le risorse normalmente dedicate a fault-tolerance per la gestione efficace di picchi di traffico, mantenendo comunque un livello di servizio garantito?

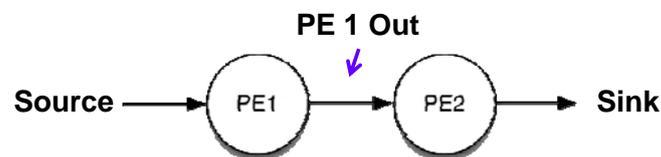
- **LAAR** è una variante dinamica di tecniche di **Active Replication**:
 - Le repliche PE sono attivate/disattivate dinamicamente in dipendenza
 - Dal carico di sistema corrente
 - Dai requisiti di garanzie di consistenza
- Requisiti dello scenario target
 - **Bassa latenza**, anche durante picchi di traffico
 - **Trade-off dinamicamente modificabile** fra garanzie di consistenza e costo runtime
 - Poter sostenere **perdita di dati limitata e predicibile** solo nel caso di guasti che occorrono durante picchi di traffico



LAAR in uno Scenario Iper-semplificato

Streaming processing graph:

- Pipeline di due PE con single-input single-output



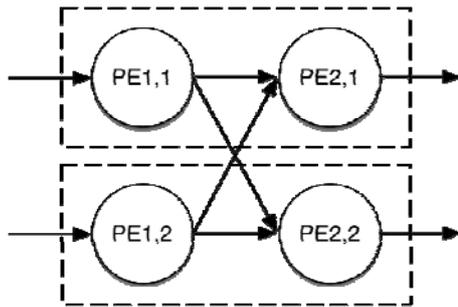
- Descrizione sintetica della applicazione di streaming:

	PE 1	PE2
Selectivity	1	1
CPU per tuple	0.1 s/t	0.1 s/t

	Data Rate
Source	4 t/s
PE 1 Out	4 t/s

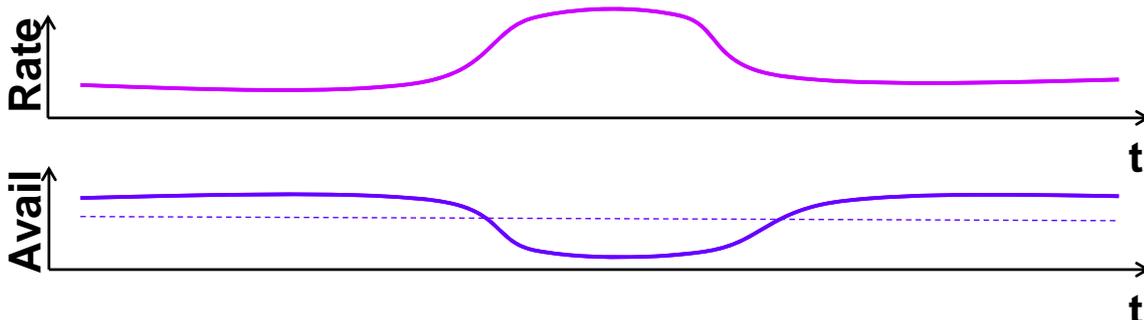
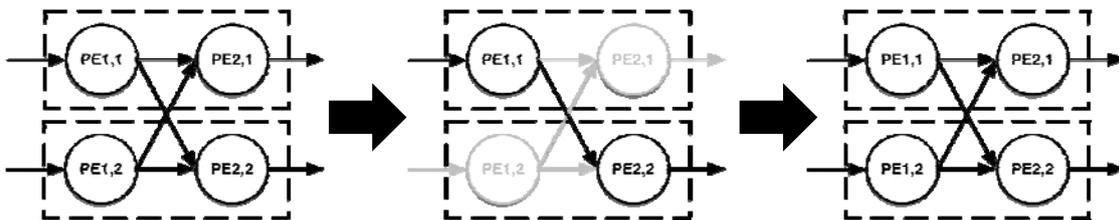
Deployment su due nodi con **active replication**

- Due copie di ogni PE su host differenti
- Ovviamente protegge da guasti singoli software o hardware



	PE 1	PE 2
Selectivity	1	1
CPU per tuple	0.1 s/t	0.1 s/t
	Rate	Peak
Source	4 t/s	8 t/s
PE 1 Out	4 t/s	8 t/s

Disattivazione Dinamica delle Repliche in LAAR





LAAR è integrato in IBM InfoSphere Streams

