

# Data Intelligence

Corso di perfezionamento post laurea  
«Intelligence e sicurezza nazionale»  
AA: 2020-2021



<http://www.disit.org/6574>

*Prof. Paolo Nesi*  
**DISIT Lab**

**Distributed Data Intelligence and Technologies Lab**  
**Distributed Systems and Internet Technologies Lab**

Dipartimento di Ingegneria dell'Informazione  
Università degli Studi di Firenze  
Via S. Marta 3, 50139, Firenze, Italia  
tel: +39-055-2758515, fax: +39-055-2758570  
<http://www.disit.dinfo.unifi.it>  
[paolo.nesi@unifi.it](mailto:paolo.nesi@unifi.it)



# *Le Sfide*

- **Internet delle Cose, droni, sensori, etc.**
- **Infrastrutture Critiche e Sistemi Cyber-Fisici**
- **Organizzazione, Fattore Umano e Ingegneria Sociale**
- **Social Network**
- **Smart City**
- **Componenti e Sistemi Hardware**
- **Cloud e Internet**
- **Biometria**

## *Le azioni*

- **Sistemi Avanzati di Crittografia**
- **Protezione di Internet**
- **Protezione dell'Informazione**
- **Riduzione delle superfici di attacco**
- **Progettazione di Sistemi Informativi Resilienti**
- **Poligoni Virtuali per Esercitarsi sulla Sicurezza**
- **Investigazioni Digitali**
- **Intelligence e Big Data Analytics**
- **Condivisione delle Informazioni**
- **Metriche e Valutazione del Rischio e Resilienza**

# sommario

- *Dati e formati* 
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence*

# *I dati e I formati*

- Formati e informazioni
- Codifica
- Informatica ?? Informazione – automatica
- Volume dei dati
  - velocità dei flussi e computabilità:
  - static e real time
- Informazione strutturata
- entità vs relazioni: rappresentazione conoscenza
- tabelle vs reticoli
- XML

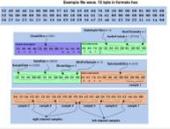


UNIVERSITÀ  
DEGLI STUDI  
FIRENZE



# Device

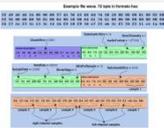
DISIT Lab, Distributed Data Intelligence and Technologies  
Distributed Systems and Internet Technologies  
Department of Information Engineering (DINFO)  
<http://www.dinfo.unifi.it>



# Programmazione

- È l'attività con cui si predispongono l'elaboratore a eseguire un *particolare insieme di azioni su particolari dati*, allo scopo di *risolvere un problema*.
- *Informatica: informazione - automatica*





# Codifica dell'Informazione

In un calcolatore si possono (e vi è la necessità di) codificare ed elaborare vari tipi di informazioni che devono essere opportunamente codificati in modo che siano computabili:

- Numeri naturali (visto)
- Numeri reali in virgola fissa (visto)
- Numeri interi (da vedere in questa sessione)
  - In varie forme
- Rappresentazione dati: testi, visualizzazione
- ...
- ...

# Tabella Bin, Decimale e Esadecimale

- Tabella da binario a decimale a esadecimale
- Rappresentazione VS codifica

<u>Esadecimale</u>	<u>Binario</u>	<u>decimale</u>
0	0000	0
1	0001	1
2	0010	2
3	0011	3
4	0100	4
5	0101	5
6	0110	6
7	0111	7
8	1000	8
9	1001	9
A	1010	10
B	1011	11
C	1100	12
D	1101	13
E	1110	14
F	1111	15



Dec	Hx	Oct	Char	Dec	Hx	Oct	Html	Chr	Dec	Hx	Oct	Html	Chr	Dec	Hx	Oct	Html	Chr
0	0	000	<b>NUL</b> (null)	32	20	040	&#32;	<b>Space</b>	64	40	100	&#64;	<b>@</b>	96	60	140	&#96;	<b>`</b>
1	1	001	<b>SOH</b> (start of heading)	33	21	041	&#33;	<b>!</b>	65	41	101	&#65;	<b>A</b>	97	61	141	&#97;	<b>a</b>
2	2	002	<b>STX</b> (start of text)	34	22	042	&#34;	<b>"</b>	66	42	102	&#66;	<b>B</b>	98	62	142	&#98;	<b>b</b>
3	3	003	<b>ETX</b> (end of text)	35	23	043	&#35;	<b>#</b>	67	43	103	&#67;	<b>C</b>	99	63	143	&#99;	<b>c</b>
4	4	004	<b>EOT</b> (end of transmission)	36	24	044	&#36;	<b>\$</b>	68	44	104	&#68;	<b>D</b>	100	64	144	&#100;	<b>d</b>
5	5	005	<b>ENQ</b> (enquiry)	37	25	045	&#37;	<b>%</b>	69	45	105	&#69;	<b>E</b>	101	65	145	&#101;	<b>e</b>
6	6	006	<b>ACK</b> (acknowledge)	38	26	046	&#38;	<b>&amp;</b>	70	46	106	&#70;	<b>F</b>	102	66	146	&#102;	<b>f</b>
7	7	007	<b>BEL</b> (bell)	39	27	047	&#39;	<b>'</b>	71	47	107	&#71;	<b>G</b>	103	67	147	&#103;	<b>g</b>
8	8	010	<b>BS</b> (backspace)	40	28	050	&#40;	<b>(</b>	72	48	110	&#72;	<b>H</b>	104	68	150	&#104;	<b>h</b>
9	9	011	<b>TAB</b> (horizontal tab)	41	29	051	&#41;	<b>)</b>	73	49	111	&#73;	<b>I</b>	105	69	151	&#105;	<b>i</b>
10	A	012	<b>LF</b> (NL line feed, new line)	42	2A	052	&#42;	<b>*</b>	74	4A	112	&#74;	<b>J</b>	106	6A	152	&#106;	<b>j</b>
11	B	013	<b>VT</b> (vertical tab)	43	2B	053	&#43;	<b>+</b>	75	4B	113	&#75;	<b>K</b>	107	6B	153	&#107;	<b>k</b>
12	C	014	<b>FF</b> (NP form feed, new page)	44	2C	054	&#44;	<b>,</b>	76	4C	114	&#76;	<b>L</b>	108	6C	154	&#108;	<b>l</b>
13	D	015	<b>CR</b> (carriage return)	45	2D	055	&#45;	<b>-</b>	77	4D	115	&#77;	<b>M</b>	109	6D	155	&#109;	<b>m</b>
14	E	016	<b>SO</b> (shift out)	46	2E	056	&#46;	<b>.</b>	78	4E	116	&#78;	<b>N</b>	110	6E	156	&#110;	<b>n</b>
15	F	017	<b>SI</b> (shift in)	47	2F	057	&#47;	<b>/</b>	79	4F	117	&#79;	<b>O</b>	111	6F	157	&#111;	<b>o</b>
16	10	020	<b>DLE</b> (data link escape)	48	30	060	&#48;	<b>0</b>	80	50	120	&#80;	<b>P</b>	112	70	160	&#112;	<b>p</b>
17	11	021	<b>DC1</b> (device control 1)	49	31	061	&#49;	<b>1</b>	81	51	121	&#81;	<b>Q</b>	113	71	161	&#113;	<b>q</b>
18	12	022	<b>DC2</b> (device control 2)	50	32	062	&#50;	<b>2</b>	82	52	122	&#82;	<b>R</b>	114	72	162	&#114;	<b>r</b>
19	13	023	<b>DC3</b> (device control 3)	51	33	063	&#51;	<b>3</b>	83	53	123	&#83;	<b>S</b>	115	73	163	&#115;	<b>s</b>
20	14	024	<b>DC4</b> (device control 4)	52	34	064	&#52;	<b>4</b>	84	54	124	&#84;	<b>T</b>	116	74	164	&#116;	<b>t</b>
21	15	025	<b>NAK</b> (negative acknowledge)	53	35	065	&#53;	<b>5</b>	85	55	125	&#85;	<b>U</b>	117	75	165	&#117;	<b>u</b>
22	16	026	<b>SYN</b> (synchronous idle)	54	36	066	&#54;	<b>6</b>	86	56	126	&#86;	<b>V</b>	118	76	166	&#118;	<b>v</b>
23	17	027	<b>ETB</b> (end of trans. block)	55	37	067	&#55;	<b>7</b>	87	57	127	&#87;	<b>W</b>	119	77	167	&#119;	<b>w</b>
24	18	030	<b>CAN</b> (cancel)	56	38	070	&#56;	<b>8</b>	88	58	130	&#88;	<b>X</b>	120	78	170	&#120;	<b>x</b>
25	19	031	<b>EM</b> (end of medium)	57	39	071	&#57;	<b>9</b>	89	59	131	&#89;	<b>Y</b>	121	79	171	&#121;	<b>y</b>
26	1A	032	<b>SUB</b> (substitute)	58	3A	072	&#58;	<b>:</b>	90	5A	132	&#90;	<b>Z</b>	122	7A	172	&#122;	<b>z</b>
27	1B	033	<b>ESC</b> (escape)	59	3B	073	&#59;	<b>;</b>	91	5B	133	&#91;	<b>[</b>	123	7B	173	&#123;	<b>{</b>
28	1C	034	<b>FS</b> (file separator)	60	3C	074	&#60;	<b>&lt;</b>	92	5C	134	&#92;	<b>\</b>	124	7C	174	&#124;	<b> </b>
29	1D	035	<b>GS</b> (group separator)	61	3D	075	&#61;	<b>=</b>	93	5D	135	&#93;	<b>]</b>	125	7D	175	&#125;	<b>}</b>
30	1E	036	<b>RS</b> (record separator)	62	3E	076	&#62;	<b>&gt;</b>	94	5E	136	&#94;	<b>^</b>	126	7E	176	&#126;	<b>~</b>
31	1F	037	<b>US</b> (unit separator)	63	3F	077	&#63;	<b>?</b>	95	5F	137	&#95;	<b>_</b>	127	7F	177	&#127;	<b>DEL</b>



128	Ç	144	É	160	á	176	⋯	193	⊥	209	≠	225	β	241	±
129	ü	145	æ	161	í	177	⋮	194	⊤	210	π	226	Γ	242	≥
130	é	146	Æ	162	ó	178	⋭	195	⊥	211	⊥	227	π	243	≤
131	â	147	ô	163	ú	179		196	—	212	⊥	228	Σ	244	∫
132	ä	148	ö	164	û	180	⊥	197	⊥	213	⊥	229	σ	245	∫
133	à	149	ò	165	ñ	181	⊥	198	⊥	214	⊥	230	μ	246	÷
134	â	150	û	166	ª	182	⊥	199	⊥	215	⊥	231	τ	247	≈
135	ç	151	ù	167	º	183	π	200	⊥	216	⊥	232	Φ	248	◦
136	ê	152	—	168	¿	184	⊥	201	⊥	217	⊥	233	⊕	249	.
137	ë	153	Ö	169	—	185	⊥	202	⊥	218	⊥	234	Ω	250	.
138	è	154	Ü	170	¬	186	⊥	203	≠	219	■	235	δ	251	√
139	ì	156	£	171	½	187	⊥	204	⊥	220	■	236	∞	252	—
140	î	157	≠	172	¼	188	⊥	205	=	221	■	237	φ	253	²
141	ï	158	—	173		189	⊥	206	⊥	222	■	238	ε	254	■
142	Ä	159	f	174	«	190	⊥	207	⊥	223	■	239	∧	255	
143	Å	192	L	175	»	191	⊥	208	⊥	224	α	240	≡		

Source: [www.asciitable.com](http://www.asciitable.com)

# Conversioni con Esadecimali

## Hexadecimal-Binary-Decimal Conversion

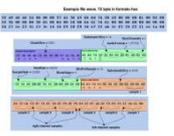
Hex Number	Binary Number	Decimal Digit 000X	Decimal Digit 00X0	Decimal Digit 0X00	Decimal Digit X000
0	0000	0	0	0	0
1	0001	1	16	256	4,096
2	0010	2	32	512	8,192
3	0011	3	48	768	12,288
4	0100	4	64	1,024	16,384
5	0101	5	80	1,280	20,480
6	0110	6	96	1,536	24,576
7	0111	7	112	1,792	28,672
8	1000	8	128	2,048	32,768
9	1001	9	144	2,304	36,864
A	1010	10	160	2,560	40,960
B	1011	11	176	2,816	45,056
C	1100	12	192	3,072	49,152
D	1101	13	208	3,328	53,248
E	1110	14	224	3,584	57,344
F	1111	15	240	3,840	61,440

# Unicode Character Code

• Unicode is a 16-bit code.

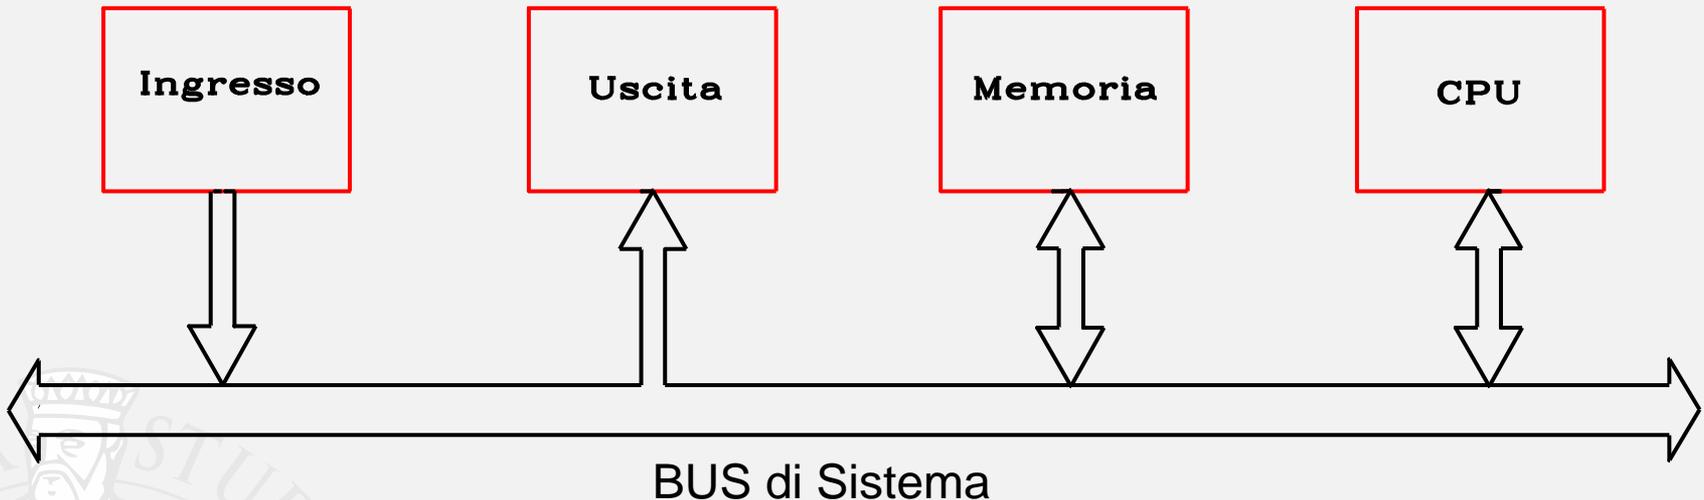
0000	NUL	0020	SP	0040	@	0060	`	0080	Ctrl	00A0	NBS	00C0	À	00E0	à
0001	SOH	0021	!	0041	A	0061	a	0081	Ctrl	00A1	¡	00C1	Á	00E1	á
0002	STX	0022	"	0042	B	0062	b	0082	Ctrl	00A2	¢	00C2	Â	00E2	â
0003	ETX	0023	#	0043	C	0063	c	0083	Ctrl	00A3	£	00C3	Ã	00E3	ã
0004	EOT	0024	\$	0044	D	0064	d	0084	Ctrl	00A4	¤	00C4	Ä	00E4	ä
0005	ENQ	0025	%	0045	E	0065	e	0085	Ctrl	00A5	¥	00C5	Å	00E5	å
0006	ACK	0026	&	0046	F	0066	f	0086	Ctrl	00A6	¦	00C6	Æ	00E6	æ
0007	BEL	0027	'	0047	G	0067	g	0087	Ctrl	00A7	§	00C7	Ç	00E7	ç
0008	BS	0028	(	0048	H	0068	h	0088	Ctrl	00A8	¨	00C8	È	00E8	è
0009	HT	0029	)	0049	I	0069	i	0089	Ctrl	00A9	©	00C9	É	00E9	é
000A	LF	002A	*	004A	J	006A	j	008A	Ctrl	00AA	ª	00CA	Ê	00EA	ê
000B	VT	002B	+	004B	K	006B	k	008B	Ctrl	00AB	«	00CB	Ë	00EB	ë
000C	FF	002C	^	004C	L	006C	l	008C	Ctrl	00AC	¬	00CC	Ì	00EC	ì
000D	CR	002D	-	004D	M	006D	m	008D	Ctrl	00AD	–	00CD	Í	00ED	í
000E	SO	002E	.	004E	N	006E	n	008E	Ctrl	00AE	®	00CE	Î	00EE	î
000F	SI	002F	/	004F	O	006F	o	008F	Ctrl	00AF	¯	00CF	Ï	00EF	ï
0010	DLE	0030	0	0050	P	0070	p	0090	Ctrl	00B0	°	00D0	Ð	00F0	ð
0011	DC1	0031	1	0051	Q	0071	q	0091	Ctrl	00B1	±	00D1	Ñ	00F1	ñ
0012	DC2	0032	2	0052	R	0072	r	0092	Ctrl	00B2	²	00D2	Ò	00F2	ò
0013	DC3	0033	3	0053	S	0073	s	0093	Ctrl	00B3	³	00D3	Ó	00F3	ó
0014	DC4	0034	4	0054	T	0074	t	0094	Ctrl	00B4	´	00D4	Ô	00F4	ô
0015	NAK	0035	5	0055	U	0075	u	0095	Ctrl	00B5	µ	00D5	Õ	00F5	õ
0016	SYN	0036	6	0056	V	0076	v	0096	Ctrl	00B6	¶	00D6	Ö	00F6	ö
0017	ETB	0037	7	0057	W	0077	w	0097	Ctrl	00B7	·	00D7	×	00F7	÷
0018	CAN	0038	8	0058	X	0078	x	0098	Ctrl	00B8	¸	00D8	Ø	00F8	ø
0019	EM	0039	9	0059	Y	0079	y	0099	Ctrl	00B9	¹	00D9	Ù	00F9	ù
001A	SUB	003A	:	005A	Z	007A	z	009A	Ctrl	00BA	º	00DA	Ú	00FA	ú
001B	ESC	003B	;	005B	[	007B	{	009B	Ctrl	00BB	»	00DB	Û	00FB	û
001C	FS	003C	<	005C	\	007C		009C	Ctrl	00BC	¼	00DC	Ü	00FC	ü
001D	GS	003D	=	005D	]	007D	}	009D	Ctrl	00BD	½	00DD	Ý	00FD	ÿ
001E	RS	003E	>	005E	^	007E	~	009E	Ctrl	00BE	¾	00DE	ý	00FE	þ
001F	US	003F	?	005F	_	007F	DEL	009F	Ctrl	00BF	¿	00DF	Ş	00FF	ÿ

NUL	Null	SOH	Start of heading	CAN	Cancel	SP	Space
STX	Start of text	EOT	End of transmission	EM	End of medium	DEL	Delete
ETX	End of text	DC1	Device control 1	SUB	Substitute	Ctrl	Control
ENQ	Enquiry	DC2	Device control 2	ESC	Escape	FF	Form feed
ACK	Acknowledge	DC3	Device control 3	FS	File separator	CR	Carriage return
BEL	Bell	DC4	Device control 4	GS	Group separator	SO	Shift out
BS	Backspace	NAK	Negative acknowledge	RS	Record separator	SI	Shift in
HT	Horizontal tab	NBS	Non-breaking space	US	Unit separator	DLE	Data link escape
LF	Line feed	ETB	End of transmission block	SYN	Synchronous idle	VT	Vertical tab



# Il Calcolatore

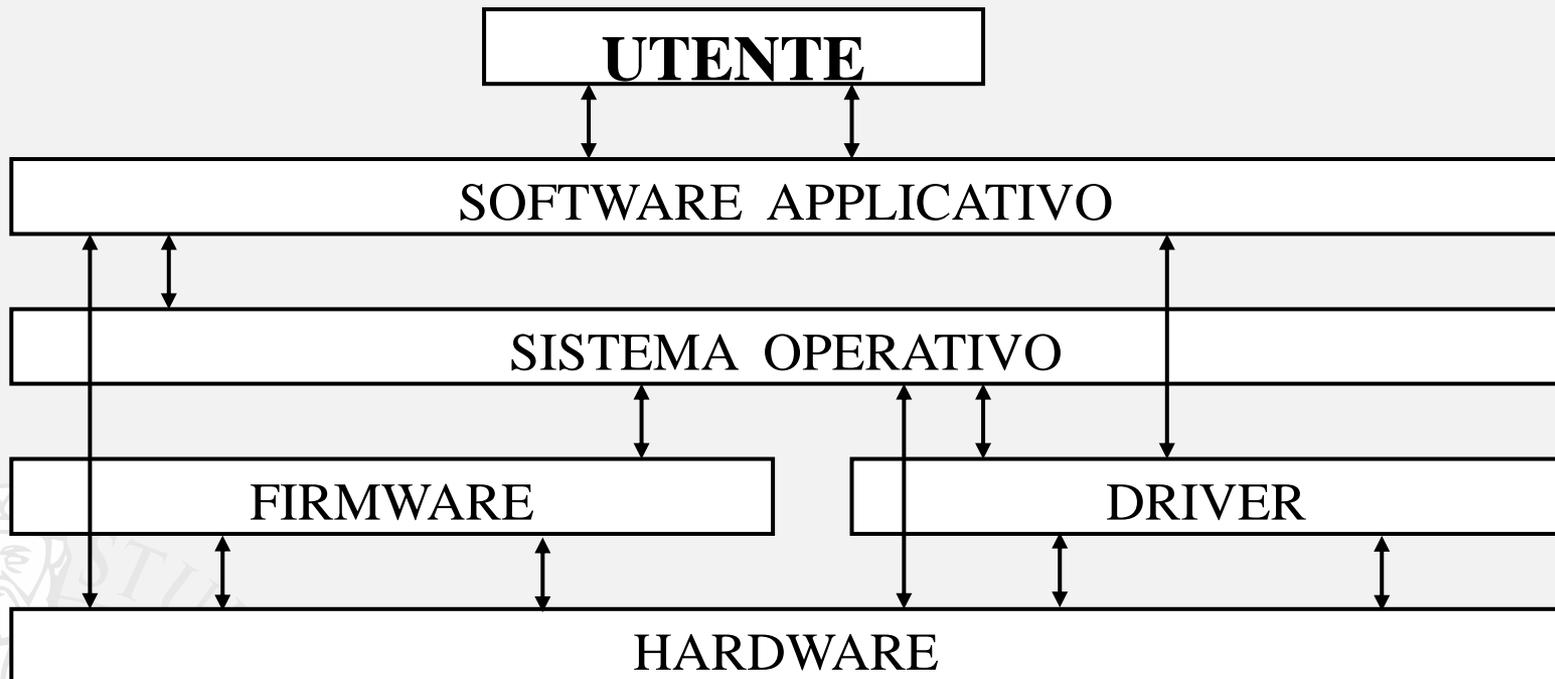
- Corrisponde allo schema dei PC anni 80
- Tuttora in largo uso nei sistemi di controllo
- Le unità sono collegate da un bus di sistema (insieme di fili che portano informazioni in parallelo: per esempio, 8 bit → 8 fili)



# Hardware e Software

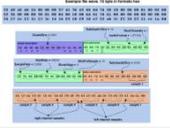
L'elaboratore è composto dall'hardware, i dispositivi fisici che lo costituiscono, e dal software, quelle procedure e istruzioni che ne dirigono le operazioni.

Visione Funzionale vs interazione reale dell'utente



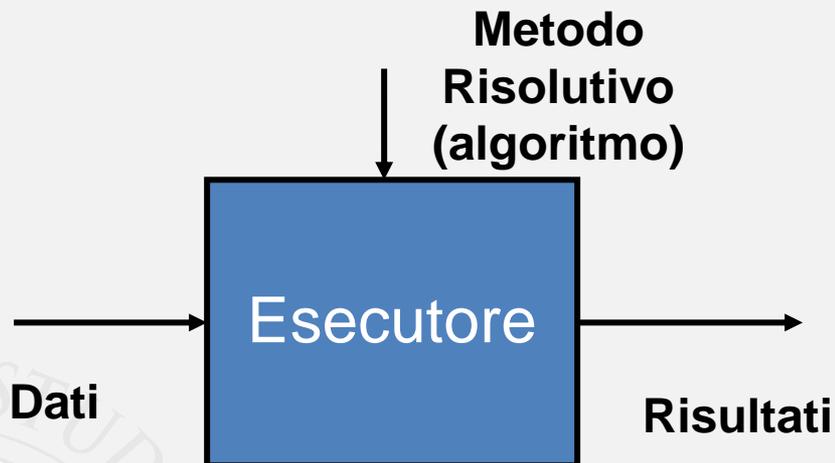
Software

# Algoritmo



Un algoritmo è una sequenza **finita** di mosse (passi) che risolve **in un tempo finito** una *classe* di problemi.

- L'esecuzione delle azioni *nell'ordine specificato dall'algoritmo* consente di ottenere, a partire dai dati di ingresso, i risultati che risolvono il problema.
- Algoritmi complessi possono risolvere problemi semplici e viceversa



**ESECUTORE/elaboratore**  
una *macchina astratta*  
capace di ***eseguire le azioni***  
specificate dall'algoritmo.

# *I dati e I formati*

- Formati e informazioni
- Codifica
- Informatica ?? Informazione – automatica
- Volume dei dati 
  - velocità dei flussi e computabilità:
  - static e real time
- Informazione strutturata
- entità vs relazioni: rappresentazione conoscenza
- tabelle vs reticoli
- XML

# Bit e byte

- 1 bit: V/F, 1/O, H/L, acceso/spento
- 1 Byte = 8 bit
- 1 Word = 16 o 32 bit (e.g., word a 16...)
- 1 nibble = 4 bit
- Un numero binario a 10 bit ha una dinamica (numero di combinazioni) di 1024, da 0 a 1023:
- Il massimo numero rappresentabile con n bit è pari alla dinamica meno 1 cioè  $(2^n - 1)$

# Prefissi Scientifici – la memoria

## Scientific Prefixes

- For computer memory,  $1K = 2^{10} = 1024$ . For everything else, like clock speeds,  $1K = 1000$ , and likewise for  $1M$ ,  $1G$ , etc.

Prefix	Abbrev.	Quantity	Prefix	Abbrev.	Quantity
milli	m	$10^{-3}$	Kilo	K	$10^3$
micro	$\mu$	$10^{-6}$	Mega	M	$10^6$
nano	n	$10^{-9}$	Giga	G	$10^9$
pico	p	$10^{-12}$	Tera	T	$10^{12}$
femto	f	$10^{-15}$	Peta	P	$10^{15}$
atto	a	$10^{-18}$	Exa	E	$10^{18}$

# Prefissi del Sistema Internazionale

$10^n$	Bit	Prefisso	Simbolo	Nome	Equivalente decimale
$10^{24}$	80	<u>yotta</u>	Y	<u>Quadrilione</u>	1 000 000 000 000 000 000 000 000
$10^{21}$	70	<u>zetta</u>	Z	<u>Triliardo</u>	1 000 000 000 000 000 000 000
$10^{18}$	60	<u>exa</u>	E	<u>Trilione</u>	1 000 000 000 000 000 000
$10^{15}$	50	<u>peta</u>	P	<u>Biliardo</u>	1 000 000 000 000 000
$10^{12}$	40	<u>tera</u>	T	<u>Bilione</u>	1 000 000 000 000
$10^9$	30	<u>giga</u>	G	<u>Miliardo</u>	1 000 000 000
$10^6$	20	<u>mega</u>	M	<u>Milione</u>	1 000 000
$10^3$	10	<u>kilo</u> o <u>chilo</u>	k	<u>Mille</u>	1 000
$10^2$	7	<u>etto</u>	h	<u>Cento</u>	100
10	4	<u>deca</u>	da	<u>Dieci</u>	10

# Flussi dati

- bps: bit per secondo
- Bps: Byte per secondo pari a numero di bps/8
- KByte, KB: 1024 Byte
- 700 kbps  $\rightarrow$  87 kBps (pari a  $700/8$ )
- 87 kBps  $\rightarrow$  89,600 Bps (pari a  $87*1024$ )
- 700 kbps  $\rightarrow$  716800 bps  
(pari a  $700*1024, 89600*8$ )

# *I dati e I formati*

- Formati e informazioni
- Codifica
- Informatica ?? Informazione – automatica
- Volume dei dati
  - velocità dei flussi e computabilità:
  - static e real time
- Informazione strutturata ←
- entità vs relazioni: rappresentazione conoscenza
- tabelle vs reticoli
- XML

# Tabelle

- Tipi diversi
- Semantica definita

Installation neue PC			
Abteilung	Geplante PC	Installations-termin	Kosten
Einkauf	2 Desktops	August	2.200€
Verkauf	2 Laptops	September	4.600€
Lager	1 Desktop 1 Laptop	Oktober	3.400€

# Esempio di Informazione strutturata

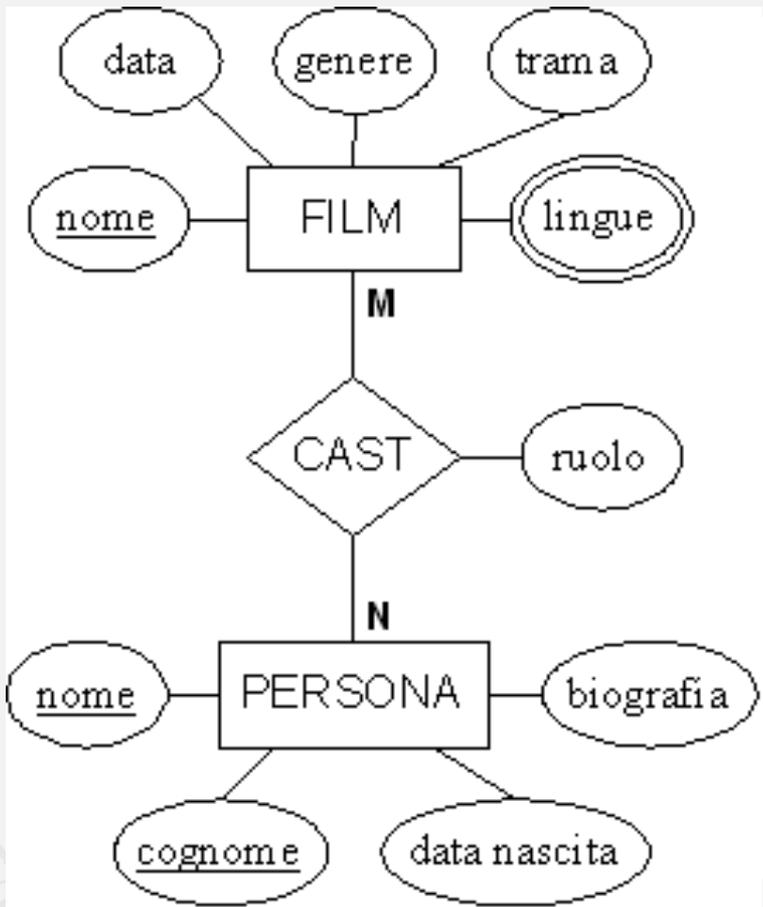
- Persona
  - Nome: massimo 25 caratteri, codifica ASCII
  - Cognome: massimo 25 caratteri, codifica ASCII
  - Età: 1 byte, numero naturale
  - Telefono: massimo 15 caratteri ????
  - Indirizzo:
    - Via/piazza: .....
    - Numero:..... Non basta.....
    - Cap:.....
    - Città:..... descrizione o riferimento.....
  - Padre:..... riferimento a ....
  - Madre:..... Riferimento a .....
  
- Semantica e dati  $\leftrightarrow$  solo dati:
  - Paolo \_\_\_\_\_ | Nesi \_\_\_\_\_ | .... | ..... | ..... | .....

# *I dati e I formati*

- Formati e informazioni
- Codifica
- Informatica ?? Informazione – automatica
- Volume dei dati
  - velocità dei flussi e computabilità:
  - static e real time
- Informazione strutturata
- entità vs relazioni: rappresentazione conoscenza
- tabelle vs reticoli
- XML



# Entità e relazioni

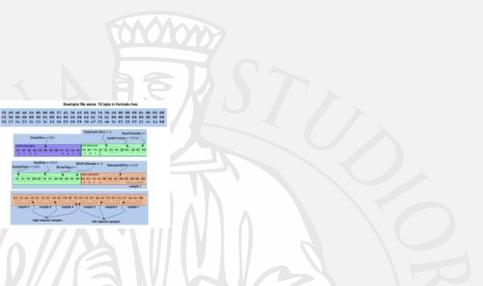
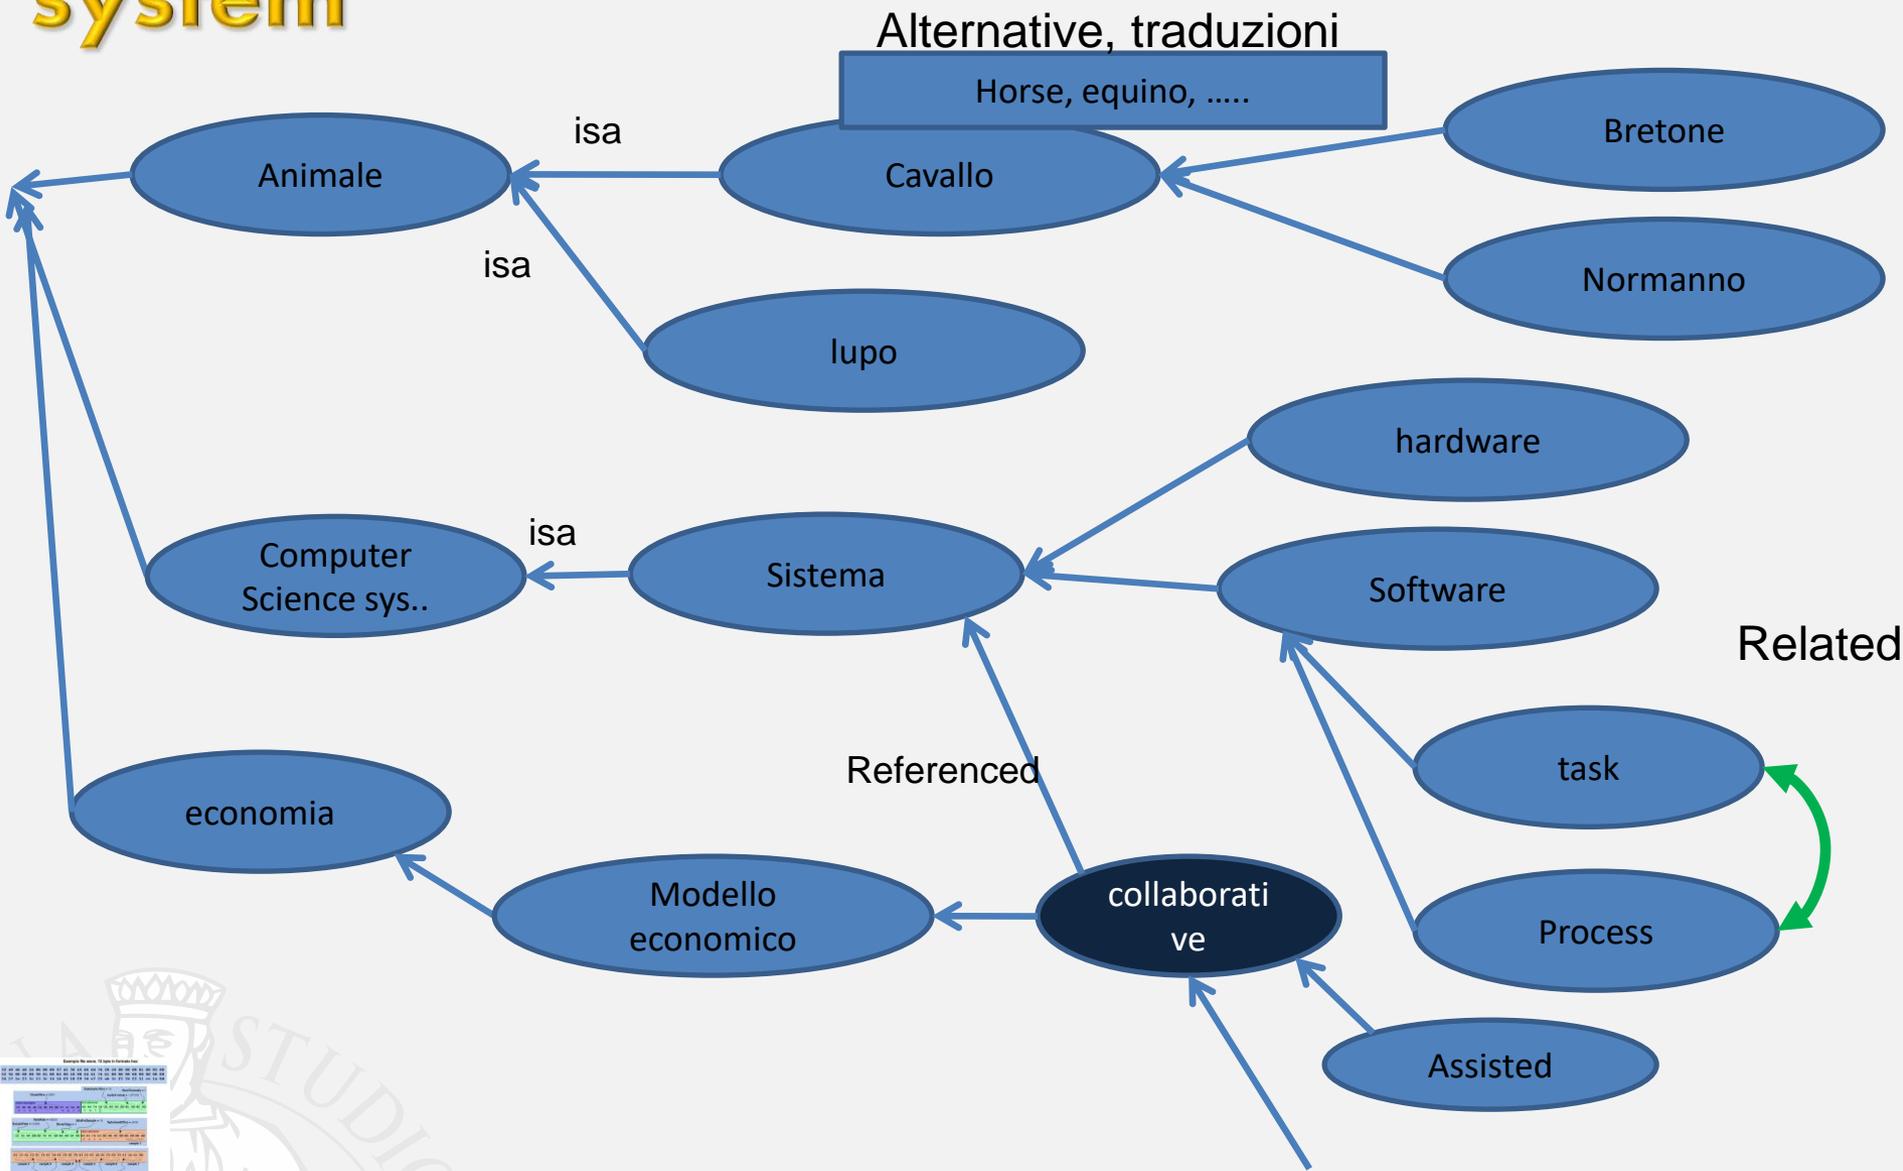


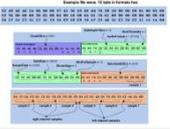
Struttura di classificazione	Simbolo
Entità	Nome entità
Relazione	nome
Attributo semplice	Nome attributo
Attributo composto	Nome attributo Nome attributo
Sottoinsieme	↑
Generalizzazione	↑

Fig.3 Rappresentazione dei concetti del modello entità-relazione



## system



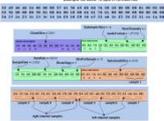


# Tabelle

- Tipi diversi
- Semantica definita
- Le relazioni stanno fra le colonne e sulle colonne

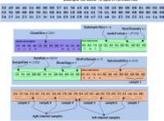
Installation neue PC			
Abteilung	Geplante PC	Installations-termin	Kosten
Einkauf	2 Desktops	August	2.200€
Verkauf	2 Laptops	September	4.600€
Lager	1 Desktop 1 Laptop	Oktober	3.400€





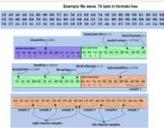
# *Il concetto di metalinguaggio*

- XML è un **metalinguaggio**
  - XML definisce un insieme regole (meta)sintattiche, attraverso le quali è possibile descrivere formalmente un linguaggio di markup, detto “applicazione XML”
  - ogni applicazione XML eredita un insieme di caratteristiche sintattiche comuni
  - ogni applicazione XML a sua volta definisce una sintassi formale particolare
  - ogni applicazione XML è dotata di una semantica specificata in modo non formale



## *XML: caratteristiche (2)*

- XML è indipendente dal tipo di piattaforma hardware e software su cui viene utilizzato
- XML permette la rappresentazione di qualsiasi tipo di documento (e di struttura testuale) indipendentemente dalle finalità applicative
- XML è indipendente dai dispositivi di archiviazione e visualizzazione.
- Un Documento XML può essere
  - archiviato su qualsiasi tipo di supporto digitale (attuale e... futuro!)
  - visualizzato su qualsiasi dispositivo di output

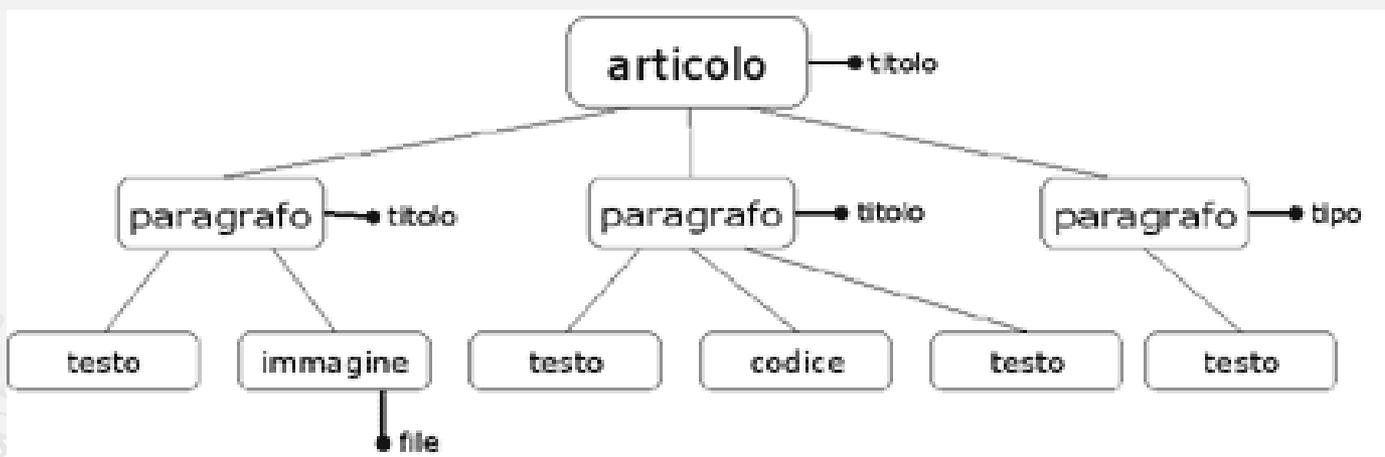


## *XML: caratteristiche (3)*

- XML può essere usato per la rappresentazione di dati strutturati (archivi, tabelle, matrici) in alternativa ai formati di database tradizionali
- XML è uno standard di pubblico dominio
- ogni software “conforme XML” è in grado di gestire dati in formato XML
- sono disponibili numerose applicazioni e librerie *open source* per la manipolazione di dati in formato XML basate su diversi linguaggi di programmazione (Java, C, Python, Perl...)
- una applicazione in grado di elaborare dati in formato XML viene definita elaboratore XML

## XML: caratteristiche (4)

- XML adotta un formato di file di tipo testuale: sia il mark-up sia il testo sono stringhe di caratteri
- XML si basa sul sistema di codifica dei caratteri ISO 10646/UNICODE
- Un documento XML è “leggibile” da un utente umano senza la mediazione di software specifico
- Concretamente, un documento XML è un file di testo che contiene una serie di tag, attributi e testo secondo regole sintattiche ben definite.



<?xml version="1.0" ?>

<articolo titolo="Titolo dell'articolo">

<paragrafo titolo="Titolo del primo paragrafo">

<testo>

Blocco di testo del primo paragrafo

</testo>

<immagine file="immagine1.jpg">

</immagine>

</paragrafo>

<paragrafo titolo="Titolo del secondo paragrafo">

<testo>

Blocco di testo del secondo paragrafo

</testo>

<codice>

Esempio di codice

</codice>

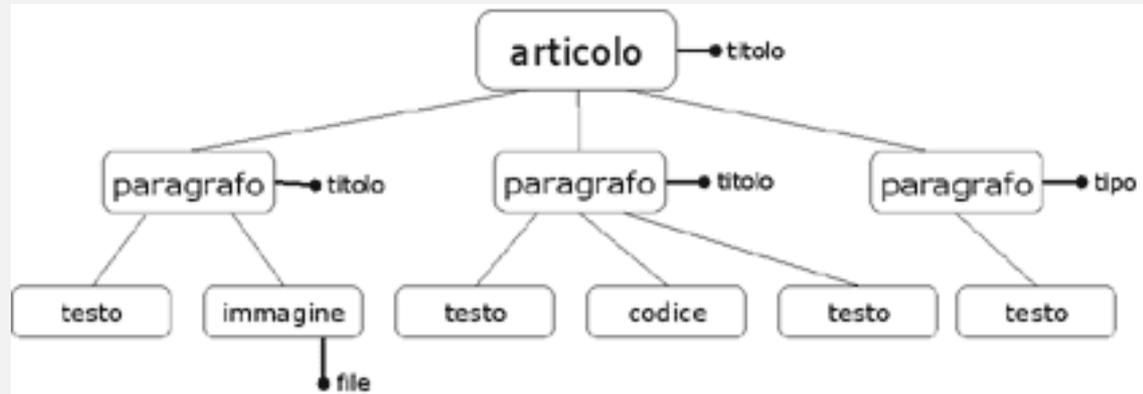
<testo>

Altro blocco di testo

</testo>

</paragrafo>

## *Esempio: articolo*



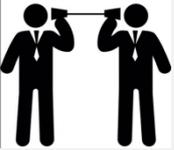
# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati* 
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence*



# *Calcolatori in rete: Networking*

- Sistemi Distribuiti
- Connessioni fra calcolatori
- IP: indirizzi e porte
- Stack ISO OSI
- Protocolli
- Connessioni intercontinentali
- Sicurezza sulla rete

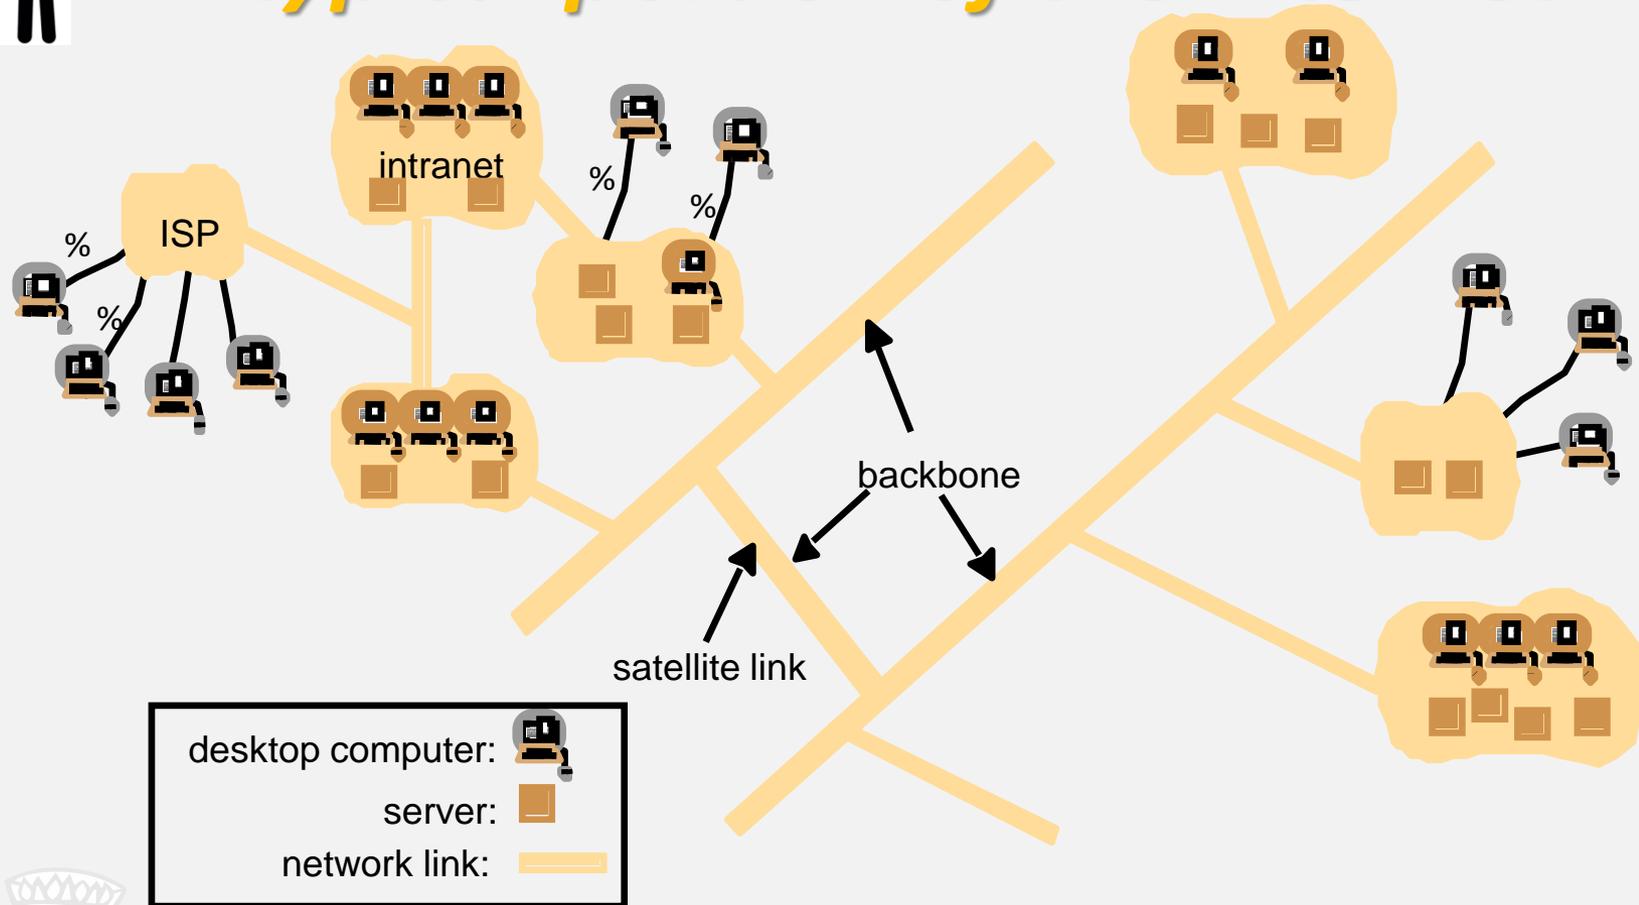


# *Sistemi Distribuiti*

- Un Sistema distribuito è composto da componenti / strumenti messi in relazione tramite una rete di computer.
  - Tali componenti comunicano fra di loro tramite messaggi
- Messaggi portano informazioni:
  - Controlli, oppure Dati
- Esempi di sistemi distribuiti sono:
  - Internet, intranet, mobile and ubiquitous computing



# A typical portion of the Internet

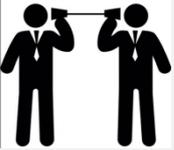




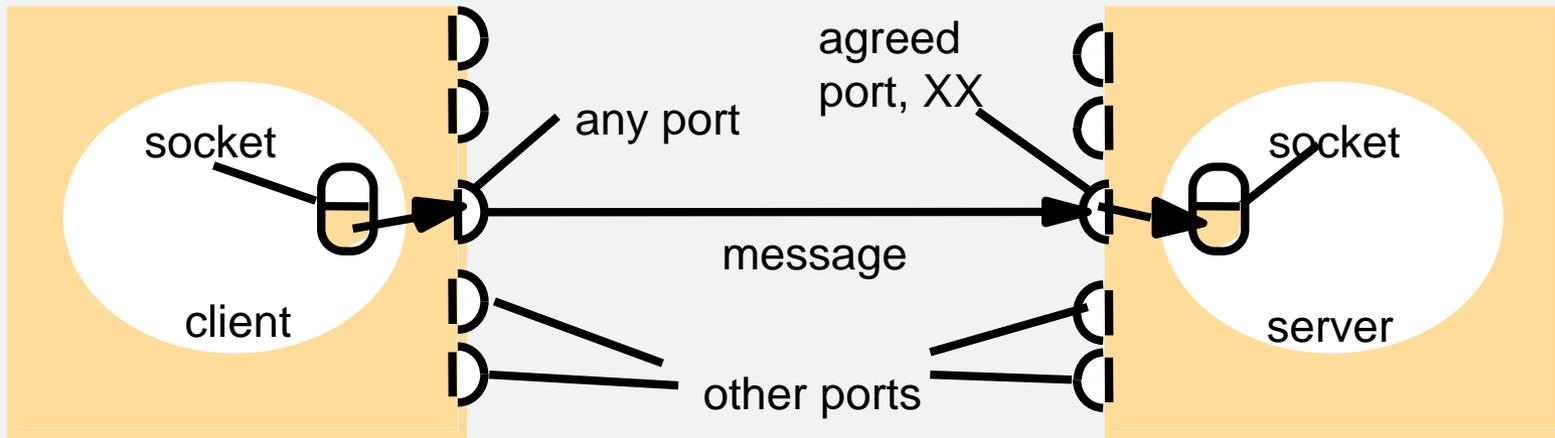
# *Calcolatori in rete: Networking*

- Sistemi Distribuiti
- Connessioni fra calcolatori
- IP: indirizzi e porte
- Stack ISO OSI
- Protocolli
- Connessioni intercontinentali
- Sicurezza sulla rete





# Sockets and ports



Internet address = 138.37.94.248:yy

Internet address = 138.37.88.249

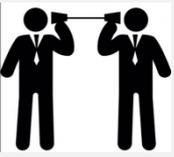
Port=yy



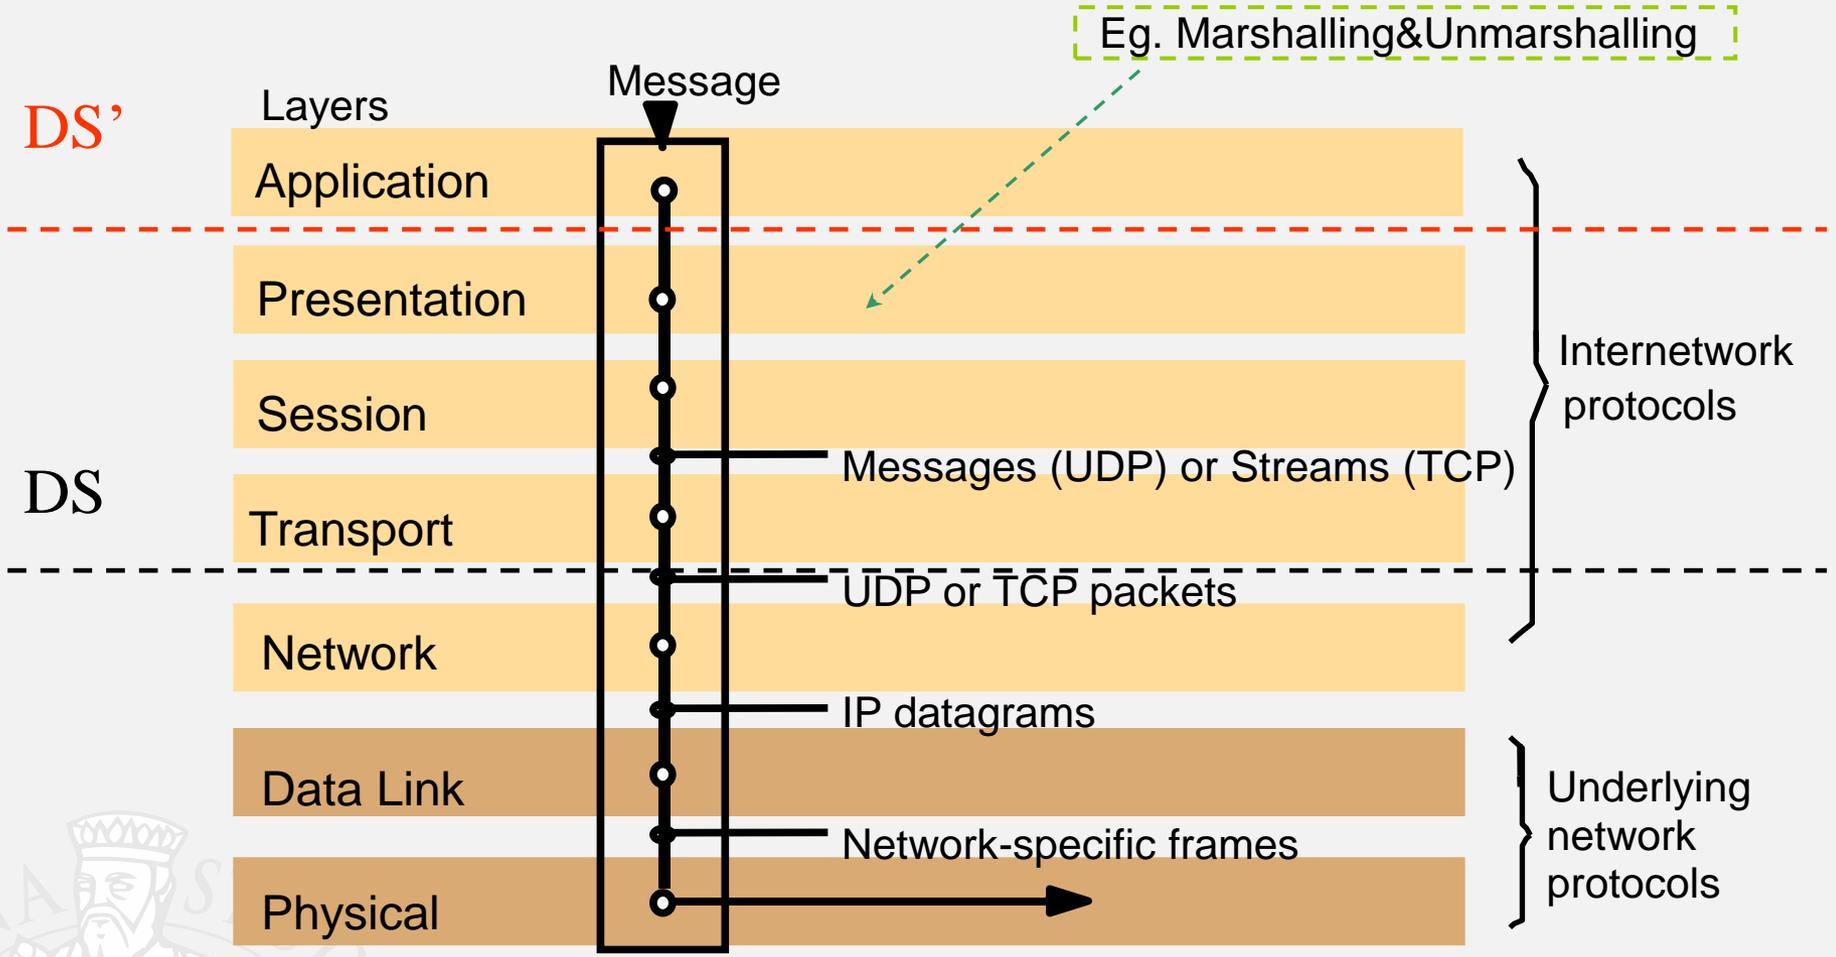


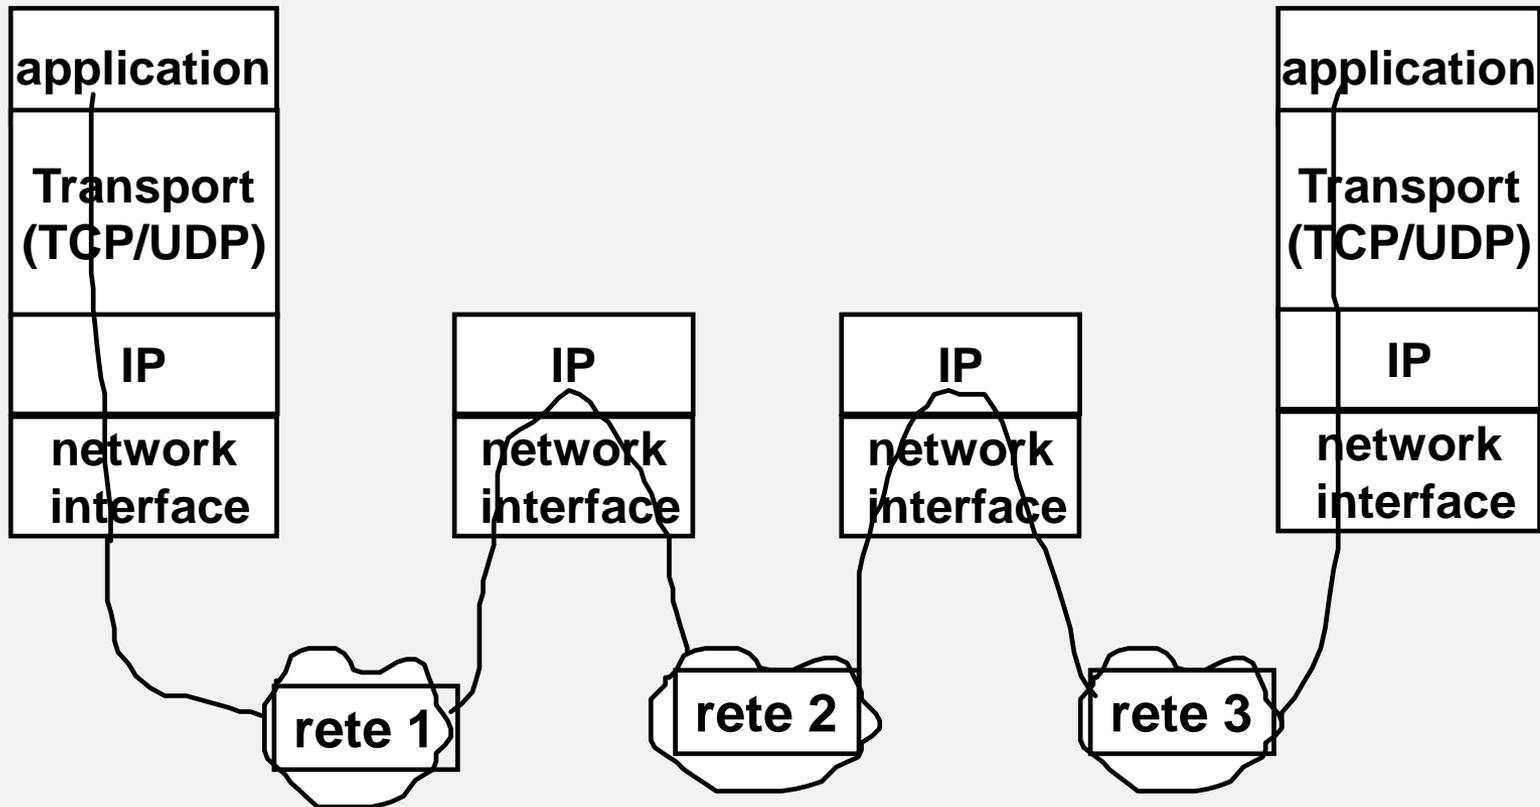
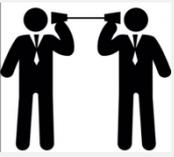
# OSI protocol summary

Layer	Description	Examples
Application	Protocols that are designed to meet the communication requirements of specific applications, often defining the interface to a service.	HTTP, FTP, SMTP, CORBA IIOP
Presentation	Protocols at this level transmit data in a network representation that is independent of the representations used in individual computers, which may differ. Encryption is also performed in this layer, if required.	Secure Sockets (SSL), CORBA Data Rep.
Session	At this level reliability and adaptation are performed, such as detection of failures and automatic recovery.	
Transport	This is the lowest level at which messages (rather than packets) are handled. Messages are addressed to communication ports attached to processes. Protocols in this layer may be connection-oriented or connectionless.	TCP, UDP
Network	Transfers data packets between computers in a specific network. In a WAN or an internetwork this involves the generation of a route passing through routers. In a single LAN no routing is required.	IP, ATM virtual circuits
Data link	Responsible for transmission of packets between nodes that are directly connected by a physical link. In a WAN transmission is between pairs of routers or between routers and hosts. In a LAN it is between any pair of hosts.	Ethernet MAC, ATM cell transfer, PPP
Physical	The circuits and hardware that drive the network. It transmits sequences of binary data by analogue signalling, using amplitude or frequency modulation of electrical signals (on cable circuits), light signals (on fibre optic circuits) or other electromagnetic signals (on radio and microwave circuits).	Ethernet base- band signalling, ISDN

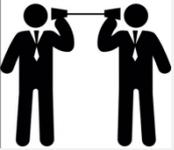


# Network Communication

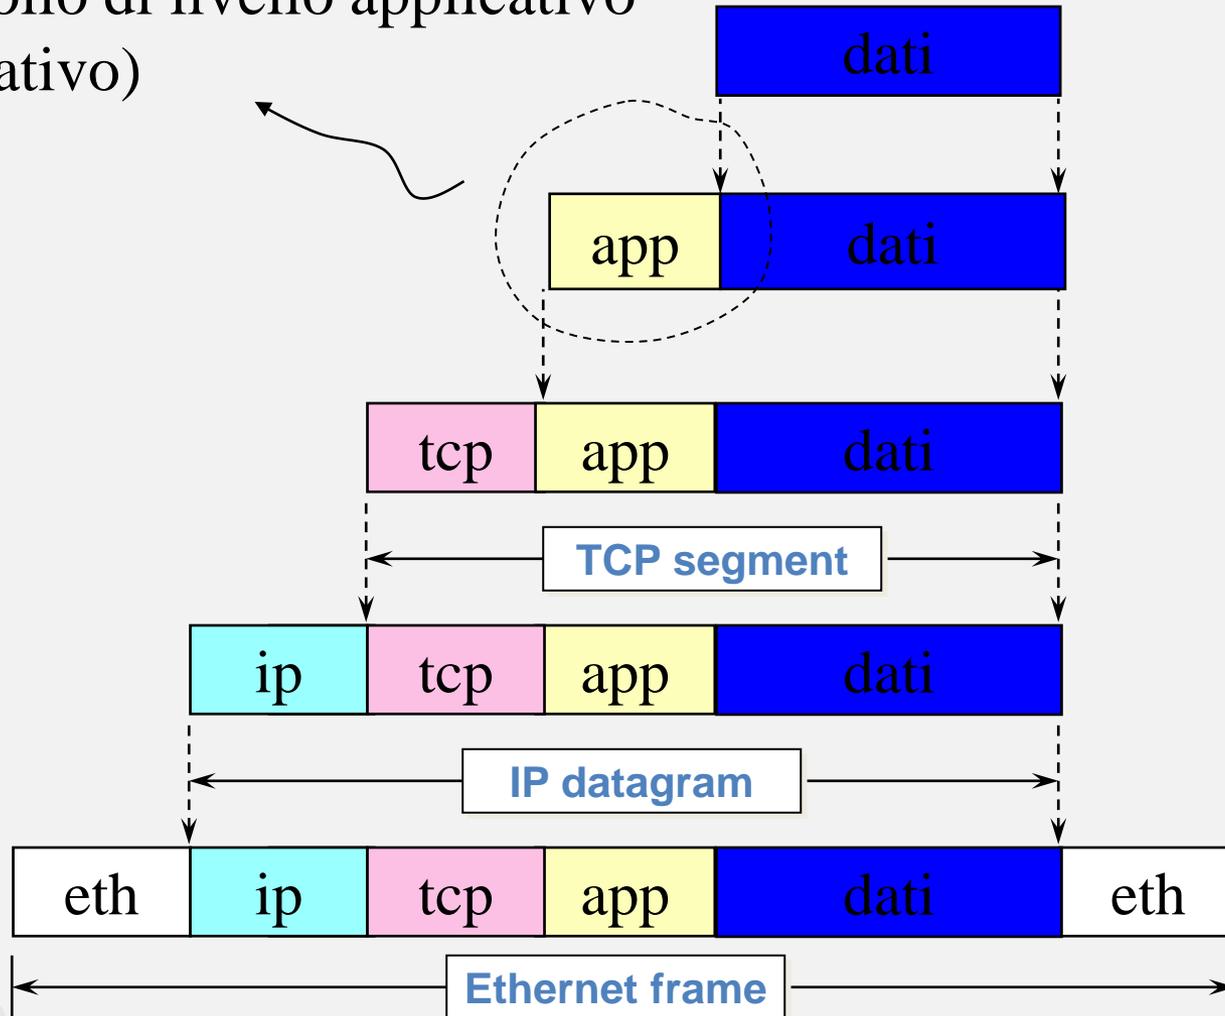


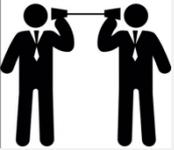


• IP virtualizza omogeneità di gestione delle informazioni tra reti distinte che compongono Internet

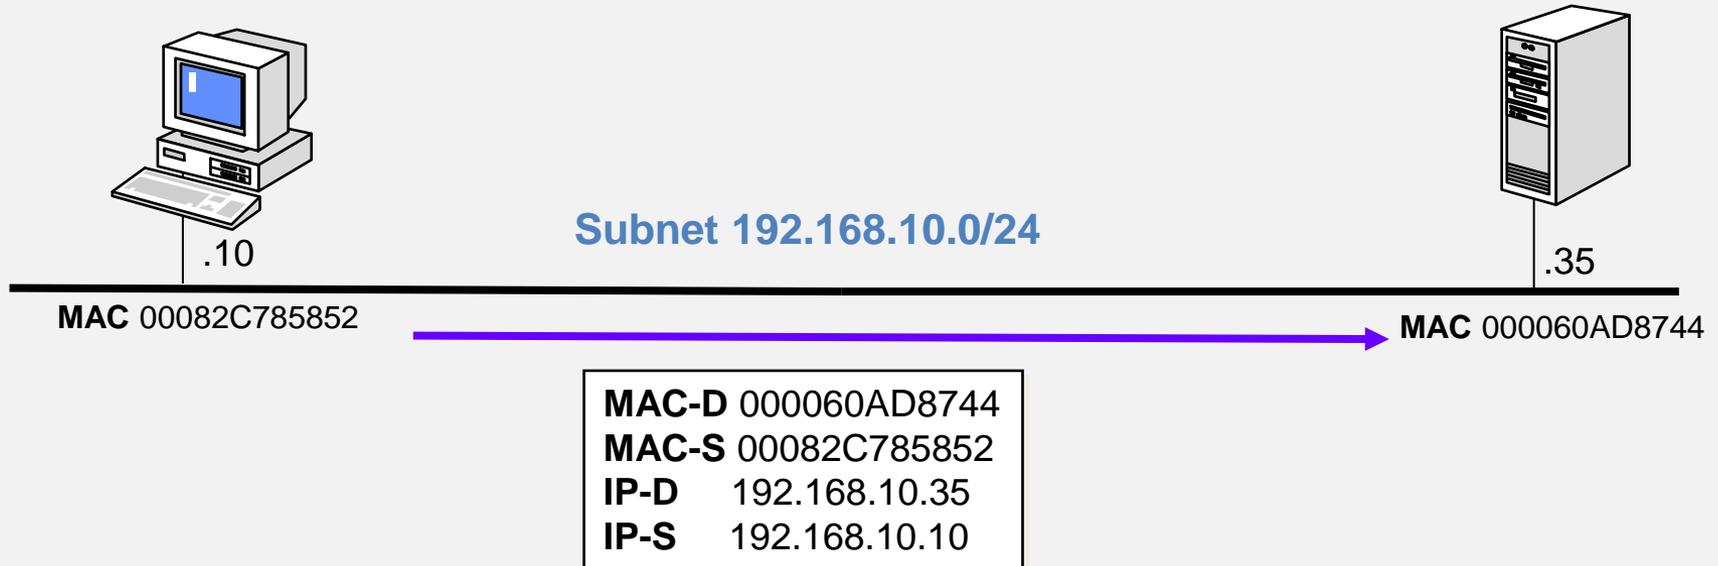


protocollo di livello applicativo  
(facoltativo)



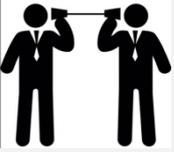


# Forwarding diretto: esempio

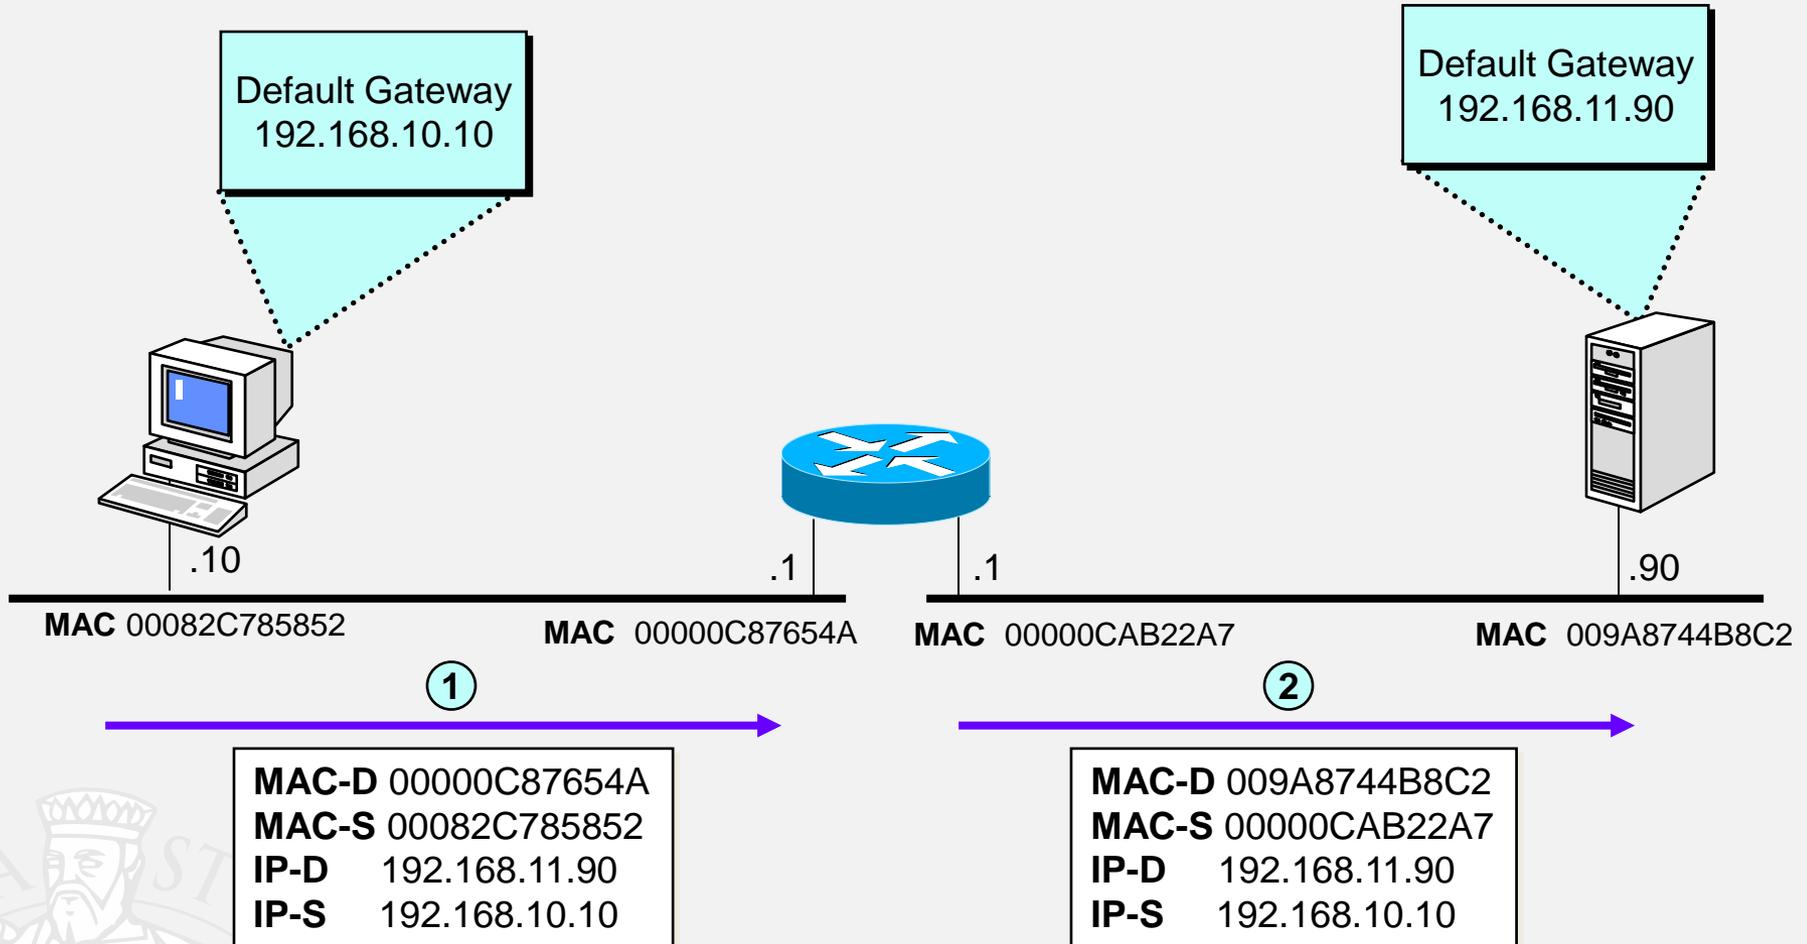


- il mittente genera un frame contenente l'indirizzo MAC dell'host destinazione





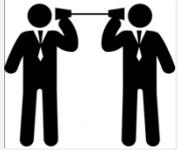
# Forwarding indiretto: esempio





## Condivisione delle Risorse

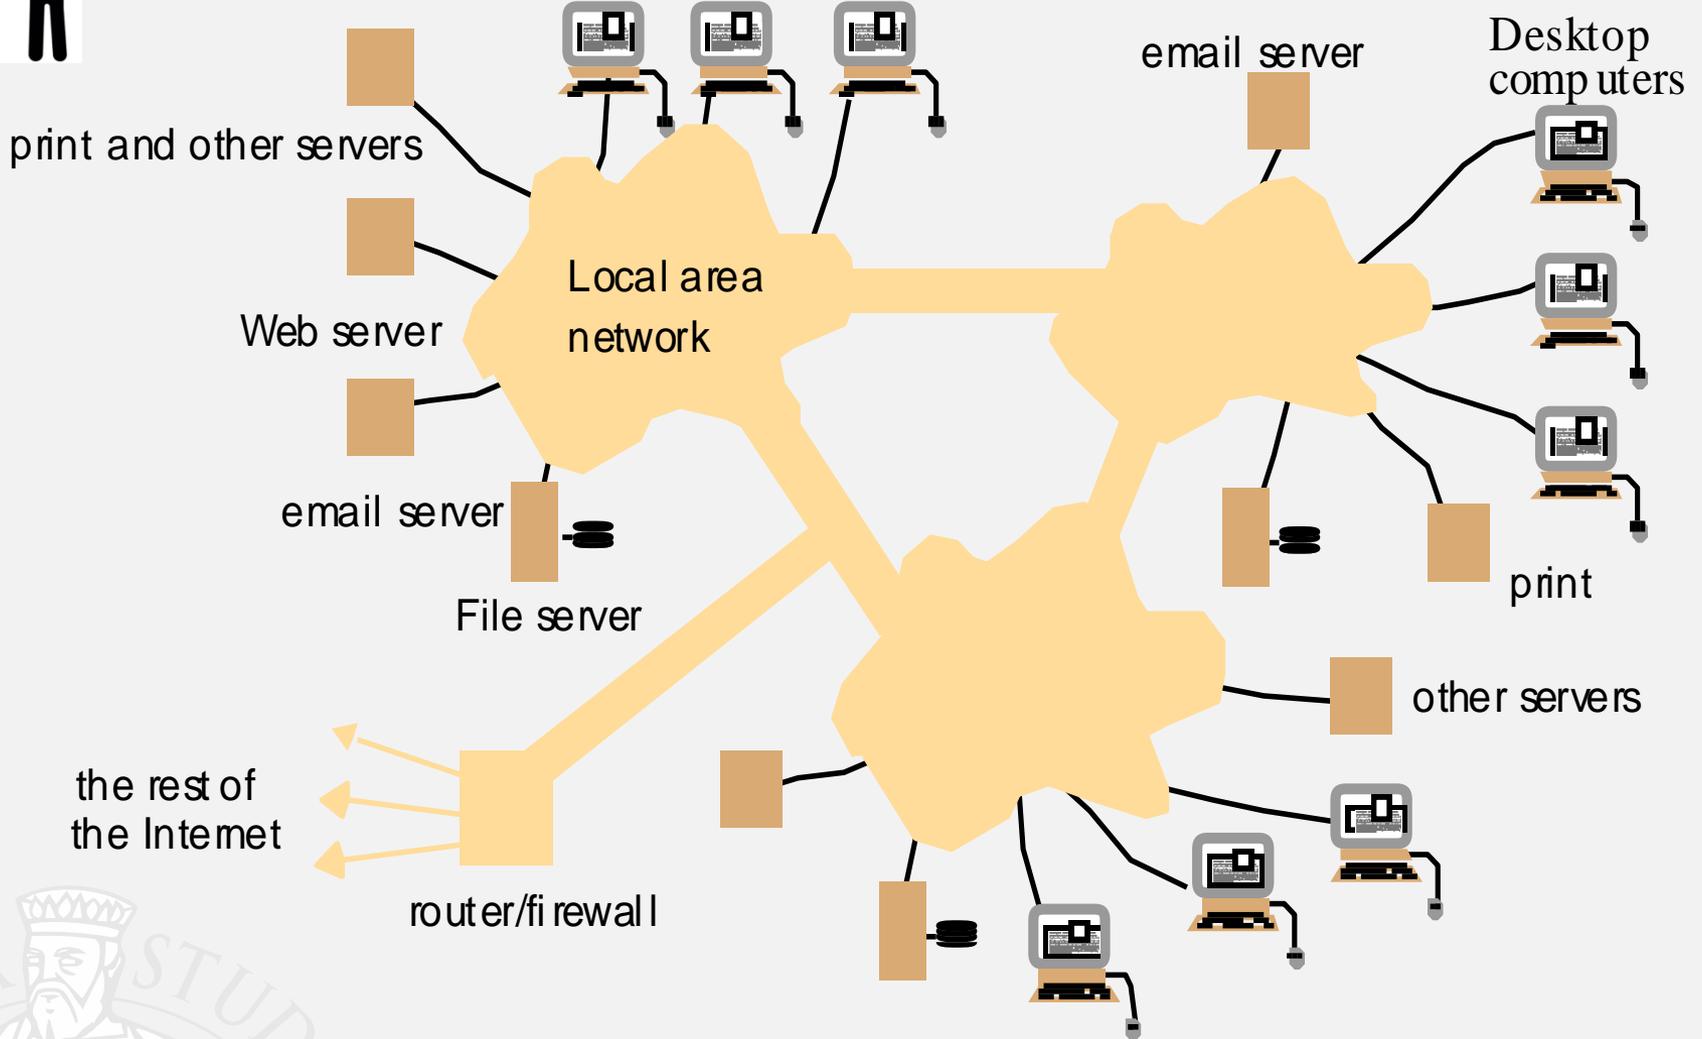
- **Condivisione di risorse hw: stampanti, file, cpu, ...**
- **WEB Servers:**
  - Web pages (HTML... XML....XSL), a range of services
- **Cooperative Work**
  - Cooperative/collaborative Work, CSCW
  - Configuration Management and development tools, CVS
  - Applicazioni P2P
- **Condivisione di servizi**
  - WEB Services, portali e chiamate REST
  - Remote Procedure Calls, RPC, ...RMI
  - Distributed Objects
  - GRID computing, parallel distributed computing
- **Condivisione servizi di calcolo: cloud computing**
  - Massive computing, GRID computing
  - Virtualizzazione, cloud, storage



## *Sistemi Eterogenei*

- **Diversi ??**
  - reti diverse
  - supporti e protocolli diversi
  - computer con hardware diversi
  - sistemi operativi diversi con gli stessi protocolli
  - linguaggi di programmazione diversi per servizi e per la realizzazione di oggetti condivisi e chiamate remote
  - implementazione di servizi diversi
  - implementazioni diverse degli stessi servizi,
  - etc.
- **Middleware to mask heterogeneity**
  - CORBA, Java RMI, J2EE, .....
  - .NET, DCOM....
  - Accesso distribuito a SQL

# A typical intranet





# *Calcolatori in rete: Networking*

- Sistemi Distribuiti
- Connessioni fra calcolatori
- IP: indirizzi e porte
- Stack ISO OSI
- Protocolli ←
- Connessioni intercontinentali
- Sicurezza sulla rete



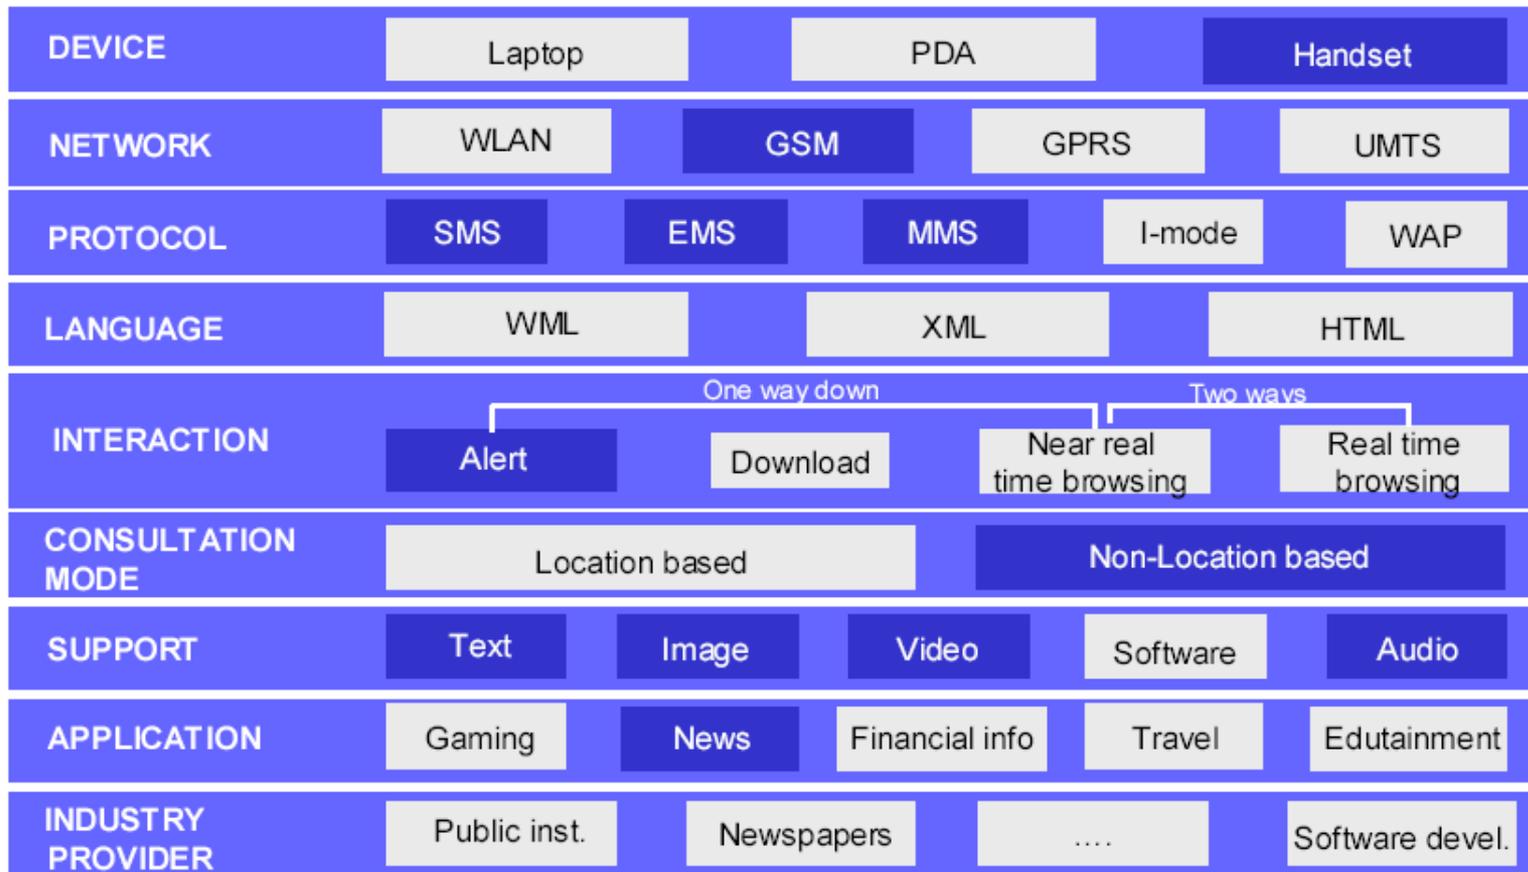
## *Internet vs Intranet*

- Protocollo TCP/IP
- Servizi di base sono:
  - WWW, World Wide Web: HTTP, XML
  - FTP, File Transfer Protocol
  - Mail, chat, meeting, etc.
  - P2P (vari protocolli), GRID
  - Multimedia distribution: IPTV, VOIP, VOD, webTV, etc.
- Connessioni a Internet
  - Via ISP: Internet Service Provider
  - da Internet a Intranet
  - di Internet sul Backbone ad elevata velocità
- WEB Services and WEB Servers





# Layers of technology



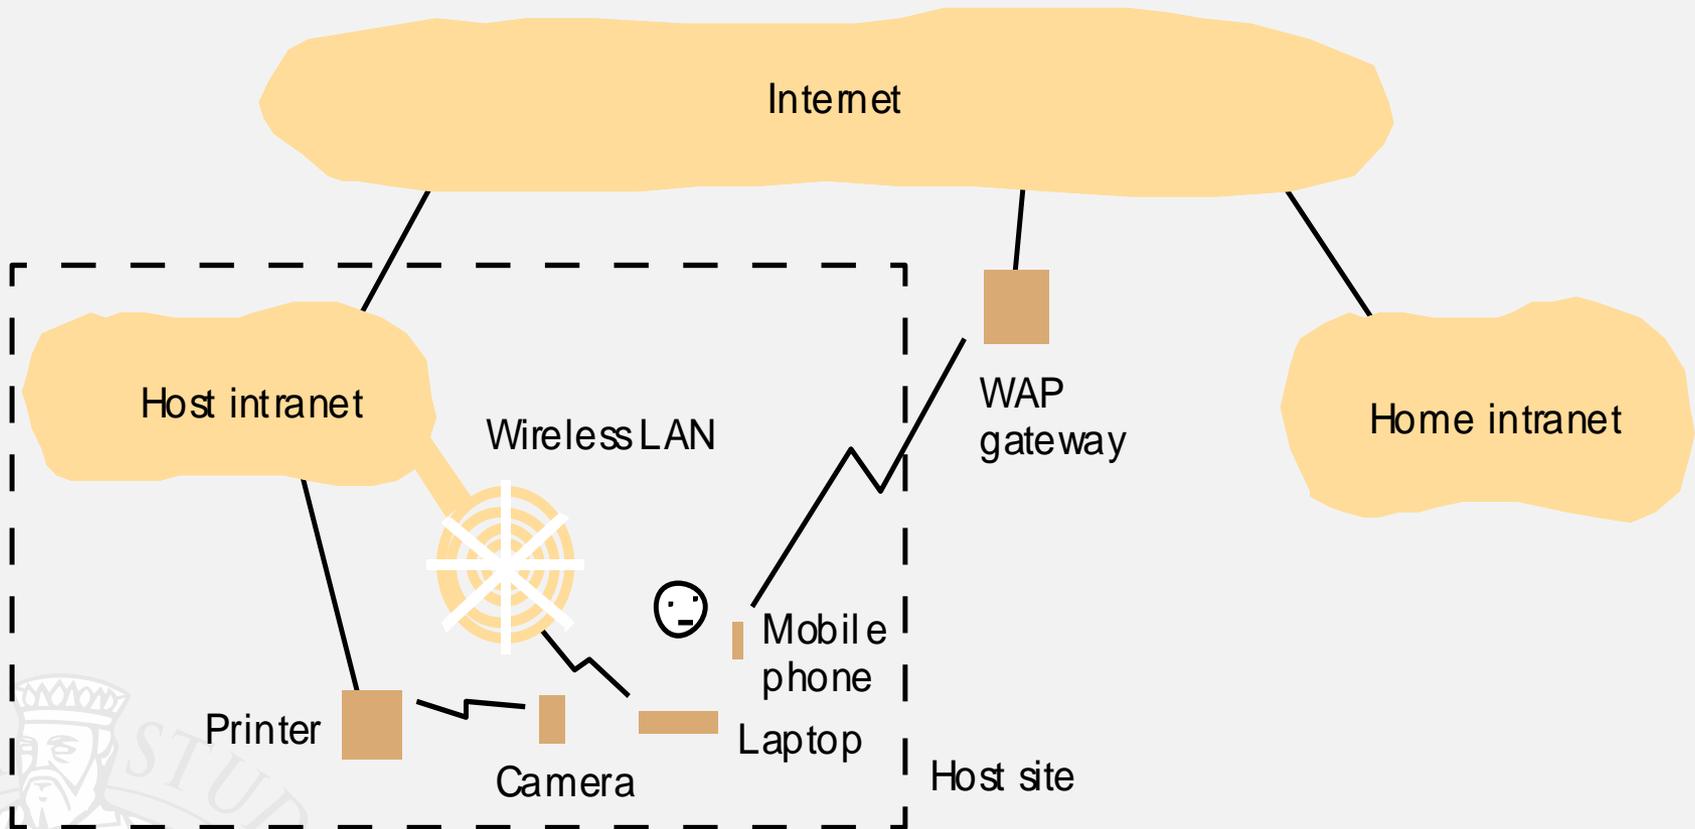
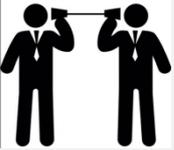
Source: Andersen



# Basi Tecnologiche x Sistemi Distribuiti

- **Problemi e tecnologie per la gestione di**
  - **Comunicazioni** fra processi concorrenti e distribuiti
    - prob: di comunicazione, incertezza/latenza, interruzione, etc.
    - soluzioni: protocolli robusti, modelli robusti
  - **Sincronizzazioni** temporali, e.g., far partire azioni in simultanea
    - prob: mancanza di un clock comune assoluto
    - prob: precisione della Sincronizzazione ...
    - soluzioni: modelli e metodi
  - **Fault** (fallimenti) in sistemi distribuiti
    - prob: fallimenti Indipendenti/dipendenti, coincidenti/sparsi
    - soluzioni: azioni di Recovering from failure
    - soluzioni: Architetture fault tolerance
- **I sistemi distribuiti sono tipicamente eterogenei**
  - Diversi per: sistema operativo, interfaccia di comunicazione, potenza, CPU, protocolli, posizione, etc.

# Portable and handheld devices in a distributed system



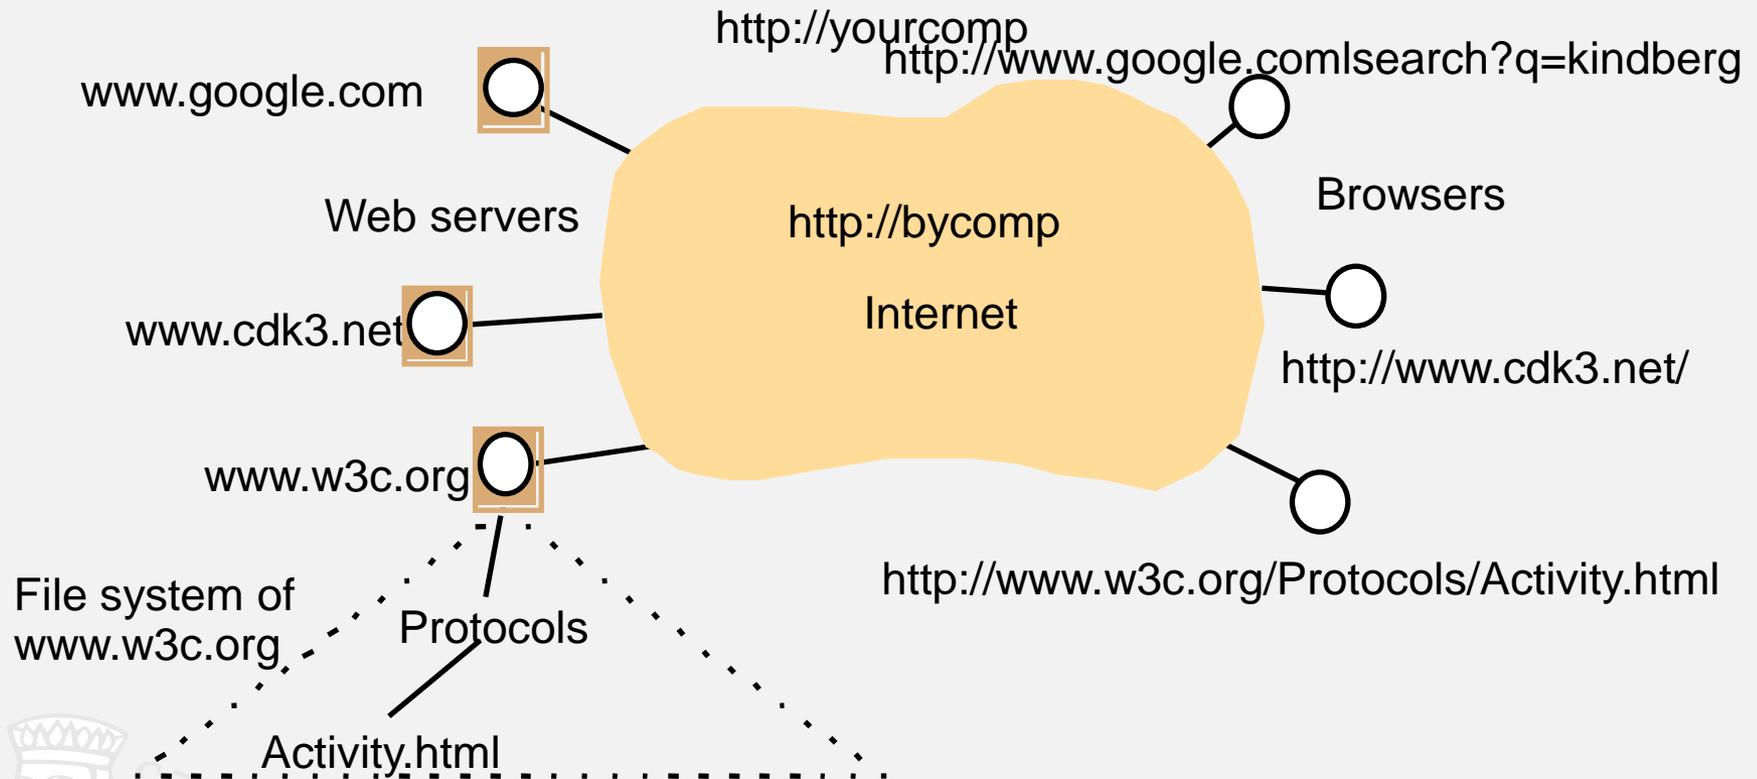


## *Intranet*

- **LAN Services:**
  - Condivisione di File, Stampanti/Printer, ...
  - Accesso a Web Services di vario tipo:
    - Accesso a db, ricerche, DNS, etc.
  - Utilizzo di WEB application per la gestione interna dell'azienda che ha realizzato l'Intranet
- **Connessioni da Intranet a Internet, gateway:**
  - Problemi di sicurezza
  - Firewall verso/da Internet
  - Connessione via provider: ADSL, mobile net, tc...



# Web servers and web browsers

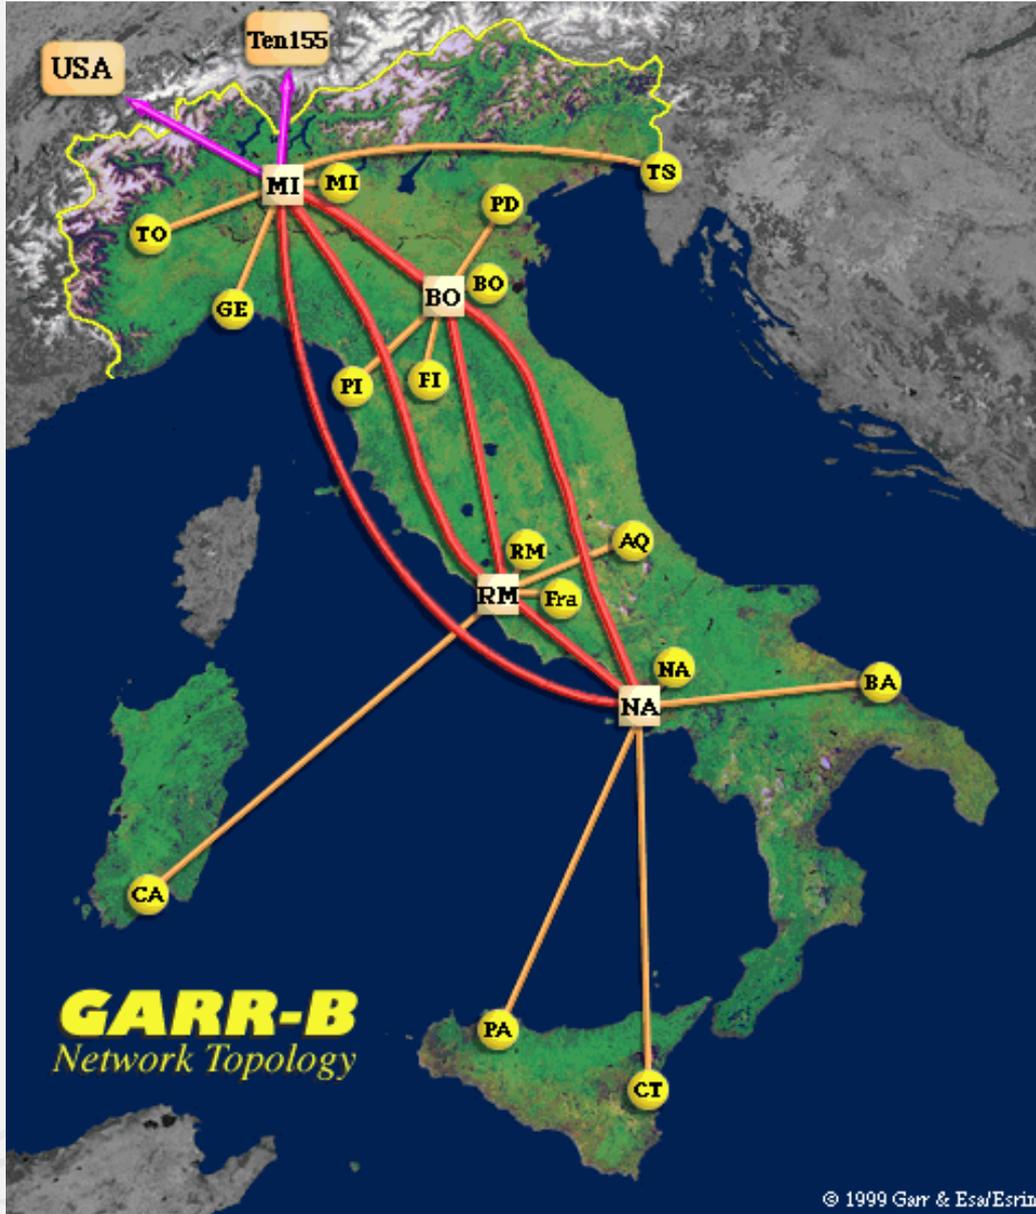




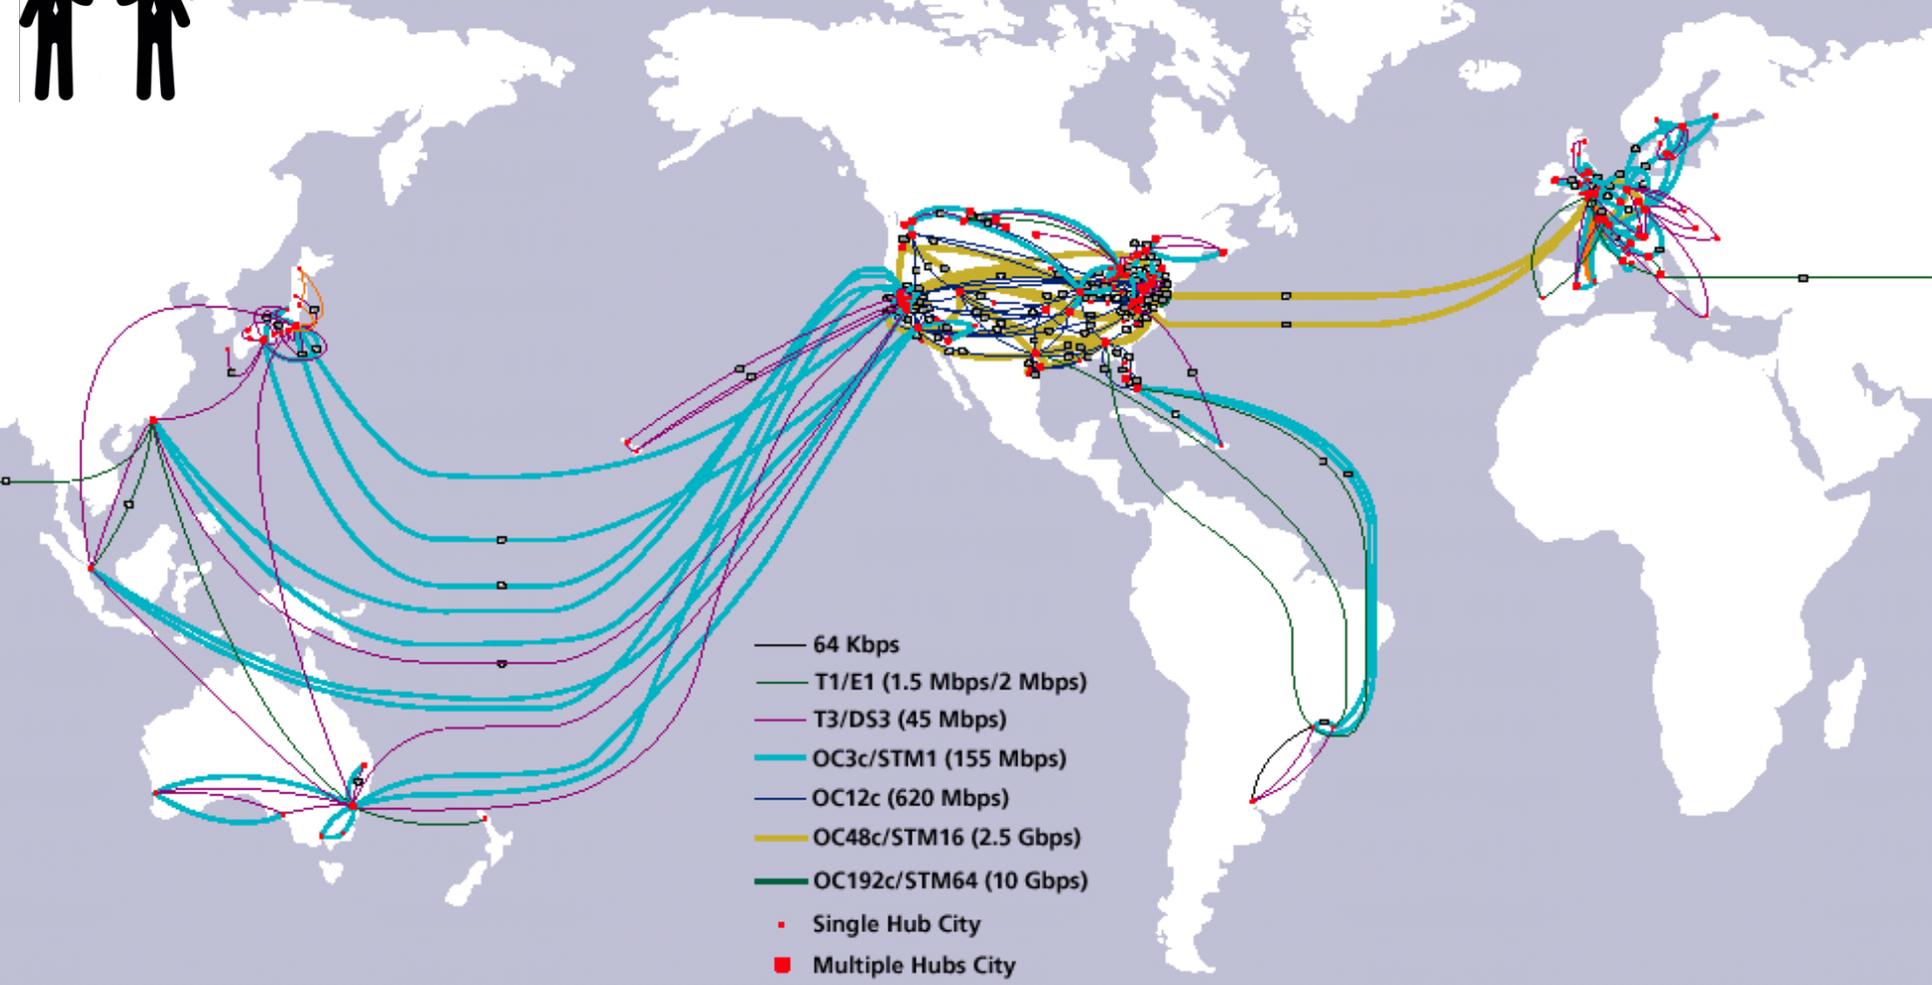
# *Calcolatori in rete: Networking*

- Sistemi Distribuiti
- Connessioni fra calcolatori
- IP: indirizzi e porte
- Stack ISO OSI
- Protocolli
- Connessioni intercontinentali
- Sicurezza sulla rete





# WorldCom's Global UUNET Internet network



For more information see [www.uu.net/network/maps](http://www.uu.net/network/maps)  
NB: UUNET also has infrastructure within individual countries, which is not shown on this map.  
January 2001

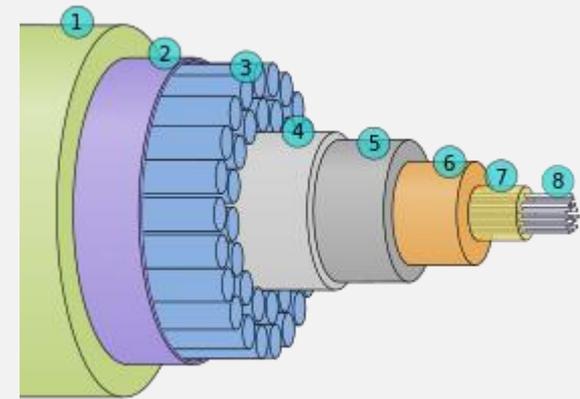




# Stesura cavi sottomarini

Un satellite geostazionario deve essere posto in orbita ad una altezza dalla superficie terrestre di 36 000 km. Alla velocità della luce le onde radio impiegano circa un quarto di secondo a percorrerlo: tempo di latenza di mezzo secondo (andata e ritorno della risposta).

Un cavo idealmente posato tra Roma e New York ha una lunghezza di 6 600 km e causa un ritardo di soli 5 centesimi di secondo.



- Una [sezione](#) di un moderno cavo sottomarino per le telecomunicazioni.
  - 1 – [Polietilene](#)
  - 2 – nastro in [Mylar](#)
  - 3 – cavi d'[acciaio](#)
  - 4 – [Aluminium](#) water barrier
  - 5 – [Policarbonato](#)
  - 6 – Tubo di [rame](#) o d'alluminio
  - 7 – [Vaselina](#)
  - 8 – [fibra ottica](#)



# *Calcolatori in rete: Networking*

- Sistemi Distribuiti
- Connessioni fra calcolatori
- IP: indirizzi e porte
- Stack ISO OSI
- Protocolli
- Connessioni intercontinentali
- Sicurezza sulla rete





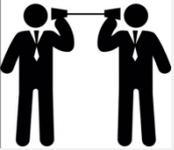
## Sicurezza

- **Controllo** degli accessi a dati e servizi
  - Consistenza dei dati
  - Firewall (indirizzi IP, protocolli e porte)
  - VPN (Virtual Private Network)
- **Sicurezza**
  - Registrazione e riconoscimento, autenticazione
  - Accesso ai servizi in modo controllato
  - SSO, single sign on
- **Gestione dei Fallimenti**
  - Detecting Failures
  - Masking Failures: resend, raid...
  - Recovering From Failures
  - Fault Tolerance, with Redundancy



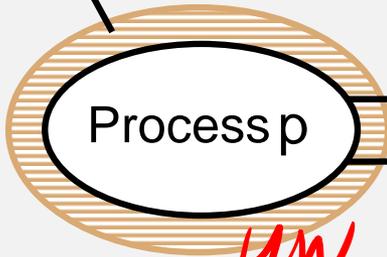
## *Security Model, controllo accesso*

- **Authentication** of users
  - User ID and password, frequently saved as MD5 into database
  - User profiling with several information of the user
  - Production of certificates per la gestione delle chiavi
- **Certification** delle integrità di elementi come
  - devices (HW+SD), SW tools, etc.
  - data e content, dati e contenuti
  - Channel, canale
- **Protezione** di canale
  - Per esempio: SSL, HTTPS, SFTP
  - Certificati per la connessione



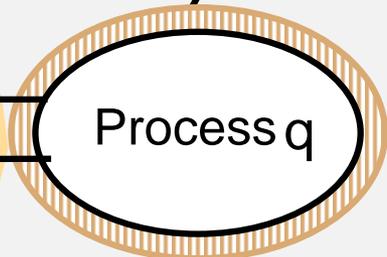
# Secure channels

Principal A



Secure channel

Principal B



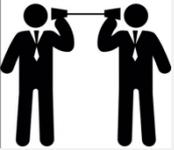
*Handwritten red notes:* ST, HNSW

*Handwritten red notes:* SSL

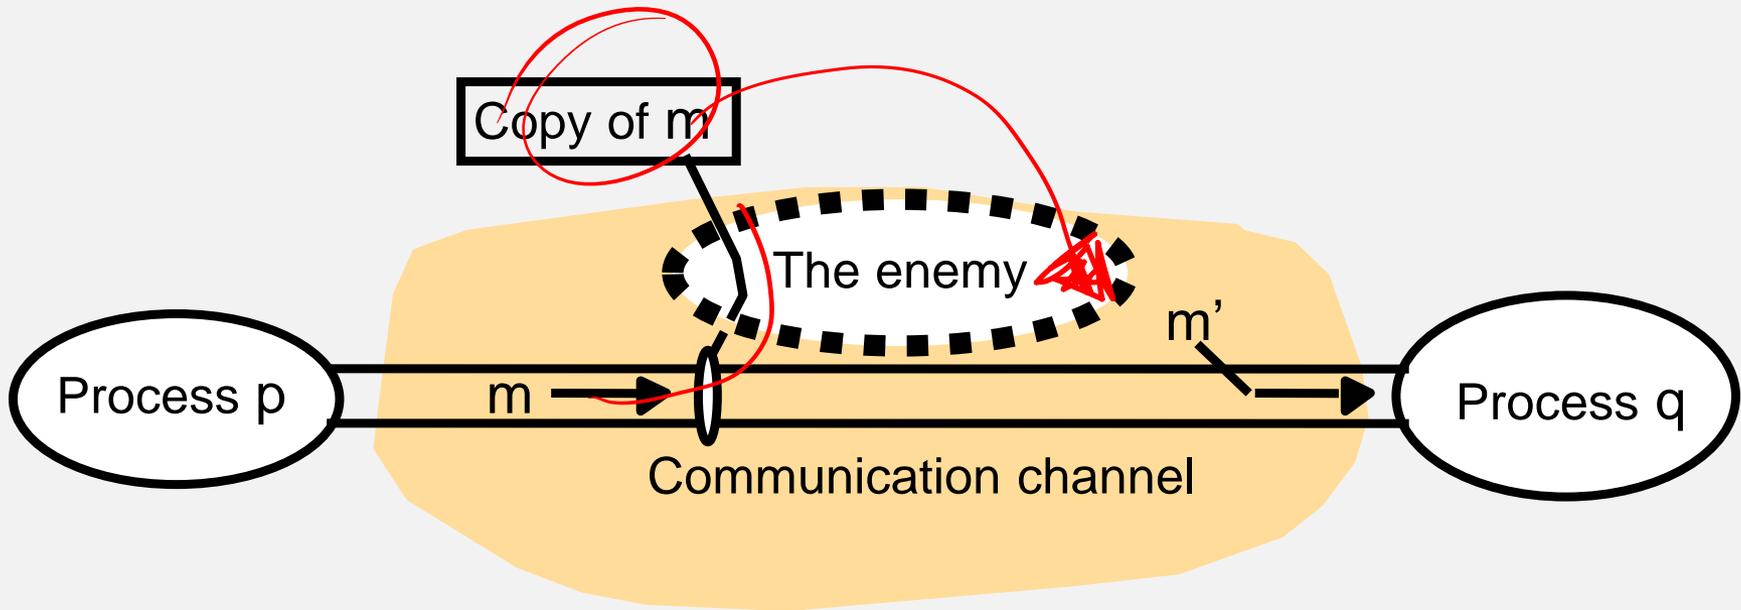
*Handwritten red notes:* [scribble]

**Device authentication**





# The Enemy, il nemico



Al momento della connessione e creazione del canale protetto sia hanno i maggiori rischi



## *Security Model con diritti (rights)*

- **Protezione** dei contenuti, degli oggetti:
  - Objects/components: software tools
  - Data: digital media, audiovisual, etc.
- **Controllo e prevenzione**
  - Controllo accesso all'oggetto:
    - Conditional Access Systems, CAS
  - Controllo dei diritti per l'uso dei servizi degli oggetti
    - Digital Rights Management, DRM
- **Sfruttamento controllato** di ogni loro caratteristica/ feature/ servizio
  - Conto corrente: leggo, muovo soldi, cambio parametri, etc.
  - Processo: start, stop, uso F1, uso F2, etc.
  - Contenuto digitale: play, print, copy, etc.

# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione* ←
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence*



# *Modelli di protezione e gestione*

- Copy protection ←
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint



# Copy Protection solution

- **Naturally digital items can be freely copied**
  - The copy is a feature of the operating system, file system
  - The operating system cannot be typically controlled
  - Microsoft is going to enforce more control on the Operating System
- **CP Solution:** prevents the Copy of digital content
  - Programs: hardware key
  - Holes in physical domain
  - Special formatting in CDs/DVDs
  - Etc.



## Utilizzo della crittografia

- Encryption è il processo che codifica un messaggio in modo da nascondere il contenuto
- Si basano sull'uso di parametri segreti chiamati *chiavi*
- Si dividono in due classi fondamentali
  - Chiavi segrete condivise (*secret-key*)
  - Coppie di chiavi pubblica/privata (*public-key*)
- Segretezza e integrità
- Autenticazione
- Firma digitale



# *Modelli di protezione e gestione*

- Copy protection
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint





## Modello di sicurezza

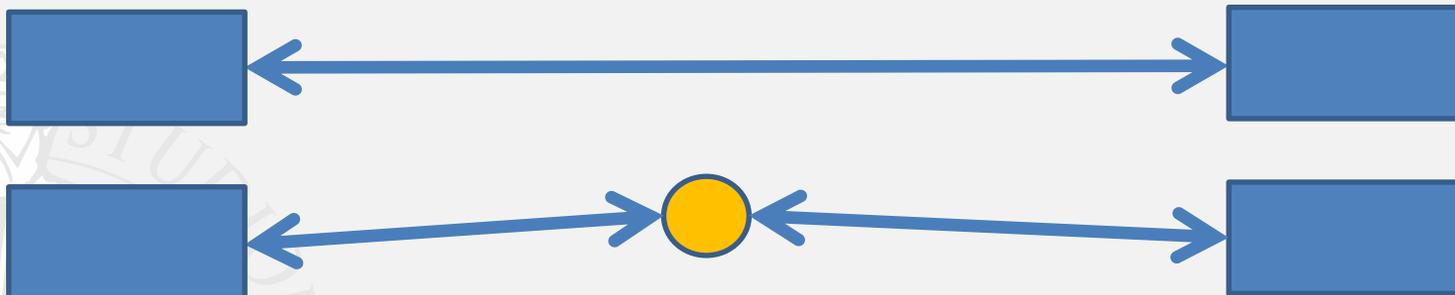
- Elementi chiave:
  - Processi
  - Risorse
  - Interfacce
- I **processi** contengono (*encapsulation*) oggetti (linguaggi di programmazione) e altre **risorse** definite dal sistema
- I processi consentono l'accesso ai **client** attraverso le loro **interfacce**
- I **principals** (utenti o altri processi) possono essere autorizzati a operare su di una determinata risorsa
- I processi interagiscono attraverso una **rete** condivisa tra molti utenti





## *Sistema distribuito: esempi di minacce*

- In molte architetture di rete è semplice
  - creare un programma che ottenga copie dei messaggi trasmessi sulla rete
  - se i clients non provvedono ad autenticare il server, che un programma possa inserirsi è spacciarsi per il processo server richiesto cosicché il client trasmetta le informazioni ignaro della loro reale destinazione
  - che un programma esegua richieste fraudolente a scapito di un sistema insicuro, a seguito di violazione dei suoi dati





## Classificazione delle minacce

- Lo scopo principale della sicurezza è consentire l'accesso alle risorse ed alle informazioni soltanto ai *principal* autorizzati
- Le minacce sono contenute in tre classi:
  - Leakage
    - Accesso ad informazioni del sistema senza autorizzazione
  - Tampering
    - Modifica non-autorizzata delle informazioni
  - Vandalism
    - Interferenza al corretto funzionamento del sistema senza guadagno da parte di chi la attua



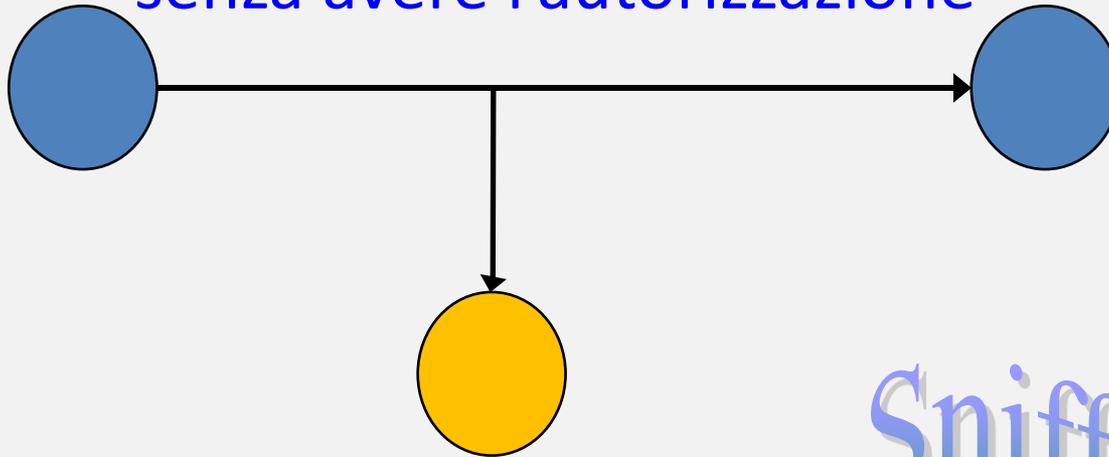
## *Tipologie di attacco al sistema*

- Gli attacchi ad un sistema distribuito contano su
  - dall'ottenere o meno l'accesso a canali di comunicazione esistente
  - dal creare nuovi canali di comunicazione che figurano come autorizzate
- Si distinguono nelle seguenti tipologie:
  - **Eavesdropping** (sniffing)
  - **Masquerading** (spoofing)
  - **Message tampering**
  - **Replayng**
  - **Denial of service, DOS**



## Eavesdropping

Ottenere copie dei messaggi  
senza avere l'autorizzazione



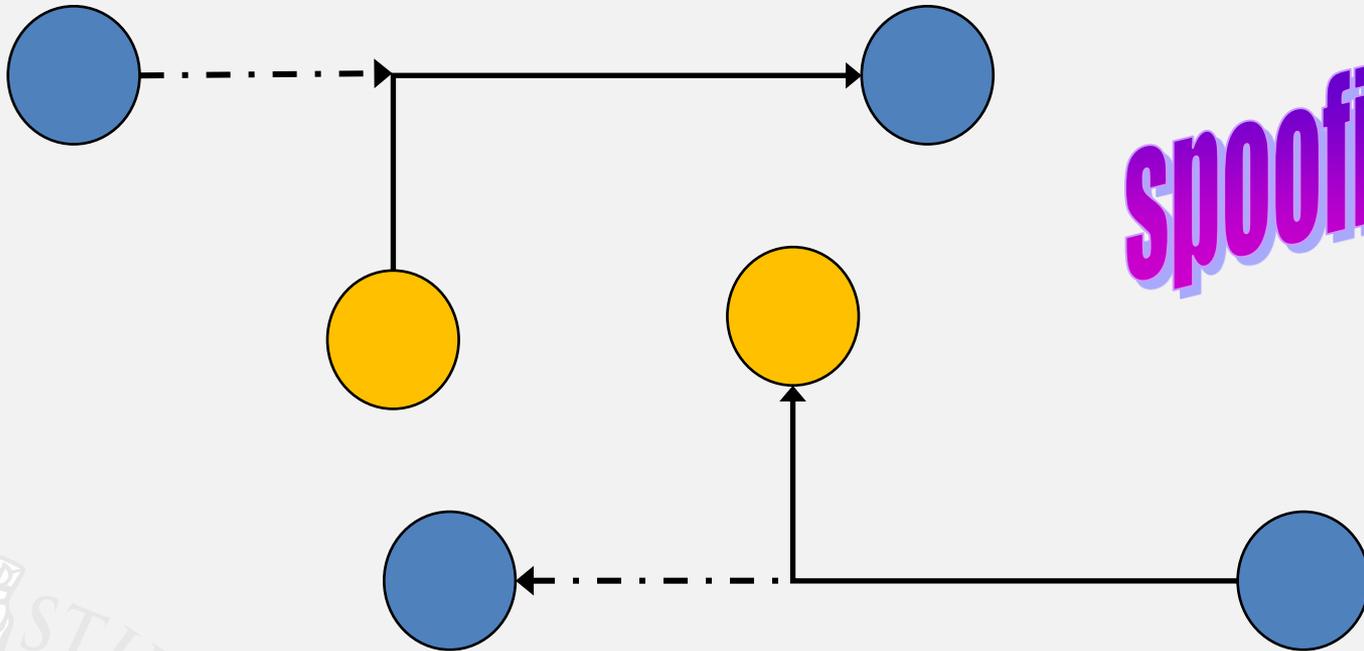
Sniffing





## Masquerading

Inviare o ricevere messaggi usando l'identità di altri principals senza la loro autorizzazione



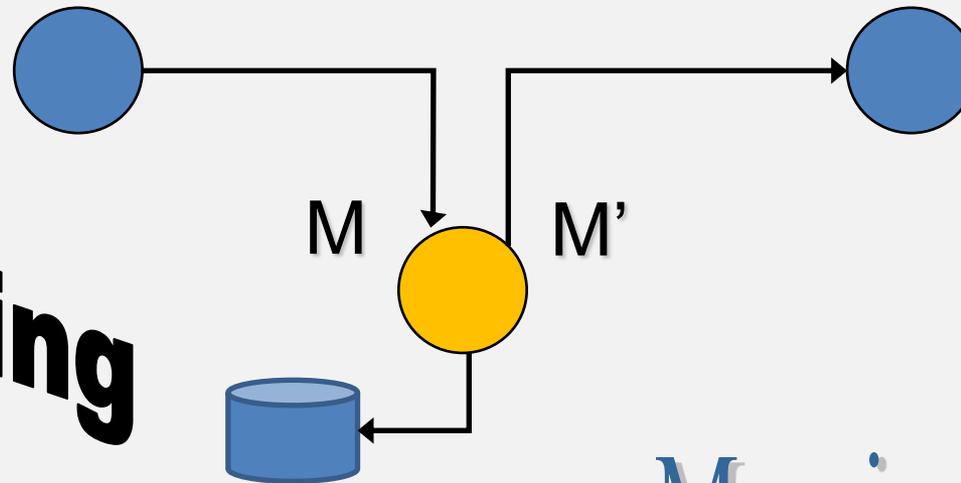
spoofing





## Message tampering

Intercettare messaggi ed alterarne il contenuto prima di ritrasmetterli alla destinazione prevista



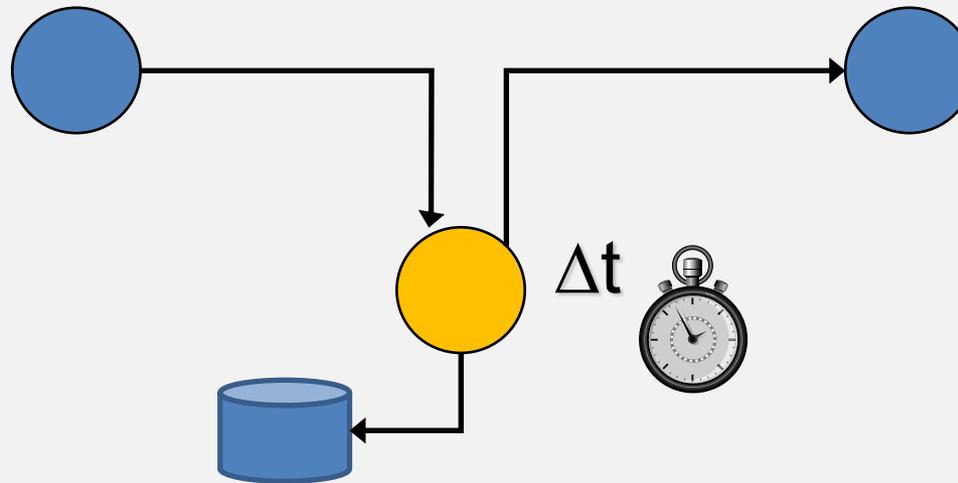
**Hijacking**

Man-in-the-middle



## Replaying

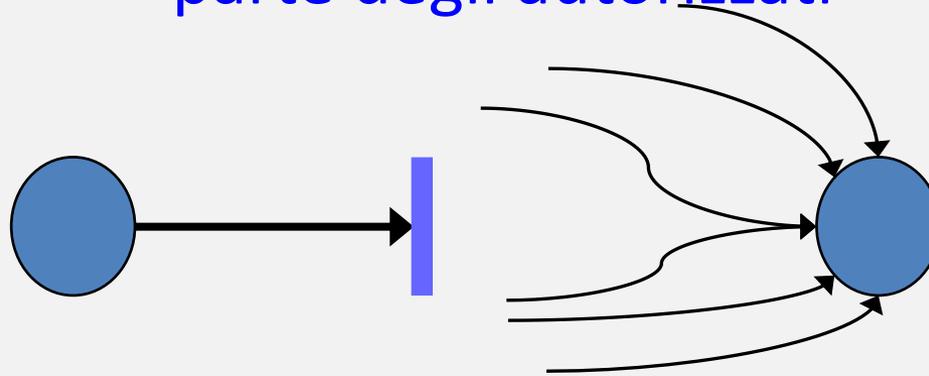
Memorizzare messaggi intercettati e inviarli in ritardo rispetto alla loro reale origine





## *Denial of service, DOS*

Saturare un canale di comunicazione o altre risorse con messaggi ripetuti in modo da negarne l'accesso da parte degli autorizzati





## *Pericoli potenziali ed effettivi*

- Tutti questi sono pericoli soltanto in teoria, ma gli attacchi che possono andare a buon fine dipendono dal sistema di sicurezza
- Attacchi con successo contano sul fatto di individuare imperfezioni del sistema di sicurezza (*holes*)
- Negli attuali sistemi in uso sono comuni e ben evidenti



## Minacce dal mobile code

- Si definisce *mobile code* un programma che viene caricato da un server remoto e viene eseguito in locale
  - Plugin, activeX, applet, ..... javascript
- In questo contesto le risorse all'interno del sistema locale possono subire un attacco dal mobile code
- JVM dà ad ogni applicazione mobile code un suo ambiente predefinito ed un security manager determina quali risorse sono disponibili
  - Le classi scaricate in memoria diversa dalle classi locali
  - Il bytecode viene controllato prima di essere eseguito
- Molti browser impediscono alle applet JAVA di accedere ai file locali, alle stampanti o alle socket del sistema
  - Si veda per esempio la definitiva cancellazioni dell'uso di Flash player nei browser



## Information leakage

- Il problema della riservatezza delle informazioni non riguarda soltanto il contenuto dei messaggi scambiati
- Anche *osservare* che in un canale sorgente-destinazione il flusso di dati è rilevante può essere un'informazione importante



## *Transazioni elettroniche sicure 1*

- E-mail
  - Anche il protocollo dedicato allo scambio di posta non prevedeva originariamente un supporto alla sicurezza, ma la crittografia è adesso comune a molti applicativi
- Acquisto di beni e servizi
  - E-commerce prevede il selezionamento dei beni da acquistare ed il pagamento attraverso il Web





## Transazioni elettroniche sicure 2

- Transazioni Bancarie
  - Le banche elettroniche offrono virtualmente i tipici servizi presenti allo sportello di una banca comune (estratto conto, bonifico bancario, domiciliazione utenze)
- Micro-transazioni
  - Altri servizi possono essere forniti dal Web tipo supporto alla *comunicazione vocale* o alla *videoconferenza*, pagabili a tempo tipicamente con importi bassi da non giustificare la sicurezza prevista per altre transazioni



## *Requisiti di sicurezza per le transazioni*

- Autenticare il venditore al compratore, cosicché egli sia sicuro di essere in contatto con il server del venditore che gli interessa
- Tenere nascoste (ed inalterate) informazioni importanti di pagamento in modo che non cadano in mani sbagliate (i.e. carta di credito)
- Se i beni sono fruibili tramite download assicurare che il contenuto sia consegnato al compratore senza alterazioni e senza accesso da parte di altri
- In aggiunta a questi requisiti può essere necessario autenticare l'identità del client per fornirgli i diritti previsti all'accesso (e-banking)

**non-ripudio**



## Progetto di sicurezza

- Progettare un sistema senza punti deboli è simile a scrivere un programma senza *bugs*
- La validazione formale è l'unica possibilità di garantire completa sicurezza
- La prova di validità è articolata in due fasi:
  - Si crea una lista di minacce possibili al sistema
  - Si mostra come ognuna di essi è gestita con successo dal sistema
- La dimostrazione può avere un aspetto informale anche se si predilige un approccio di tipo formale

Progettare un sistema di sicurezza è un esercizio nel bilanciare i costi in relazione alle minacce



## Considerazioni worst-case

Le interfacce dei processi server sono necessariamente aperte

- Gli indirizzi degli host possono subire *spoofing*
- Una chiave segreta generata è sicura al momento della sua generazione, ma la sua segretezza diminuisce con il tempo
- Gli algoritmi sono disponibili ai responsabili di sicurezza come agli attacker
- Gli attacker dispongono spesso di grandi risorse di calcolo
- La base di fiducia (hardware e software) è spesso la causa delle debolezze



## *Tecnologie per la sicurezza*

- Utilizzo della crittografia
- Certificati
- Controllo di accesso
- Credenziali
- Firewall





## *Modelli di protezione e gestione*

- Copy protection
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint





## Utilizzo della crittografia

- Encryption è il processo che codifica un messaggio in modo da nascondere il contenuto
- Si basano sull'uso di parametri segreti chiamati *chiavi*
- Si dividono in due classi fondamentali
  - Chiavi segrete condivise (*secret-key*)
  - Coppie di chiavi pubblica/privata (*public-key*)
- Segretezza e integrità
- Autenticazione
- Firma digitale



## Algoritmi di crittografia

Un messaggio si dice criptato quando il mittente applica alcune regole per trasformare il testo originale (*plaintext*) in un altro testo (*ciphertext*)

$$E(K_1, M) = \{M\}_K$$

- Il ricevente deve conoscere la trasformazione inversa per ritrasformare il *ciphertext* nel messaggio originale

$$D(K_2, \{M\}_K) = M$$

$$K_1 = K_2$$

**simmetrico**

$$K_1 \neq K_2$$

**asimmetrico**

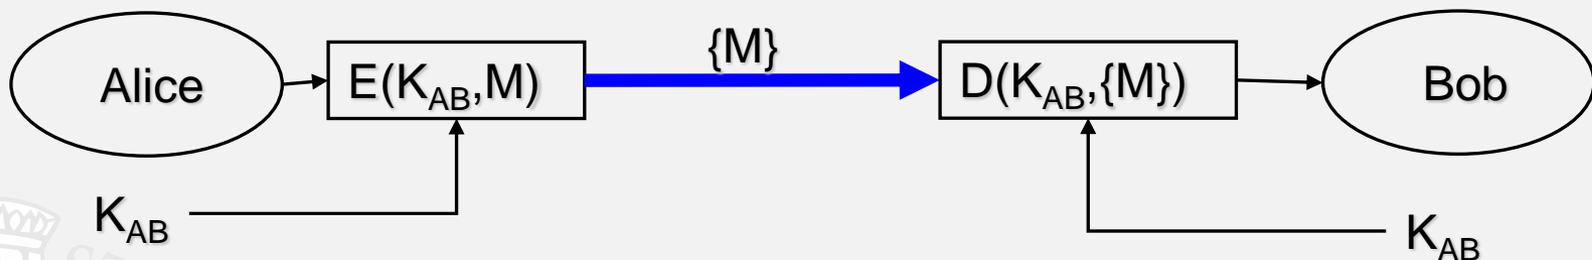


## Scenario 1: secret communication

Alice vuole inviare alcune informazioni segretamente a Bob

$$\{M\} = E(K_{AB}, M)$$

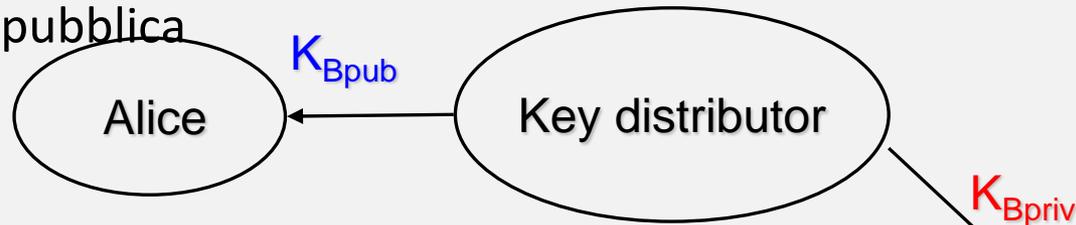
- Alice e Bob conoscono entrambi la chiave segreta  $K_{AB}$
- La comunicazione è segreta finchè  $K_{AB}$  non è compromessa



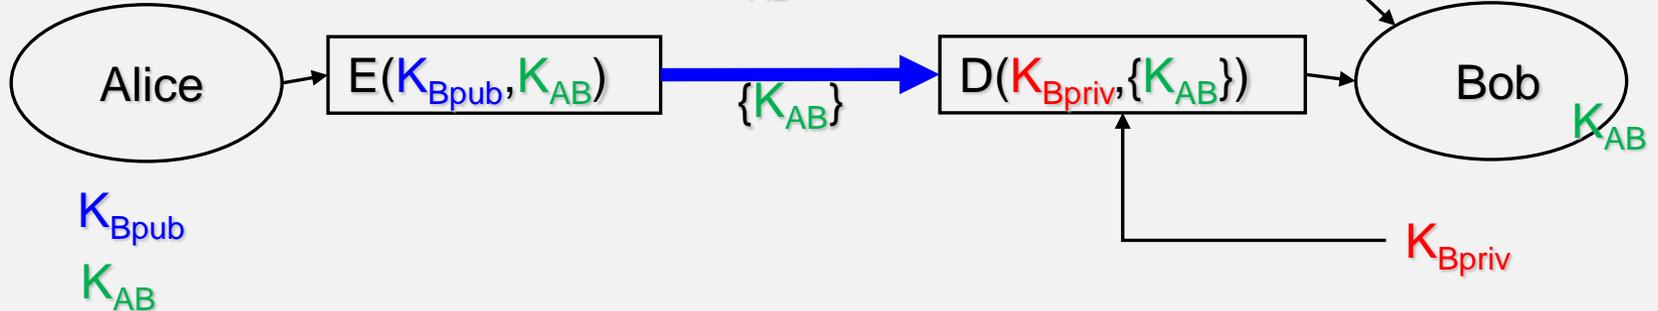


## Scenario 3: authenticated with public-key

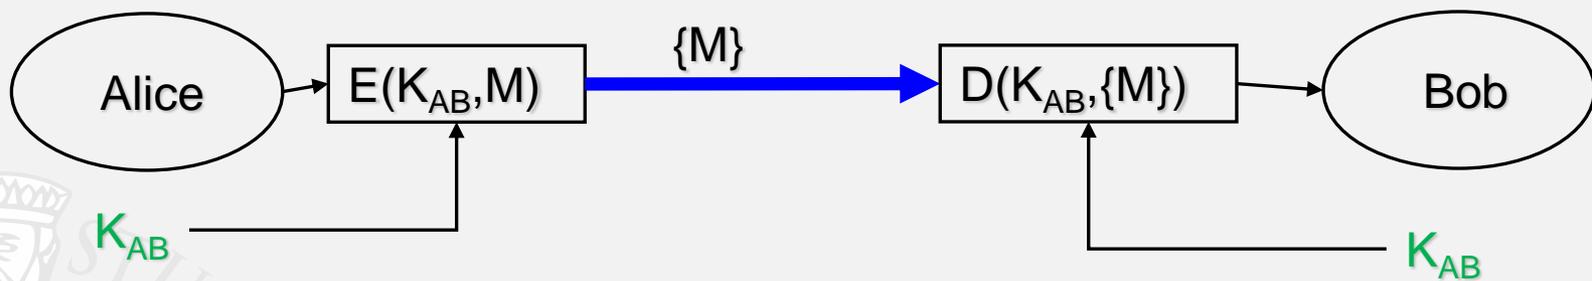
- Richiesta chiave pubblica



- Determinazione chiave di sessione  $K_{AB}$

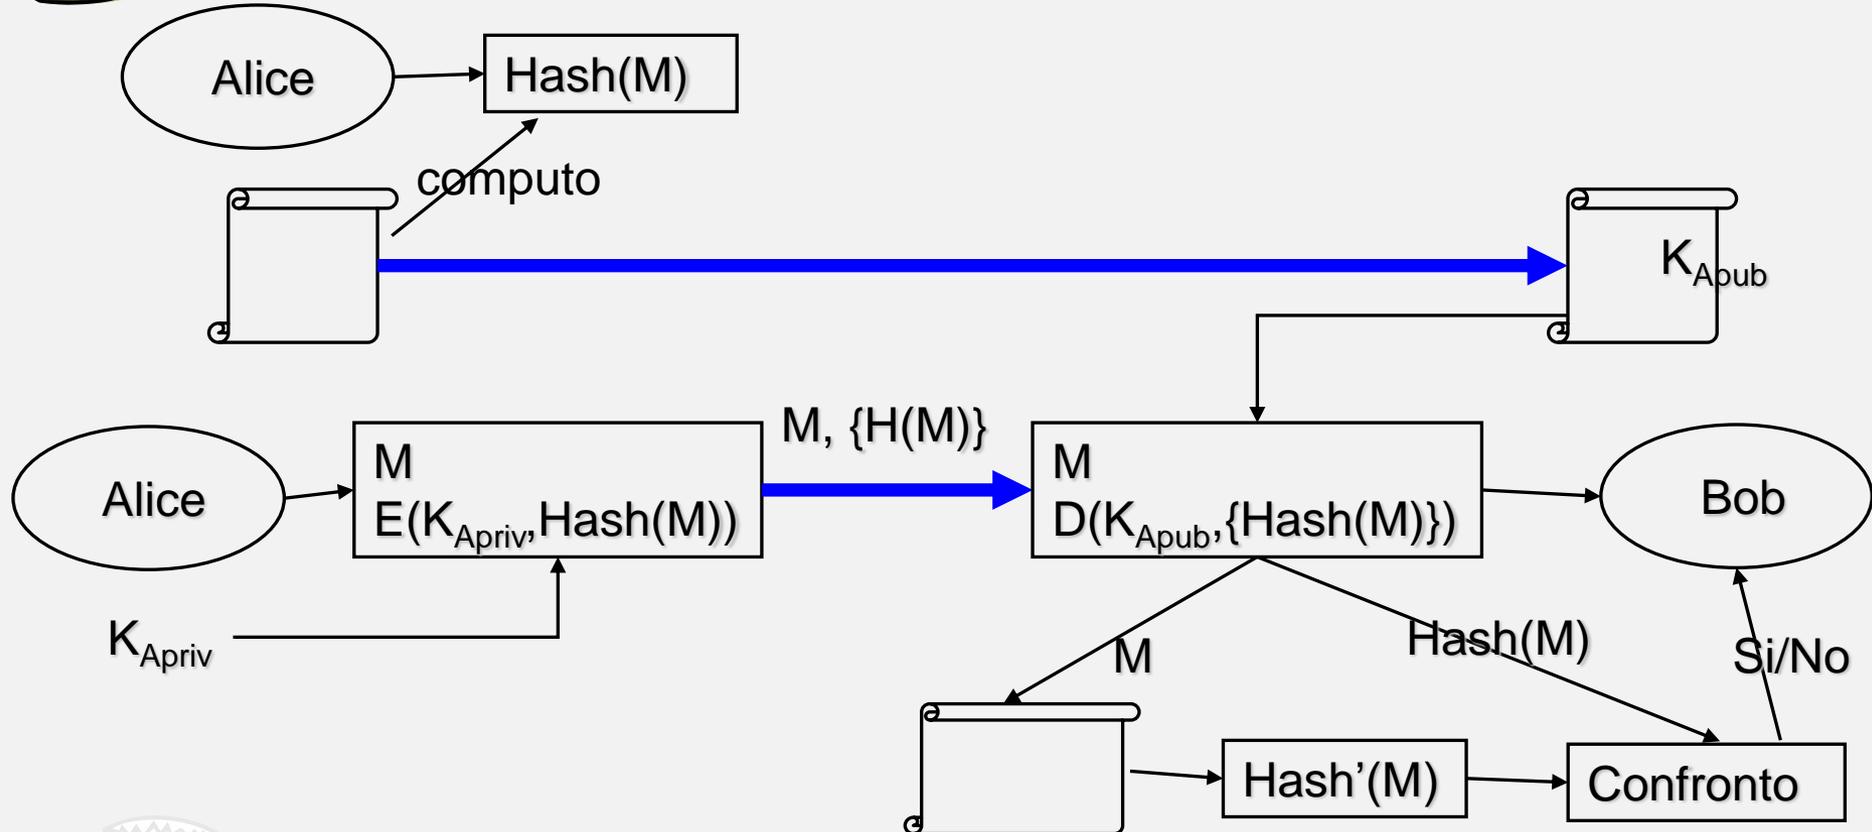


- Cumunicazione sicura





## Scenario 4: digital signature





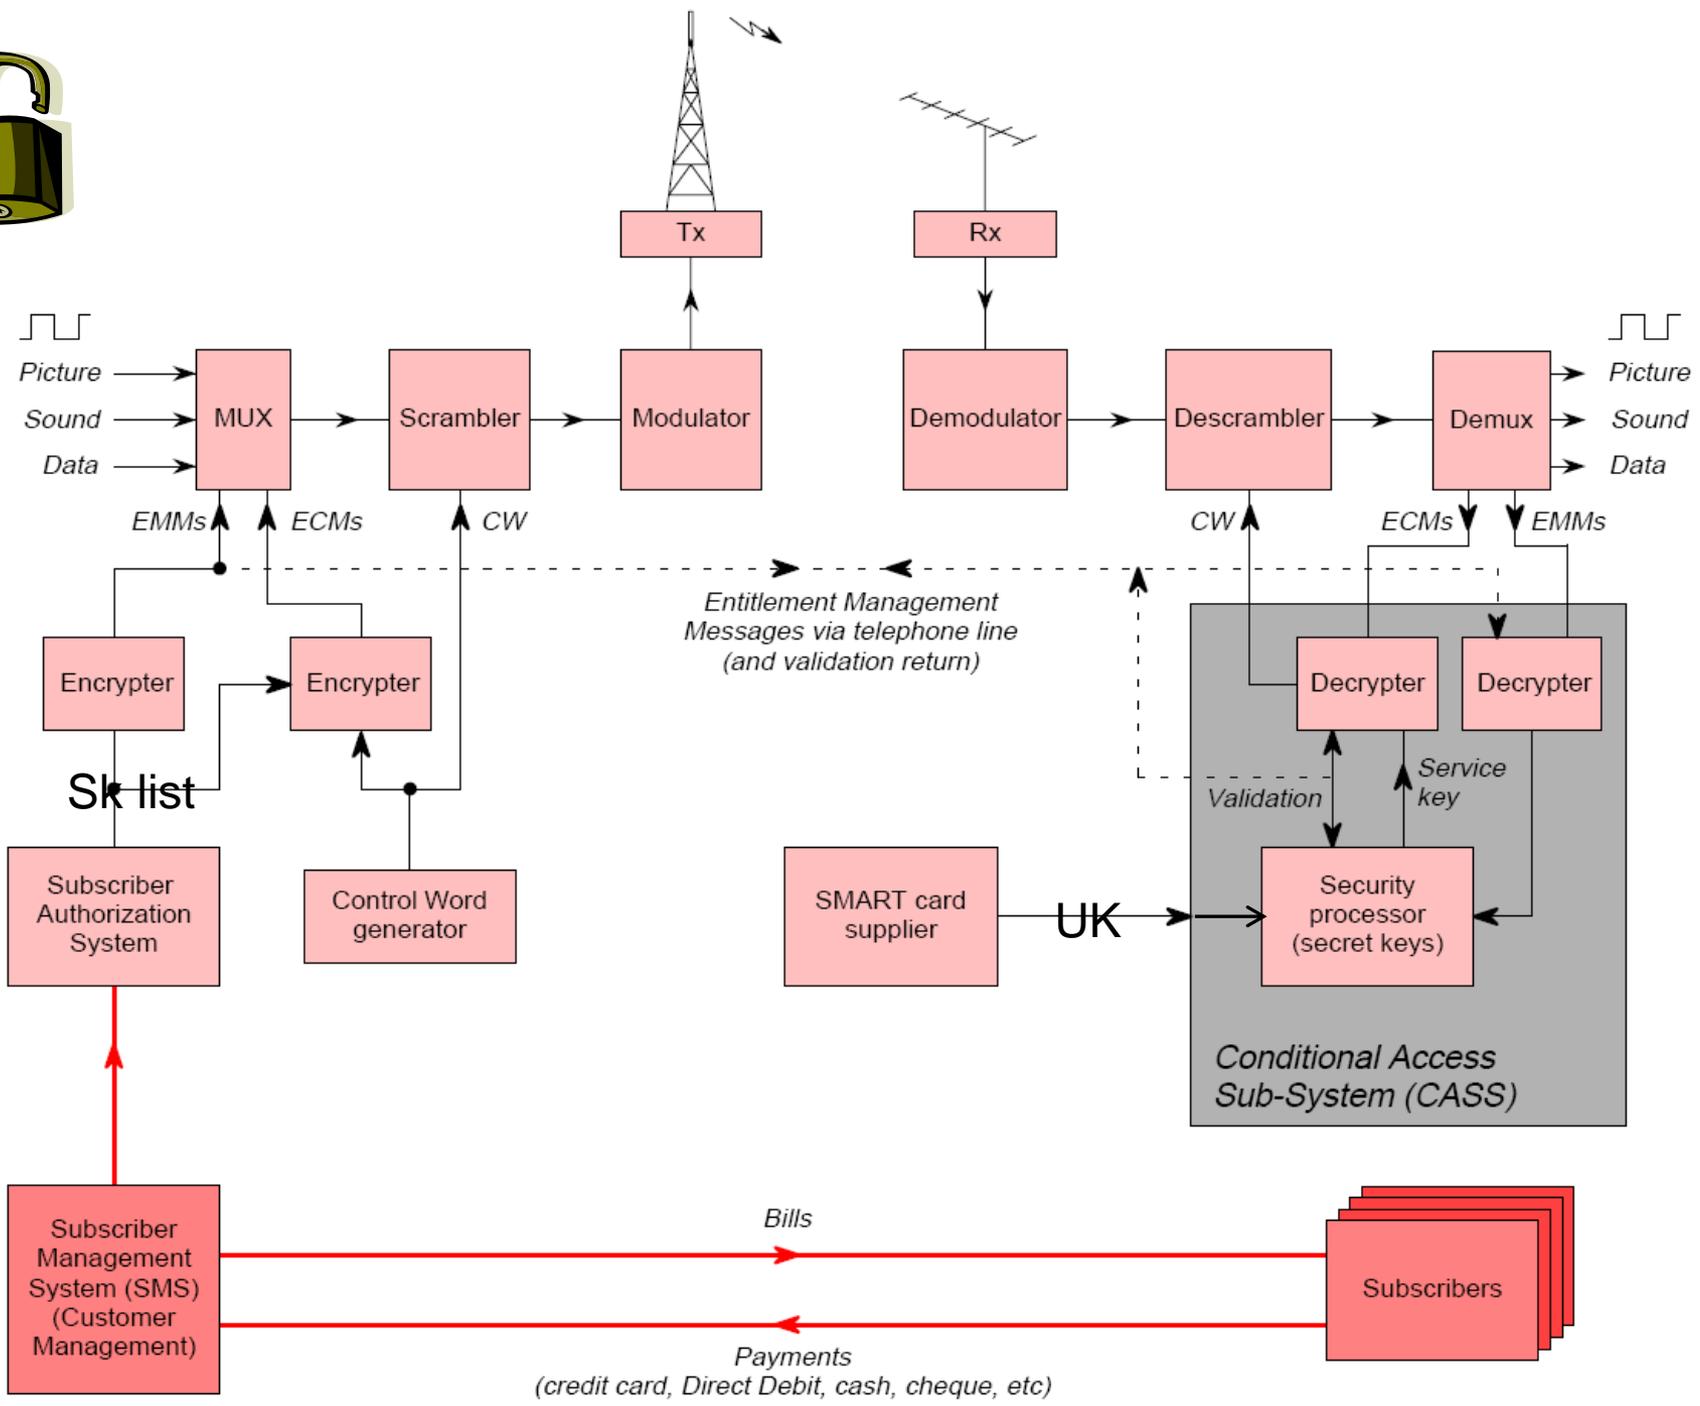
# *Modelli di protezione e gestione*

- Copy protection
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System ←
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint



## ***CAS: Conditional Access Systems***

- **Systems that controls the access to the content**
  - Typically used on streaming towards STB/Decoders
  - Copy is assumed not possible since the content is not stored locally and neither accessible to the final user.
- **For PC:**
  - Partially suitable for open platforms such as PC
    - On PC: SSL, HTTPS, etc.
  - Temporary storage of smaller content on the disk, may be encrypted
- **For STB:**
  - The most interesting and diffuse solution





## *Modelli di protezione e gestione*

- Copy protection
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint





# Rights Management

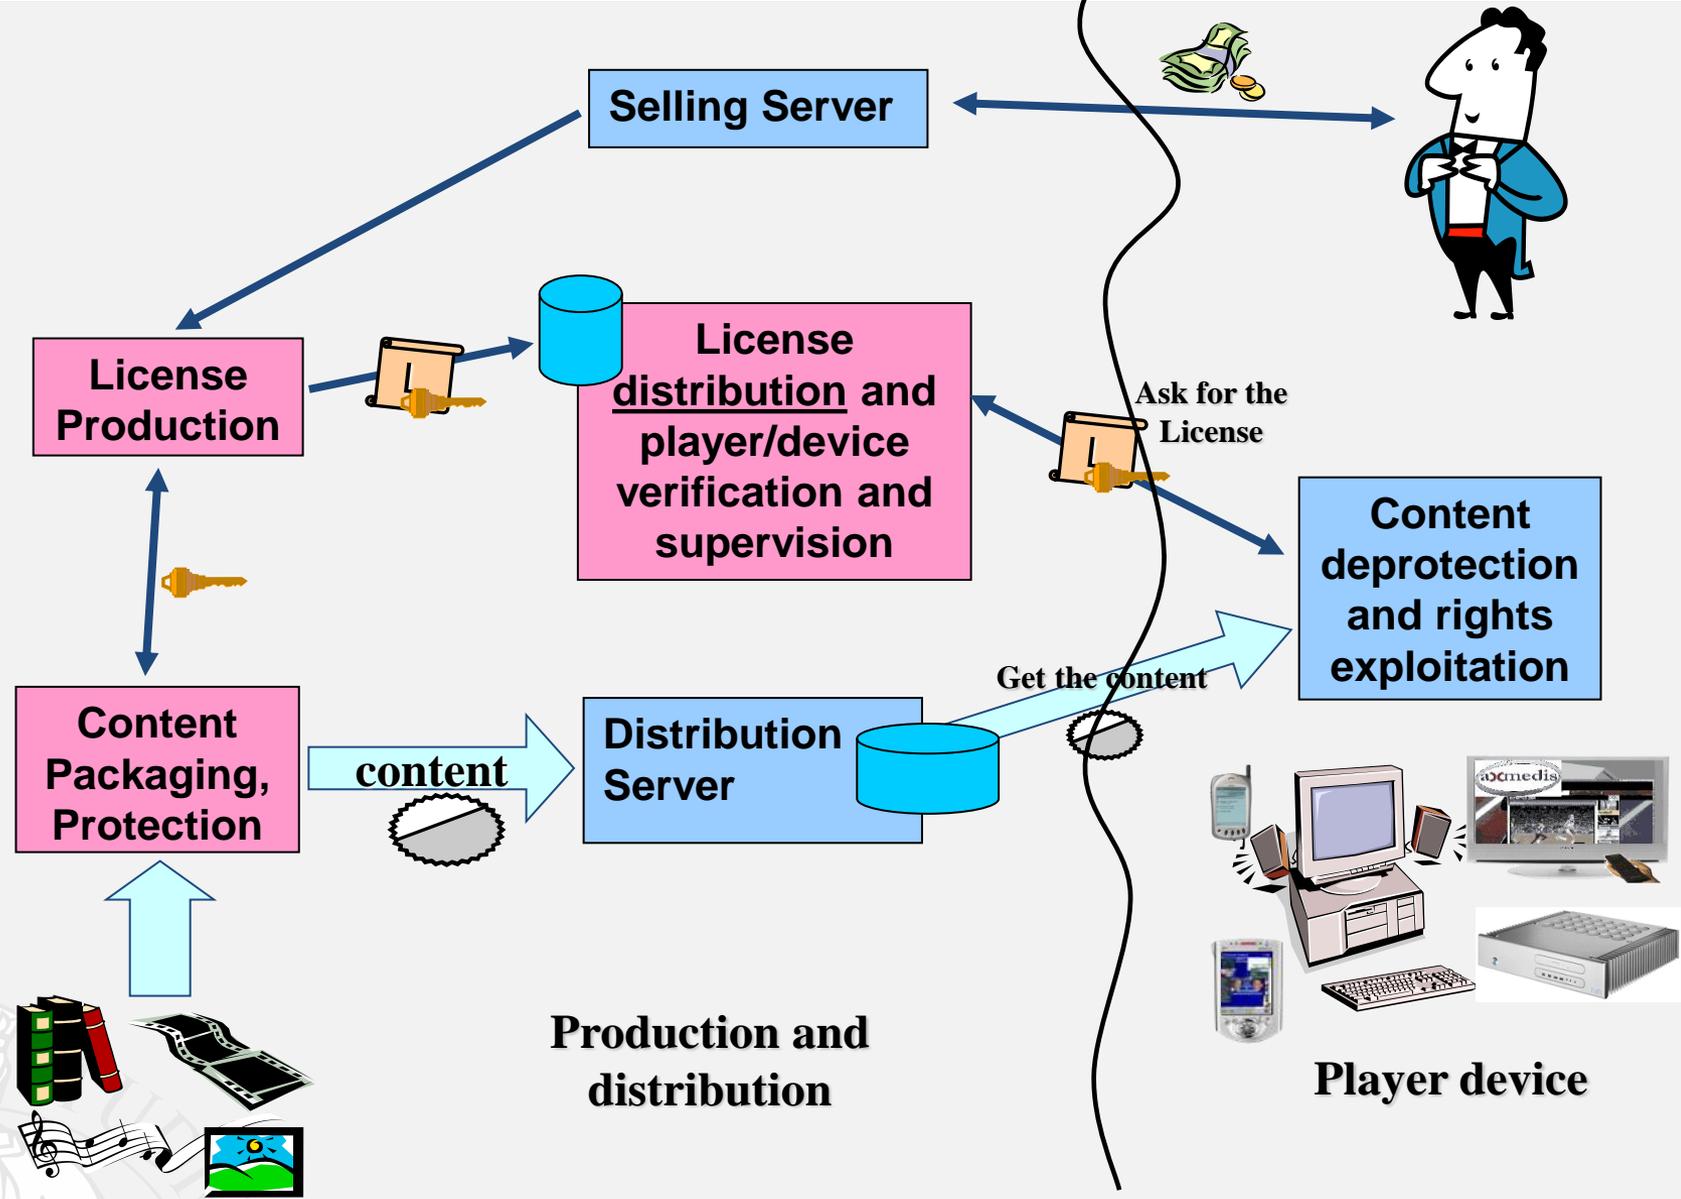
- **DRM: Digital Rights Management**
  - general term many times abused, confused, ...
- Management of Digital Rights
  - Limited to the management of rights of digital content ? → NO!!!
- **Digital Management of Rights → YES!!!**
  - More correct and reasonable
  - Management of both rights for original *works* and related *manifestations*, digital *resources*, etc.
  - in many solutions DRM is not intended in this way



## Aim of ..... Digital Rights Management

- To allow exploiting digital content functionalities (rights) in a controlled manner
  - To who has been **authenticated/certified**
  - To do what (are the rights) is defined in a formal **license**
  - **Verifying/Control/Supervise** if the above conditions and others are respected
  - By using technologies to **protect content** (e.g., encryption, fingerprint, watermark, etc.)
- Cons:
  - Registration of users (in some case can be relaxed)
  - Authentic. of users and/or tools/terminal/devices
  - Control of users
- *It has to be supported by a set of additional technical solutions*

# Simple protection with Key sending



**Production and distribution**

**Player device**

# *Content Elements of the package*

## • **Metadata:**

- Identification information, unique ID, distributor ID, etc.
- Classification information also for indexing: Dublin core, etc.
- Semantic Descriptors, MPEG-7, for indexing, etc.
- References to Owner, to distributor, etc.
- Etc.

Metadata

## • **Digital Resources:**

- Any digital information: images, doc, txt, video, game, application, file, audio, etc.
- Hierarchy of digital resources

Resource

## • **Protection Information:**

- What has to be done to access at a given information/resource
- Tools used, their parameters, etc.

Prot-Info Model



## • **License:**

- Which rights are provided, who is the recipient, conditions, etc.

License Model





# An example of statement



Condition = November 2003



Resource = Ocean Wilds



Right = Play

- Rosy can Play 3 times the Ocean Wilds in November 2003.



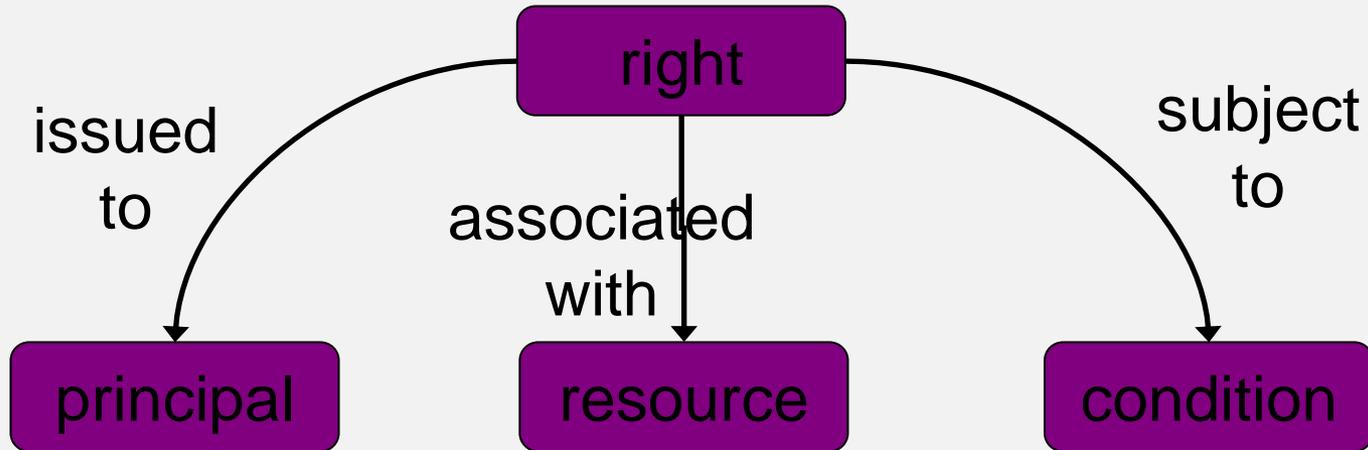
## MPEG-21 — REL, Rights Expression Language

- **REL is** a machine-readable language, XML
  - to declare rights and permissions
  - uses terms defined in the Rights Data Dictionary, RDD
- **REL allows to define licenses** that give specific permissions to Users to perform certain actions on certain resources, given that certain conditions are met
  - Grants can also allow Users to delegate authority to others
- **Systems and device have to**
  - parse and validate the REL formalizations
  - check permissions before any further action is done
- **REL licenses** are wrapped into MPEG-21 Digital Items when the object is governed
- **MPEG-21 DID parser** is responsible for discovering and identifying where to gather licenses





# REL data model



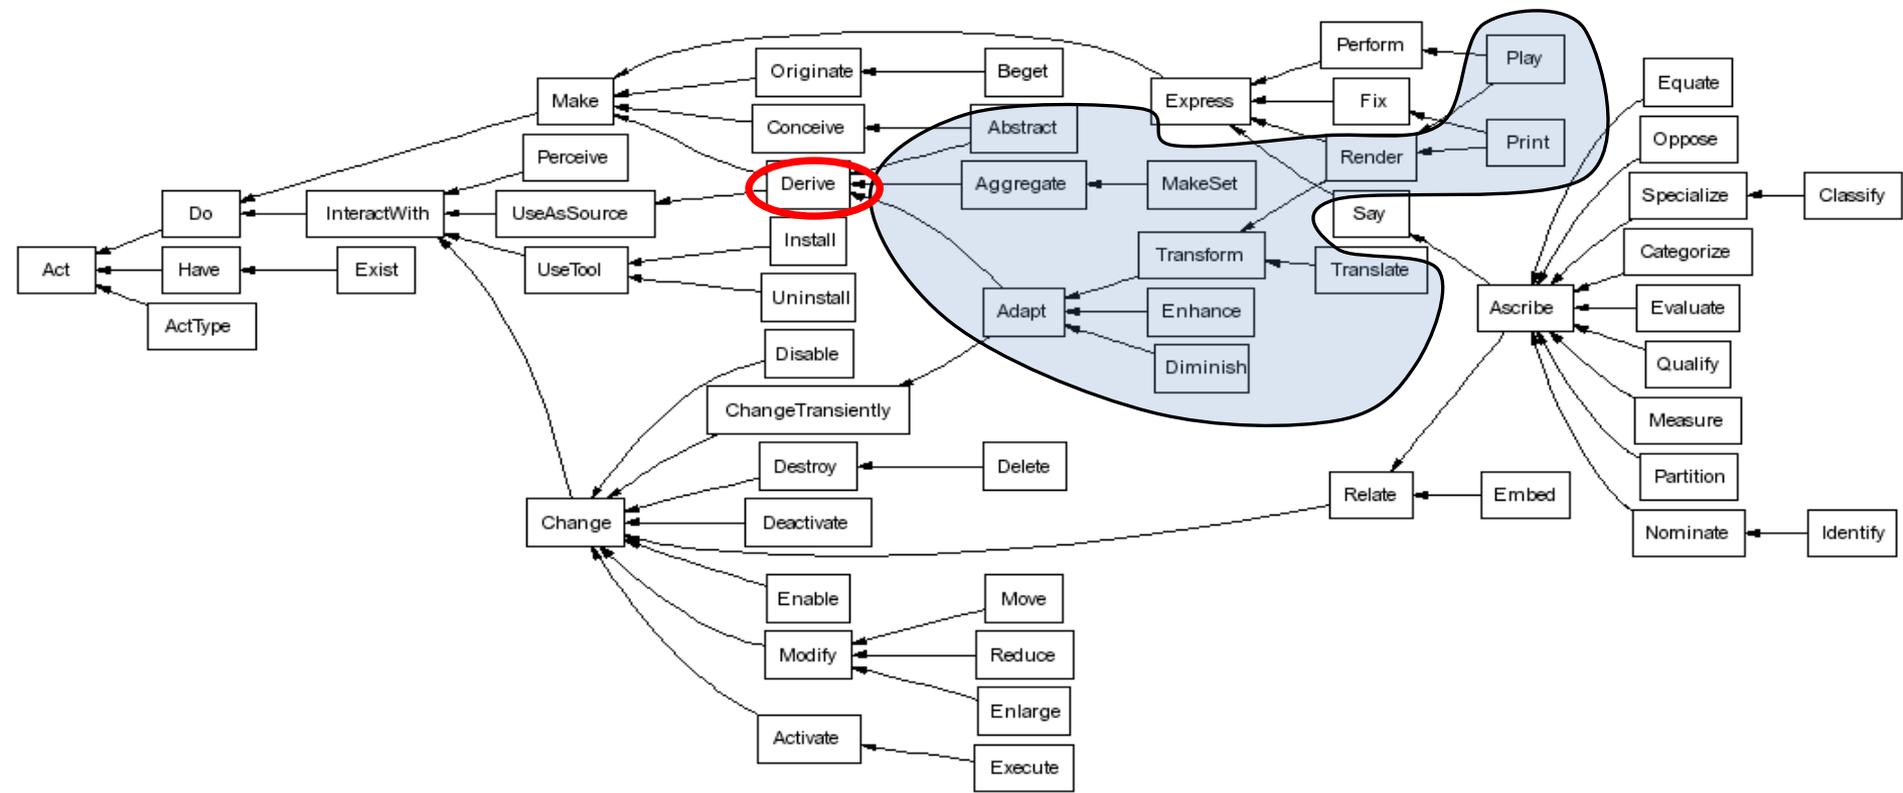
- REL grant formalization consists of
  - principal to whom grant is issued
  - rights the grant specifies
  - resource to which right in grant applies
  - condition to be met before grant can be exercised





# RDDOnto (Garcia, Delgado, 2007)

- Example: Act hierarchy.

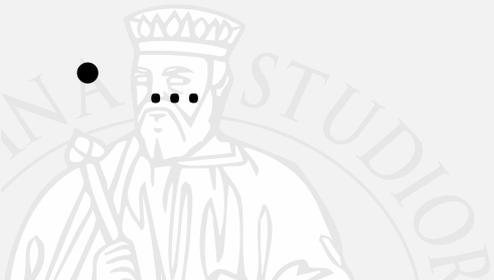




# Licences

- Relazioni fra rights!
  - Relazioni di Implicazione
- Relazioni fra licenze
  - Licenza di emissione di licenze per certi diritti
- License di Dominio
- License con diritti condizionati:
  - tipologia di utenti, location, tempo, etc...

- ...





# Creative Commons, CC



- Nel commercio elettronico e' necessario includere anche alcune slide relative alle licenze CC.
  - Fino ad ora abbiamo visto tecnologia al servizio della protezione della proprieta' intellettuale
  - CC mette a disposizione degli strumenti, dei formalismi legali che possono essere o meno adottati da chi pubblica i propri contenuti
  - Questi sono license formalizzate:
    - ♣ **Struttura della Licenza CC:**
      - ➔ Legal Code: testo legale che la descrive
      - ➔ Commons Deed: short description della licenza
      - ➔ Digital Code: metadati da associare
- (see S. Aliprandi, 2005, 2006...)

<http://www.copyleft-italia.it/cc/brochureCCv2.pdf>





# Creative Commons, CC



## □ **Le licenze CC**

- ♣ Nate in USA
  - ♣ Sono state adattate alla legislazione nazionale di diversi stati e anche a livello europeo
    - specialmente per contenuti generati dagli utenti e in ambito culturale
    - Questo permette in un certo qual modo di avere una trascodifica fra le questioni legali nazionali e quelle di altre nazioni, ma solo per certe questioni.
  - ♣ Licenze CC ipotizzano uno share, copyleft
- E' stato fatta una codifica delle licenze CC in MPEG-21 REL
- ♣ Non e' vero l'opposto, tutte le licenze che si possono formalizzare in MPEG-21 non hanno una controparte in CC



# Ogni Licenza chiede che il Licenziatario

- Ottenga il tuo permesso per fare una qualsiasi delle cose che
  - ♣ hai scelto di limitare con la licenza,
  - ♣ for example: limitare gli usi commerciali o quelli di opera derivata
- Mantenga l'indicazione di diritto di autore intatta su tutte le copie del tuo lavoro
- Faccia un link alla tua licenza dalle copie dell'opera
- Non alteri i termini della licenza
- Non usi mezzi tecnologici per impedire ad altri licenziatari di esercitare uno qualsiasi degli usi consentiti dalla legge

# Ogni licenza CC permette le seguenti azioni a patto che:

*i licenziatari rispettino le condizioni della licenza CC assegnata:*

□ Possono

- ♣ Copiare l'opera;
- ♣ Distribuire l'opera;
- ♣ Comunicare al pubblico, rappresentare, eseguire, recitare o esporre l'opera in pubblico, ivi inclusa la trasmissione audio digitale dell'opera;
- ♣ Cambiare il formato dell'opera.



# Alcuni marker CC

## ▣ Libertà' per l'utente

- 
  - ♣ Sei libero di distribuire, comunicare, rappresentare, eseguire, recitare o esporre l'opera in pubblico, ivi inclusa la trasmissione audio digitale dell'opera;
- 
  - ♣ Sei libero di modificare questa opera

## ▣ Condizioni di uso

- 
  - ♣ Devi riconoscere la paternità' di questa opera
  - ♣ Per esempio citando e riportando un link alla sorgente



# Licenze Creative Commons

## □ Offrono 6 diverse articolazioni

- ♣ per artisti, giornalisti, docenti, istituzioni e, in genere, creatori che desiderino **condividere in maniera ampia** le proprie opere secondo il modello "**alcuni diritti riservati**".

## □ Altre condizioni d'uso, il detentore dei diritti puo'



- ♣ non autorizzare a priori **usi prevalentemente commerciali** dell'opera (opzione *Non commerciale*, acronimo inglese: *NC*)



- ♣ non autorizzare la creazione di **opere derivate** (*Non opere derivate*, acronimo: *ND*); no extract, no aggregate, ..



- ♣ Imporre di rilasciarle **con la stessa licenza dell'opera originaria** (*Condividi allo stesso modo*, acronimo: *SA*, da "Share-Alike").

*Le combinazioni di queste scelte generano 6 licenze CC, disponibili anche in versione italiana, come descritto in seguito!*

# 2 of the 6 CC licenses, 1/3

## □ Attribution Non-commercial No Derivatives (by-nc-nd)



- ♣ The most restrictive of our six main licenses, allowing redistribution.
- ♣ This license is often called the “free advertising” license
- ♣ *it allows others to download your works and share them with others as long as they mention you and link back to you,*
- ♣ they can't change them in any way or use them commercially

## □ Attribution Non-commercial Share Alike (by-nc-sa)



- ♣ *Let others remix, tweak, and build upon your work non-commercially, as long as they credit you and license their new creations under the identical terms.*
- ♣ Others can download and redistribute your work just like the by-nc-nd license, but they can also translate, make remixes, and produce new stories based on your work.
- ♣ All new work based on yours will carry the same license, so any derivatives will also be non-commercial in nature.



# 2 of the 6 CC licenses, 2/3

## □ Attribution Non-commercial (by-nc)



- ♣ Let others remix, tweak, and build upon your work non-commercially, and their new works must also acknowledge you and be non-commercial,
- ♣ they don't have to license their derivative works on the same terms.

## □ Attribution No Derivatives (by-nd)



- ♣ allows for redistribution, commercial and non-commercial,
- ♣ as long as it is passed along unchanged and in whole, with credit to you

# 2 of the 6 CC licenses, 3/3

## □ Attribution Share Alike (by-sa)

- ♣ *lets others remix, tweak, and build upon your work even for commercial reasons, as long as they credit you and license their new creations under the identical terms.*
- ♣ This license is often compared to open source software licenses.
- ♣ All new works based on yours will carry the same license, so any derivatives will also allow commercial use.

## □ Attribution (by)

- ♣ *lets others distribute, remix, tweak, and build upon your work, even commercially, as long as they credit you for the original creation.*
- ♣ This is the most accommodating of licenses offered, in terms of what others can do with your works licensed under Attribution.

- Distribution models
- Terminologies
- Business Models & Value Chain
- Copy protection
- Conditional Access Systems
- Digital Rights Management
- Content Modeling and Packaging
- Licensing and content distribution
- Creative Commons Licensing
- Composition of Licenses, data aggregation



- **Licenses:** MPEG-21, ODRL, XACML, Xrml, etc..
  - Suitable for media, Unsuitable for data
- **Data Licenses:** CC, ODC, OGL, IODL
  - Mainly open data and declinations
  - **Permissions:** derivative, commercialize, derivative...
  - **Restrictions/duties:** attribution, notice, ...
- **Getting Composing Data Set → Licences Composition is needed**
  - See [www.disit.org/6877](http://www.disit.org/6877) extension
- Formal models to **grant rights**
- Techniques for **right enforcement/verification**
  - Almost missing on RDF stores



## DISIT extension

First License	Second License													
	CC0	CC-PDM	CC-BY-ND	CC-BY-NC-ND	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	ODC-PDDL	ODC-BY	ODC-ODbL	OGL 2.0	OS OpenData
CC0	No restrictions	No restrictions	-	-	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	No restrictions	ODC-BY	ODC-ODbL	OGL 2.0	OS OpenData
CC-PDM	No restrictions	No restrictions	-	-	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	No restrictions	ODC-BY	ODC-ODbL	OGL 2.0	OS OpenData
CC-BY-ND	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CC-BY-NC-ND	-	-	-	-	-	-	-	-	-	-	-	-	-	-
CC-BY	CC-BY	CC-BY	-	-	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	CC-BY	CC-BY	ODC-ODbL	CC-BY	OS OpenData
CC-BY-SA	CC-BY-SA	CC-BY-SA	-	-	CC-BY-SA	CC-BY-SA	-	-	-	CC-BY-SA	CC-BY-SA	ODC-ODbL	CC-BY-SA	CC-BY-SA
CC-BY-NC	CC-BY-NC	CC-BY-NC	-	-	CC-BY-NC	-	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	CC-BY-NC	CC-BY-NC	-	CC-BY-NC	-
CC-BY-NC-SA	CC-BY-NC-SA	CC-BY-NC-SA	-	-	CC-BY-NC-SA	-	CC-BY-NC-SA	CC-BY-NC-SA	CC-BY-NC-SA	CC-BY-NC-SA	CC-BY-NC-SA	-	CC-BY-NC-SA	-
ODC-PDDL	No restrictions	No restrictions	-	-	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	No restrictions	ODC-BY	ODC-ODbL	OGL 2.0	OS OpenData
ODC-BY	ODC-BY	ODC-BY	-	-	ODC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	ODC-BY	ODC-BY	ODC-ODbL	ODC-BY	OS OpenData
ODC-ODbL	ODC-ODbL	ODC-ODbL	-	-	ODC-ODbL	ODC-ODbL	-	-	-	ODC-ODbL	ODC-ODbL	ODC-ODbL	ODC-ODbL	ODC-ODbL
OGL 2.0	OGL 2.0	OGL 2.0	-	-	CC-BY	CC-BY-SA	CC-BY-NC	CC-BY-NC-SA	CC-BY-NC-SA	OGL 2.0	ODC-BY	ODC-ODbL	OGL 2.0	OS OpenData
OS OpenData	OS OpenData	OS OpenData	-	-	OS OpenData	CC-BY-SA	-	-	-	OS OpenData	OS OpenData	ODC-ODbL	OS OpenData	OS OpenData



# *Modelli di protezione e gestione*

- Copy protection
- I modelli di attacco in rete
- La crittografia, la firma digitale
- Conditional Access System
- Digital Rights Management, DRM
- Licenze per il DRM
- Watermark
- fingerprint





# Watermark: Persistent Association



### Mayor's Speech Code

NEW YORK, December 19, 1997

Mayor Rudolph W. Giuliani said today that his latest action against so-called quality-of-life problems would be a crackdown on Brooklyn accents in public places. "I got rid of mine, so why can't everyone else?" he said at a press conference outside police headquarters in lower Manhattan.

Giuliani's remarks disgusted many Brooklyn residents, who staged a march on City Hall to protest the mayor. Said one, who refused to be identified, "Fuhgeddabout it. Youse can't got no idea how bad dis marks us feel," followed by descriptions of the mayor that employed characterizations unprintable in this newspaper.

The Rev. Al Sharpton showed up at the rally as well, with 27 of his faithful followers. One of them, the activist Sonny Canon, said, "I'm anti-Brooklyn. Let's talk about being anti one thing at a time."

Meanwhile, residents of Manhattan's exclusive Upper East Side expressed favorable opinions on the mayor's move. "I say, it does rather make a difference, you know, because one can't understand them when they come over to fix the plumbing or something," said Biff "Biff" Biffington V, a partner at the Brown Brothers Harriman investment bank and a Park Avenue resident.

An informal survey of young bond sales assistants at the O'Flaherty's Bar on 3rd Avenue elicited comments like, "Yeah, like, it's, you know, like, the piss-poor English they talk, you know, like it sucks. Where I come from on Long Island, we talk real good."

The mayor ended his remarks yesterday afternoon with a pledge to crack down on Greek coffee cups in public places.



- Watermark
- Encryption

### Mayor's Speech Code

NEW YORK, December 19, 1997

Mayor Rudolph W. Giuliani said today that his latest action against so-called quality-of-life problems would be a crackdown on Brooklyn accents in public places. "I got rid of mine, so why can't everyone else?" he said at a press conference outside police headquarters in lower Manhattan.

Giuliani's remarks disgusted many Brooklyn residents, who staged a march on City Hall to protest the mayor. Said one, who refused to be identified, "Youse can't got no idea how bad dis makes us feel," followed by descriptions of the mayor that employed characterizations unprintable in this newspaper.

The Rev. Al Sharpton showed up at the rally as well, with 27 of his faithful followers. One of them, the activist Sonny Canon, said, "I'm anti-Brooklyn. Let's talk about being anti one thing at a time."

Meanwhile, residents of Manhattan's exclusive Upper East Side expressed favorable opinions on the mayor's move. "I say, it rather does make a difference, you know, because one can't understand them when they come over to fix the plumbing or something," said Clayton "Biff" Harrington II, a partner at Brown Brothers Harriman and a Park Avenue resident.

An informal survey of young bond sales assistants at the Random Bar on 3rd Avenue elicited comments like, "Yeah, like, it's, you know, like, the piss-poor English they talk, you know, like it sucks. Where I come from in New Jersey, we talk real good."

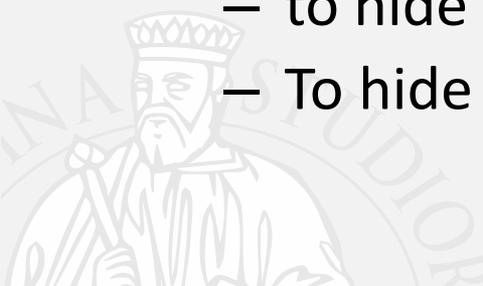
The mayor ended his remarks yesterday afternoon with a pledge to crack down on Greek coffee cups in public places.





# Watermark

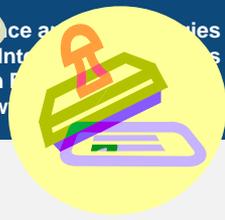
- What is the watermark (also called steganographic)
- a technology to embed an information in the content: image, video, text, audio, etc
  - Which information is watermarked:
    - Object ID
    - Owner ID
    - Distributor ID
    - Eventual coding of the license (governed object)
    - Etc.
  - Once read it can be used
    - to hide IDs to demonstrate the ownership of the content
    - To hide a sort of license





## *Watermark features*

- Transparency: visible, invisible
- Robustness: tolerance to attacks
  - Adaptation, DA-AD
- Capacity: amount of information embedded
- Blindness: reference to the source image Hidden or visible
- Removable or not:
  - when it is separable from the digital resource obtaining the original digital resource
- Single or multiple:
  - when more than one Watermark is present
- Readable
  - by all or only by the owner: when there is not need to have a special key/parameters to read it
  - with an absolute certainty or with some statistical confidence
  - To be estimated during streaming
- Etc.



## *Usage of Watermark*

- **Content Producers/Distributor**
  - watermark the content (images, audio, video, etc.)
- **Content integrators and distributors**
  - are informed and may add one more watermark with their code or reference
- **End users**
  - are not aware about that, if it is undetectable is easy
- **The terminal**
  - may or may not be capable to read it





# Fingerprint and descriptors



## What is the Fingerprint

- It is an ID-code estimated on the digital content or resource that present in practical an high probability to be unique for that content with respect to other similar content
- To make the recognition of the digital content possible
  - Indexing into the database
- **Fingerprint as a high level content descriptor**
  - Resources
    - Audio: Rhythm, tonality, duration, genre, etc.
    - Video: number of scenes, description of the scene, etc.
    - Text: main keywords, summary, topics, etc.
  - Collected as MPEG-7 descriptors
  - Vectors of those features, etc.
  - Independent on the resolution, format, etc.
  - May be Computationally intensive
  - Etc.



# Fingerprint Features

## Features:

- Never included with the content if its aim is the usage for content protection
- Included in the content (package) only if it is used as content descriptor
- Robust to adaptation processing: Scaling: time, space, color, etc.
- Short and concise
- Repeatable
- Light to be estimated
  - estimable during streaming, on the basis of a short duration of the content streaming
- Robust to eventual watermark addition
- Etc.
- **Typically more computational intensive** with respect to WM:
  - The WM code is read/extracted from the content
  - The FP code has to be estimated from the content

# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati* 
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence*



## *Dati vs Metadati*

- Dati, open data 
- Dati privati, dati pubblici
- Linked Open Data
- Metadati e indicizzazione
- Dati e smart city
- User Profile





# *i dati: una classificazione*

- **Dati pubblici:**
  - web, broadcasting (radio, tv), etc.
- **Dati istituzionali e/o privati: archivi, etc.**
  - Tipicamente accessibili solo per service provider: banche, uffici GOV, poste, etc.
- **Dati privati per servizi privati: archivi, etc.**
  - Se noti possono essere accessibili per questioni di sicurezza nazionale
  - Operatori: energia, telecom, ...
- *Alcuni di questi dati sono difficilmente accessibili in modo sistematico*



### Privati Statici

- Codice fiscale
- Foto non condivise
- Aspetti legali
- Cartella clinica
- ..

- Movimenti personali non pubblicati
- Relazioni personali non pubblicate

- comportamenti social media
- contributi
- consumi

- Traffico personale
- Posizione mezzi,
- Meteo
- Parcheggi
- Posizione taxi
- Code ai musei
- Posizione CarSharing
- ...

### Privati Tempo reale

### Publici statici (open data)

statistiche: incidenti, censimenti, votazioni

- Statistiche accessi alla ZTL
- Strutture pubbliche UNIFI

posizione dei punti di interesse

- Musei
- Strutture della città
- Servizi attivi

- Info traffico
- video camere
- Info Meto
- Info Ambiente
- Terremoti
- Parcheggi

- Stato accessi alla ZTL
- Stato dei servizi

### Publici Tempo reale (open data)



# *i dati*

- **Dati Privati e Semantica:**
  - A. Trasmissioni: streaming, progressive download, P2P**
    - Generati da un o più persone, o riprodotte, etc.
    - *Conversazioni audio, video, telefonate, chat, etc.*
  - B. Dati personali generati:** prodotti dalla singola persona
    - Generati o modificati dalla persona intenzionalmente,..
    - *email, documenti, fogli di calcolo, immagini, video, agende, etc.*
  - C. Profili utenti indotti:** caratterizzano la singola persona
    - Generati dal comportamento e dalle azioni della persona in vari servizi privati e GOV, anche in modo non intenzionale
    - *Descrittori del comportamento, relazioni, scelte, spese, conoscenze, log chiamate, etc.*





## *Dati vs Metadati*

- Dati, open data
- Dati privati, dati pubblici
- Linked Open Data ←
- Metadati e indicizzazione
- Dati e smart city
- User Profile





# Linked Open Graph: Linked Open Data



## Linked Open Graph

Select a SPARQL endpoint:  
**OSIM UNIFI Competences (by DISIT)**

Examples:

- Paolo Nesi
- Dip. Ingegneria dell'Informazione

Choose a class:  
Search for keyword

keyword:  
università

uri: [www.dsi.unifi.it/CMSAteneoCompetence#University](http://www.dsi.unifi.it/CMSAteneoCompetence#University) Request

Multiple endpoint search

**Your data**

sparql endpoint: (optional)

uri:  Request

Multiple endpoint search

**Status**

Requests:

università [OSIM UNIFI Competences (b  
Dip. Ingegneria dell'Informazione [OSIM (b

Remove Clear

**Type of relations**

Select all Deselect all Invert  Hide all inverse

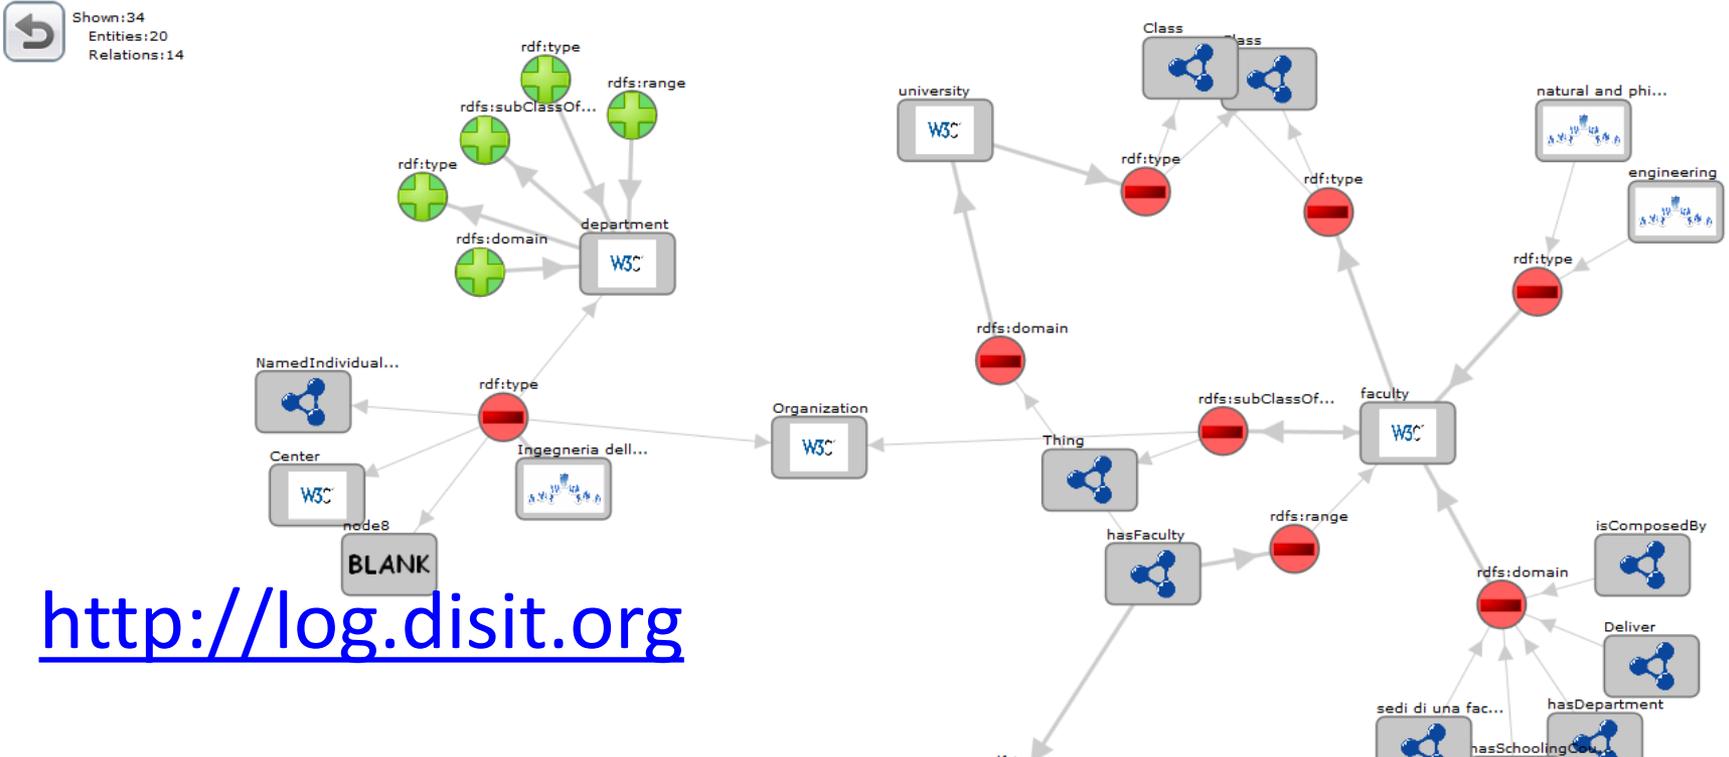
foaf:depiction  owl:sameAs

rdf:type  rdfs:domain

rdfs:range  rdfs:seeAlso

rdfs:subClassOf

## Linked Open Graph





## *Dati vs Metadati*

- Dati, open data
- Dati privati, dati pubblici
- Linked Open Data
- Metadati e indicizzazione
- Dati e smart city
- User Profile



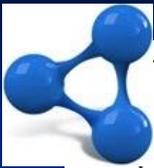


# Metadati

- Sono descrittori di dati
- Vi sono svariati standard di descrizione
  - DC, METS, MPEG-21, MPEG-7, EDM, ..FRBR, ...
- Descrivono vari aspetti, in varie lingue,
- Possono essere specifici per il contesto, etc.
- Oggi sono spesso formalizzati in XML e codificati in ASCII.



# Indexing



Media Types	DC (ML)	Technical	Performing Arts	Full Text	Tax, Group (ML)	Comments, Tags (ML)	Votes
# of Index Fields*	468	10	23	13	26	13	1
Cross Media: html, MPEG-21, animations, etc.	$Y_n$	$Y$	$Y$	$Y$	$Y_n$	$Y_m$	$Y_n$
Info text: blog, web pages, events, forum, comments	$T$	$N$	$N$	$N$	$N$	$Y_m$	$N$
Document: pdf, doc, ePub	$Y_n$	$Y$	$Y$	$Y$	$Y_n$	$Y_m$	$Y$
Audio, video, image	$Y_n$	$Y$	$Y$	$N$	$Y_n$	$Y_m$	$Y_n$
Aggregations: play lists, collections, courses, etc.	$Y_n$	$Y$	$Y$	$Y/N$	$Y_n$	$Y_m$	$Y_n$

\* = (# of Fields per Metadata type) × (# of Languages)

ML: Multilingual; DC: Dublin Core; Tax: Taxonomy





# Modello di ricerca vs algebra

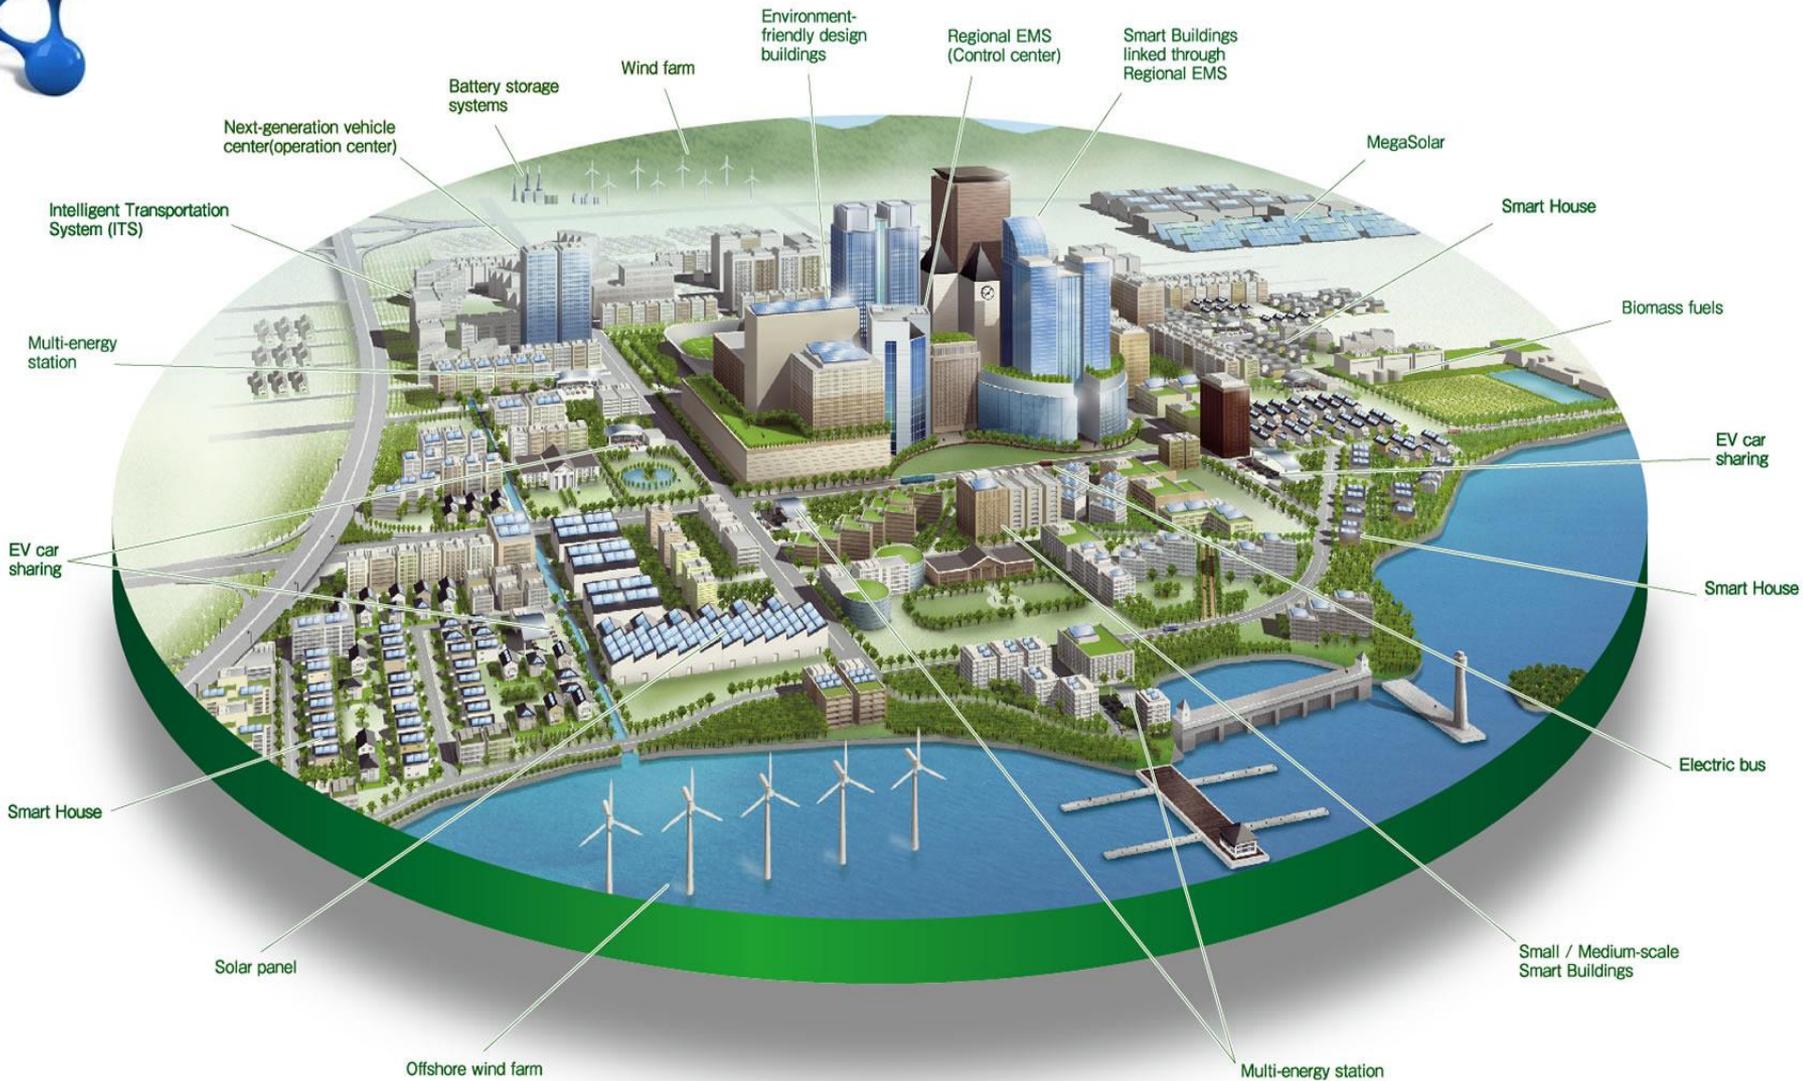
- **Esempio:**
  - **query1 AND query2** will match all the items containing both **query1** and **query2**.
  - **query1 OR query2** will match all the items containing **query1** or **query2** or both.
  - **query1 [AND] NOT query2** will match all the items containing **query1** and *NOT query2*.
  - **+query1 -query2** will match all the items containing **query1** but not **query2**.
- Modelli indicizzati Faceted: e.g.: [www.eclap.eu](http://www.eclap.eu)
- Modelli



## *Dati vs Metadati*

- Dati, open data
- Dati privati, dati pubblici
- Linked Open Data
- Metadati e indicizzazione
- Dati e smart city ←
- User Profile







# *Sustainability of the Growth*

- To be **planned and managed** with respect to increment of population and their needs
  - increment of efficiency:
    - compensation of the increments of costs
  - Increment of quality of life:
    - compensation of the decrement of quality of life
  - provisioning of new services:
    - compensation of the inadequacy of services
  - Decision support for strategic aspects
    - Corrections, prediction, new services, etc.
- **Towards citizens**
  - Informing citizens on the new adaptations, making them aware about that
  - Forming citizens to adopt virtuous behaviour in the usage of services and resources



# *Smartness, smart city needs 6 features*

- Smart Health
- Smart Education
- Smart Mobility
- Smart Energy
- Smart Governmental
  - Smart economy
  - Smart people
  - Smart environment
  - Smart living
- Smart Telecommunication





# Smart health

(can be regarded as smart governmental)

- Online accessing to health services:
  - booking and paying
  - selecting doctor
  - access to EPR (Electronic Patient Record)
- **Monitoring** services and users for,
  - learn people behavior, create collective profiles
  - personalized health
  - Inform citizens to the risks of their habits
  - Improve efficiency of services
  - redistribute workload, thus reducing the peak of consumption





# Smart Education

(can be regarded as smart governmental)

- Diffusion of ICT into the schools:
  - LIM, PAD, internet connection, tables, ..
- Primary and secondary schools → university  
→ industry & services
- **Monitoring** the students and quality of service,
  - learn student behavior, create collective profiles,
  - personalized education
- suggesting behavior to
  - Informing the families
  - moderate the peak of consumption
  - increase the competence in specific needed sectors, etc.
  - Increase formation impact and benefits



# Smart Mobility



- Public transportation:
  - bus, railway, taxi, metro, etc.,
- Public transport for services:
  - garbage collection, ambulances,
- Private transportation:
  - cars, delivering material, etc.
- New solutions (public and/or private):
  - electric cars, car sharing, car pooling, bike sharing, bicycle paths
- Online:
  - ticketing, monitoring travel, infomobility, access to RTZ, parking, etc.



# Smart Mobility and urbanization

- **Monitoring** the city status,
  - learn city behavior on mobility
  - learn people behavior
  - create collective profiles
  - tracking people flows
- **Providing Info/service**
  - personalized
  - **Info** about city status to
  - help moving people and material
  - education on mobility,
  - moderate the peak of consumption
- **Reasoning to**
  - make services sustainable
  - make services accessible
  - Increase the quality of service



# Smart Energy

## Smart building:

- saving and optimizing energy consumption, district heating
- renewable energy: photovoltaic, wind energy, solar energy, hydropower, etc.

## Smart lighting:

- turning on/off on the basis of the real needs

## Energy points for electric: c

- cars, bikes, scooters,

## Monitoring consumption, learn people/city behavior on energy consumption, learn people behavior, create collective profiles

## Suggesting consumers

- different behavior for consumption: different time to use the washing machine

## Suggesting administrations

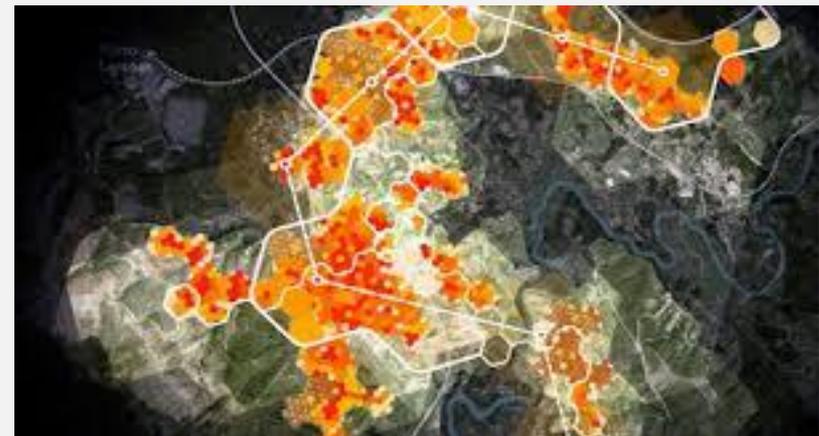
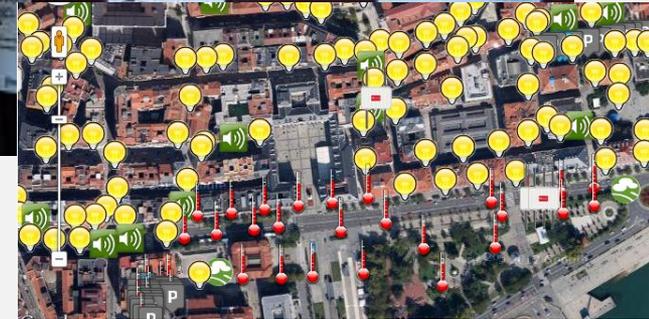
- restructuring to reduce the global consumption,
- moderate the peak of consumption





# Smart Governmental Services

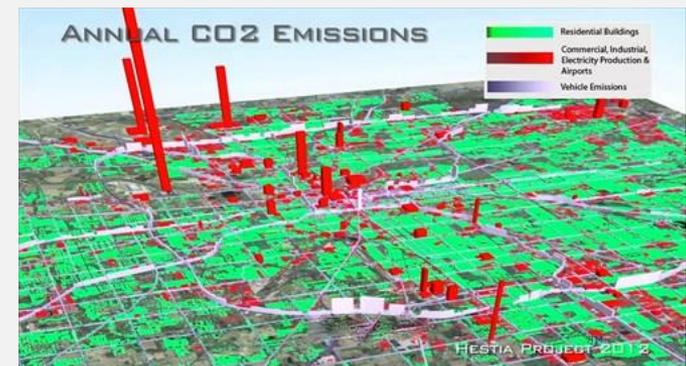
- service toward citizens:
  - on-line services:
    - register, certification, civil services, taxes, use of soil, ...
  - Payments and banking:
    - taxes, schools, accesses
  - Garbage collection:
    - regular and exceptional
  - Quality of air:
    - monitoring pollution
  - Water control:
    - monitoring water quality, water dispersion, river status





# Smart Governmental Services

- **Service toward citizens:**
  - **Cultural Heritage:** ticketing on museums,
  - **Tourism:** ticketing, visiting, planning, booking (hotel and restaurants, etc. )
  - **social networking:** getting service feedbacks, monitoring
- **Social sustainability of services:**
  - crowd services
- **Social recovering** of infrastructure,
  - New services, exploiting infrastructures
- **Monitoring** consumption and exploitation of services, learn people behavior, create collective profiles
  - Discovering problems of services,
  - Finding collective solutions and new needs...



# Telecommunication, broadband

- **Fixed Connectivity:**
  - ADSL or more, fiber,
- **Mobile Connectivity:**
  - Public wifi, Services on WiFi, HSPDA, LTE
- **Monitoring** communication infrastructure
- Providing information and formation on:
  - how to exploit the communication infrastructure
  - Exploiting the communication for the other services,
  - moderate the peak of consumption





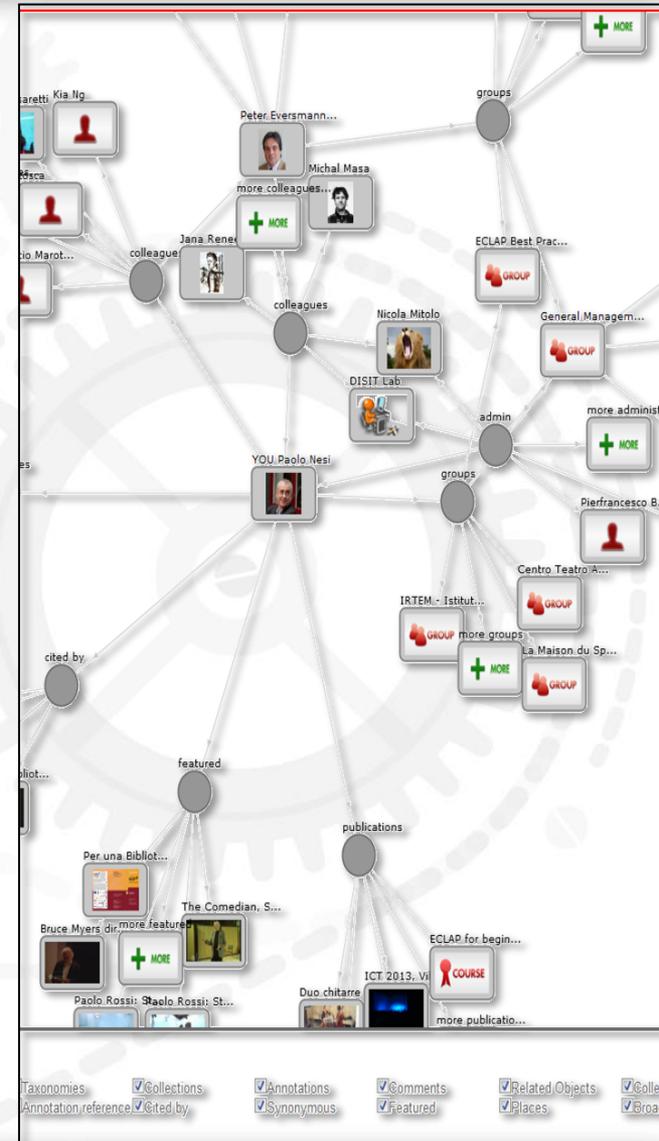
## *Dati vs Metadati*

- Dati, open data
- Dati privati, dati pubblici
- Linked Open Data
- Metadati e indicizzazione
- Dati e smart city
- User Profile ←



# I profili degli utenti

- **Gli utenti possono:**
  - fornire informazioni preziose sulla città come «**sensori intelligenti**» per tenere sotto controllo il livello dei servizi della città e/o nuove necessità
  - **essere profilati per ricevere dei servizi personalizzati, benefici diretti**
- Informazioni anonime:
  - *velocità degli spostamenti: auto a piedi, code e flussi cittadini, temperature, meteo*
  - *Uso dei servizi*
- private in consenso informato, statistiche e attuali:
  - *Azioni e dati personali*
  - *Relazioni con altre persone*
  - *Movimenti puntuali*





# User Profile

- **Static user profile aspects**
  - generically provided during registration
    - frequently not so much detailed in generic Social Networks,
    - users prefer to avoid filling in ‘useless’ forms and/or to provide false data.
  - In small thematic and business oriented Social Networks the information is much more reliable.
  - Dependent on the Social Network objectives
- **Dynamic user profile aspects**
  - generate on the basis of the user’s activities performed on the SN elements, such as the actions performed on
    - content, other users, on groups, on chat, etc.
  - estimated/inferred by assessment/analysis



# Static Aspects of User profile

## □ Static information collected during registration++

- ♣ Name, surname,
- ♣ Nationality and languages (multiple)
- ♣ Genre, age, etc..other personal info,.
- ♣ Instruction/School, work, family structure, etc.
- ♣ Personal photo
- ♣ Jobs: several different jobs with periods, etc..
- ♣ Competences: several skills
- ♣ Economical data: range, etc.
- ♣ Explicit Preferred content:
  - topics, genre, period, area, etc.
- ♣ Subscribed (slow dynamic):
  - lists, groups, ..



# Dynamic Aspects of User profile

- **dynamic information collected on the basis of the activities:**
  - ♣ votes and comments/annotations on:
    - contents, forums, web pages, etc.;
  - ♣ downloads and play/view/executions of content, web pages, etc.;
  - ♣ uploads and publishing of user provided content;
  - ♣ marked content as preferred/favorite;
  - ♣ recommend content/groups or users to other users;
  - ♣ chat with other users, publishing forum topic on groups;
  - ♣ queries performed on the portal, etc.;
  - ♣ create a topic in a forum or contribute to a discussion;
  - ♣ relationships/connections with other users or groups;
  - ♣ Etc.



# Dynamic aspects of user actions

- Statements written on blogs and micro blogs
  - ♣ Short Comments in a context
  - ♣ Recurrent user and statement
  - ♣ The same statement on more than one blog (pushed by pushers)
  - ♣ Dates and time, successive blog posts
  
- Statements on comments
- Assessment of:
  - ♣ Market trends, market vigilance
  - ♣ Pharmavigilance

# Esempio di Profilo utenti

## ➤ Informazioni statiche:

### • Informazioni generali:

- nome, cognome, sesso,
- foto, data di nascita,
- descrizione personale,
- località di provenienza (ISO 3166),
  - Nazione
  - Suddivisione
  - Provincia

### • lingue parlate (ISO 369)

### • Informazioni di contatto:

- lista di contatti di instant messaging

### • Scuola e Lavoro:

- scelta del livello scolastico,
- nome della scuola,
- tipo di lavoro,
- nome del posto di lavoro

### • Interessi:

- Vettore contenente la lista di valori del campo  
Type degli oggetti scelti dall'utente

## ➤ Informazioni dinamiche:

- Lista di oggetti preferiti

- Lista di amici

- Lista gruppi

- Voti positivi ad oggetti

- Commenti ad oggetti

- Blog post

- ...

- ...

- Informazioni sulle preferenze  
sulla base delle  
visualizzazioni degli oggetti

- Format

- Type

- Taxonomy

# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City* 
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence*

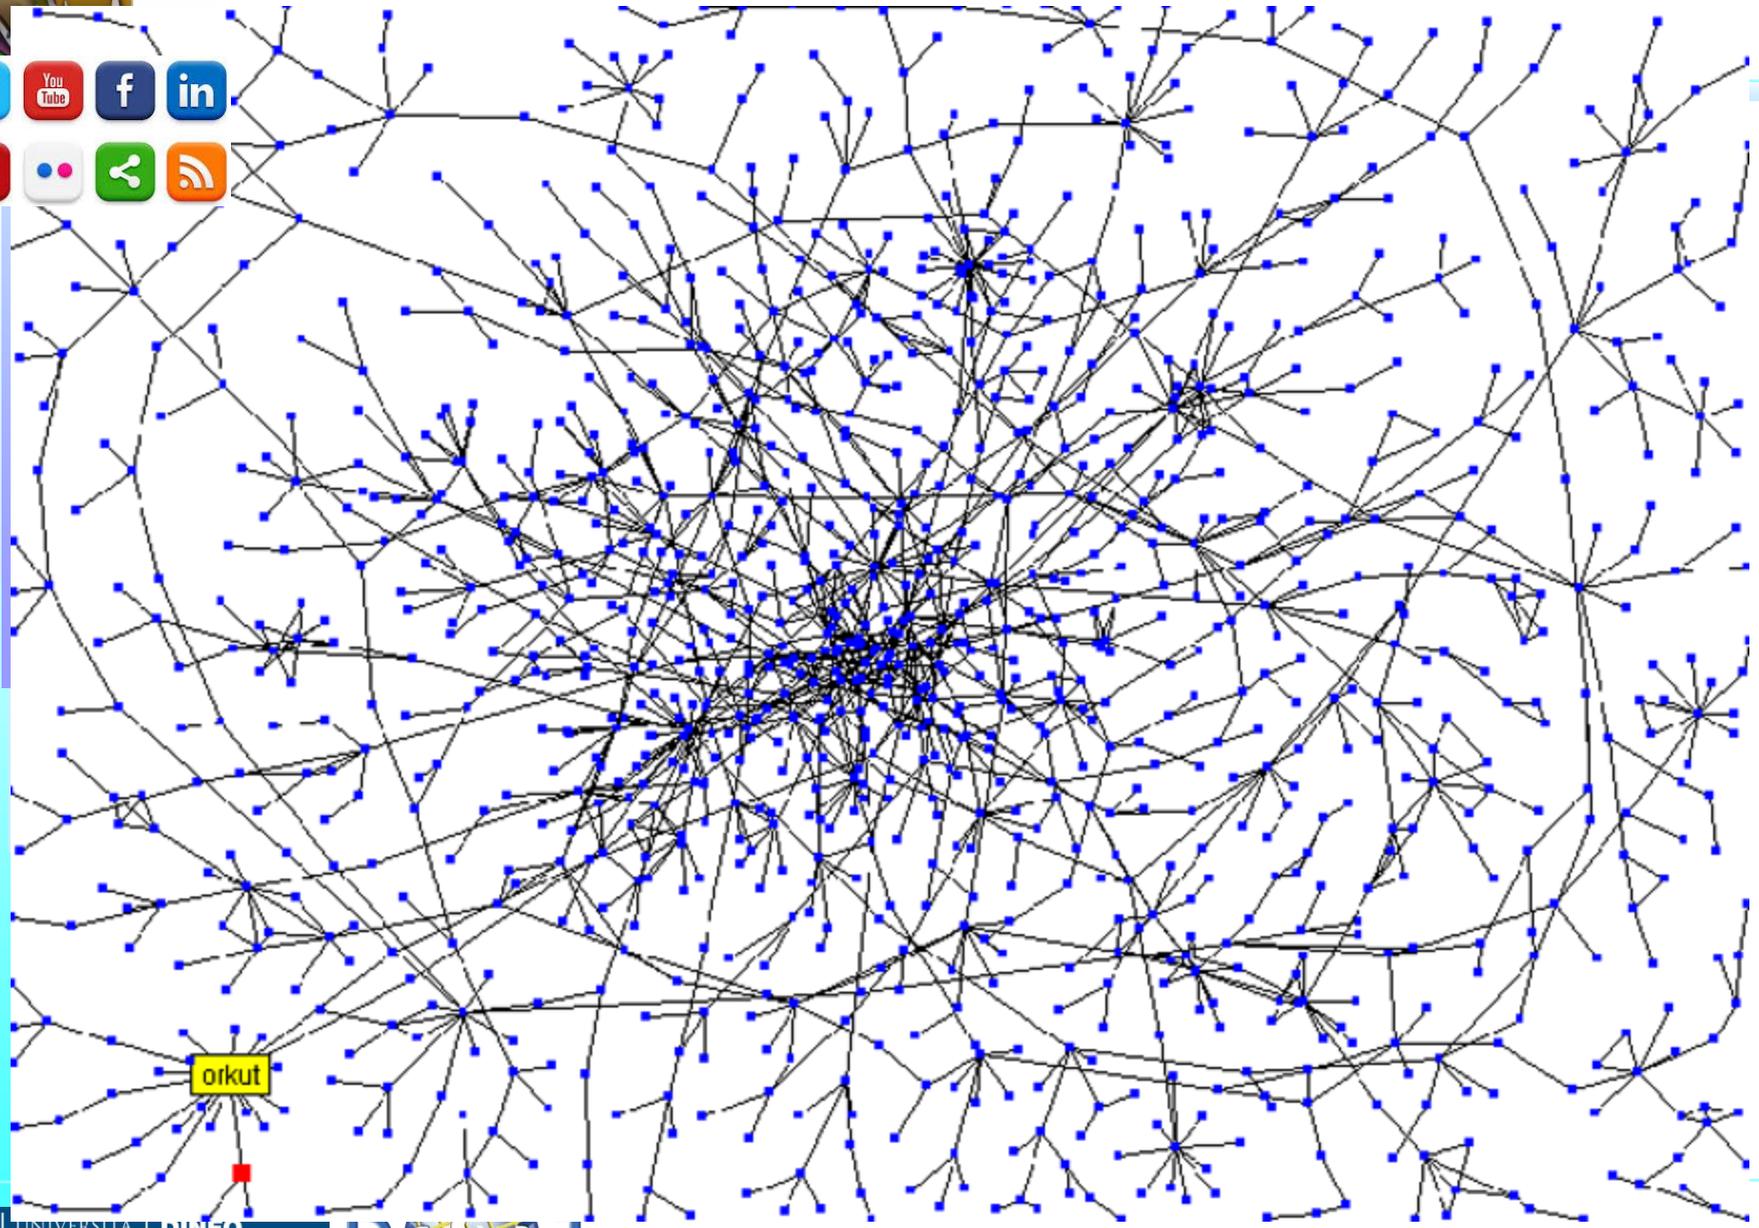


# Social Network e Smart City

- Relazioni fra utenti 
  - Si veda <http://osim.disit.org> per UNIFI
- Social network analysis
- Social Network
- Social graphs
- Social network interoperability
- Smart city model

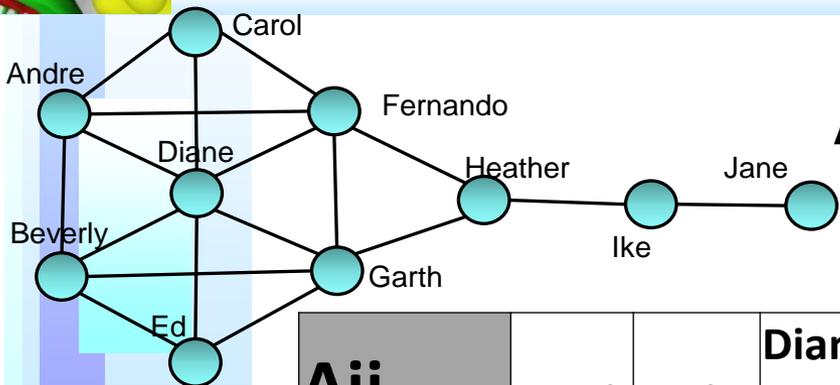


# Stanford Social Web





# Matrix of connections

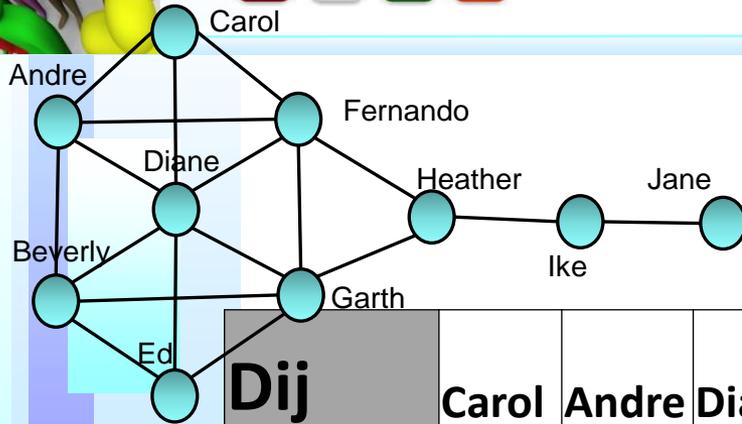


$A[i][j]$ : matrix of connections

<b>Aij</b>	Carol	Andre	Diane	Fernando	Beverly	Ed	Garth	Heather	Ike	Jane	NC
<b>Carol</b>	0	1	1	1	0	0	0	0	0	0	3
<b>Andre</b>	1	0	1	1	1	0	0	0	0	0	4
<b>Diane</b>	1	1	0	1	1	1	1	0	0	0	6
<b>Fernando</b>	1	1	1	0	0	0	1	1	0	0	5
<b>Beverly</b>	0	1	1	0	0	1	1	0	0	0	4
<b>Ed</b>	0	0	1	0	1	0	1	0	0	0	3
<b>Garth</b>	0	0	1	1	1	1	0	1	0	0	5
<b>Heather</b>	0	0	0	1	0	0	1	0	1	0	3
<b>Ike</b>	0	0	0	0	0	0	0	1	0	1	2
<b>Jane</b>	0	0	0	0	0	0	0	0	1	0	1
<b>nc</b>	3	4	6	5	4	3	5	3	2	1	36



# Matrix of distances

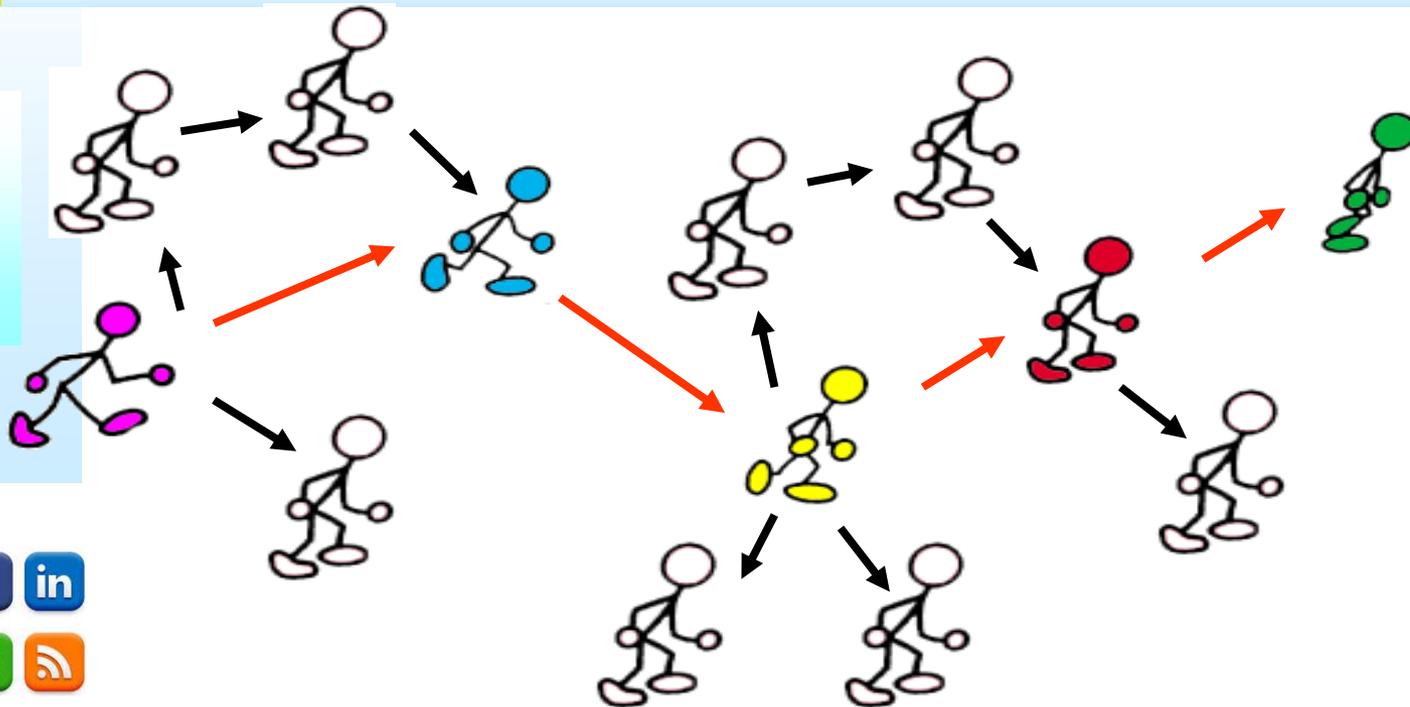


$D[i][j]$ : matrix of distances  
 $N*(N-1)/2$  elements

<b>Dij</b>	Carol	Andre	Diane	Ferna ndo	Beverl y	Ed	Garth	Heath er	Ike	Jane
<b>Carol</b>	0	1	1	1	2	2	2	2	3	4
<b>Andre</b>		0	1	1	1	2	2	2	3	4
<b>Diane</b>			0	1	1	1	1	2	3	4
<b>Fernando</b>				0	2	2	1	1	2	3
<b>Beverly</b>					0	1	1	2	3	4
<b>Ed</b>						0	1	2	3	4
<b>Garth</b>							0	1	2	3
<b>Heather</b>								0	1	2
<b>Ike</b>									0	1
<b>Jane</b>										0

89

# Averaged shortest path from one person to another



MIT: 6.4 hops

Stanford: 9.2 hops

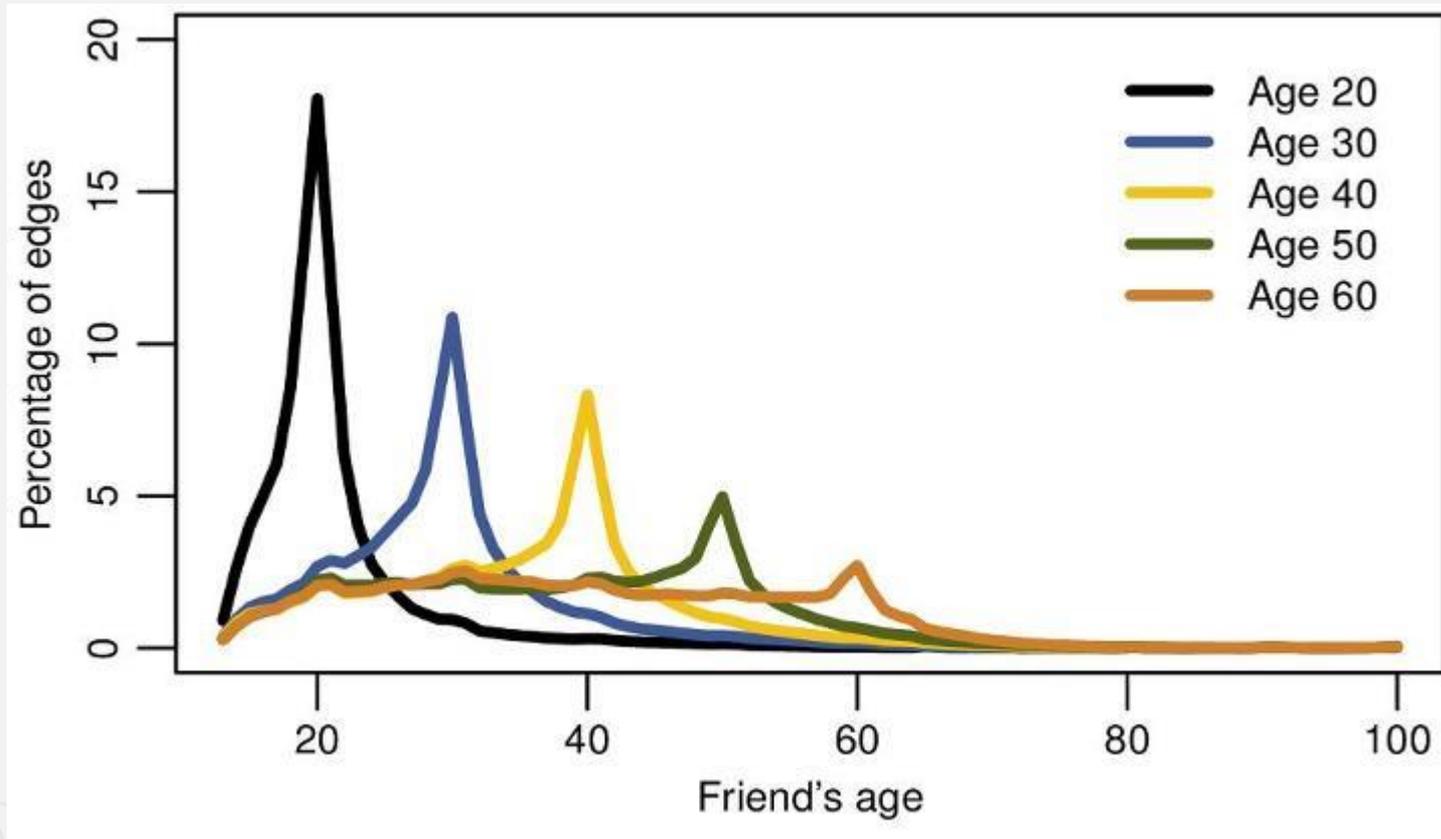
Our example: 1.97 hops

Sum of shortest paths: 89  
10 Nodes  
45 possible connections





# *Distribuzione dei colleghi (facebook)*





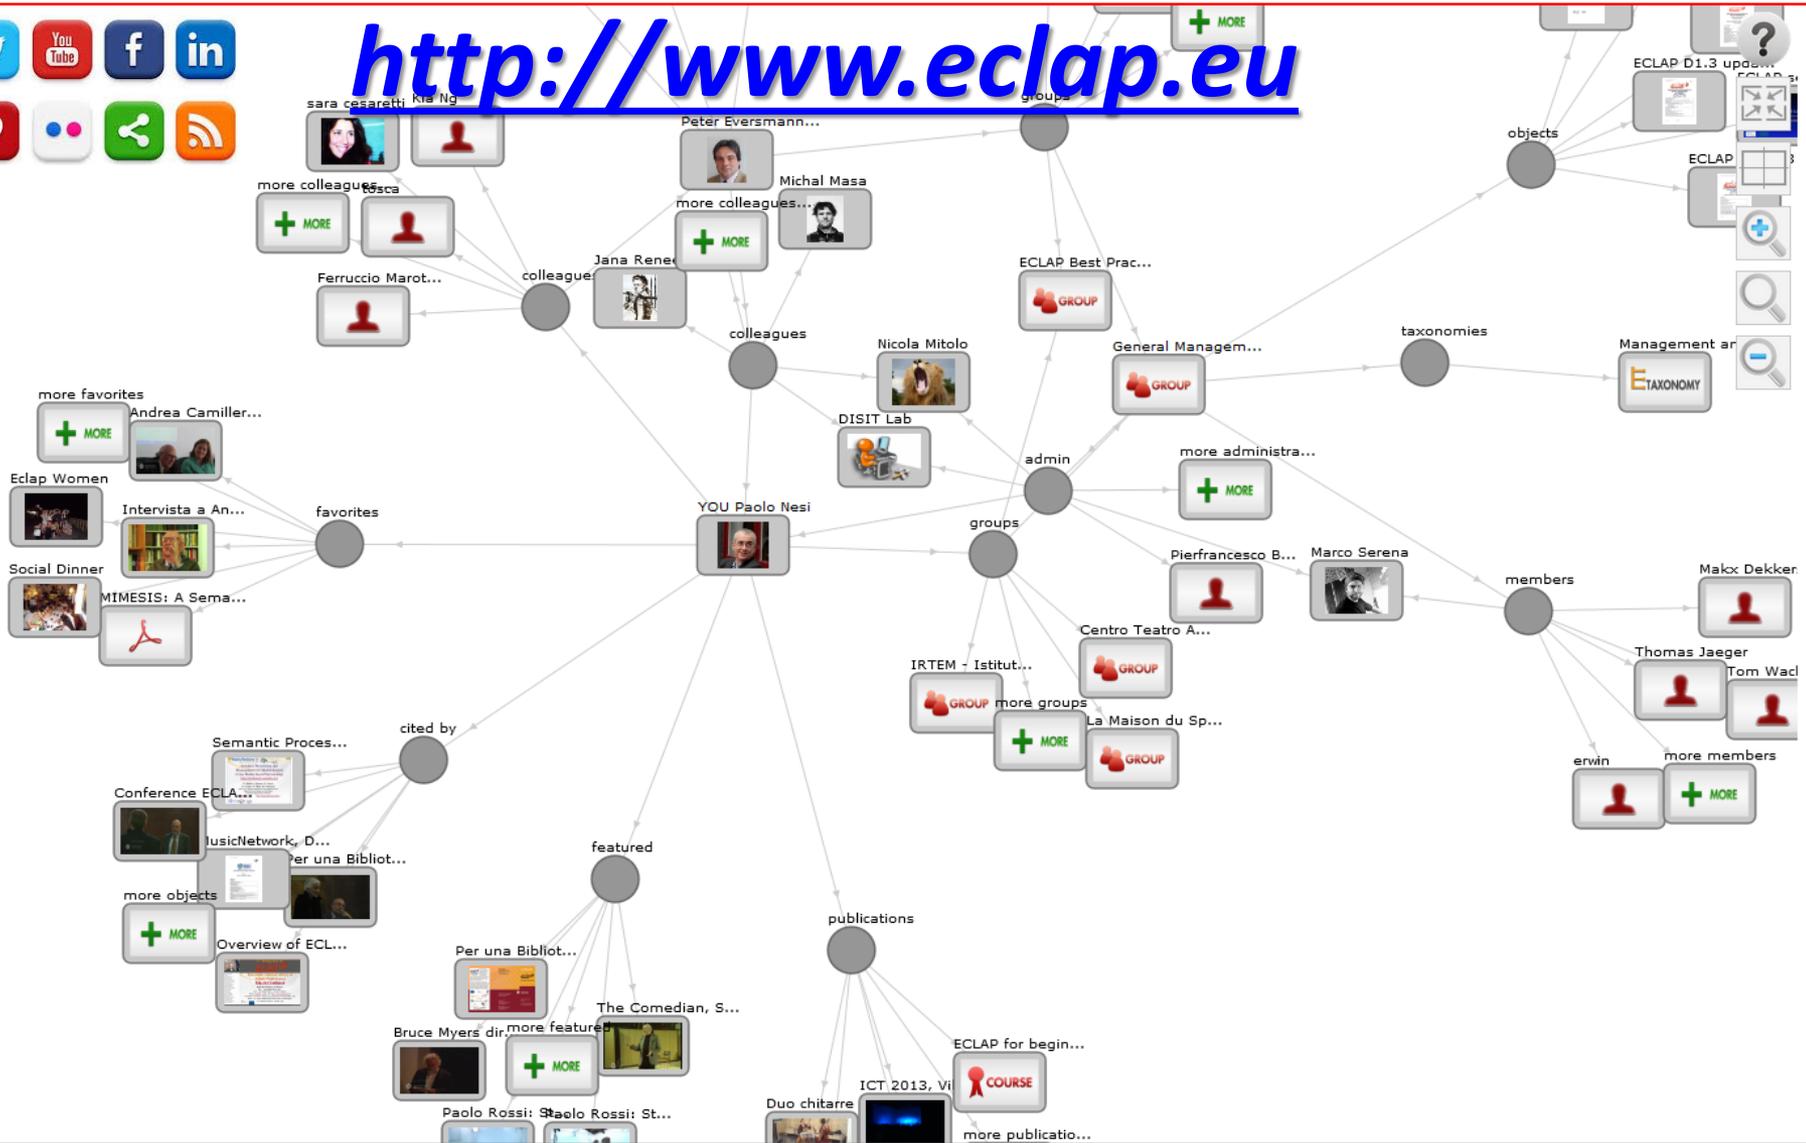
# Social Network e Smart City

- Relazioni fra utenti
  - Si veda <http://osim.disit.org> per UNIFI
- Social network analysis
- Social Network
- Social graphs 
- Social network interoperability
- Smart city model





<http://www.eclap.eu>



actions

- Groups
- Administrators
- Cited Names
- Favorite
- Writer
- Taxonomies
- Annotation reference
- Collections
- Cited by
- Annotations
- Synonymous
- Comments
- Featured
- Related Objects
- Places
- Colleagues
- Broader
- Publications
- Narrower
- User's favorites
- Formed



# Social Network e Smart City

- Relazioni fra utenti
  - Si veda <http://osim.disit.org> per UNIFI
- Social network analysis
- Social Network
- Social graphs
- Social network interoperability
- Smart city model





## Networks

- SN may be **interoperable** with other portals and SN
- **Allowing:**
  - **posting** comments and contributions via the so called ***Social Icon*** interface
  - **importing** user registration/profile and info or directly with some SSO
  - **exporting** SN content in other portals, for example via some API.
  - **hosting** SN players into other WEB portal pages, via some HTML segment to be copied
  - **hosting** widgets/applications into the WEB pages of the Social Network, via some programming model



# Interoperability for Users

- Interchange of user profiles
  - **OpenID**: user identity standard, to allow user profile and credential interoperability among portals, is SSO method
  - **OAuth**: delegation protocol for accessing to credentials, user authentication
  - **OpenSocial** (by **Google** with MySpace): exchange of user profile.
    - Many big Social Networks have joined the OpenSocial API movement, including hi5, LinkedIn, Netlog, Ning, Plaxo, Orkut, Friendster, Salesforce, Yahoo, Ning, SixApart, XING, etc.
  - **Facebook** Connect is in competition with OpenSocial
  - Other technologies:
    - XUP of W3C, XMPP, FOAF, XFN, etc..

# Obiettivi: Twitter Vigilance

- **Monitorare** Canali Twitter con
  - **Elevata affidabilità** e precisione, seguendo eventi lenti, veloci ed esplosivi
  - **Gestione multiutente** per canali multipli: pubblici e privati
  - **Data analytics e sentiment analysis** in modo assistito e diretto
- **Un Canale di Twitter Vigilance:** un insieme di ricerche attive e adattive su social media Twitter.
  - Ogni ricerca può essere semplice o complessa
  - Ogni utente qualificato può gestire più canali e ricerche
- **Attivo**
  - da Aprile 2015 per il collezionamento dati,
  - da settembre per il calcolo automatico big data analytics,
  - da ottobre per la Sentiment Analysis automatizzata.
- **Gestisce** con disinvoltura
  - Anche 580.000 tweet per giorno
  - Oltre 30 Milioni di Tweet





# Ricerca full text e Faceted

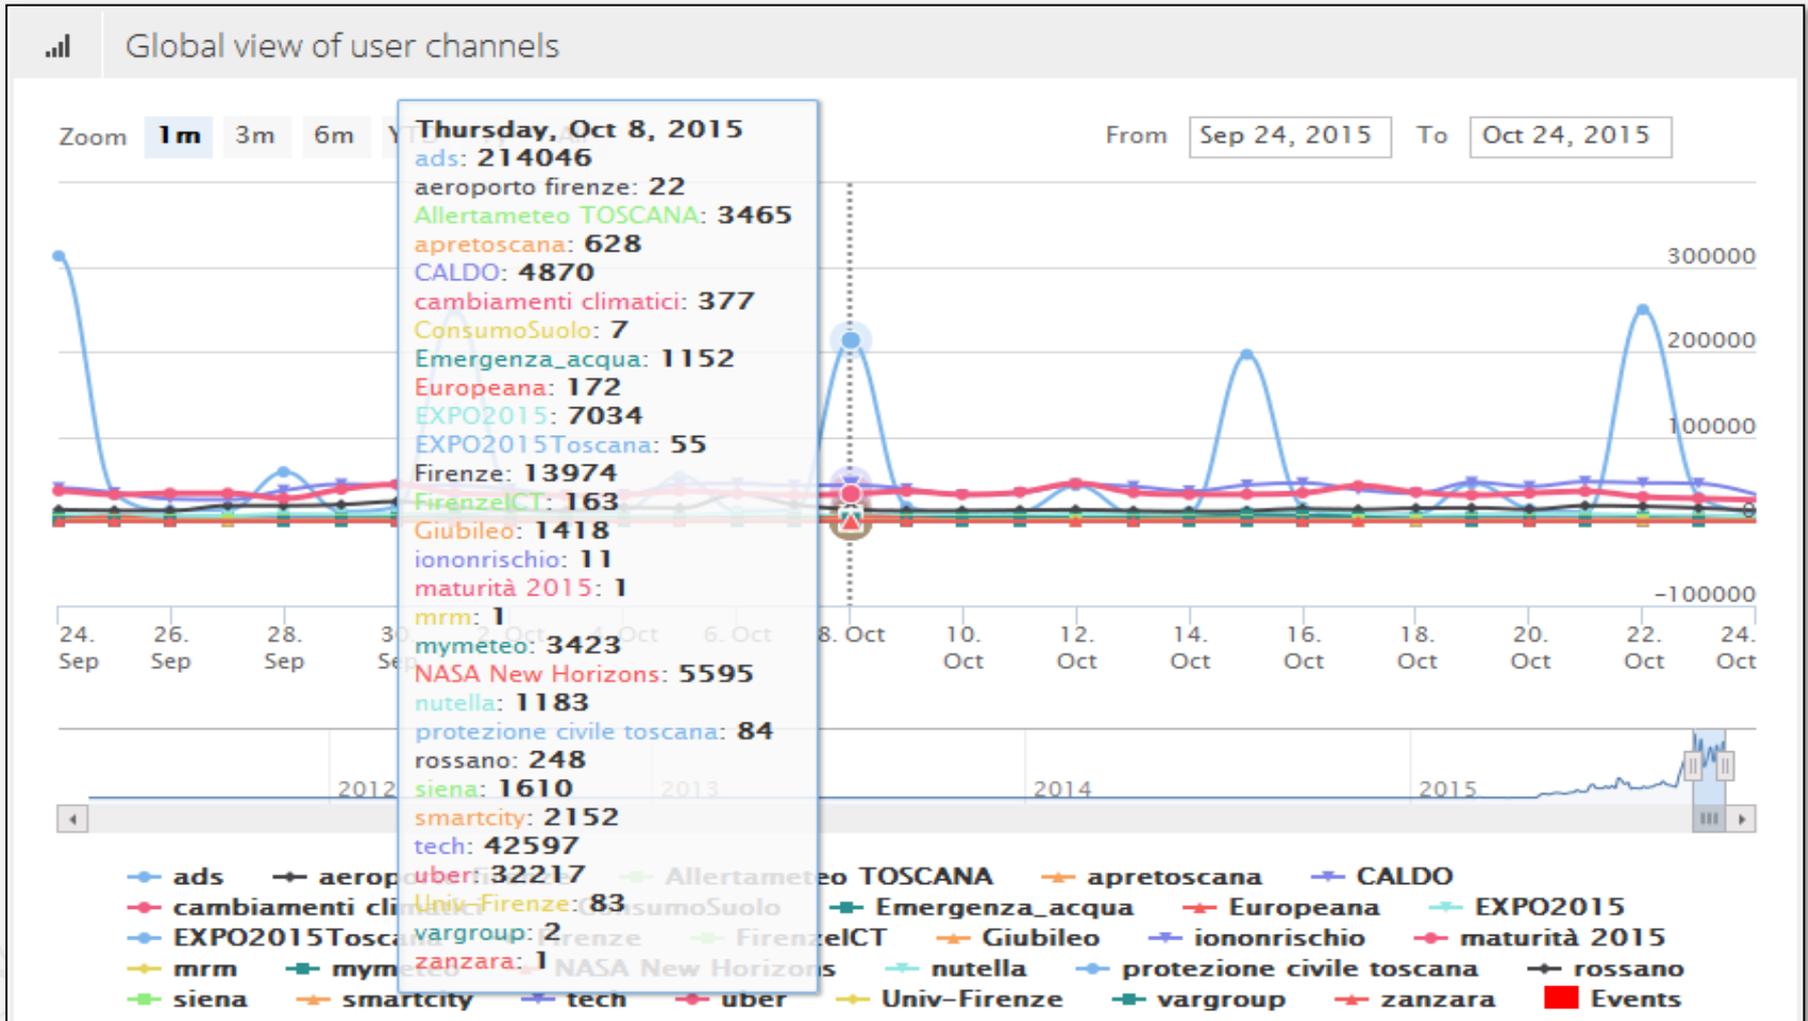
The screenshot displays a Twitter search interface for the query "twitter". The left sidebar lists various filters such as "name\_s", "twitterUser", "hashtagsOnTwitter", and "mentions". The main content area features a "publicationTime" bar chart showing tweet volume from 2015-06-11 to 2015-10-21. Below the chart is a "Marker Map" of Europe with blue location pins. A "Filter Bar" indicates no filters are currently applied. The "Grid Results" section shows a list of tweets, including one about "rischio smog e ozono" and another about "costes económicos de la independencia de cataluña".

*For faceted search on the whole storage with special care on: channels, search, users, mentions, hashtags, geographic, language, Tweet/ ReTweet, date and time, etc.*

# *Alcuni Canali di TwitterVigilance*

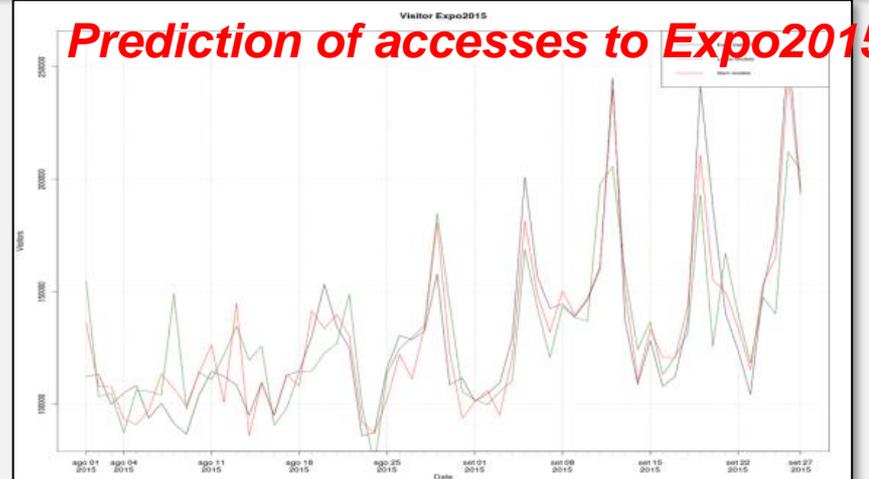
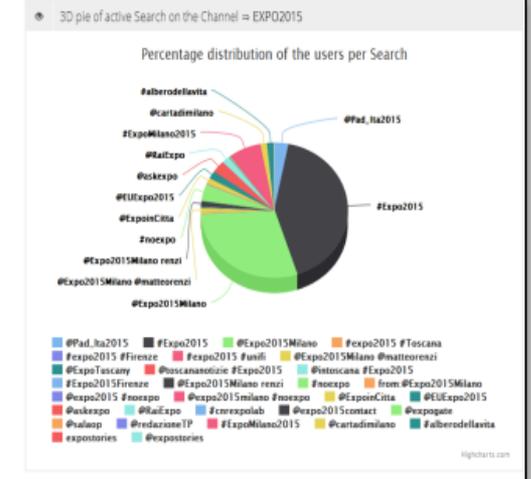
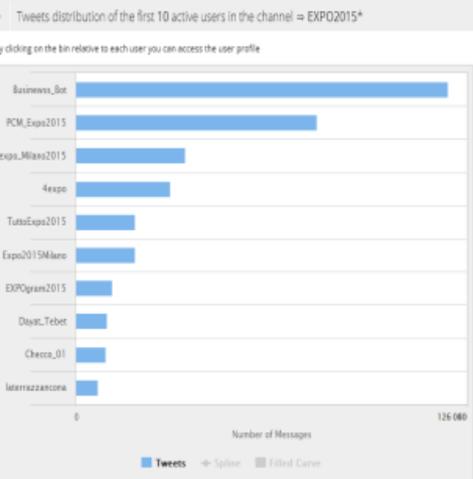
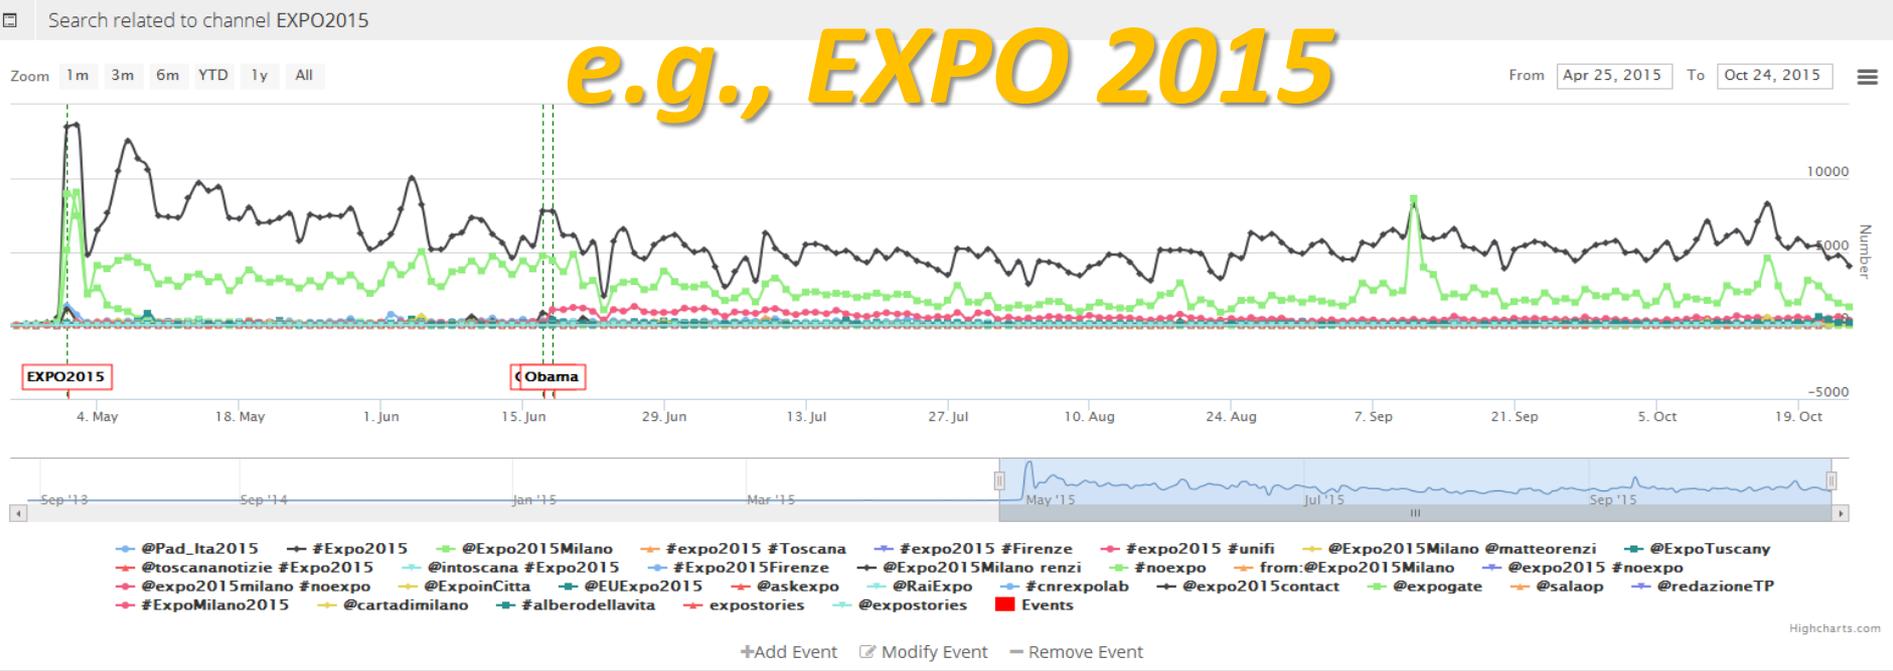
- <http://www.disit.org/tv> canali pubblicati
  - **Esempi di Canali:**
    - EXPO 2015, CNR EXPO2015,
    - Firenze, ApreToscana, maturità,
    - ConsumoSuolo, meteo, allerta meteo toscana, protezione civile,
    - farmaco vigilanza, smart drug,
    - ECLAP e Europeana, advertising TV, laudatesi, etc.
- **Are tematiche:** meteo, ambiente, advertising, eventi pubblici, farmacovigilanza, smart city, politica, etc.

# Canali Pubblici al Nov. 2015



# Twitter Vigilance: le analisi

- **Analisi e caratterizzazione della comunicazione**
- **Percezione sociale, eventi pubblici, naturali..**
- **Scoprire, identificare e calcolare**
  - **Nascita / crescita di nuove occorrenze** in tempo reale: eventi, fatti, meteo, condizioni critiche, etc.
    - *Supporto alla decisioni, ridurre i tempi di reazione, valutare la percezione, ridurre i costi, incrementare la resilienza come capacità di reagire*
  - **Chi influenza** la comunicazione, le comunità e come: i pusher, gli attori, i *follower*, le sorgenti, etc.
  - **Predizione su eventi** periodici, per esempio presenze ad eventi, presenze sui canali televisivi, etc.
  - **Misure indirette** basate sulla popolazione: rischio sicurezza, degrado, neve, grandine, vento, etc.

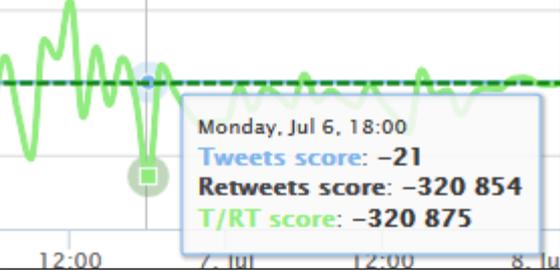


# Twitter Vigilance: sentiment analysis

- **Controlla e analizza in automatico il livello di apprezzamento e/o dissenso per:**
  - prodotti, servizi, promozioni, cambiamenti in città,
  - persone, azioni politiche, eventi,
  - programmi TV, attori, cantanti (surrogato di "auditel")
- Permette di effettuare
  - Valutazioni di **andamento** a breve e lungo termine
  - Valutazioni **comparative** a breve e lungo termine
  - **Predizioni** in certe situazioni
  - **Identificazioni in quasi real time** della nascita di eventi esplosivi, situazioni critiche, etc., uso di utenti come sensori diffusi

# Sentiment Analysis

## Canale CALDO



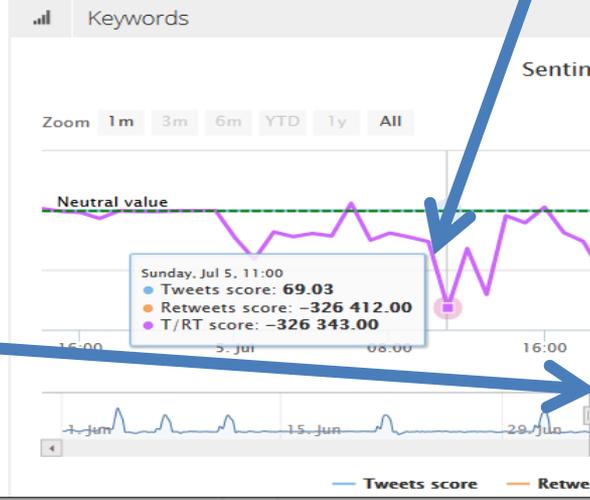
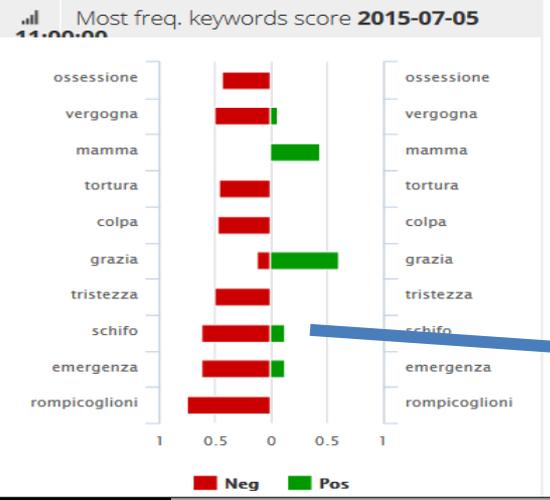
## SA sul canale CALDO: la ricerca "caldo" ha dato un sentiment negativo



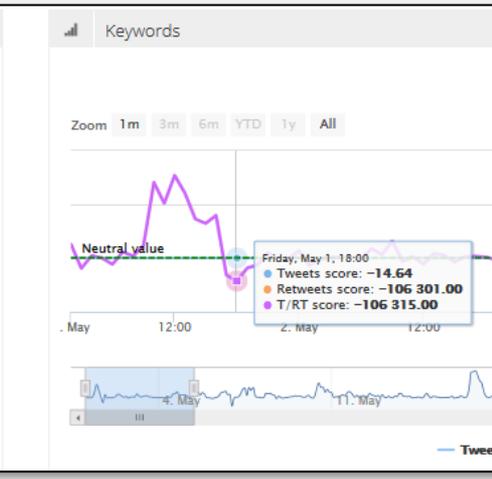
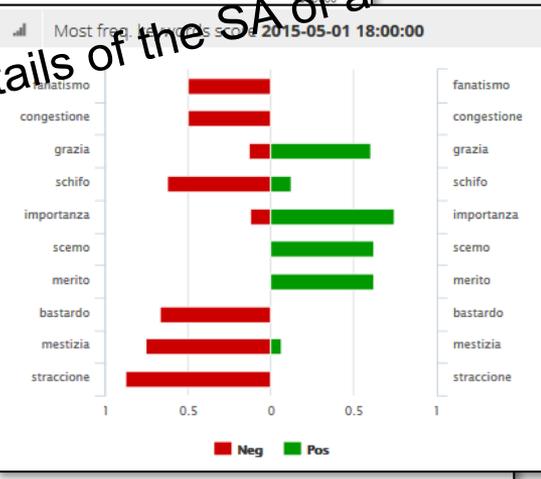
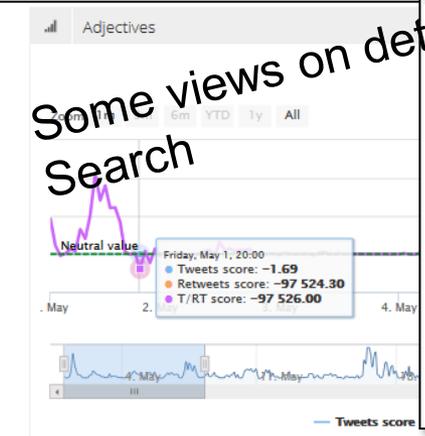
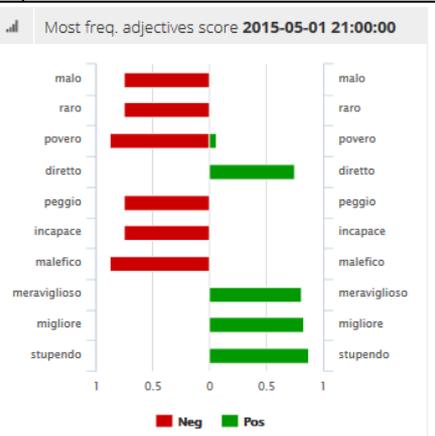
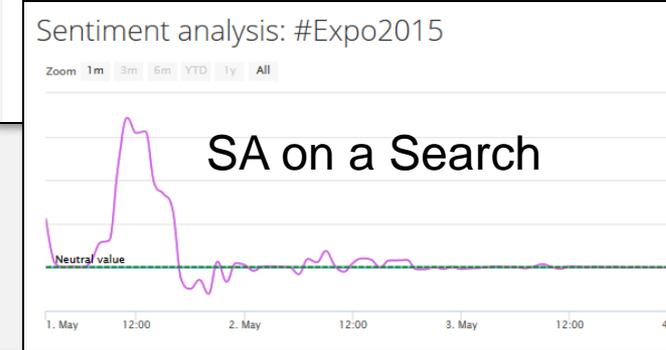
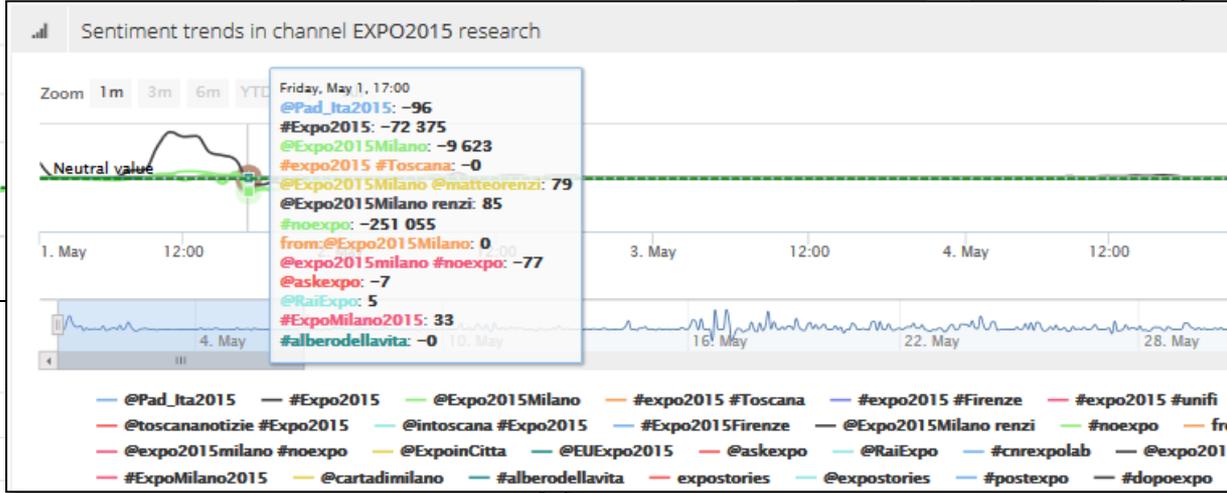
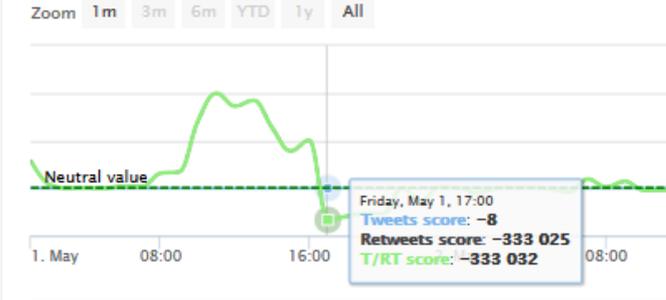
Un sentiment marcatamente negativo: -313272  
Anche su key multiple

Pochi Tweet negativi hanno provocato un enorme numero di

- **emergenza** caldo, una rete per i più deboli  
<http://t.co/x6e4dkwqk8>
- continua l'**emergenza** #caldo. domani fino a 43 gradi percepiti in #piemonte  
<http://t.co/gvuyafeq0o>
- cerolini su gestione **emergenza** caldo a pescara  
<http://t.co/zecmr7t4zv>  
**#emergenza**caldo **#pescara**
- **emergenza** caldo, in arrivo i 38 gradi nella città metropolitana di milano. consulta il bollettino emesso: <http://t.co/n5oocelibv>



## Sentiment trends in channel EXPO2015 SA on a channel



Some views on details of the SA of a Search

# *Social Network e Smart City*

- Relazioni fra utenti
  - Si veda <http://osim.disit.org> per UNIFI
- Social network analysis
- Social Network
- Social graphs
- Social network interoperability
- Smart city model 



## Sfide: richieste e deduzioni

Pub.  
Amm.



**Miglioramento dei servizi**

vendita di servizi,  
miglioramento,  
vendita di dati  
profilazioni

Operatori:  
Mobilità,  
energia,  
Salute,...



Miglioramenti e  
predizioni sui servizi

**Sistema Smart City**

**Accesso ai dati  
per le PMI, PA**



**Servizi & Suggerimenti**  
Trasporto, Mobilità, Commercio,  
Turismo Cultura, salute,...

**Personal Time Assistant** biglietti,  
suggerimenti, informazioni, aiuto, etc.



**Comportamenti  
degli utenti**



User profiling  
Profili Collettivi  
Segmentazione



**Dati: pubblici e privati, statici e in tempo reale**

**Privati:** comportamenti, social media, contributi, consumi

**Pubblici:** mobilità, traffico, video camere, ambiente, acqua, statistiche,  
accesso alla ZTL, servizi, musei, punti di interesse, ...

## Scenari che da fantascientifici diventano reali...

### Grazie a infrastrutture che..

- **Raccolgono dati e statistiche su**

- Ambiente & energia
- Trasporti & mobilità
- Commercio & Turismo
- Servizi al cittadino
- Comportamento e stato della popolazione nel rispetto della privacy, anonymity

- **Producono analisi, previsioni e deduzioni** su base

- Statistica, analitica, logica...
- sporadiche e/o in tempo reale



*possiamo dire che*

- *Gli utenti dovrebbero consumare la loro energia quando le industrie non lo fanno...*
- *Le auto elettriche dovrebbero essere ricaricate vicino alla generazione di energia*
- *Ora: vi sono 34 posti liberi in Piazza Stazione*
- *Ora: Il #4 arriva alla fermata in 3 minuti*



### Wifi operativi 21



### SmartDS: via santa marta 3 21



### Bus attivi 20

29

### Ataf RT 20

64.1%

### Informazioni disponibili 21

Servizi al Cittadino: 23452

Eventi giornalieri: 29

Open Data disponibili: 143

### Servizi duplic. 20

19.4%

### Accessi ai servizi singoli (web e mobile) 22



### Bus attivi 20

### Ataf RT 20

### Parcheggi liberi 20

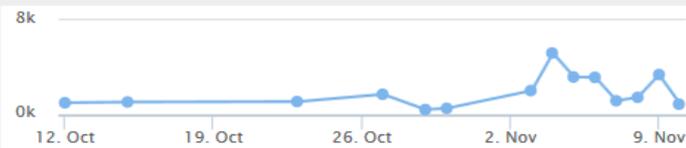
0%

### Twitter trends/citazioni 21

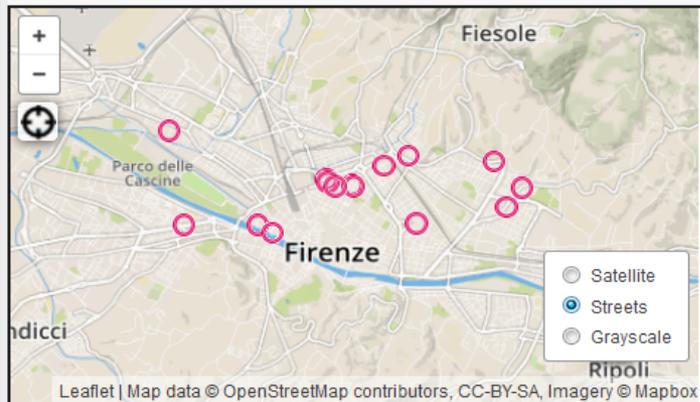
Principali Twitter Trends: #firenze #fiorentina #pontevecchio

Citazioni: @comunefi #fiorentina #pontevecchio

### Rilievi wifi 22



### Posizione in tempo reale degli autobus ATAF 21



### Previsioni RT 20

98.9%

### Previsioni meteo del comune di FIRENZE 2199961

Tuesday	Wednesday	Thursday	Friday	Saturday
bit cloudy 13°C / 19°C	mist 9°C / 20°C	bleary 8°C / 20°C	bit cloudy /	cloudy /

Latest Update: 2015-11-10T08:35:00+01:00

### Parcheggi RT 20

66.0%

### Smart City Engine 21

CPU	Mem Totale	Job Eseguiti
0.1%	24034 MB	954

### Query Servicemap 22



### Stato corse ATAF 21

Linee: 6 17 4

in Orario in Anticipo in Ritardo

60.6% 17.1% 22.4%

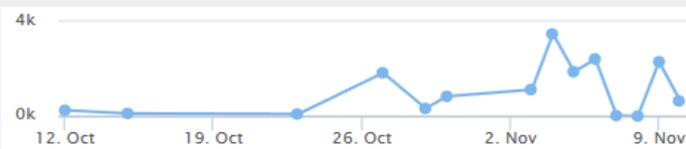
### Sensori RT 20

99.3%

### Eventi del giorno 22

- L'arte di Francesco - Capolavori d'arte e terre d'Asia dal XIII al XV secolo
- "The Medici Dynasty Show"
- TOSCANA '900
- Carlo Dolci 1616- 1687

### Query Km4city API 22



# Dati singoli ai dati aggregati ...

- Sistemi di **raccolta dati che devono essere integrati a livello semantico**
  - milioni di milioni di dati complessi arrivano ogni giorno alle centrali per essere analizzati: **Open Data, Real Time Data, Linked Data**

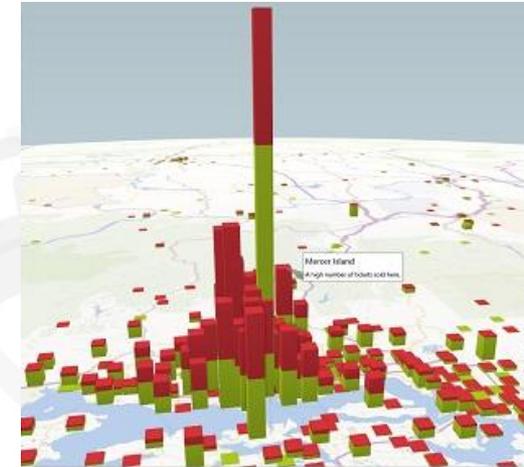
**Sensori ed attuatori, sistemi di comunicazione, kit su veicoli**

- OD, sensori, social network, blog, etc.

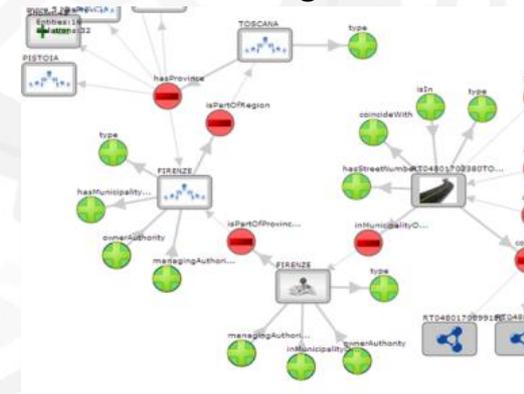


# Da dati aggregati alle deduzioni....

- Soluzioni di **intelligence per l'analisi dei dati**, per produrre in automatico:
  - deduzioni, correlazioni, implicazioni....
  - Supporto alle decisioni per le Pub. Ammin.
  - suggerimenti/raccomandazioni agli utenti anche in base ai loro profili (per esempio: medicina personalizzata), planning; alle aziende
- Soluzioni di **analisi per la comprensione di dati complessi**
  - fraseggi delle persone sulle social network, i commenti riguardo ai servizi della PA, le richieste di miglioramento dei servizi... (Natural Language Processing)
  - Comprensione di andamenti complessi da misurazioni puntuali (Data Mining, Knowledge Mining)



Microsoft geoflow



<http://Log.disit.org>

# Infrastruttura della Smart City



- Gestore del traffico
- Sensori
- Energia
- Ferrovie
- Operatori Telefonia
- .....
- .....
- Social Media

centrali

- Acquisizione dati
- Aggregazioni e dati
- Dati in Real Time
- Social Data trends

Acquisizione dati e comprensione

Motore Smart City

Elaborazione

Real Time Computing

Ragionamento e deduzione

- Servizi Profilati
- Servizi Profilati
- InFormazione dei cittadini
- Data / info visualizzaz.
- Data / info esport
- Suggerimenti e allarmi

Azione e visualizzazione

## Applicazioni



## interconnessione



- La sfida va verso *l'integrazione di grosse moli di dati non omogenei* per produrre *deduzioni più ampie e precise*
  - Dalle *infrastrutture di monitoraggio e controllo*: energia, ambiente, salute, traffico, taxi, etc.



## Sii-Mobility

- **servizi personalizzati**, connessi alla mobilità nella città
- Piattaforma di **partecipazione e sensibilizzazione**
- integrazione di **metodi di pagamento** e di identificazione
- gestione delle aree a traffico controllato
  - **dinamica dei confini**
  - **politiche di accesso**
- **interoperabilità** ed integrazione dei sistemi di gestione
- **scambio dati fra PA e privati**





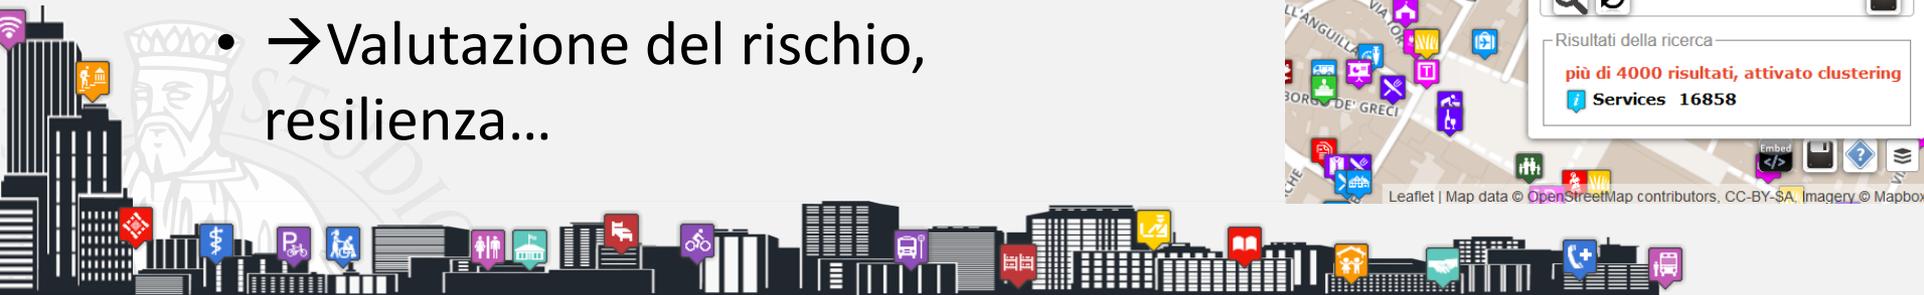
- Autostrade
- SS Fi-Pi-Li
- SS Fi-Si
- Ferrovie (primarie)
- - - Aree





# Km4City: Aggregatore Dati

- Fornire più informazioni di quelle che riceve in ingresso:
  - Sfrutta soluzioni big data e di intelligenza artificiale: learning, self correction, reasoning, data mining per connessioni con altri dati
  - dati aggregati come un servizio via API
    - Fornisce servizi integrati
    - Supporto alla decisioni, suggerimenti, dashboard
    - → Valutazione del rischio, resilienza...



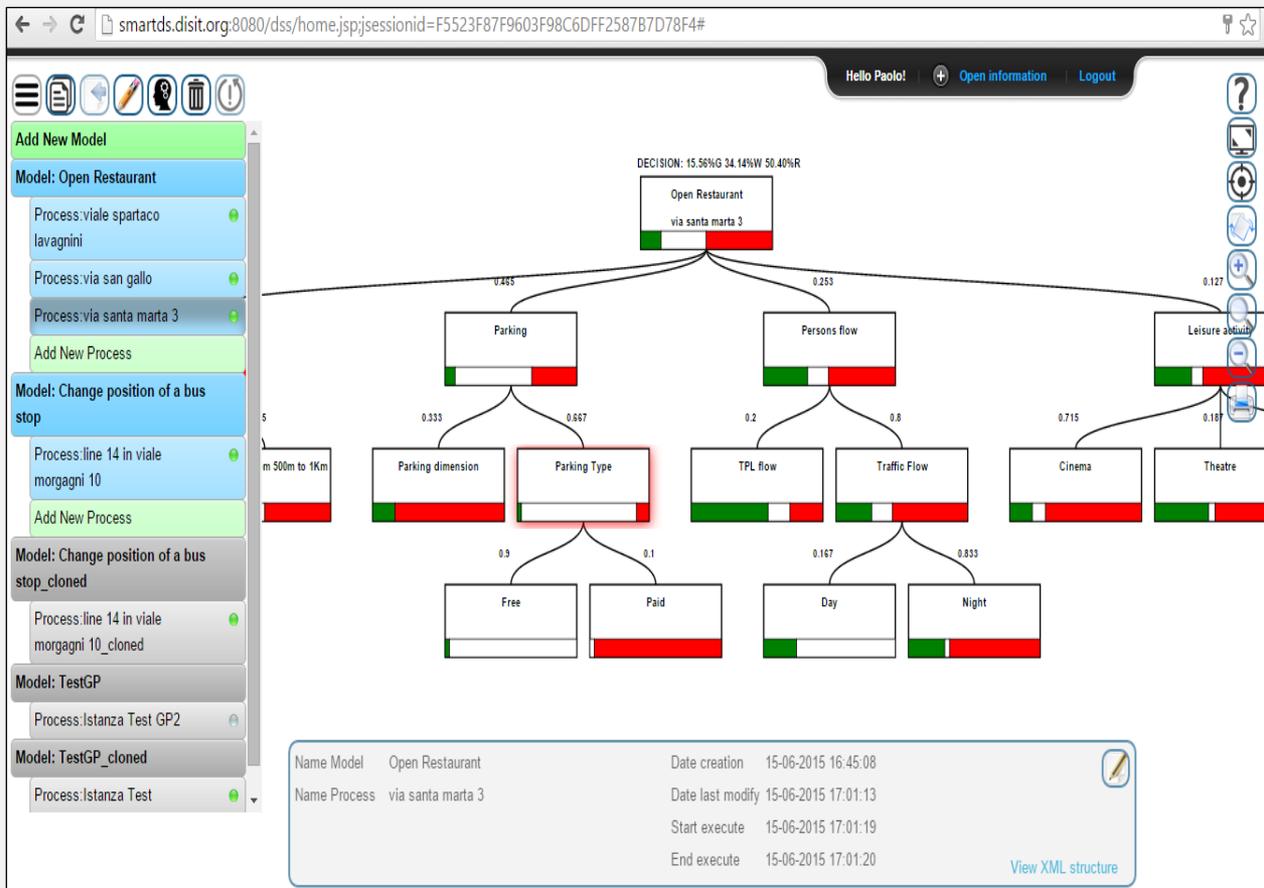


# Smart City Decision Support

- *Smart Decision Support System basato su System Thinking avanzato*

## Integra

- Modello matematico per la propagazione della conoscenza di esperti e dei gruppi di lavoro
- Modello di lavoro collaborativo per il Supporto alle decisioni
- Processi decisionali misti che combinano esperti, social media, valori dai dati base, valori statistici, sondaggi, workshop, etc.
- Produzione e ricalcolo in tempo reale, produzioni di allarmi e alert
- Connessione a modelli computazionali, Twitter Vigilance, Km4City Data store, City DashBoard





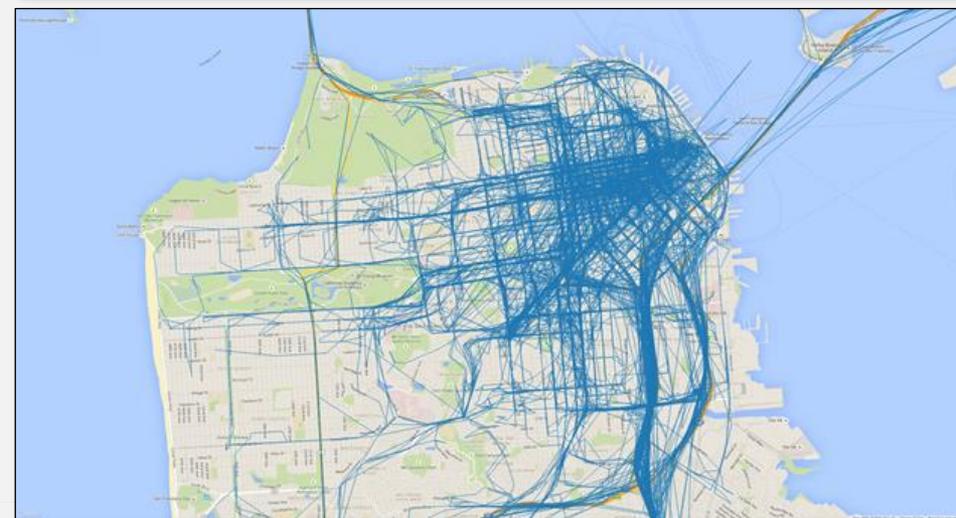
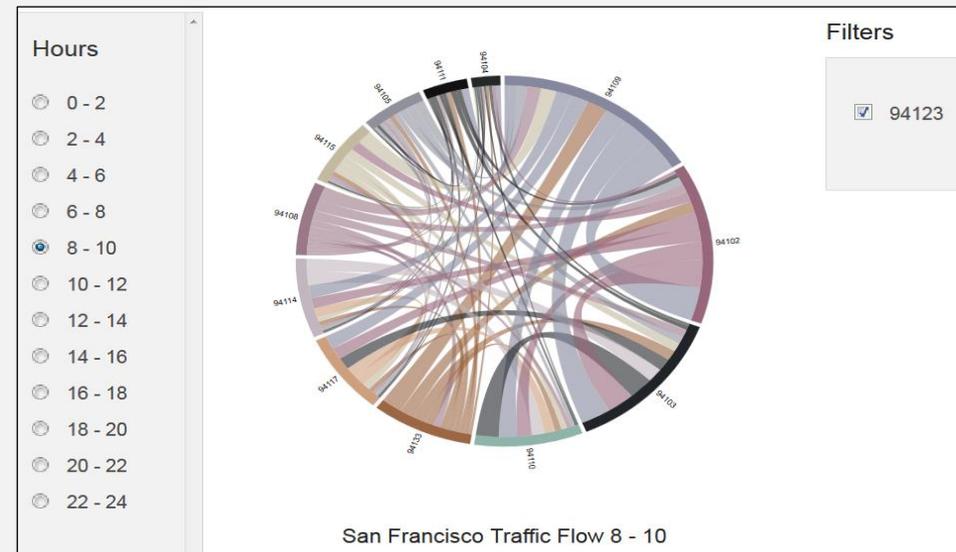
## • Mappe di Origine Destinazione

- Sensors, vehicle toolkit, mobile App, Wi-Fi Access Points, etc.
- Calcolo delle matrici e contestualizzazione dei dati

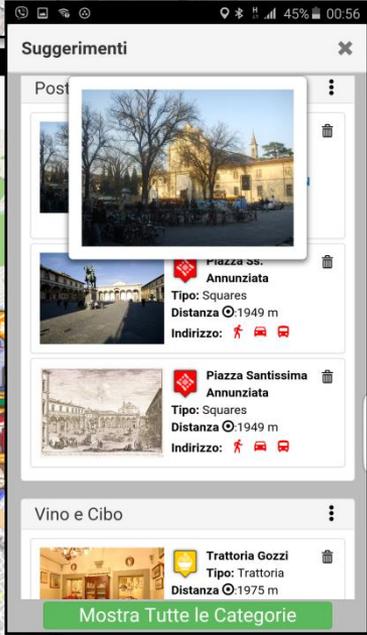
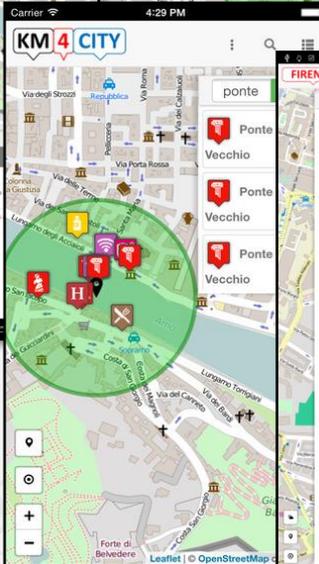
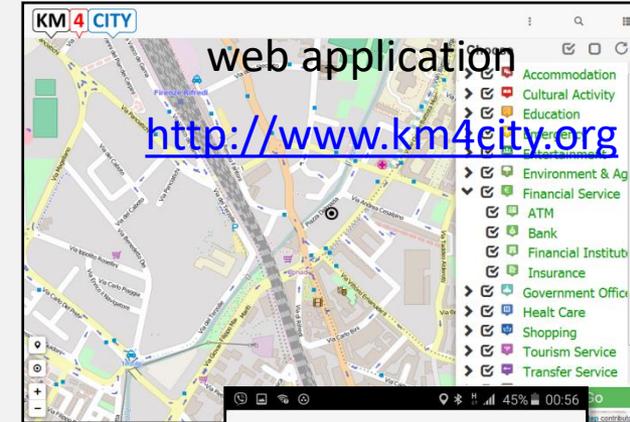
## • Valutazione dei Flussi di Persone e veicoli

- Miglioramento dei servizi
- Adattamento in tempo reale dei servizi,
- Calcolo di percorsi ottimi
- Predizione di condizioni critiche
- Identificazione precoce di condizioni critiche
- Supporto alla decisioni, connessione con SmartDS e Twitter
- Incremento della Resilienza
- Analisi sui servizi connessi alla mobilità in città
- Analisi dei flussi turistici

<http://www.disit.org/6694>



# Km4CityMobile App: all stores





UNIVERSITÀ  
DEGLI STUDI  
FIRENZE



# La città invisibile. Le informazioni digitali nei contesti urbani

Domenica 11 gennaio

USE CASE 1

Seleziona una linea:

Linea 4

Seleziona una fermata:

TUTTE LE FERMATE

USE CASE 2

Seleziona una provincia:

AREZZO

Seleziona un comune:

MONTEVARCHI

Villa Fabbricotti

Tipologia:   
E-mail:   
Indirizzo: Via Vittorio Emanuele II, 64   
Link: [LINK LOD](#)

FERMATA: STATUTO

FERMATA: GUIDO MONACO

Bernini

Tipologia: ristorante   
Email: [info.flo@albanihotels.com](mailto:info.flo@albanihotels.com)   
Indirizzo: Via Fiume, 2   
Note:   
[LINK LOD](#)

Selezione Attuale: Linea Bus: LINE4

Cerca Attività

Tipo Servizio:

- Accommodation
- Cultural Activity
- Education
- Emergency
- Entertainment
- Financial Service
- Government Office
- Health Care
- Shopping
- Tourism Service
- Transfer Service
- Wine And Food
- Near Bus Stops

Raggio di Ricerca:

Entro 100 metri

Cerca!

<http://servicemap.disit.org>

Previsioni Meteo per il comune di MONTEVARCHI:

Sabato	Domenica	Lunedì	Martedì	Mercoledì
poco nuvoloso	nuvoloso	pioggia debole e schiarite	nuvoloso	pioggia debole e schiarite
8 - 16	5 - 14	7 - 15	-	-

Leaflet | Map data © 2011 OpenStreetMap contributors, Imagery © 2012 CloudMade

## INCONTRI CON LA CITTÀ

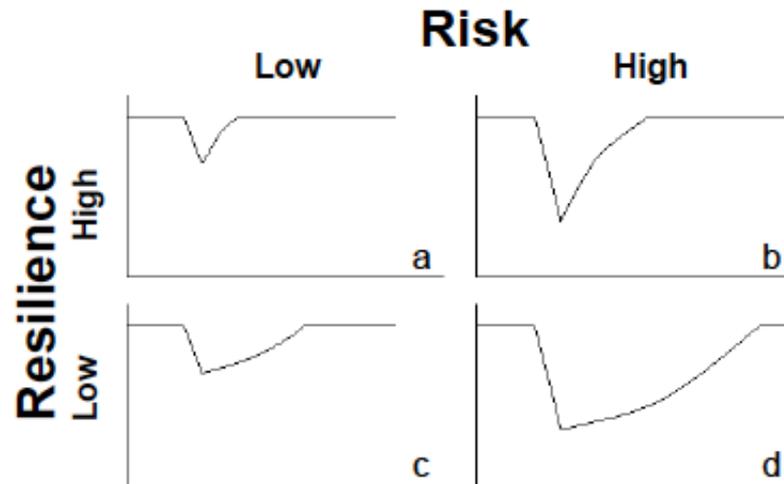
leggere il presente per comprendere il futuro

Relatore **Paolo Nesi**  
Ordinario di Sistemi di elaborazione  
delle informazioni



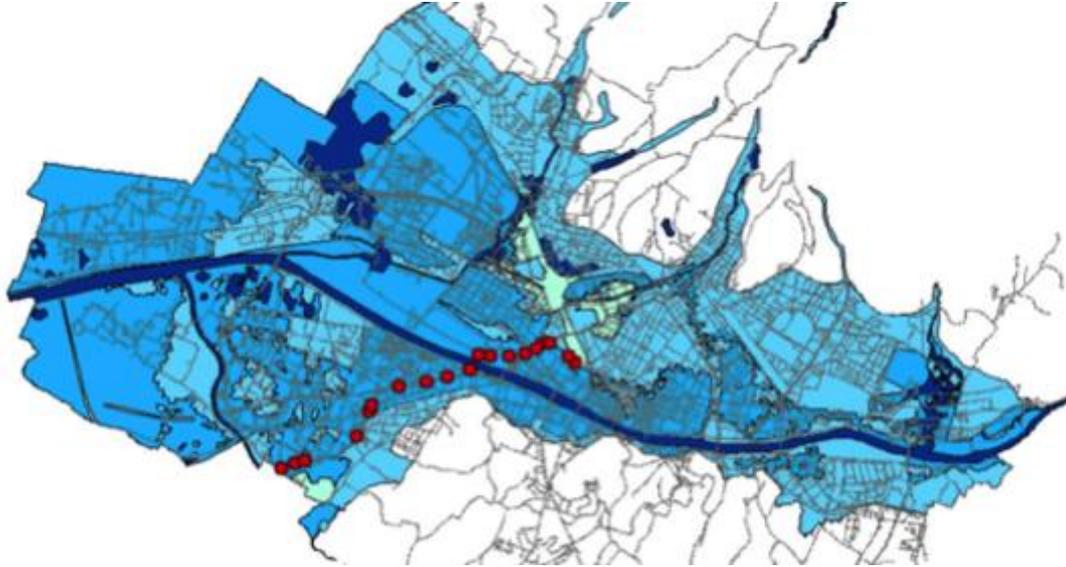
# Resilienza

la capacità di un sistema, una comunità o una società esposti a catastrofi di **resistere, assorbire, adattarsi e riprendersi** dagli effetti di una catastrofe in maniera efficiente e tempestiva, attraverso la protezione e il ripristino delle sue strutture e funzioni essenziali.[UNISDR 2009]





# Firenze Pilota



**Oltre il 70% delle  
infrastrutture cittadine sono a  
rischio idrogeologico**

Definire modelli per analizzare il traffico per automatico e semi-automatico riconoscimento di eccezionali (flood) situazioni e relative azioni correttive attraverso l'applicazione delle ERMG definite nel progetto

Eseguire vari scenari di eventi di piena, al fine di valutare la resilienza del sistema di trasporto urbano e le interdipendenze attraverso l'integrazione del sistema CRAMSS con il sistema di gestione del traffico reale a Firenze



Paolo Nesi, Emanuele Bellini, UNIFI  
Smart City Meeting,  
Firenze, 13 Novembre



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE





# Attiko METPO pilota



98Km linee  
 65 stazioni  
 1M passeggeri al giorno

- Esaminare le prestazioni delle regole e procedure di funzionamento della metropolitana esistenti per la gestione di eventi critici
- Eseguire vari scenari di minacce per valutare la resilienza del sistema di trasporti urbani di Atene attraverso l'impiego delle ERMG definite nel progetto
- Misurare l'impatto dei sentimenti umani negativi (ad esempio, la paura) sulla capacità di tenuta del sistema di trasporto urbano nel periodo post-attentato tramite un sondaggio preferenza



Paolo Nesi, Emanuele Bellini, UNIFI  
 Smart City Meeting,  
 Firenze, 13 Novembre



UNIVERSITÀ  
 DEGLI STUDI  
 FIRENZE



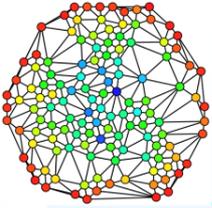
# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP* 
- *Data Mining*
- *Data Intelligence*

# ***Motori di Ricerca e Crawling***

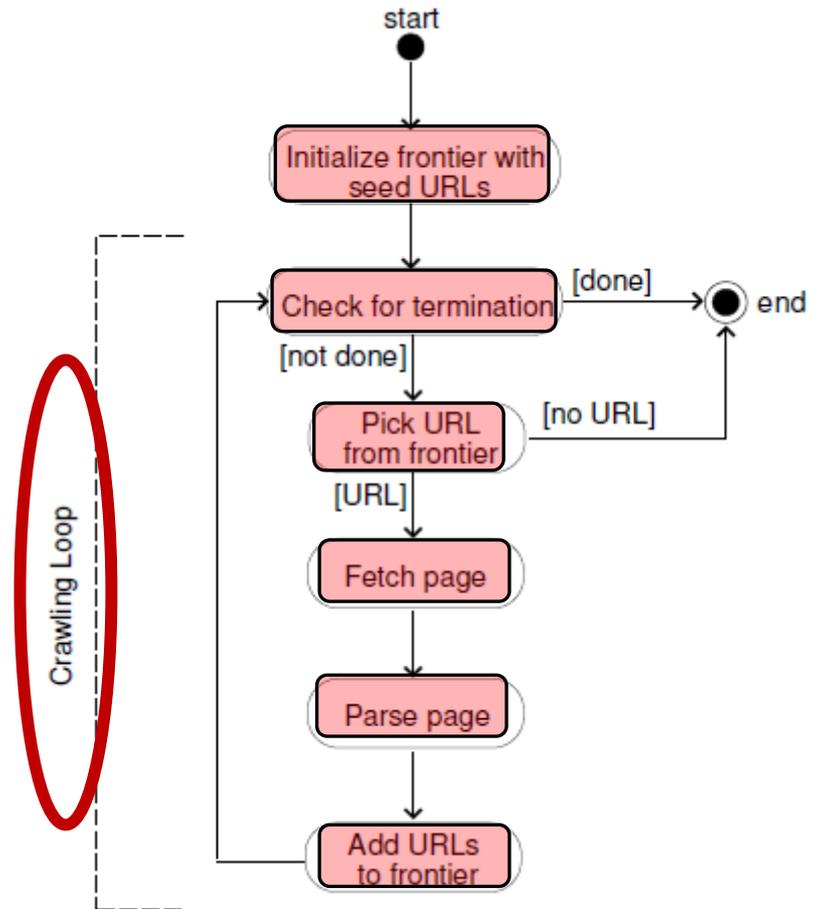
- Cosa fa' un motore di ricerca 
- Crawling
- Come viene fatto
- Indexing
- NLP: Natural language Processing

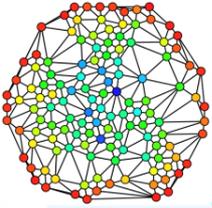




# Web Crawler - Generalità

- Un web crawler è un programma per estrarre automaticamente l'informazione contenuta nel web
- E' utilizzato per creare una copia locale di tutte le pagine visitate per una loro successiva elaborazione (estrazione di informazioni, indicizzazione, ecc..)
- Il web è visto come un grafo: i nodi sono le pagine web e gli archi sono gli hyperlinks

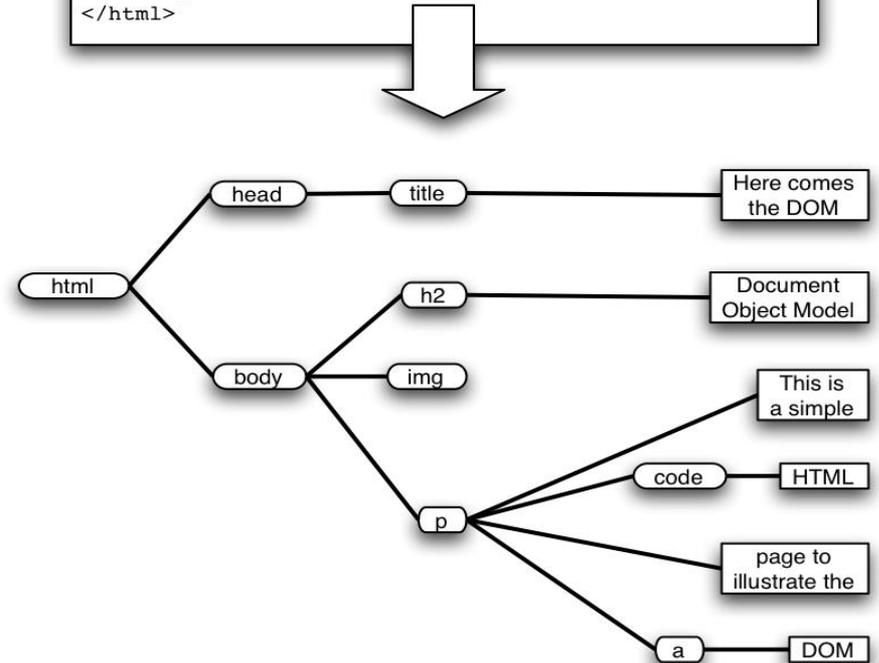




# Considerazioni implementative: Parsing

- I documenti HTML hanno una struttura ad albero - DOM (Document Object Model)
- Spesso i documenti HTML non rispettano gli standard di sintassi
- Occorre trattare le entità HTML e gli unicode nei testi
- Vi sono molti formati diversi di files:
  - ♣ Flash, SVG, RSS, AJAX...

```
<html>
<head>
  <title>Here comes the DOM</title>
</head>
<body>
  <h2>Document Object Model</h2>
  
  <p>
    This is a simple
    <code>HTML</code>
    page to illustrate the
    <a href="http://www.w3.org/DOM/">DOM</a>
  </p>
</body>
</html>
```



# ***Motori di Ricerca e Crawling***

- Cosa fa' un motore di ricerca
- Crawling
- Come viene fatto
- Indexing 
- NLP: Natural language Processing



# Indexing

## ■ Indexing & Search system

- Based on Apache Solr

## ■ Multilingual aspects

- Translate the metadata or translate the query?.. both
  - metadata translation
  - Query translation

## ■ Indexing schema

- Dublin Core + DCTerms (multi language)
- Performing Arts
- Technical (provider, content type, GPS, IPR, duration, quality, ...)
- Groups associations (multi language)
- Taxonomy associations (multi language)
- Comments & multi language tags
- FullText of the textual digital resources

# Indexing

Media Types	DC (ML)	Technical	Performing Arts	Full Text	Tax, Group (ML)	Comments, Tags (ML)	Votes
# of Index Fields*	468	10	23	13	26	13	1
Cross Media: html, MPEG-21, animations, etc.	$Y_n$	$Y$	$Y$	$Y$	$Y_n$	$Y_m$	$Y_n$
Info text: blog, web pages, events, forum, comments	$T$	$N$	$N$	$N$	$N$	$Y_m$	$N$
Document: pdf, doc, ePub	$Y_n$	$Y$	$Y$	$Y$	$Y_n$	$Y_m$	$Y$
Audio, video, image	$Y_n$	$Y$	$Y$	$N$	$Y_n$	$Y_m$	$Y_n$
Aggregations: play lists, collections, courses, etc.	$Y_n$	$Y$	$Y$	$Y/N$	$Y_n$	$Y_m$	$Y_n$

\* = (# of Fields per Metadata type) × (# of Languages)

ML: Multilingual; DC: Dublin Core; Tax: Taxonomy



**Technical**

N° accesses 28

Format video

Type video

Duration 00:12:48.0

Video quality available LD MD

Available platforms PC, iPhone/iPad, Android, Windows Phone 7, Windows Mobile 6.5

Upload date Sun, 2012-01-15 04:08

Group  
Centro Teatro Ateneo, University of Rome La Sapienza, UNIROMA, Italia

Published by CTA-UNIROMA

Upload user marcomaci

Original filename ITUR1CTAVGA09074.mov

Workflow type Europeana

Content-url link to this content

QR code



axoid urn:axmedis:00000:obj:03b7454d-6b7f-464a-9050-1d42e98cff88

**Classification**

**IPR information**

**Performing arts metadata**

**Technical**

**Classification**

Type Videosintesi rematica di prove dello spettacolo, a cura di Valentina Valentini

Language Ita

Source BVU

isPartOf Vittorio Gassman

Original metadata language it

**IPR information**

Rights  
Ferruccio Marotti, Centro Teatro Ateneo - "Sapienza" Università di Roma, Eredi Gassman

IPR owner page link to page

Europeana rights Europeana: Unknown copyright status

Public No

PC permission

	Public	Group	Educ.	Trusted
Download HD PC	No	No	No	Yes
Play HD PC	Yes	Yes	Yes	Yes
Download LD/MD PC	No	No	No	Yes
Embed	No	No	No	Yes
Play LD/MD PC	Yes	Yes	Yes	Yes

Mobile permission

	Public	Group	Educ.	Trusted
Download mobile browser	No	No	No	Yes
Play mobile browser	Yes	Yes	Yes	Yes
Download mobile app	No	No	No	Yes
Play mobile app	Yes	Yes	Yes	Yes

**Performing arts metadata**

**Location**

**Performing arts metadata**

First performance date 1983-07-15

Performance place Teatro Ateneo

Performance city Roma

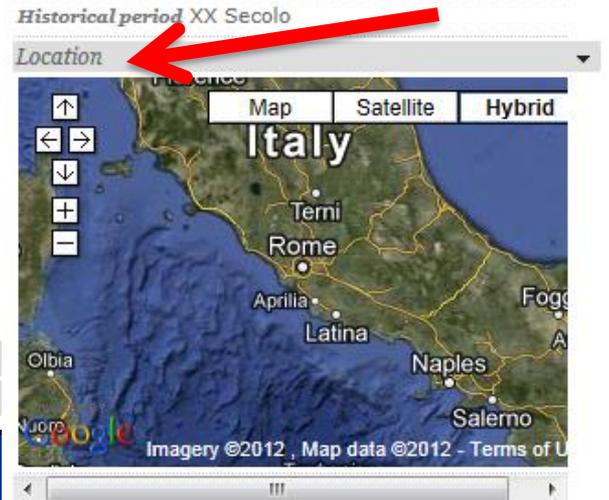
Performance country Italia

Performing Arts Group Compagnia del Teatro Manzoni diretta da Vittorio Gassman, con la collaborazione del 46° Maggio Musicale Fiorentino, della Bottega Teatrale di Firenze e dell'Estete Teatrale Veronese

Performers and crew Riprese: A. Muschietti; Tecnico audio e video: S. Casaluci; Interpreti e personaggi: Alessandro Esposito (Duncan, re di Scozia, un portiere), Danilo De Girolamo (Malcom), Roberto Medina (Donalbain), Vittorio Gassman (Macbeth), Carlo Montagna (Banquo), Luciano Virgilio (Macduff), Gian Franco Baroni (Lennox), Stefano De Sando (Ross), Luca Lazzareschi (Angus), Sergio Basile (Siward, conte di Northumberland, un capitano, un sicario), Lorenzo Gioielli (figlio di Siward, Fleance, figlio di Banquo), Alessandro Nisivoccia (un medico), Sergio Meogrossi (primo sicario), Federico Grassi (un sicario), Annamaria Guarnieri (Lady Macbeth), Giovanna Carcasci (Lady Macduff), Regina Senatore, Gabriella Chiari, Francesca Tardella, Franco Concilio, Franco Felici, Federico Grassi, Luca Lazzareschi, Stefano Molinari, Guido Paternesi (streghe). Scene e costumi: Paolo Tommasi; Musiche: Gianandrea Gazzola; Regia: Vittorio Gassman

Genre Teatro

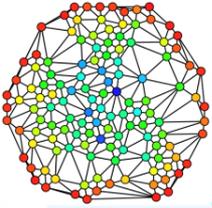
Historical period XX Secolo



# ***Motori di Ricerca e Crawling***

- Cosa fa' un motore di ricerca
- Crawling
- Come viene fatto
- Indexing
- NLP: Natural language Processing





# Natural Language Processing NLP (1)

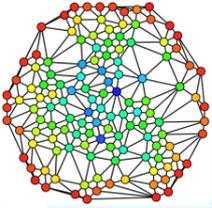
## □ Scenario / Requisiti

- ♣ Dotare l'IA delle abilità linguistiche proprie dell'essere umano
- ♣ Comprensione e generazione del testo
- ♣ Contesto multi-language: differenti regole e strutture a seconda della lingua

## □ Applicazioni

- ♣ Generalizzazione delle query nei motori di ricerca
  - *“Chi si occupa di sistemi distribuiti nell'Università di Firenze ?”*
- ♣ Supporto automatizzato per Help-Desk
- ♣ Tutoring assistito (e-tutoring, e-teaching...)
- ♣ Summarization: creare compendi da una collezione eterogenea di documenti
- ♣ Machine translation: tradurre testi in lingue diverse



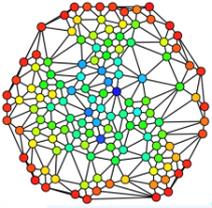


# Ambiguità dei linguaggi naturali (1)

## □ Scenario / Requisiti

- ♣ I linguaggi sono purtroppo ambigui.
- ♣ Le ambiguità si possono avere a 4 livelli:
  - ✓ Ambiguità lessicale: «attacco» (verbo, sostantivo)
  - ✓ Ambiguità strutturale: «Ieri ho visto l'uomo col telescopio»  
«Una vecchia legge la regola»
  - ✓ Ambiguità semantica: «acuto» (persona intelligente, tipo di suono)
  - ✓ Ambiguità pragmatica: «se Buffon non gioca contro la Spagna, l'Italia perderà»
    - L'intensione comunicativa viene recepita diversamente dagli interlocutori:
    - interpretazione emotiva: l'assenza di Buffon è psicologicamente fondamentale per i tifosi
    - Interpretazione referenziale: l'Italia senza Buffon è più debole

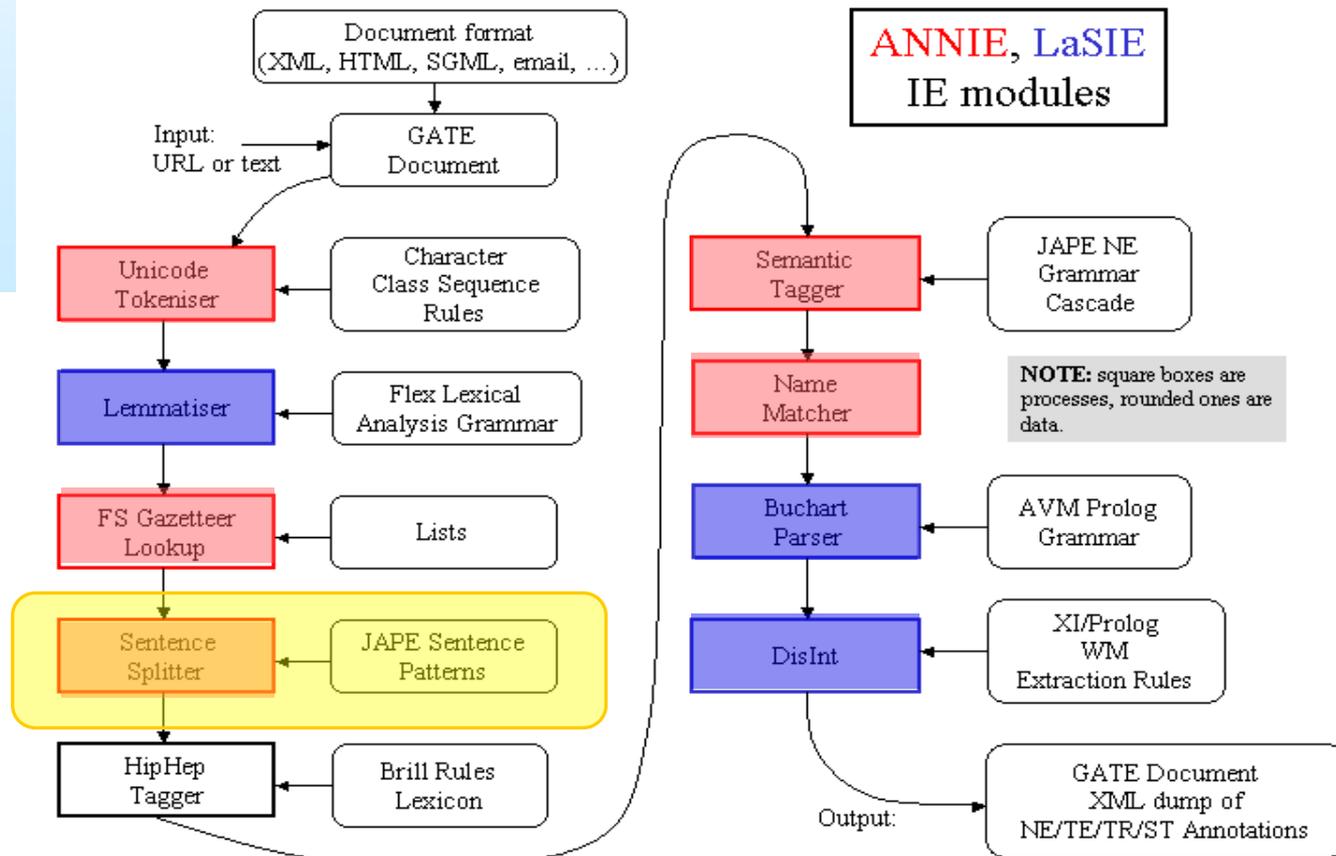
**Ciò rende il processo di elaborazione del linguaggio naturale molto complicato**

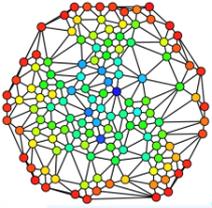


# NLP Tools: GATE (1)

## □ GATE – *General Architecture for Text Engineering*

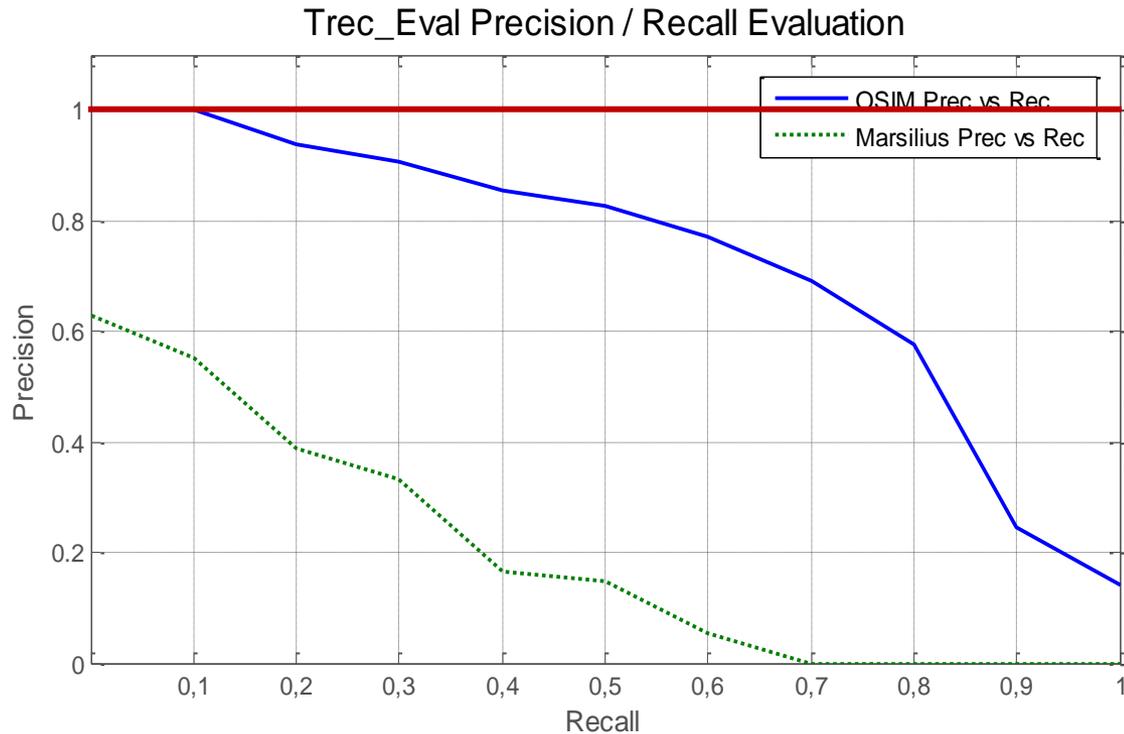
- ♣ Supporta documenti plain text, XML, RTF, HTML, SGML





# Validazione (2)

- Set di query su un sottoinsieme di 4 dipartimenti
- Profondità dei risultati fissata  $N = 20$
- Curva *Precision – Recall* ottenuta con il software standard *Trec\_Eval*



**Ottimo ideale**

# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining* 
- *Data Intelligence*

# Data Mining

- Il processo di data mining consiste nel estrarre significato dai dati.
- Sono strumenti e processi di data mining (molti li abbiamo già visti):
  - Data harvesting and reconciliation
  - Semantic modeling and knowledge modeling
  - Web crawling
  - Blog crawling e vigilance
  - Sentiment analysis
  - Keyword extraction, KP extraction
  - NLP
  - Business intelligence

# Data mining

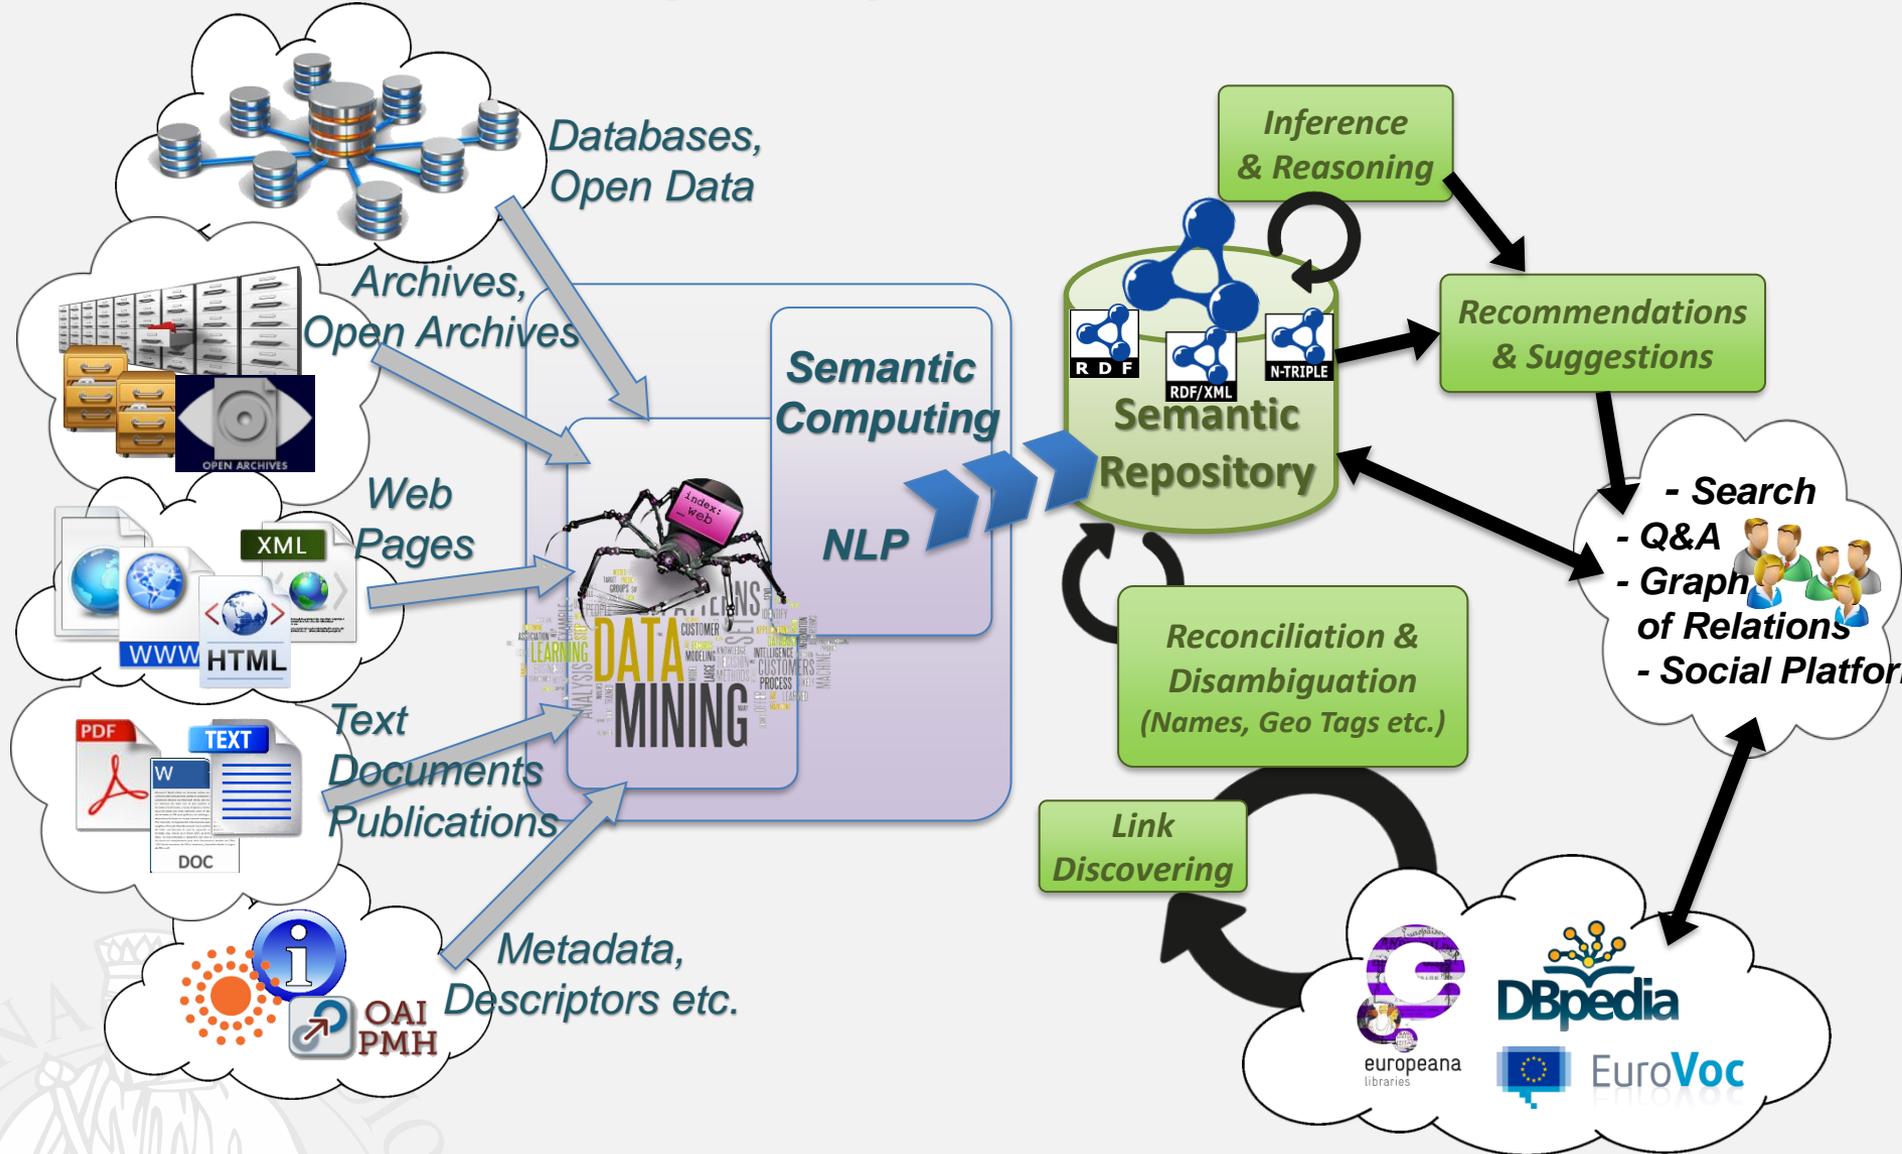
- Data base technology
  - Knowledge modeling
  - Information science
  - Semantic computing
  - Machine learning
  - Pattern matching
  - Visualization
  - Statistics
  - NLP
  - .....
- Data acquisition
  - Data integration and aggregation
  - Data selection
  - Data cleaning/filtering
  - Data transformation
  - Knowledge representation
  - .....

# *Data integration*

- Data warehousing provides the enterprise with a memory
- Data Mining provide the Enterprise with the basis for intelligence



# Knowledge Work-flow: from Sources to Final Users



# Localization via web crawling

- Using the **Ge(o)Lo(cator)** framework:
  - Mining, retrieving and geolocating web-domains associated to companies in Tuscany (thanks to a Distribute Web Crawler based on Apache Nutch + Hadoop)
  - Extraction of geographical information based on a hybrid approach (thanks to Open Source **GATE** Framework + using external gazetteers)
  - Validation in 2 steps: Evaluation of Complete Address Array Extraction, Evaluation of Geographic Coordinate Extraction
- New services found, can be transformed into RDF triples and added to the repository!

# RDF Store Enrichment, for service

## Localization via web crawling

TABLE I. COMPARISON TABLE REPORTING EVALUATION DETAILS FOR EVALUATION TASK 1: ADDRESS ARRAY EXTRACTION, AND TASK 2: GEOGRAPHIC COORDINATES EXTRACTION (EMPLOYING BOTH THE SMART CITY REPOSITORY AND THE GOOGLE GEOCODING API).

Evaluation Tasks	TP	FP	FN	TN	Precision	Recall	F-Measure
1) Address Array Extraction	74.5%	7.8%	5.9%	11.8%	90.5%	92.7%	91.6%
2a) Geographic Coordinates Extraction (Smart City Semantic Repository)	57.8%	4.7%	29.5%	8.0%	92.5%	66.2%	77.1%
2b) Geographic Coordinates Extraction (Google Geocoding)	48.9%	31.1%	11.1%	8.9%	61.1%	81.5%	69.8%

- **Precision** rate for geographic coordinates extraction (employing the Smart City Semantic Repository) has increased, with respect to the value obtained in the evaluation of address array extraction.
- Slightly decreasing **TN** rate for Test (2a) with respect to Test (1): exploiting the extraction of high level features (such as building names) allows the system to obtain correct coordinates even for domains with incomplete Address Array.
- **Recall** rate for Test (2a) significantly decrease with respect to Test (1). This is due mainly to the noise generated by the supplementary logic and the extended semantic queries required to obtain the geographical coordinates.
- Higher **Recall** rate achieved when using the Google Geocoding APIs: Google Repository is by far larger than DISIT Smart City RDF datastore, so that it is able to index a huge amount of resources, even if this can affect the precision rate.

## VIP names identification

- Searching RDF and/or MySQL stores looking for VIP names (citations) into strings:
  - *Via Leonardo Da Vinci*
  - *Piazza Lorenzo il Magnifico*
  - *Palazzo Medici Riccardi*
  - *Etc.*
- The idea is to link those entities with LD/LOD information as dbPedia information and



# *Uso del Data Mining*

- Il Data Mining trova le relazioni di base (Modeling and representation) che in seguito sono utilizzate per algoritmi di:
  - Business intelligence
  - DSS: decision support system
  - Knowledge models and deduction queries
  - ...



# *Data Mining Techniques*

- Matchmaking
  - Matching demand and offer
- Classification and prediction
  - Recommendation, guessing new behaviors, fault prediction
- Cluster analysis:
  - Classification and recommendation
  - Market segmentation, collective intelligence, collective profiling
- Outlier analysis:
  - Fraud detection
- Etc.

# sommario

- *Dati e formati*
- *Comunicazione fra sistemi computerizzati*
- *Modelli di protezione e gestione*
- *Dati vs Metadati*
- *Social network e Smart City*
- *Motori di Ricerca, Crawling e NLP*
- *Data Mining*
- *Data Intelligence* ←

# *I Dati e Metadati*

- **Metadati associati ai dati** li contestualizzano, e.g.:
  - *Autore, data/time, località, user name, numero telefonico, etc.*
  - *Nomi delle persone coinvolte in una chat*
- **I Metadati accessibili per un servizio**
  - Possono permettere il congiungimento di tracce su servizi diversi.
  - Non è detto che siano riconciliabili con quelli di un altro, e.g.:
    - *Email vs numero telefonico, residenza vs user name su skype, etc.*

# *I Dati e vie di comunicazione*

- **Dati e flussi** (real time, streaming e non) in relazione a server o persone singole, come da metadati
  1. **entranti ed uscenti dal paese (dati anche criptati o in chiaro)**
    - In US e altri paesi, questi dati vengono acquisiti, memorizzati ed analizzati per questioni di sicurezza nazionale.
  2. **interni alla nazione (da e vero server nel paese).**
    - Questo accesso e registrazione dati è tipicamente visto come intercettazione, invasione della privacy, ed è giustificata a termini di legge.

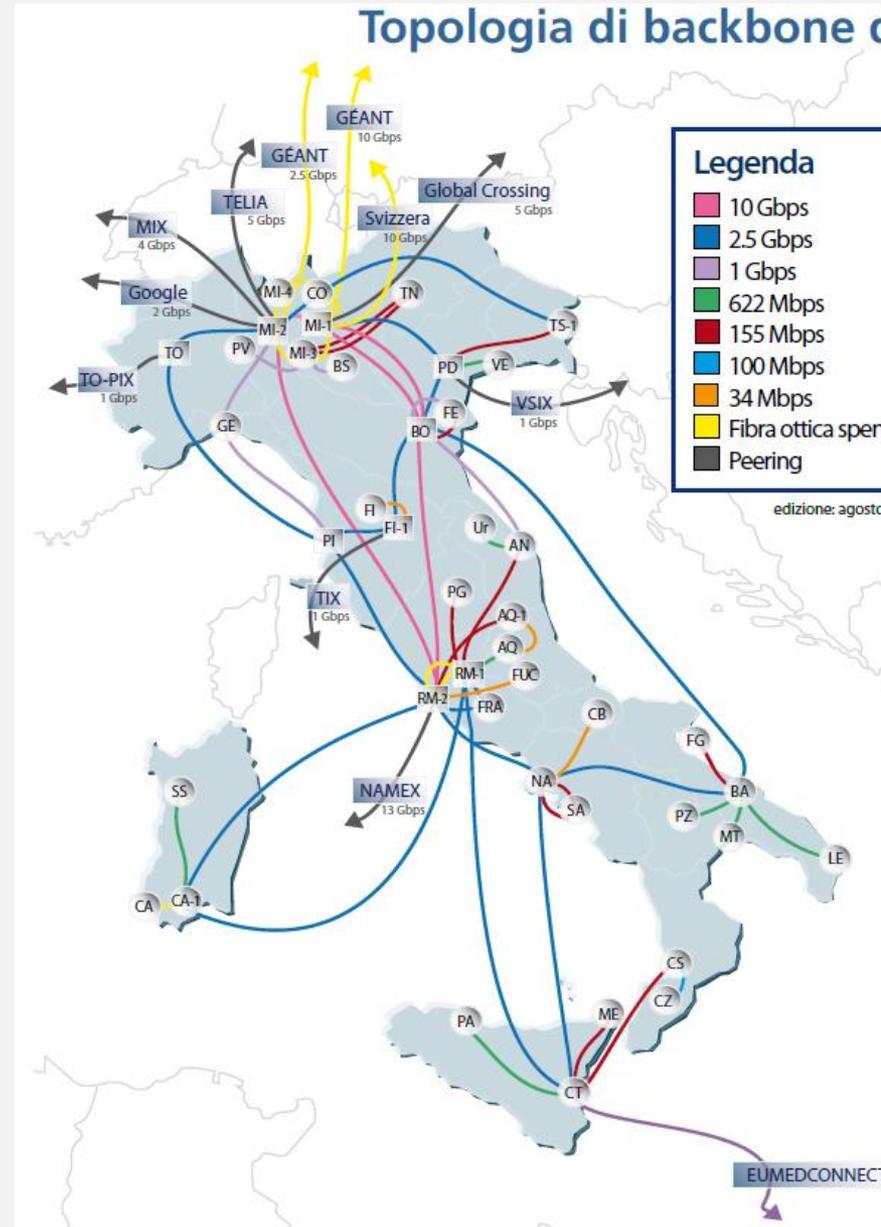
# Accesso Dati e Metadati

- Questi transitano o sono memorizzati in modo stabile o temporaneo su apparati e su server tipicamente
  - posizionati all'estero o nel nostro paese,
    - in cloud tipicamente
  - accessibili solo per:
    - Service provider (nazionali e/o internazionali)
    - gestori di rete a livello nazionale
    - fornitori di servizi

# *stream entranti ed uscenti dal paese*

- **Accesso al flusso dati:**
  - I flussi entranti ed uscenti dal paese possono includere dati del tipo A, B, e C, anche codificati in modo criptato
  - Reti nazionali:
    - Rete pubblica: GARR
    - Rete privata tramite svariati operatori
  - Eventuali connessioni satellitari dirette
- L'accesso agli stream può fornire un dato complessivo più completo ma molto più costoso da ricostruire.
  - *Gli stream sono in tempo reale, e le informazioni di contesto sono complesse da estrarre ed ottenere*
- Per certe tipologie di dato è meno costoso estrarre i metadati ed il contesto dal server che eroga il servizio invece che a livello di stream:
  - *per esempio: è più semplice accedere ad email, chat, docs, etc. tramite il loro server, che dallo stream.*

- pieno supporto ad applicazioni innovative quali griglie, telemedicina, e-learning, multimedia, fisica delle alte energie, radioastronomia, osservazione della Terra, supercalcolo ed offre servizi di rete avanzati quali VPN (Virtual Private Network), Multicast e IPv6.
- integrante del sistema mondiale delle reti della ricerca e collabora con le principali organizzazioni che operano nel campo del networking quali DANTE, TERENA, Internet2, IETF. È interconnessa con le altre reti della ricerca europee e mondiali, tramite collegamenti a 10 Gbit/s con la rete GÉANT, e con il resto dell'Internet commerciale con multipli collegamenti a 2.5 Gbit/s e a 10 Gbit/s.





# Data Mining in breve

- **insieme di tecnologie:** decodifica, integrazione (riconciliazione), comprensione, deduzione....
- **Decodificare il dato:**
  - dal formato trasmissivo (anche se criptato) ad uno comprensibile
- **Estrazione della semantica**
  - da formati a descrizioni semantiche, e.g.:
    - video → *descrizioni delle scene, riconoscimento facce, riconoscimento azioni ed oggetti, ...*
    - audio → *testo, rumori, ...*
    - Blog → *contesto e significato, ...*

# Comprensione del Dato

- **mettere in relazione ed integrare:**
  - i dati vs contesto (persone, data, luogo, etc.), le informazioni di contesto possono essere
    - nel contenuto: *citazioni di nomi, date, etc.*
    - informazioni in possesso del service provider, e pertanto vanno dedotte dal contesto sui server di servizio:
      - *chi ha aperto la connessione, chi ha telefonato, dove era, etc.*
      - *Nicola ha detto a Fra45 che «.....», Nicola e Fra 45 sono Mario Rossi, e Carlo Bianchi*
  - i dati elementari + metadati provenienti da server e stream diversi fra di loro per
    - identificare correlazioni, cause  $\leftrightarrow$  effetti, predizioni, evoluzioni temporali, comportamenti tipici, etc.

## Esempio NSA

- Sembra che vi sia un accordo fra il sistema di intelligence US/NSA e alcuni service provider per accedere a stream / dati + metadati di contesto:
  - Per esempio: *Apple, Google, Facebook, Microsoft, Yahoo, AOL, dropbox, etc.*
  - Questo non significa che NSA ha un accesso diretto ai server
- **I service provider hanno accesso a dati diversi in funzione del loro business**, per esempio casi come per esempio:
  - *ISP provider (AOL): stream voip, contatti, .....*
  - *FaceBook-SN: profili, comportamenti, amicizie, contatti, posizioni gps, preferenze di vario tipo, .....*
  - *MS-game: contatti, date e time presenze/posizioni*
  - *MS-email: contatti, email,....*
  - *Dropbox-filessharing: file, contatti, .....*

# Accedere ai Flussi e Dati

- **I Service Provider che agiscono su:**
  - **Flussi e connessioni** (*carrier, ISP provider, op. telefonia..*):
    - Non è detto che per i loro fini effettuino la registrazione /memorizzazione di tutti i dati del flusso che gestiscono
    - Devono avere apparati e programmi appositi per memorizzare tali dati e rendere possibile la ricerca mirata e contestualizzata.
      - Sono possibili anche registrazioni mirate per contesto, keyword, etc.
      - Invio di dati compressi per ogni ricerca
  - **Servizi e Dati:** SN, email, img, etc. → tipicamente su cloud
    - Tipicamente, memorizzano tali dati perché sono funzionali a fornire il loro servizio e suggerimenti/raccomandazioni
    - Devono avere apparati e programmi appositi per rendere possibile la ricerca mirata e contestualizzata.
      - Invio di dati compressi per ogni ricerca

# *Dati e Cloud*

- **I Cloud dei Service Provider hanno**
  - storage e capacità computazionale estesa
- **Perché farlo nei loro cloud!:**
  - I flussi e i contesti sono complessi
  - Costi elevati di replicazione e dello storage
  - Costi elevati di banda / trasmissione del dato
  - Costi elevati di filtraggio del dato alla sorgente per ridurre la memorizzazione e i costi in generale, ma anche per mirare la ricerca a certe condizioni e casi, ...
  - Aspetti legali relativi al trattamento del dato.
    - I service provider hanno accordi con i loro utenti che gli autorizzano alla memorizzazione dei loro dati personali (per un certo lasso di tempo e per certi fini) ma non hanno il permesso di condividerli, etc.....

# Completezza dei dati dei Service Provider

- **Non è detto** che i dati associati all'erogazione di servizi dei Service Provider (come SN, email, chat, File sharing, etc.)
  - includano i dati di contesto necessari per le operazioni di integrazione e di intelligence, e.g.:
    - Per una SN non è indispensabile memorizzare ore minuti e secondi del momento in cui si è marcato come preferito un contenuto, o che altro.
    - alcune SN tengono conto solo del numero delle azioni e non delle singole azioni
  - siamo memorizzati per un lasso di tempo sufficiente, e.g.:
    - i testi delle chat dopo un certo lasso di tempo vengono cancellati
  - non siano già stati anonimizzati per garantire l'utente finale
- **Non è detto** che i service provider abbiano i dati con lo stesso dettaglio e qualità per tutti i loro utenti, e che siano quelli necessari per gli scopi di intelligence:
  - I fornitori di energia, acqua, gas, etc., non fanno monitoraggio dei consumi di tutti i loro utenti con un campionamento fine
  - I dati delle telecamere per la sicurezza non registrano tutto, etc.

# *Completezza dei dati dei Service Provider*

- **Al fine di garantire la presenza e l'accessibilità di tali informazioni importanti, sono necessari accordi con gli operatori per definire:**
  - cosa è necessario accedere/conservare
  - il formato delle richieste (target) e di cosa deve essere prodotto come risultato verso i servizi di integrazione dell'intelligence



# Integrazione del Dato e Ragionamento

- La **visione di insieme** è **può essere importante e fondamentale per fare delle deduzioni** con integrazione/riconciliazione di dati che provengono
  - da service provider:
    - diversi, e.g., *telefonata e email, registrazione account Apple, etc.*
    - in condizioni diverse: *nazionali ed internazionali*
  - da archivi istituzionali, dati pubblici in rete (web), open data, anagrafe, etc.
- **Questa operazione** in US viene svolta dall'FBI DITU, che
  - Integra e re-invia questi dati a FBI, CIA, etc.

# Target vs Integrazione

- La definizione del Target è importante come l'integrazione del dato
  - Target può includere: lista dei service provider, canali di trasmissione, keyword, contesti, etc.
- Sulla base del Target, i dati ricevuti vanno passati ad una profonda analisi:
  - *aggregazione, comprensione, valutazione di completezza e consistenza*
  - Problematiche relative a:
    - Tecniche di data mining, intelligenza artificiale, interventi umani, Big Data, ....
    - Mole e complessità del dato, costi, tempi di elaborazione, competenze

# *Service provider e Copertura*

- I Service Provider, anche se integrati fra di loro, **non hanno una copertura** al 100% sui dati nazionali anche solo di dati/flussi entranti/uscenti
  - Nazionali
  - Internazionali (posizione geografica dei loro server)
- **Accordi internazionali** di scambio e/o accesso ai dati dei server locali (anche localizzati in altre nazioni) possono permettere di completare un quadro di intelligence.
  - Si veda accordi presunti fra NSA e Service Provider in altre nazioni e/o altre nazioni
  - In Europa si potrebbe ipotizzare la necessità di avere degli accordi bilaterali multipli per definire protocolli di scambio e di accesso a informazioni.

# Considerazioni generali

- Complessità ed incertezze dovute al:
  - processo di acquisizione, integrazione e comprensione dei dati ha dei margini di incertezza
    - mancanza di completezza e coerenza dei dati (certi dati sono sporadici)
    - Incertezze nei processi di data mining, che possono essere ridotte per integrazione, si una qualità e certezza sul dato variabile
  - difficile accessibilità dei dati, specialmente se nazionali
  - costi per la memorizzazione e l'elaborazione
    - dimensioni immense e crescenti dei dati che transitano
    - velocità e deperibilità del dato sui server
  - ....
- I Target sono dei desiderata più che delle *query di ricerca*:
  - Per questo motivo, gli investimenti per aumentare l'affidabilità del processo di intelligence sono molto elevati.
  - Spesso gli investimenti hanno coinvolto direttamente i Service Provider, per farli conformare a direttive sul trattamento dei dati e per predisporre soluzioni di accesso on demand

# *Quadro di Riferimento (CINI)*

- **Evoluzione della minaccia cyber**
  - I professionisti nel crimine come servizio
  - Comportamenti e vittime: pervasività e vulnerabilità
  - Modus operandi e servizi diversificati e personalizzati
- **Dinamiche del Cyberspace e Governance di Internet**
- **Multipolarità e Cyber-war**
  - Canali, cloud, strutture intermedie, ...
- **Politica digitale e sicurezza informatica in Italia**

## ***Le raccomandazioni***

- **Strategia, pianificazione e controllo**
- **Sicurezza come investimento**
- **Cyber Security Center - un'alleanza nazionale tra accademia, pubblico e privato**
- **Razionalizzazione del patrimonio informativo della Pubblica Amministrazione**
- **Formazione**
- **Certificazioni, Best Practices e Framework di Sicurezza Nazionale**



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

**DINFO**  
DIPARTIMENTO DI  
INGEGNERIA  
DELL'INFORMAZIONE

**DISIT**  
DISTRIBUTED SYSTEMS  
AND INTERNET  
TECHNOLOGIES LAB

# *Hacker vs cybersecurity: Quanto è sicuro lo spazio digitale delle nostre informazioni?*

***<http://www.disit.org>***

***Paolo Nesi, [paolo.nesi@unifi.it](mailto:paolo.nesi@unifi.it)***

***Tel: 335-5668674***



# Le nostre informazioni

- Profilo personale vs profilo collettivo
- Dati anonimi vs dati non anonimi
- Diretti: **spostamenti** (assicurazioni, telefoni, ), **azioni...**
- Indirette: video, wifi touch, BT touch, RFID, etc.
- **Comunicazioni:** telefoniche, email, sms, chat, ..
  - Ancora movimenti, ma anche preferenze, ..
- **Transazioni:** bancarie, commerciali, ...
  - Ancora movimenti, ma anche preferenze, ..
- Etc.



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

**DINFO**  
DIPARTIMENTO DI  
INGEGNERIA  
DELL'INFORMAZIONE

**DISIT**  
DISTRIBUTED SYSTEMS  
AND INTERNET  
TECHNOLOGIES LAB

# Traiettorie personali

**Recommender - Real Time City Users - positions and movements** i

DISIT - Distributed Systems and Internet Technologies Lab

**Time Range:** 2016-06-21 15:00:51 - 2016-06-21 18:00:51

**Radius:** 
<
>
0.0008

**Max Opacity:** 
<
>
0.80

**Heatmaps**

Global (811)  All (45)  Citizen (600)

Commuter (43)  Student (33)  Tourist (34)

Disabled (0)  Operator (56)  Unknown (0)

**Time Range:**

5 min  10 min  15 min  30 min  60 min

3 hours  6 hours  9 hours  12 hours

1 day  3 days  1 week  1 month

**Distinct people**  Local Extrema  Movements

**Clustered markers**  Location clustered markers

**To Date**  2016/06/21 18:01:19  static

**Reply Speed:**

Realtime  10 s  30 s  1 min  5 min

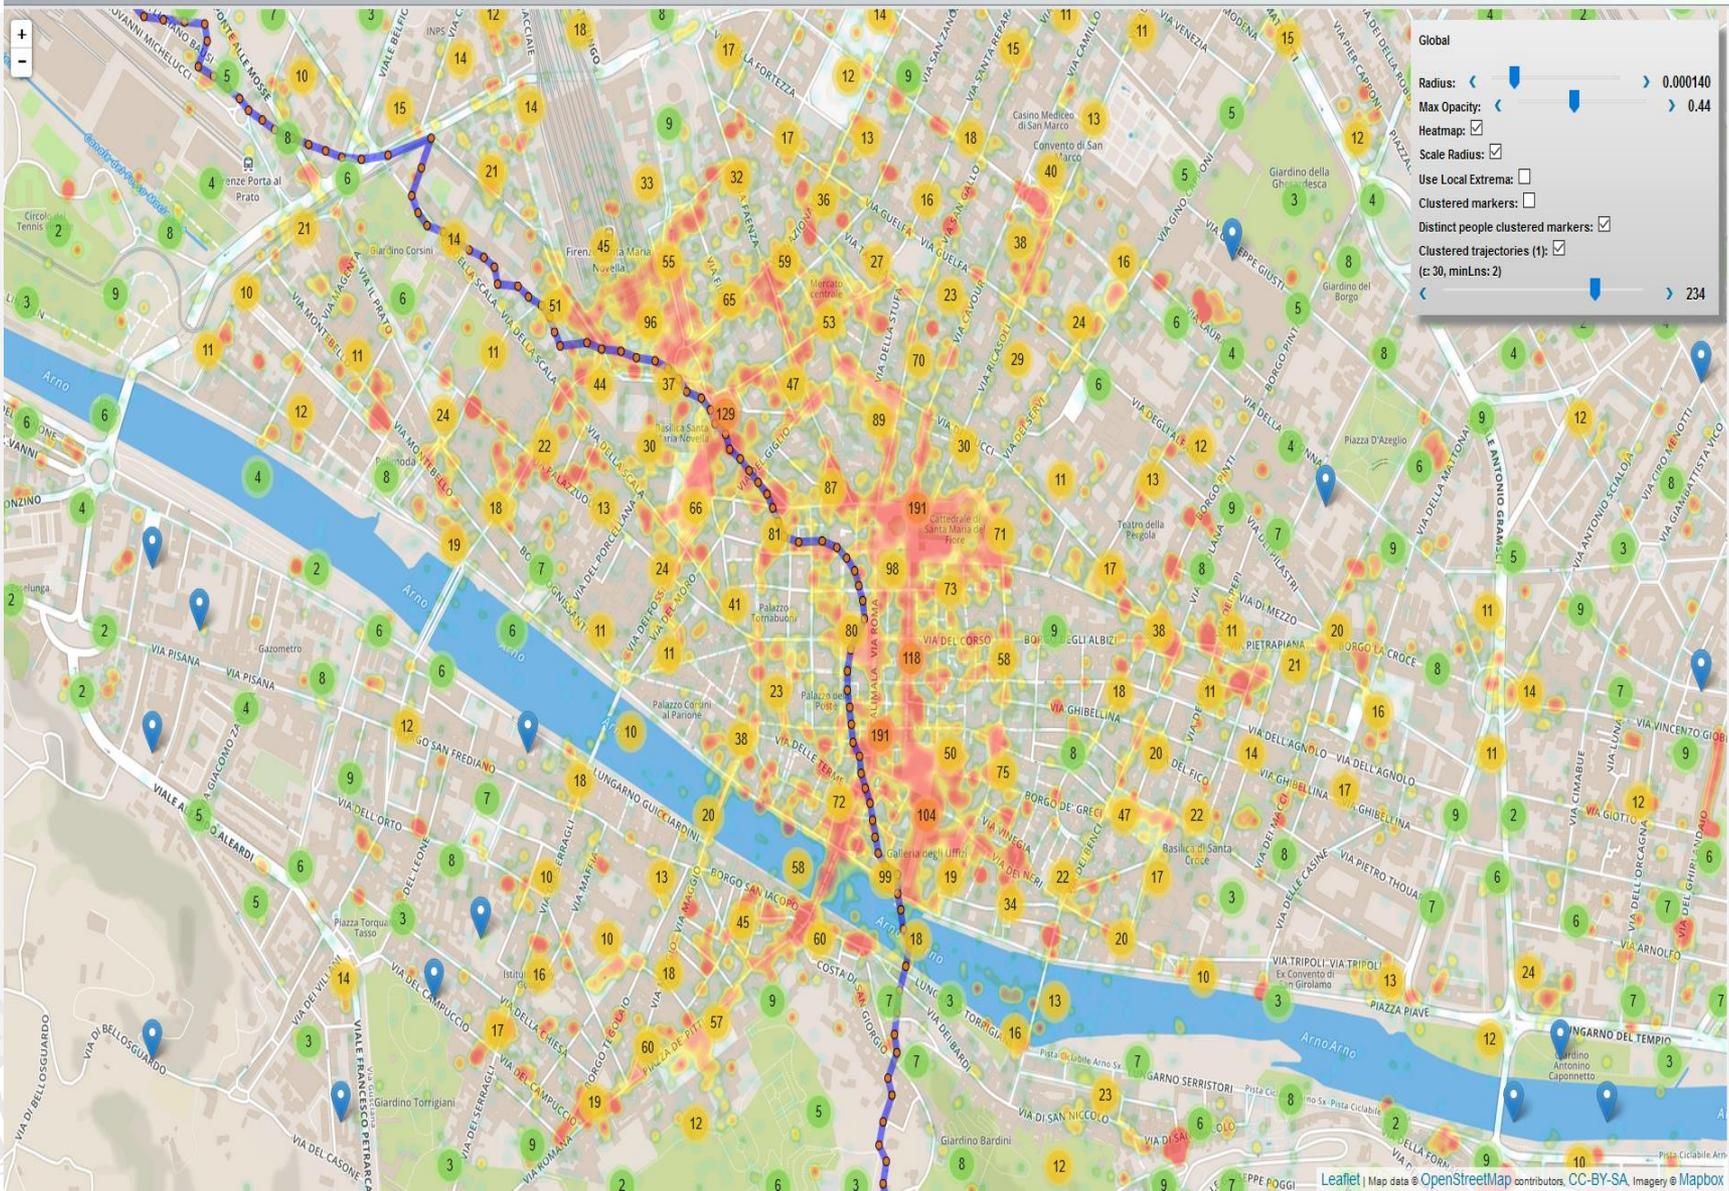
15 min  30 min  1 h  2 h  3 h

# Traiettorie collettive



Recommender - Heatmap and Trajectories Clusters of City Users Together  
DISIT - Distributed Systems and Internet Technologies Lab

Firenze - Sunday January 8 2017 13:57:00





# Promio

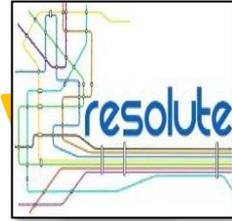
## personale vs collettivo

- Benefici e ritorni (profilo collettivo vs personale)
  - Essere informati
  - Avere dei suggerimenti personalizzati
  - ..
  - Medicina personalizzata
  - ..
- → Termini d'uso
- → GDPR (General Data Protection Regulation)

*Apprendere il  
modello  
collettivo per  
produrre  
suggerimenti,  
aiuto nei  
profili  
personali*

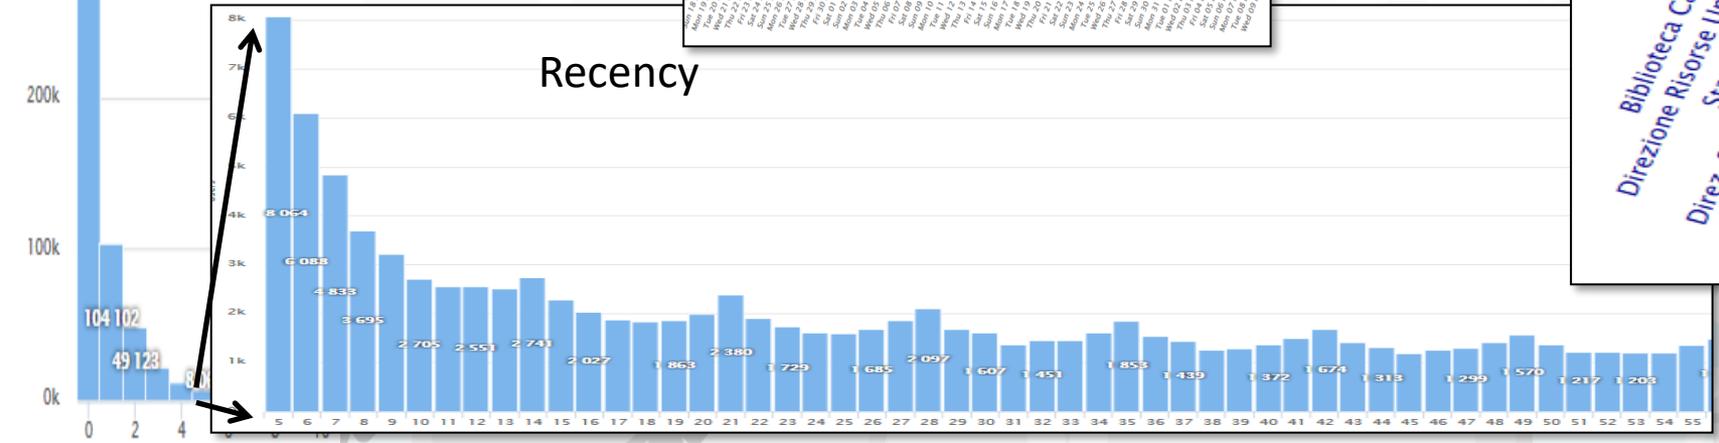
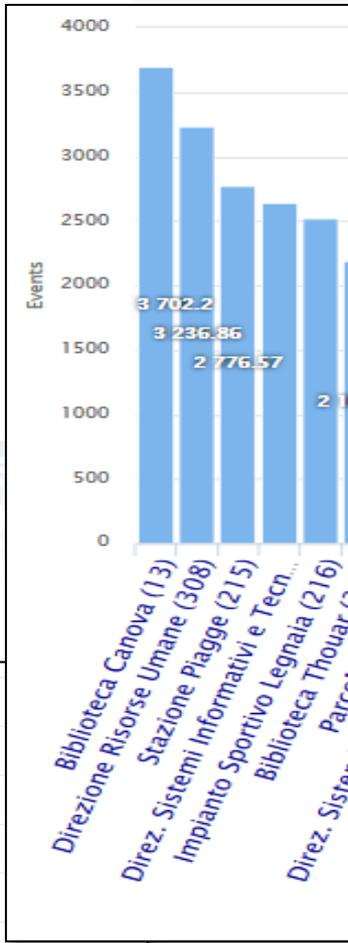
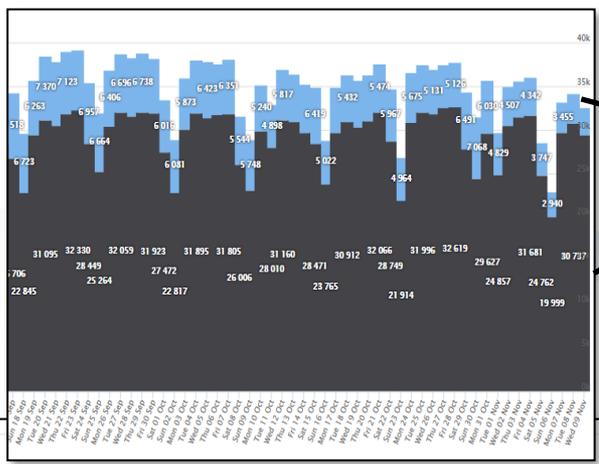
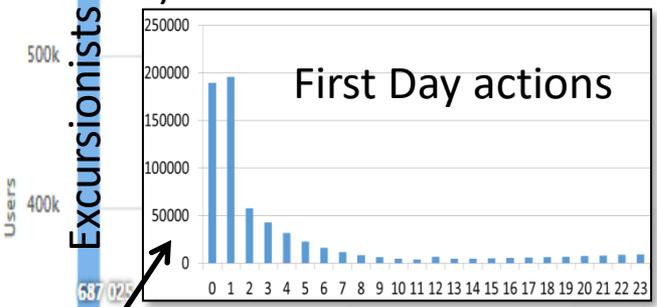


# User Behavior Analysis

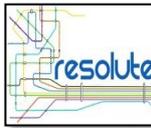


Distinct APs: 343  
 Distinct APs (last 24 hours): 311  
 Distinct Users (last 180 days): 1102098  
 Distinct Excursionists (last 180 days, < 24 h): 687025

Where



# Characterizing City Areas

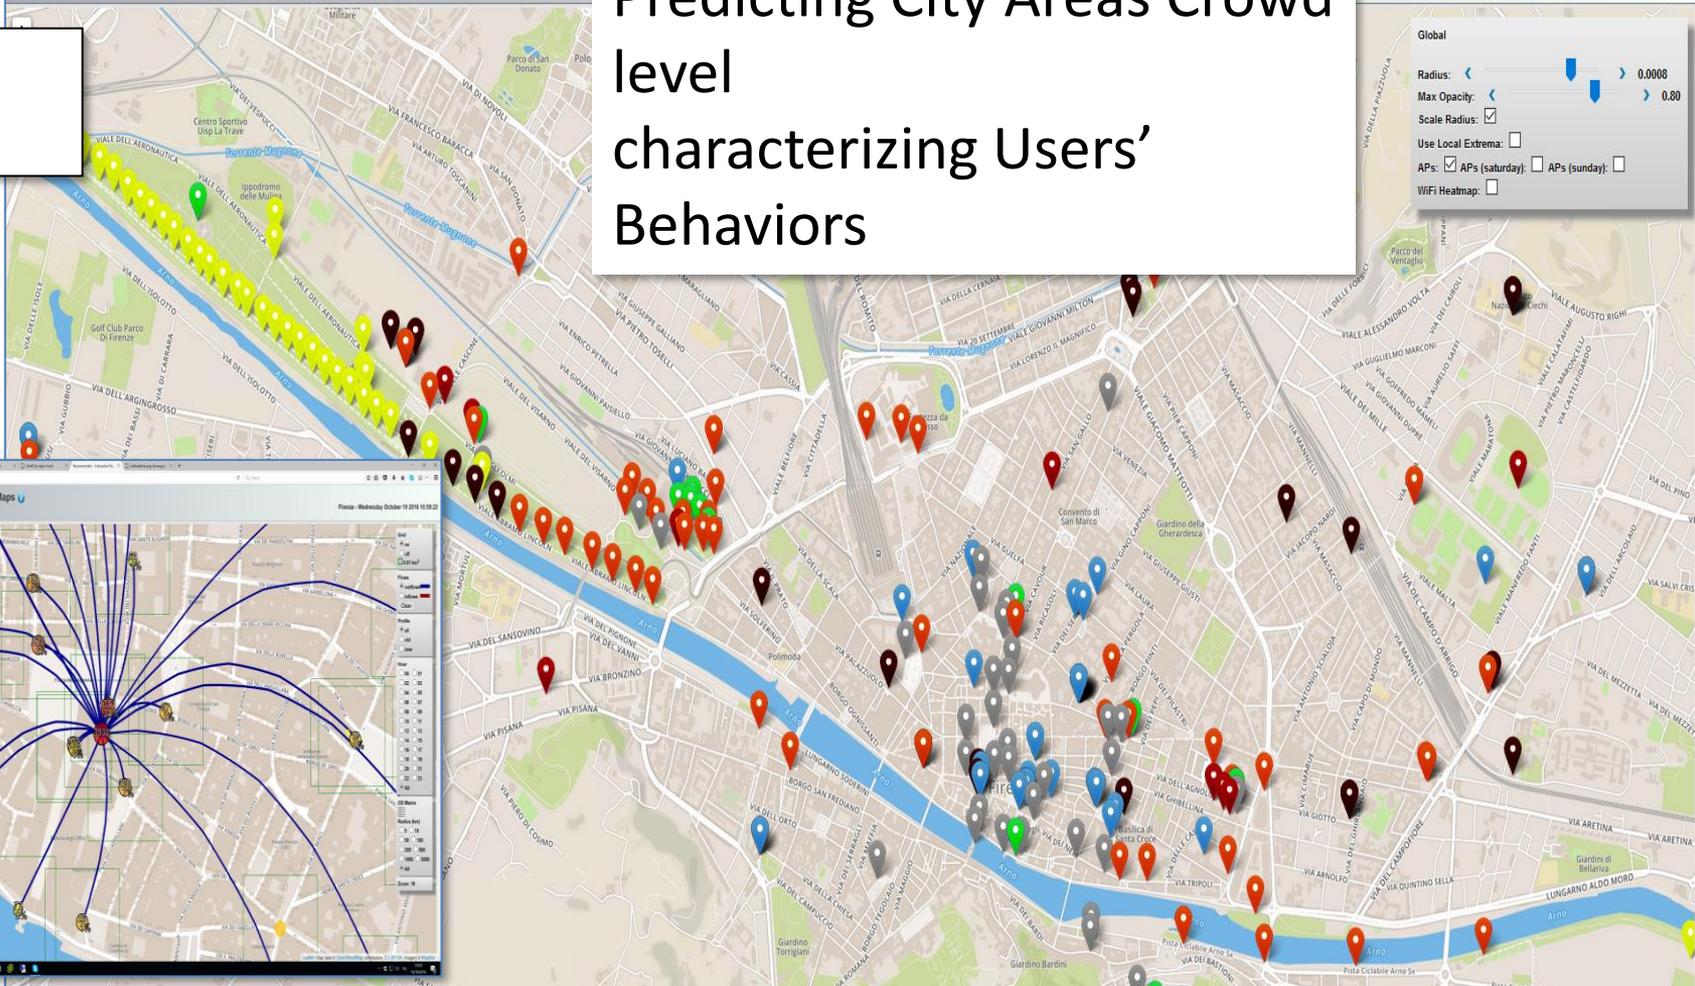


**DISIT** Firenze Wi-Fi: Access Points Clusters Coverage Map  
DISIT - Distributed Systems and Internet Technologies Lab

Wi-Fi  
based

## Predicting City Areas Crowd level characterizing Users' Behaviors

Firenze - Saturday November 12 2016 19:16:33



Global

Radius:

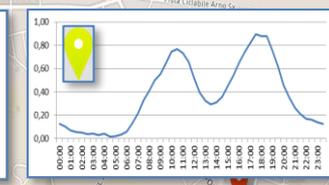
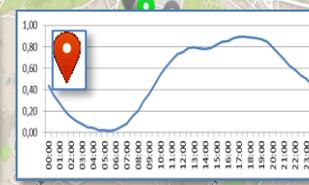
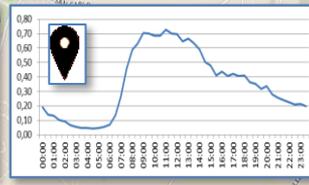
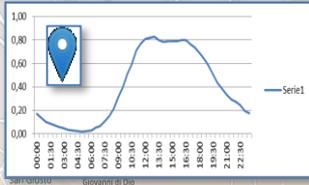
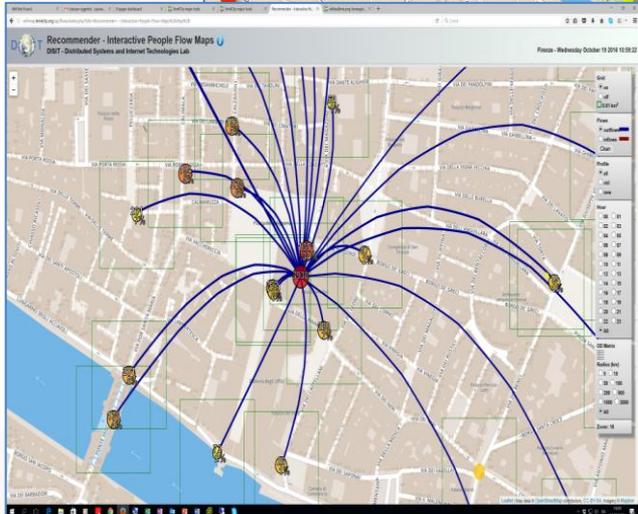
Max Opacity:

Scale Radius:

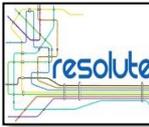
Use Local Extrema:

APs:  APs (saturday)  APs (sunday)

WiFi Heatmap:

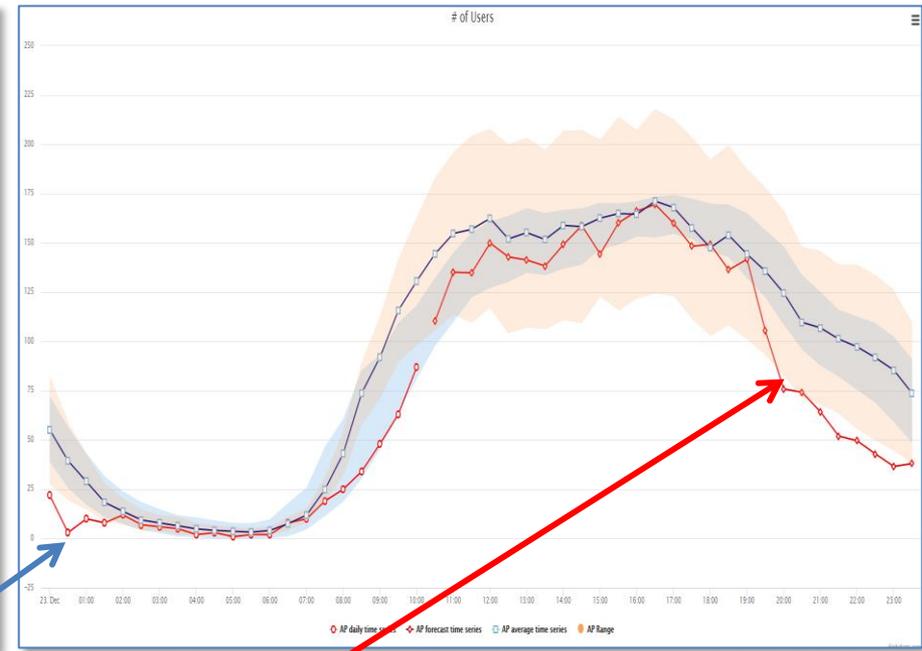
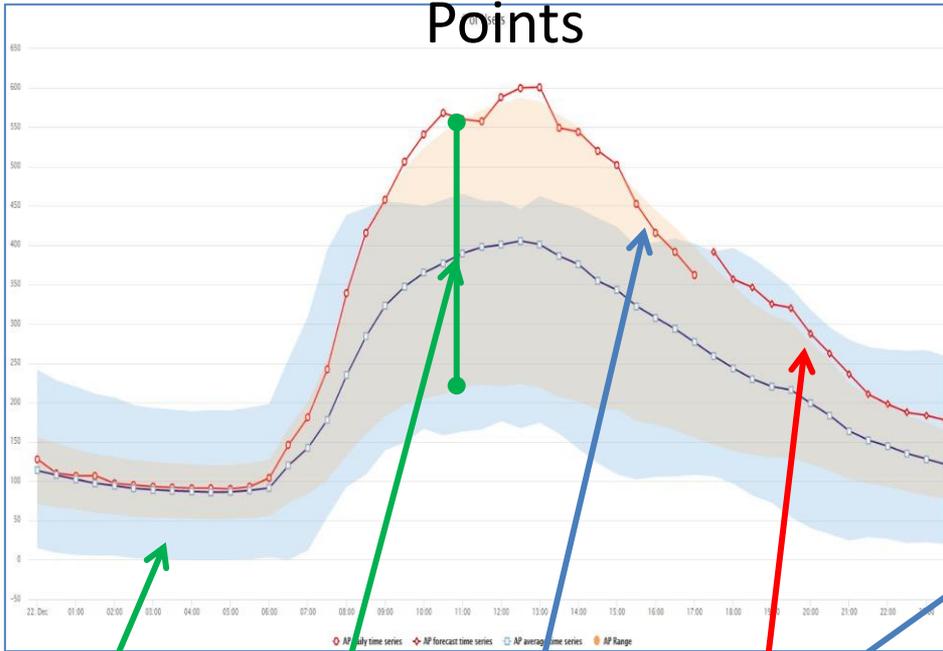


# Prediction and identification of anomalies



## Guessing number of users of Wi-Fi Access

### Points



Cluster confidence

AP average and confidence

Actual AP trend for today

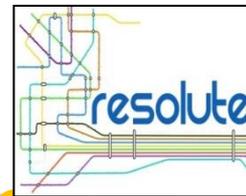
AP prediction for the next time slot in the day on the basis of past



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

**DINFO**  
DIPARTIMENTO DI  
INGEGNERIA  
DELL'INFORMAZIONE

**DISIT**  
DISTRIBUTED SYSTEMS  
AND INTERNET  
TECHNOLOGIES LAB



# Risk Assessment

# Decision Support

## Systems

Event Flood Observation Traffic Observation Damage analysis Layers panel Vulnerability info Service Observation

Aerial with labels Save Analysis Export Configuration

**Service**

NAME: villa maria teresa hospital...

ADDRESS: VIA DELLA CERNAIA, FIRENZE

SERVICE TYPE: [http://www.dist.org/km4city/schema/Public\\_hospital](http://www.dist.org/km4city/schema/Public_hospital)

SERVICE CLASS: <http://www.dist.org/km4city/schema/HealthCare>

SERVICE: <http://www.dist.org/km4city/resource/7/ab1f0c49b843576727ad8766081c2db>

VALUE: 100

WKT DESCRIPTION: POINT (11.2561 43.7868)

**Traffic observations:**

From	Date	km/h	cap/km	cat/h
VIA DELLA MANTONIA	2016-10-10 18:01:08	58	15	2405
LUNGARNO AMERIGO VESPUCCI	2016-10-10 18:01:08	18	65	1842
VIA CARMELO CAVALOR	2016-10-10 18:01:08	81	12	2508
VIA VALFONDA	2016-10-10 18:01:08	27	53	3307
VIA VITTORIO ALFIERI	2016-10-10 18:01:08	23	58	2798
VIA SENESE	2016-10-10 18:01:08	27	54	3216
VIA GUELFA	2016-10-10 18:01:08	98	3	400
VIA DELLA SCALA	2016-10-10 18:01:08	80	13	2157
PIAZZA DI SAN FELICE	2016-10-10 18:01:08	62	10	1897
BORGO SAN FREDIANO	2016-10-10 18:01:08	57	17	2890
VIA VITTORIO ALFIERI	2016-10-10 18:01:08	10	74	195
VIA DEL CAMPUCCIO	2016-10-10 18:01:08	80	13	2157
VIA DEI BENICI	2016-10-10 18:01:08	62	59	2679
PIAZZALE DI PORTA ROMANA	2016-10-10 18:01:08	54	8	1361

**Relevant Services**

Street	Type	Value
WALE MAZZINI GIUSEPPE, FIRENZE	Public_hospital	100
VIA FOSSCOLO UGO, FIRENZE	Public_hospital	100
VIA INCONTRI, FIRENZE	Public_hospital	100
VIA DEI BASSI, FIRENZE	Public_hospital	100

Hello Paolo! Open Information Logout

**Add New Model**

- Model: Open Restaurant
  - Process viale spartaco lavagnini
  - Process via san gallo
  - Process via santa marta 3
  - Add New Process
- Model: Change position of a bus stop
  - Process line 14 in viale morgagni 10
  - Add New Process
- Model: Move a Bus Stop Location
  - Model: TestGP
    - Process istanza Test GP2
  - Model: TestGP\_cloned
    - Process istanza Test GP2\_cloned
  - Model: G (+ C0)
    - Process Move Bus Stop
    - Process Move Bus Stop
  - Model: G (+ C0)\_cloned
    - Process Move Bus Stop
  - Model: Open Restaurant\_cloned
    - Process viale spartaco lavagnini
  - Model: Open Restaurant\_cloned

**Decision Tree:**

- Open Restaurant viale spartaco lavagnini
  - Other restaurant near
    - Restaurant within 500m
    - Restaurant from 500m to 1km
  - Parking
    - Parking dimension
      - Free
      - Paid
    - Parking type
      - Day
      - Night
  - Persons flow
    - Traffic flow
      - Cinema
      - Theatre
    - Leisure activity

Name Model: Open Restaurant  
Name Process: viale spartaco lavagnini  
Date creation: 15-06-2016 15:58:23

**Assessing Risk**

- hydraulic
- Seismic

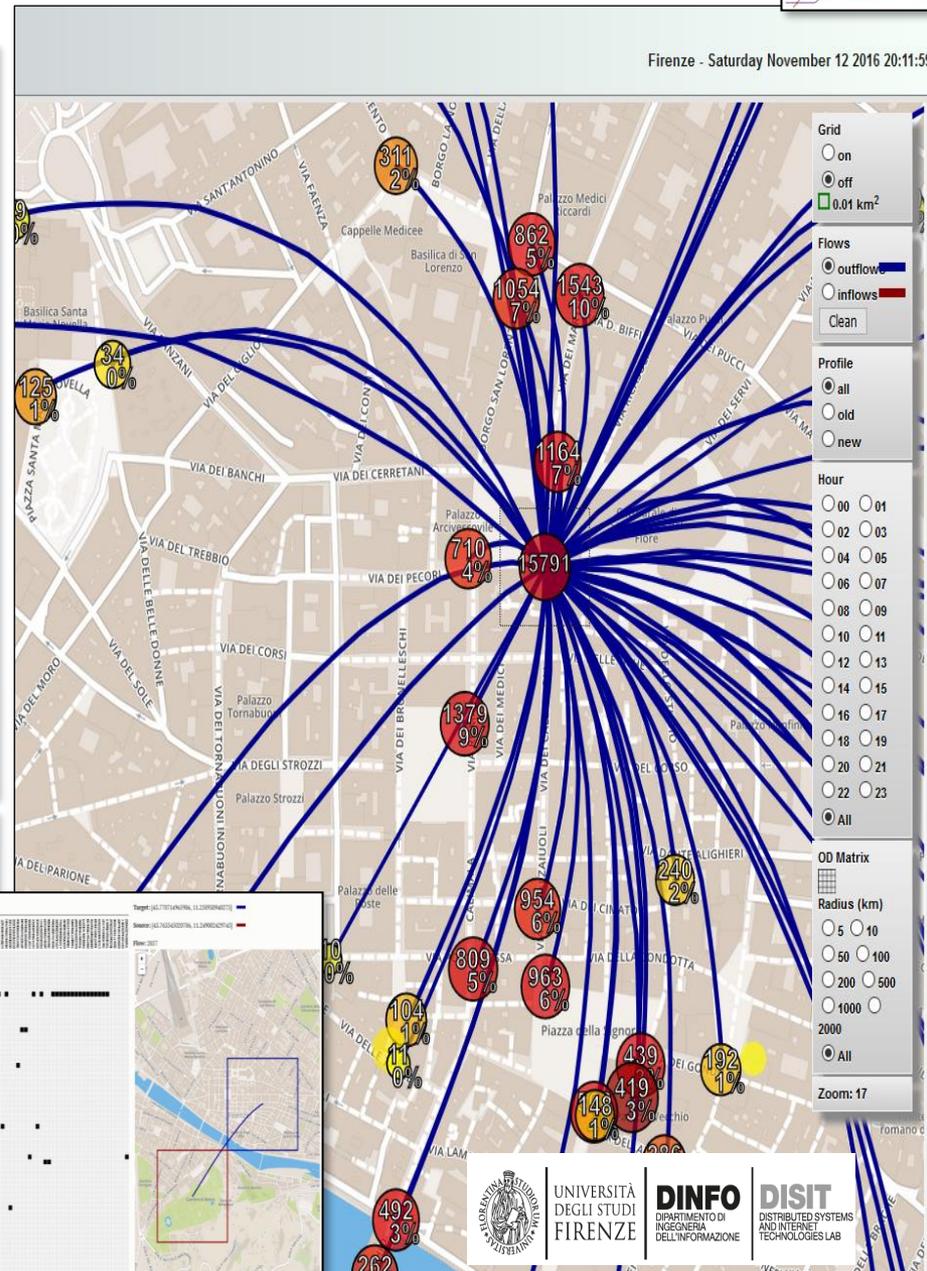
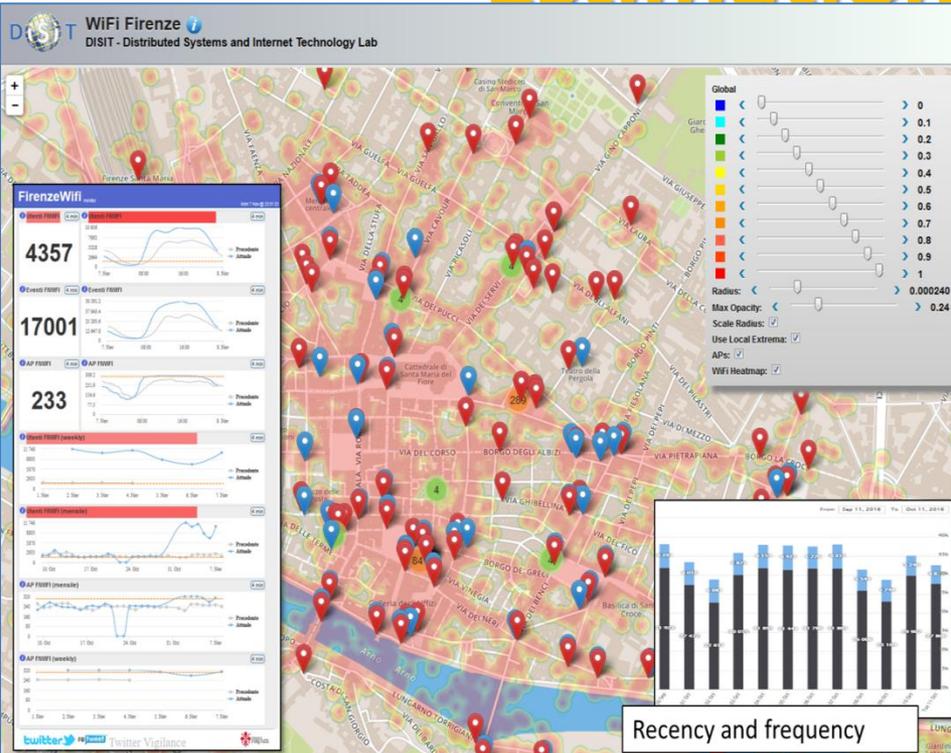
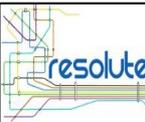
**Data and Service Aggregator**

**Creating and activating**

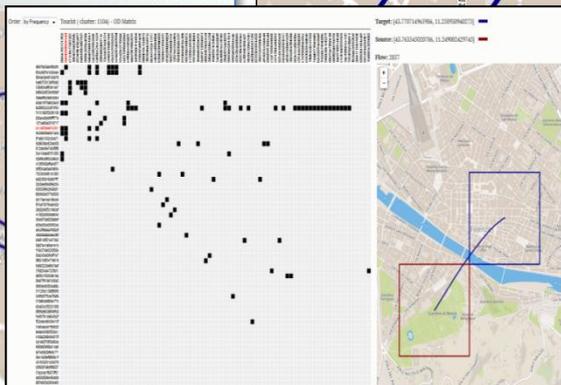
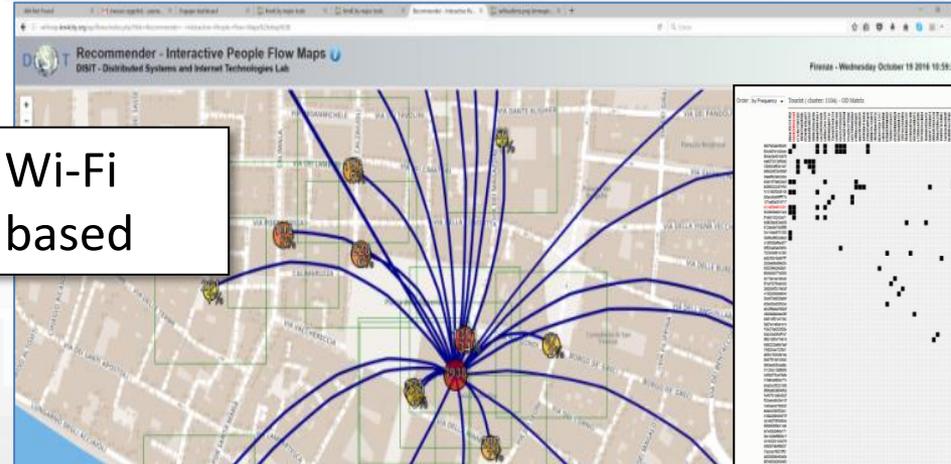
- Decision Support models



# Origin Destination Matrix Estimation

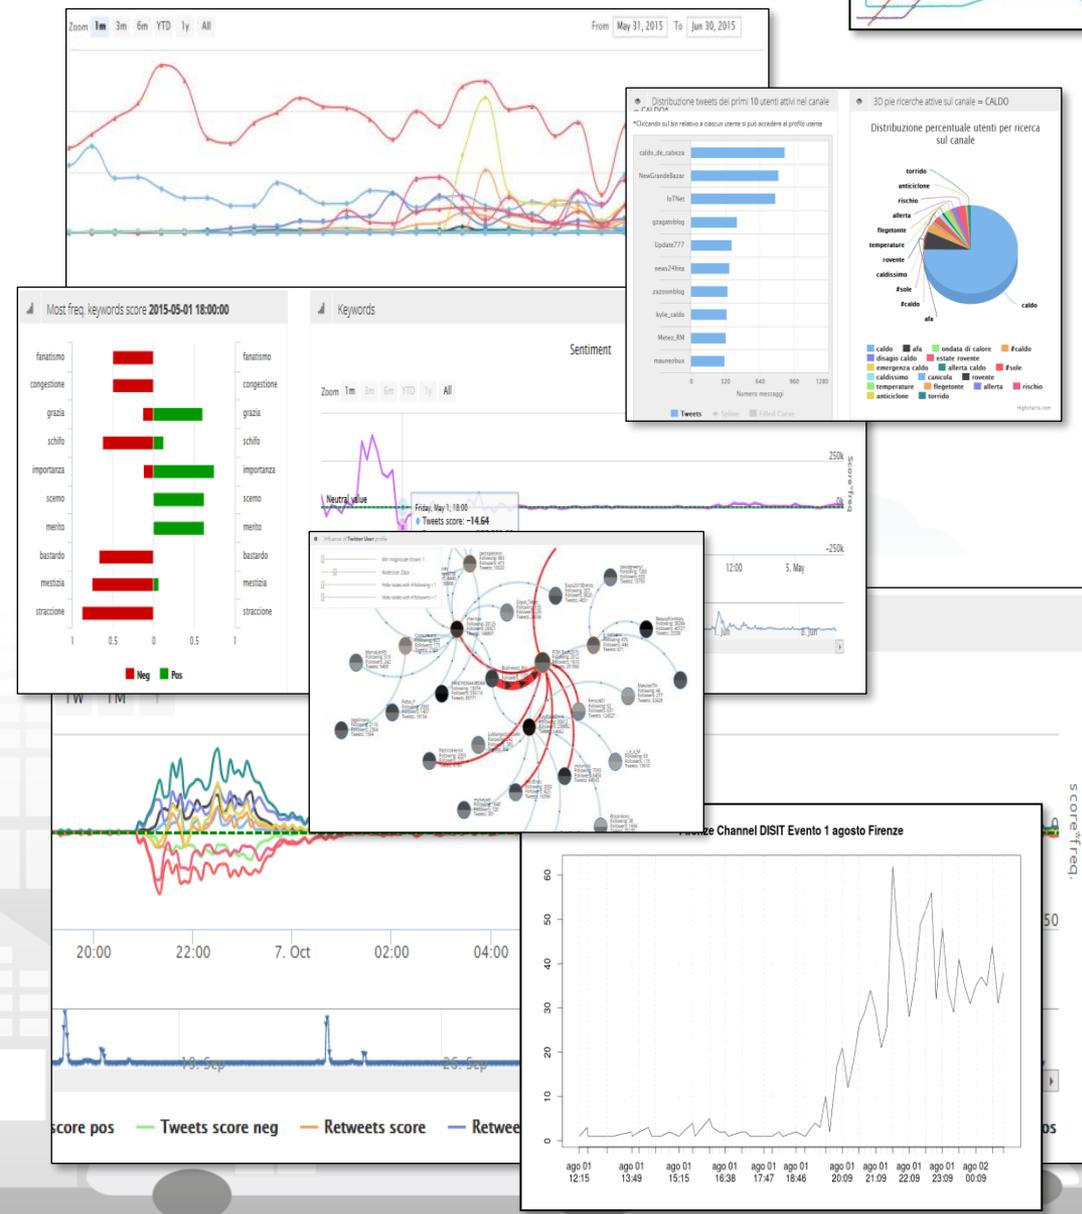


Wi-Fi based



- **Transazioni:** bancarie, commerciali, ...
  - Ancora movimenti, ancora in rete, ma anche preferenze, ..
  - semplici da comprendere
    - Propensione all'acquisto, capacità di spesa, etc.
    - Analisi dei comportamenti anomali.
- **Comunicazioni:** telefoniche, social media, email, sms, chat, ..
  - movimenti, preferenze, azioni, ..
  - Analisi del testo in linguaggio naturale
  - ..
  - Etc.

- <http://www.disit.org/tv>
- <http://www.disit.org/rttv>
- Citizens as sensors to
  - Assess sentiment on services, events, ...
  - Response of consumers wrt...
  - Early detection of critical conditions
  - Information channel
  - Opinion leaders
  - Communities
  - Formation
  - Predicting volume of visitors for tuning the services





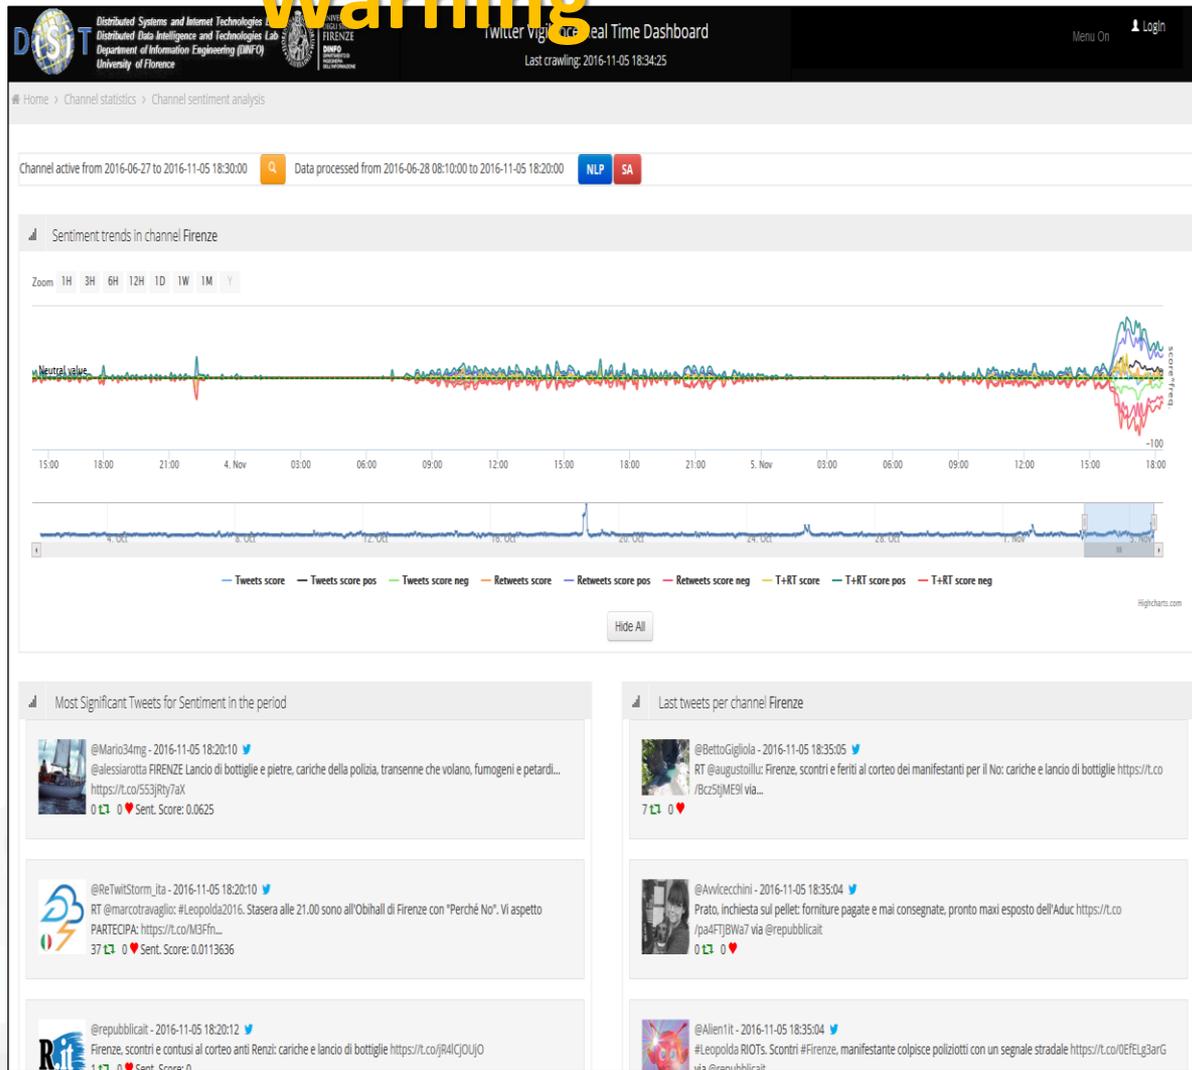
UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

**DINFO**  
DIPARTIMENTO DI  
INGEGNERIA  
DELL'INFORMAZIONE

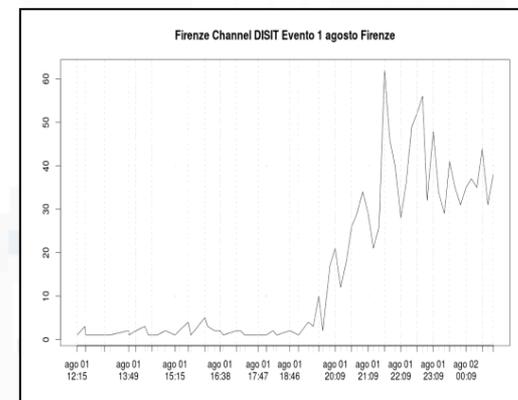
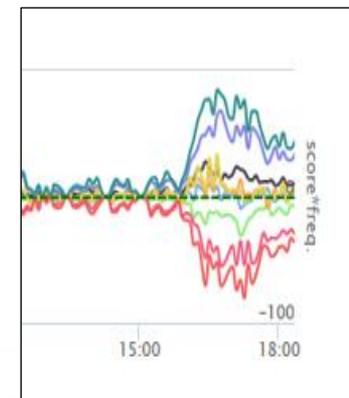
**DISIT**  
DISTRIBUTED SYSTEMS  
AND INTERNET  
TECHNOLOGIES LAB  
<http://www.disit.org>

# Twitter Vigilance

## Real Time Twitter Vigilance, Early Warning



## Sentiment Analysis



# Gli attacchi ai dati personali

- **Keylogger**: processo che registra cosa digitate
- **Fake AP**: un AP finto che registra il vostro accesso
- **Phishing**: Fake WEB page di banca
- **Sniffing**: su vari media (rame, fibra, etc..)– Man in the middle
- **Hijacking**: acquisizione della vostra identità nel digitale
- **Molti di questi attacchi** arrivano via: email, USB, pagine WEB, Applicazioni, giochi, ..



- **La sicurezza dovrebbe garantirla il provider, fornitore del servizio**
  - Protocolli: HTTPS, LDAP (SSO),
  - Certo non è cosa facile lo dimostrano i furti di password effettuati con successo a carico di grossi providers
- **GDPR (General Data Protection Regulation)**
  - Diritto di sapere quali tipi di dati personali sono memorizzati
  - Diritto di concedere i propri dati o meno per tipo di dato
  - Diritto di vedere cancellati i propri dati (vs security nazionale)
  - ...





- **Soluzioni di rete:** *Firewall*, antivirus, anti *rootkit*, etc.
- Soluzioni corporate per monitoraggio e il *Data Analytic* per identificare
  - pattern/firme di aggressori, se note, ...
  - comportamenti anomali:
    - acquisti fatti in luoghi distanti, movimenti bruschi, errori nella password, movimenti strani sui conti, acquisti non usuali, volume acquisiti, ..
    - perdite di potenza sui cavi in rame o fibra
    - ...

# Data Intelligence

Corso di perfezionamento post laurea  
«Intelligence e sicurezza nazionale»

*Prof. Paolo Nesi*  
DISIT Lab

**Distributed Data Intelligence and Technologies Lab**  
**Distributed Systems and Internet Technologies Lab**

Dipartimento di Ingegneria dell'Informazione  
Università degli Studi di Firenze  
Via S. Marta 3, 50139, Firenze, Italia  
tel: +39-055-2758515, fax: +39-055-2758570  
<http://www.disit.dinfo.unifi.it>  
[paolo.nesi@unifi.it](mailto:paolo.nesi@unifi.it)

