



InformaticaUmanistica

Biblioteche Digitali

Obiettivi del corso

Il corso ha lo scopo di fornire le **basi teoriche e sperimentali** relative alle tecniche ed alle metodologie per la **organizzazione, creazione e gestione** di una Biblioteca Digitale.

- Panoramica generale del settore delle Biblioteche Digitali, con una visione approfondita di alcuni degli aspetti più rilevanti
- Analisi delle aree di ricerca più promettenti nel settore
 - Analisi dei diversi utilizzi applicativi delle Biblioteche Digitali, evidenziando in particolare le applicazioni al settore dei Beni Culturali
 - Utilizzo sperimentale delle Biblioteche Digitali, evidenziando le problematiche relative alla loro creazione e gestione.

Pasquale Savino

ISTI - CNR



UNIVERSITÀ DI PISA

Programma del corso

- ◆ Introduzione alle Biblioteche Digitali
- ◆ Metadati
- ◆ Esempi di Biblioteche Digitali (con esercitazioni)
- ◆ Architettura e tecnologie di base delle Biblioteche Digitali
- ◆ Progettazione di una Biblioteca Digitale (con esercitazioni)
- ◆ Nuove tendenze

Materiale didattico

- ◆ Lucidi, disponibili sul sito Web del corso
- ◆ Ian Witten, David Bainbridge, "How to Build a Digital Library", Morgan Kaufmann Publishers
- ◆ Michael Lesk, "Practical Digital Libraries", Morgan Kaufmann Publishers
- ◆ William Y. Arms, "Digital Libraries", The MIT Press

Lezioni e ricevimento

◆ Lezioni

- Giovedì – 10:15 – 12:00
- Venerdì – 12:15 – 13:00

◆ Ricevimento

- Venerdì – 15:30 – 17:00 previo appuntamento, presso ISTI-CNR, Via Moruzzi, 1 (Area della Ricerca – San Cataldo)



InformaticaUmanistica

Introduzione alle Biblioteche Digitali



UNIVERSITÀ DI PISA

Sommario [1/2]

◆ Cenni storici

- Vannevar Bush
- Dalle Biblioteche ai Cataloghi Automatizzati
- Gli OPAC accessibili via Web
- Le Biblioteche Digitali

◆ Cos'è una Biblioteca Digitale

- Definizione
- Confronto tra BD e database, sistemi IR, WWW, biblioteca tradizionale
- Vantaggi delle BD
- Alcuni esempi di Biblioteche Digitali

Sommario [2/2]

◆ Cosa ha permesso la nascita delle Biblioteche Digitali

- Evoluzioni tecnologiche
- ### ◆ Tipologie di Biblioteche Digitali
- Biblioteche Pubbliche e Biblioteche Specializzate
 - Tipi di documenti trattati
 - Libri
 - Documenti testuali
 - Immagini
 - Audio/video
 -

Vannevar Bush (1890-1974)

- ◆ Direttore dell'US Office of Scientific Research and Development
- ◆ Ha predetto diverse evoluzioni tecnologiche
 - L'idea del "MEMEX" (1945) conteneva molte delle idee sulle quali si basano il Web e le Biblioteche Digitali
 - Il MEMEX aveva lo scopo di fornire ai ricercatori la possibilità di scambiarsi facilmente informazioni e di avere accesso alla totalità delle conoscenze disponibili

Cenni storici

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	9
----------------------------	----------------------	---

Memex

- ◆ Integrazione di computer, tastiera e scrivania
- ◆ “archivio meccanizzato privato e biblioteca”
 - Eliminazione degli aspetti che rendevano ripetitivo e inefficiente il retrieval di informazione
 - Implementazione basata sull'uso di microfilm
- ◆ Indicizzazione associativa
 - “il processo di legare due elementi insieme è l'aspetto più importante”
 - Preludio agli ipertesti...
- ◆ L'articolo di Bush non prevedeva l'uso di sistemi di ricerca free-text
 - knowledge trails only; Yahoo minus keyword searching

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	10
----------------------------	----------------------	----

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	11
----------------------------	----------------------	----

Dalle Biblioteche tradizionali alle Biblioteche Digitali

- ◆ **Biblioteche tradizionali**
 - Inizialmente erano luoghi dedicati alla conservazione dei documenti
 - Con l'aumento della quantità di documenti immagazzinati, si è reso necessario creare degli strumenti di ricerca efficaci
 - L'avvento dei calcolatori ha permesso di automatizzare e rendere più efficienti ed efficaci gli strumenti di ricerca
 - ◆ **Biblioteche digitali**
 - I documenti stessi sono in forma digitale
 - ➔ Ricerca basata sul contenuto
 - ➔ Conservazione degli oggetti digitali
 - ➔ Protezione da accessi indesiderati, ecc.
- ◆ La biblioteca svolge il ruolo di “mediatore” tra gli oggetti “portatori di informazione” (documenti) e gli “utilizzatori dell’informazione”
-
- ```
graph TD; A[documenti] --> B[Biblioteca]; B --> C[utenti]
```

## Le Biblioteche tradizionali

- ◆ DOCUMENTO: Qualsiasi oggetto utilizzabile a fini di consultazione, ricerca, informazione
  - ◆ DOCUMENTO: Qualsiasi oggetto utilizzabile a fini di consultazione, ricerca, informazione

|                            |                      |    |
|----------------------------|----------------------|----|
| Pasquale Savino – ISTI-CNR | Biblioteche Digitali | 13 |
| Pasquale Savino – ISTI-CNR | Biblioteche Digitali | 14 |

## Funzioni delle biblioteche

- ◆ SELEZIONE
  - ◆ ACQUISIZIONE
  - ◆ DESCRIZIONE
  - ◆ ACCESSO ===>
    - Strumenti per la ricerca dei documenti o delle informazioni sui documenti
  - ◆ CONSERVAZIONE
- ◆ ANTICAMENTE: Ordinamento fisico dei documenti
- ◆ NELL'EPOCA MODERNA: Ordinamento delle descrizioni dei documenti
- =====> I CATALOGHI

## Strumenti per la ricerca

## Strumenti per la ricerca

- ◆ Ordinamento fisico
- ◆ I documenti sono collocati secondo un certo criterio:
  - ➔ Data di "arrivo" (liste inventariali)
  - ➔ Soggetto (classificazione)
  - ➔ Tipo di documento

...e possono essere ricercati soltanto in base a quel criterio

### ◆ Il catalogo:

- Ciascun documento è descritto con un insieme di elementi significativi, scelti secondo le regole della descrizione bibliografica (Titolo, autori, ... soggetto, ... collocazione); la descrizione è riportata su una o più schede
  - Ciascuna scheda è intestata con uno degli elementi bibliografici ritenuti utili a ricercare il documento ==> Punti di accesso
  - Le schede intestate sono ordinate nel catalogo secondo i punti di accesso

- ◆ Il catalogo permette la ricerca di un documento conoscendo uno qualsiasi dei suoi punti di accesso

- ◆ Il catalogo permette la ricerca di un documento conoscendo uno qualsiasi dei suoi punti di accesso

## La varietà delle -teche

[depositi==>collezioni, raccolte]


- ◆ Biblioteche
  - ◆ Emeroteche
  - ◆ Cineteche
  - ◆ Discoteche
  - ◆ .....==> Mediateche
  - ◆ Archivi
  - ◆ Musei
- ◆ Ciascuna tipologia di documenti ha proprie regole di descrizione
- .....ma rimangono valide le regole di organizzazione dei cataloghi

## I cataloghi “automatizzati”

## I cataloghi “automatizzati”

- Indici : liste ordinate di elementi particolari della descrizione bibliografica, utili a identificare il documento di interesse : Autori - titoli - soggetti - collane -


◆ L'uso dei calcolatori ha reso le prestazioni dei cataloghi più potenti e più flessibili



## I cataloghi “automatizzati”

- ◆ Nei cataloghi a schede si può ricercare un documento solo attraverso uno dei suoi punti di accesso

I cataloghi di ultima generazione costruiscono “indici degli indici”



## I cataloghi “automatizzati”

Ricerche con dati non certi:

AUT = Rossi AND TIT = Servizi

TIT = bibliogr#

PAROLA = biblio# AND DATA > 1999

### ◆ INTERFACCIA UTENTE-SISTEMA:


- ◆ Il modo in cui il sistema informativo si presenta all'utente per istruirlo e guidarlo a svolgere le operazioni

## Il catalogo delle biblioteche automatizzate

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

25



### Il catalogo del Servizio Bibliografico Nazionale: [WWW.sbn.it](http://www.sbn.it)

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

26

## Cos'è una Biblioteca Digitale

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

28

## Definizione informale

Una Biblioteca Digitale è una collezione organizzata di oggetti digitali accessibili in rete, ed un insieme di servizi che ne permettono la conservazione, l'accesso e la ricerca, oltre che l'organizzazione e la manutenzione della collezione. La collezione può contenere dati di tipo diverso, quali ad esempio testi, immagini, audio, video, ecc.

## Cos'è una BIBLIOTECA DIGITALE ? OGGETTI DIGITALI

### Dalle descrizioni dei documenti

==> ai DOCUMENTI

Dai cataloghi ==> ai “DEPOSITI” distribuiti sulla rete contenenti:

- Oggetti digitali (testi, suoni, immagini tridimensionali, video, fotografie, film, ...)
- Metadati (descrizioni degli oggetti)


## Gli oggetti digitali

- ◆ Una Biblioteca Digitale permette di archiviare “documenti” contenenti vari tipi di dati .....
- Testo
- Immagini
- Video
- Audio
- 3D objects
- Virtual-reality worlds
- .....
- Composizione dei tipi di dati precedenti

## I principali servizi di una Biblioteca Digitale

- ◆ Accesso e recupero
  - Cataloghi
  - Riferimenti
  - Indici
- ◆ Conservazione
- ◆ Gestione
  - Controllo dell'accesso
  - Condivisione dei dati
  - Gestione della collaborazione tra gli utenti
    - E.g. collaborative filtering, catalogazione, ....
    - .....
- ◆ Una Biblioteca Digitale dovrà fornire almeno tutti i servizi offerti da una Biblioteca tradizionale

## Che cos'è una Biblioteca Digitale? Un sistema distribuito per la gestione di risorse digitali accessibili dalla rete Internet



Pasquale Savino - ISTI-CNR

Biblioteche Digitali

33

## In cosa differisce una Biblioteca Digitale da un DataBase

- ◆ Un database tradizionale SQL ha la relazione come contenitore base dell'informazione:

```
select name
 from employee, project
 where employee.deptnumber = "25" AND
 project.number = "100"
```
- ◆ I database sfruttano strutture e relazioni note
- ◆ Il retrieval dei DBMS non è probabilistico

34

## In cosa differisce una BD da un sistema di IR tradizionale?

- ◆ La differenza è meno netta che per i DBMS
- ◆ I sistemi IR systems possono essere considerati precursori delle BD
- ◆ I sistemi di IR si sono occupati tradizionalmente di documenti testuali ma loro evoluzioni trattano anche documenti multimediali
  - Match esatto - Boolean, text pattern searching
  - Match non esatto - probabilistic, vector space, clustering
- ◆ Le BD possono essere considerate un superset dei sistemi IR

Pasquale Savino - ISTI-CNR

Biblioteche Digitali

34

## In cosa differisce una BD dal WWW?

- ◆ La differenza principale è legata all'organizzazione dei documenti
  - Il WWW non impone alcuna organizzazione dell'informazione, mentre nelle BD tutte le operazioni sono soggette a procedure ben definite.
  - In particolare, nelle BD sono definiti precisi schemi di metadati che permettono l'accesso ai documenti
- ◆ Alcuni motori di ricerca del web (Yahoo, Lycos) tentano di aggiungere una qualche organizzazione ai documenti trattati
  - Comunque, non tutti i documenti del web sono gestiti
  - La maggior parte dei motori di ricerca si basa su text search (Altavista, Google)

Pasquale Savino - ISTI-CNR

Biblioteche Digitali

35

## In cosa differisce una BD dal WWW?

### ◆ Un'altra differenza sostanziale è legata al controllo degli inserimenti

- I documenti nel web possono essere inseriti da chiunque, mentre in una BD l'inserimento è permesso solo a particolari utenti

- I motori di ricerca selezionano i documenti da indicizzare tra quelli presenti nel web, mentre nelle BD tutti i documenti vengono indicizzati sulla base dei criteri definiti

### ◆ Le DB sono soggette ad un maggior controllo (per gli inserimenti, gli accessi e le ricerche) del WWW, ed hanno un insieme di utenti ben preciso

## Quali sono le differenze tra una DB ed una Biblioteca Tradizionale (BT)?

### ◆ Biblioteca Digitale


- Rimuovendo la restrizione della esistenza fisica degli oggetti si ottengono notevoli vantaggi
  - ➔ Accessi multipli, trasmissione elettronica
  - ma anche alcune complicazioni .....
  - ➔ Proprietà intellettuale, diritti di accesso, etc.

### ◆ Una BT offre anche vantaggi dal punto di vista sociale ed educativo

- Molti BT offrono servizi aggiuntivi che non possono essere offerti da una BD (ambiente di conversazione, comunicazione tra i lettori, ...) .... almeno per ora

## Cos'è una BIBLIOTECA DIGITALE ?

Analogie con un sistema di gestione per biblioteche "tradizionali"



## Quali sono le differenze tra una DB ed una Biblioteca Tradizionale (BT)?


### ◆ Le BT gestiscono oggetti (documenti) fisici

- Anche se le BT utilizzano delle schede elettroniche per individuare i documenti, questi si trovano in una ben precisa posizione fisica
- Questo porta a delle ovvie implicazioni
  - ➔ Gli oggetti possono esistere solo in un luogo
  - ➔ Un solo utente per volta può accedere all'oggetto
  - ➔ L'oggetto può essere acceduto solo recandosi fisicamente presso la Biblioteca o attraverso meccanismi di distribuzione postale

Cos'è una BIBLIOTECA DIGITALE?

**Analogie con un sistema di gestione per biblioteche "tradizionali": La comunicazione in rete: protocolli di comunicazione**

Dalla comunicazione




Pasquale Savino – ISTI-CNR Biblioteche Digitali 41

Biblioteche Digitali 41

41

Cos'è una BIBLIOTECA DIGITALE ?  
Analoga con un sistema di gestione nei biblioteche "tradizionali"

**La comunicazione in rete fra utente e sistema:**  
**protocolli di comunicazione**



Biblioteche Digitali 42

42 | Blaueche Digitali

42

## Vantaggi delle Biblioteche Digitali

## ◆ Vantaggi per gli intenti

- Si costruisce un BD nella convinzione di poter fornire una migliore distribuzione dell'informazione
    - **Informazione disponibile dove è necessario**
    - **Maggiori quantità di informazione disponibile**
    - **Possibilità di selezionare facilmente quello che interessa**
    - **Possibilità di utilizzare media diversi (testo, immagini, audio, video, ecc.)**
    - **L'informazione può essere condivisa**
    - **L'informazione è sempre aggiornata**
  - Accesso 24/24

Cos'è una BIBLIOTECA DIGITALE ?

**Analogie con un sistema di gestione per biblioteche "tradizionali"**

I servizi "di base" di una biblioteca digitale:

- Interfaccia
  - Presentazione degli oggetti digitali (“Acquisto” e catalogazione)
  - Deposito
  - Ricerca/Browsing/Recupero degli oggetti digitali

42

## Vantaggi delle BD

### ◆ Vantaggi economici

- Le biblioteche convenzionali risultano sempre più costose
  - ➔ Infrastrutture
  - ➔ Personale
  - ➔ Pubblicazione
- Attualmente anche le BD hanno costi elevati ma ....
  - ➔ I costi sono destinati a scendere, in particolare i costi di archiviazione e distribuzione

### ◆ Le BD richiedono la definizione di nuovi modelli dei costi





Pasquale Savino – ISTI-CNR

Biblioteche Digitali

45

Each of these libraries cost more to build than the cost of scanning its books



from Lesk,  
http://community.bellcore.com/lesk/columbia/session1/

## Alcuni esempi di Biblioteche Digitali

### ◆ Esempi di cataloghi di Biblioteche Digitali (Chemical Abstracts, Inspec, Biblioteca del CNR di Pisa)

### ◆ Biblioteche Pubbliche

- Library of Congress
- New York Public Library
- Boston Public Library

### ◆ Biblioteche Specializzate

- NTRSDL
- Documentari storici (DB ECHO)

## Cosa ha permesso la nascita delle Biblioteche Digitali

from Lesk, http://community.bellcore.com/lesk/columbia/session1/

46

48

Biblioteche Digitali

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

Pasquale Savino – ISTI-CNR

## Un po' di storia

- ◆ I primi tentativi di archiviare informazione bibliotecaria con i computer datano dalla fine degli anni '60. I problemi riguardavano
  - Alto costo dei computer
  - Interfaccia Uomo/Macchina scadente
  - Mancanza di reti di comunicazione

### ◆ Primi risultati

- Library of Congress ha memorizzato le schede MARC (formato per machine readable cataloguing)

### ◆ Architettura dei sistemi

- Piccole quantità di informazione memorizzata su un computer centrale
- Gli utenti erano connessi a terminali remoti di bassa qualità e con bassa velocità di connessione al computer centrale

## Evoluzioni tecnologiche [1/3]

- ◆ Archiviazione elettronica sta diventando sempre più economica rispetto alla carta
  - Gli edifici delle Biblioteche tradizionali impegnano circa ¼ dei costi
  - Le Biblioteche tradizionali hanno problemi di espansione (alti costi, tempi lunghi, ecc.)
  - I costi di archiviazione elettronica tendono a diminuire (circa 30% per anno)

## Evoluzioni tecnologiche [2/3]

- ◆ Miglioramento della qualità dei display
  - Miglioramento della risoluzione
  - Disponibilità di software di visualizzazione
  - Disponibilità di standard di visualizzazione

### ◆ Reti ad alta velocità

- Connessione diffusa
- Aumento della velocità dei link della rete
- Aumento della velocità delle connessioni locali
- In alcuni paesi è più facile (e veloce) ricevere informazione tramite la rete internet che a stampa

## Evoluzioni tecnologiche [3/3]

- ◆ Accesso alla Biblioteca
  - Le Biblioteche tradizionali sono accessibili solo agli utenti dell'organizzazione
  - Esistono organizzazioni con biblioteche molto fornite (per es. centri medici specializzati) ma molti utenti non possono accedervi
  - L'accesso ad una Biblioteca Digitale richiede costi sempre più bassi
  - Meno di 1000 Euro per il computer
  - Meno di 10 Euro/mese per la rete

## Tipologie

- ◆ Biblioteche Pubbliche e Biblioteche Specializzate
- ◆ Gestione letteratura “white” e “gray”
- ◆ Gestione di vari tipi di dati

## Tipologie di Biblioteche Digitali

## Biblioteche Pubbliche e Specializzate

- ◆ Una Biblioteca Pubblica prevede che utenti con interessi diversi possano accedere all'informazione
  - L'accesso è comunque controllato
  - Gli utenti sono costituiti dal grande pubblico
  - I documenti trattano di argomenti diversi
- ◆ Le Biblioteche Specializzate hanno le seguenti caratteristiche
  - L'insieme degli utenti è piccolo e con interessi molto focalizzati
  - Analogamente i documenti riguardano argomenti molto focalizzati
  - È importante controllare efficacemente l'accesso (utenti non autorizzati, possibilità di visionare gli oggetti ma non di copiarli, ecc.)

## Biblioteche Pubbliche e Specializzate

### ◆ Esempi di Biblioteche Specializzate

- tradizionali - NASA LaRC Technical Library
- digitali - NASA Technical Report Server, ACM Digital Library, ETRDL

### ◆ Biblioteche Pubbliche

- tradizionali – Biblioteca comunale di Pisa
- digitali – Yahoo, Boston public library

White and Grey Literature

- ◆ La distinzione tra le due non è sempre molto chiara
  - ◆ La definizione fornita da Grey Net:
    - “that type of publication unavailable through normal book-selling channels, often produced in small quantities with limited distribution, promotion, and exploitation”
    - <http://www.greynet.org/pages/1/index.htm>

# White and Grey Literature

- ◆ Grey Net ammette comunque che la pubblicazione elettronica ha cambiato questa definizione, che andrà quindi sostituita
  - ◆ Intuitivamente la letteratura
    - White: autore e publisher sono di solito diversi, il lavoro è stato revisionato in modo indipendente, l'opera può essere ottenuta facilmente
    - Grey: è possibile che non sia stato revisionato; spesso viene pubblicato direttamente dall'autore o dalla sua organizzazione; può essere difficilmente reperibile

Basswala Sawina ISTI CNB

57

9  
L

Esempi

- ◆ **White**
    - Riviste, libri, proceedings di conferenze, etc.
  - ◆ **Grey**
    - Rapporti tecnici, rapporti governativi, etc.

## Gestione di vari tipi di dati nelle BD

- ◆ Libri
  - ◆ Documenti
  - ◆ Immagini
  - ◆ Audio

Baccalaureate Sawin's List

10

57

9  
L

## Gestione di libri

- ◆ Automazione accesso ai cataloghi delle Biblioteche tradizionali
- ◆ Utilizzo di Cataloghi elettronici
- ◆ I servizi della Biblioteca rimangono gli stessi delle Biblioteche tradizionali, la ricerca dei libri risulta più veloce, ed è possibile effettuare ricerche complesse (ad es. libri scritti congiuntamente da due autori, oppure i libri su un certo argomento scritti in un dato periodo, ecc.)
- ◆ Si utilizzano tecnologie tradizionali per la gestione dei cataloghi
- ◆ È importante uniformare i cataloghi di varie biblioteche per permettere ricerche di libri su più cataloghi

## Gestione di documenti testuali


- ◆ Il primo passo delle Biblioteche tradizionali alle Biblioteche Digitali prevede che la biblioteca abbia i documenti in forma elettronica, non solo i cataloghi
- ◆ La forma più semplice di contenuto (ma anche quella di più facile utilizzo) è il testo
  - ◆ Documenti testuali ottenuti in modi diversi
    - Creati direttamente per accesso on-line
    - Convertiti da stampa
    - Digitalizzati dalle tracce audio di film o programmi televisivi
- ◆ È importante uniformare i cataloghi di varie biblioteche per permettere ricerche di libri su più cataloghi

## Rappresentazione di documenti testuali

- ◆ Struttura
  - Descrive la divisione del testo in vari elementi sia fisici (caratteri, parole) che logici (titolo, autori, capitoli, ecc.)
  - La struttura viene spesso rappresentata da linguaggi di markup
- ◆ Linguaggi di Markup
  - SGML (Standard Generalized Markup Language)
  - HTML/XML
- ◆ Visualizzazione
  - Descrive il modo in cui il documento viene visualizzato sullo schermo
- ◆ Linguaggi di visualizzazione
  - TeX, PostScript, PDF

## Testo


## Markup e Style Sheets



Pasquale Savino – ISTI-CNR

Biblioteche Digitali 65

## Alternative Renderings



Pasquale Savino – ISTI-CNR

Biblioteche Digitali 66

## Markup Languages

### SGML (Standard Generalized Markup Language)

A system for creating markup languages that represent the structure of a document

### XML (eXtensible Markup Language)

A simplified version of SGML intended for use with online information

### DTD (Data Type Definition)

A markup specification for a class of documents, defined within the SGML framework

### HTML (Hypertext Markup Language)

A markup and formatting language with links to other objects

## XML Example (Metadata)

```
<?xml version="1.0"?>
<!DOCTYPE dlib-meta0.1 SYSTEM "http://www.dlib.org/dlib-
meta01.dtd">
<dlib-meta0.1>
 <title>Digital Libraries and the Problem of Purpose</title>
 <creator>David M. Levy</creator>
 <publisher>Corporation for National Research Initiatives</publisher>
 <date date-type = "publication">January 2000</date>
 <type resource-type = "work">article</type>
```

*continued on next slide*

Pasquale Savino – ISTI-CNR

Biblioteche Digitali 67

Biblioteche Digitali

68

## XML Example (Metadata)

*continued from previous slide*

```
<identifier uri-type = "DOI">10.1045/january2000-levy</identifier>
<identifier uri-type =
"URL">http://www.dlib.org/dlib/january00/01levy.html</identifier>
<language>English</language>
<relation rel-type = "InSerial">
<serial-name>D-Lib Magazine</serial-name>
<issn>1082-9873</issn>
<volume>6</volume>
<issue>1</issue>
</relation>
<rights>Copyright (c) David M. Levy</rights>
</dlib-meta0.1>
```

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

69

Biblioteche Digitali

70

## Page-Description Languages

- ◆ Lo scopo è quello di presentare i documenti elettronici con una qualità simile a quella dei documenti a stampa
- ◆ I primi metodi di formattazione del testo erano specifici per la stampa
- ◆ Attualmente sono altrettanto importanti le problematiche relative alla visualizzazione su schermo
- ◆ Vedremo brevemente tre diversi strumenti
  - TeX – Produzione e formattazione di documenti
  - PostScript – Stampa di alta qualità
  - Portable Document Format (PDF)

### PostScript

- ◆ Linguaggio grafico sviluppato dalla Adobe Systems, utilizzato principalmente per la creazione di rappresentazioni grafiche di documenti da stampare
- ◆ Molti programmi di gestione documenti possono produrre una rappresentazione PostScript del documento da inviare a device di stampa
- ◆ Vi possono essere piccole variazioni dovute ai vari interpreti PostScript
- ◆ Utilizzato anche per la memorizzazione e lo scambio di documenti

### TeX

- ◆ Linguaggio sviluppato agli inizi degli anni '80 da Donald Knuth
- ◆ Al contenuto del documento vengono aggiunti una serie di comandi che danno le direttive di formattazione e visualizzazione.
- ◆ Contiene istruzioni specializzate per la notazione matematica
- ◆ Include un sistema specifico (Metafont) per il disegno di font

## Portable Document Format (PDF)

- ◆ Sviluppato dalla Adobe come linguaggio di memorizzazione di pagine di documenti in un formato portabile su diversi sistemi
- ◆ Utilizzato principalmente per documenti creati in forma elettronica
- ◆ Documenti acquisiti da scanner (bit-map) possono essere estremamente grandi in PDF
- ◆ Questo implica che in alcune situazioni il PDF può essere poco adatto ad essere usato nelle Biblioteche Digitali
- ◆ I lettori di file PDF sono gratuiti, mentre i programmi di generazione di PDF sono a pagamento


Pasquale Savino – ISTI-CNR

Biblioteche Digitali


73

## Metodi di scanning


### Bitonal



### Color



### Grayscale



### Special Treatment

- ◆ Dipende da

- Risoluzione dello scanner (numero di pixel per  $\text{cm}^2$ )
- bit depth (numero di bit per pixel)
- image enhancement
- color management
- compression
- system performance
- operator judgment and care

## Acquisizione di documenti come immagine

- ◆ Le singole pagine sono acquisite come immagini tramite uno scanner
- ◆ Ogni singola pagina viene rappresentata come una sequenza di punti (pixels)
- ◆ Ad ogni pixel viene assegnato un valore (nero, bianco, grigio, colore), rappresentato con un codice binario
- ◆ Si possono applicare tecniche di compressione della codifica per ridurre l'occupazione dell'immagine

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

74

## Qualità dell'immagine acquisita

76

Biblioteche Digitali

75

Pasquale Savino – ISTI-CNR

## Riconoscimento caratteri

## OCR Comparison

- ◆ Processo di trasformazione di una immagine in testo
  - ◆ Dipende dalla qualità dell'immagine
  - ◆ Utilizza tecniche di image processing combinate con tecniche linguistiche (ad es. utilizzo di dizionari)
  - ◆ Il risultato è affetto da errori
  - ◆ In una Biblioteca Digitale è opportuno, in generale, conservare sia l'immagine originale che il testo riconosciuto.
  - ◆ Il testo può essere utilizzato per la ricerca per contenuto documento

卷之三

## OCR Comparison of 6 PT Type

卷之三

The above reproduction represents the first number of a periodical published by American emigrants belated in Panama in 1849. The original consisted of four pages, about six by ten inches in size, and was printed on lightblue paper. So far as we are informed, but four numbers appeared, the others being published on the 3d, 10th, and 17th of March. This publication throws interesting side lights on the Panama trip, of which there is an account. Lists of arrivals are printed in each number. Washington's Birth-

卷之三

**Results of OCR from 600 DPI File:**

The above reproduction represents the first number of a periodical published by American emigrants belated in Panama in 1842. The original consisted of four pages, about six by ten inches in size, and was printed on lightblue paper. So far as we are informed, but if our numbers appearred, it is others being published on the 3d, 10th, and 17th of March. This publication throws interesting side lights on the P303333 trip, of which there is an account. Lists of arrivals are printed in each number. Washington's Birthday, it appears, was duly celebrated by American citizens with a procession and a banquet, and

## Results of OCB from 300 DPI File:

Tias above osyoehs's lib lbs llsat 'sasatabe of A porisaliassi psbilatal by Assoito's sasigasilla bsaAssl is Pa'sassd isa 0849. Its soigissi hsahibsal sifssu psgsa, allassi ais by lsis inasbea in sias, and a'sas psisassal so light bloss papso. las faa ad ate ate latfoossasal, basl fs'so ossasabass a1spAssAl, alas ohlastb issiog psblissal s's lts vi-, ashi, asasi sylls of Massila. Tislb p'sblisalisa liada shi i'ssishliogaq hide higalb sta lltts PsCalsA 10115, of

## Gestione del video

OCR Results  
from 600 dpi  
Image File

OCR Results  
from 300 dpi  
Image File

## Image of Original Text

◆ Perchè è importante poter gestire biblioteche digitali di audiovisivi

- ◆ Caratteristiche specifiche dell'audio/video
- ◆ Applicazioni delle biblioteche digitali audio/video

- ◆ Alcuni esempi di biblioteche digitali audio/video

THE JOURNAL OF CLIMATE

## The importance of video

- ◆ Video can be considered today the primary information and communication channel, due to
  - Richness in information contained
  - Appeal
- ◆ Video libraries will become essential in many application fields
  - Personal information
  - Distance learning
  - Telemedicine
  - .....

## Video characteristics

- ◆ High video production vs print production
  - TV stations produce 50 Million hours of video per year (25,000 TB)
  - Newspapers and periodicals produce less than 200 TB of data per year
- ◆ Storage and transmission problems
  - Video is usually compressed
- ◆ Richness in content
  - Difficulties in automatic extraction of content description

## Services of A/V Digital Libraries

- ◆ Digital Video Libraries are more complex than traditional DLs; they require the integration of several specialized technologies
- ◆ They offer the same services of text digital libraries
- ◆ Specific characteristics of Indexing and retrieval services
  - Indexing based on the integration of different technologies for the automatic feature extraction
    - Integration of manual and automatic indexing
    - Retrieval based on different video features

## Characteristics of an Audio/Video DL

## The need of A/V DLs

- ◆ **Nowadays, video is present in many situations**
  - TV broadcasting
  - Professional applications, such as medicine, journalism, advertising, education, training, surveillance, etc.
  - Movies
  - Historical videos
  - Personal videos
- ◆ **The combination of audio and video is a very powerful communication channel**
  - approximately 50% of what is seen and heard simultaneously is retained

Pasquale Savino – ISTI-CNR

85

Biblioteche Digitali

86

## A/V vs traditional DLs [1/2]

- ◆ **Library creation**
  - Traditional DLs, contain text documents
    - Library creation requires automatic acquisition of text, extraction of document content, and indexing
  - This process is well known and many different techniques have been developed
    - Video is extremely rich in "content" but ....
    - the indexing of video content is difficult, expensive, and extremely dependent from the user and the application
    - A possible approach consists in an appropriate integration of automatic content extraction (e.g. speech recognition, image analysis, etc.) and manual indexing

## ◆ Library exploration

- Traditional DLs, contain text documents
  - Library exploration requires simple interfaces to formulate queries on free text and document metadata.
- Video libraries should permit
  - To formulate queries on many different "dimensions"
    - Text, as extracted from speech and captions
    - Images extracted as key frames
    - Motion information
    - Other features automatically extracted
    - Metadata provided manually

## A/V vs traditional DLs [2/2]

- ◆ **Most of the video material produced is used only once, due to the difficulty to archive it, to protect and to retrieve.**
- ◆ **A large video library of distributed and network searchable videos would enable**
  - Preservation of precious and expensive material
  - Reduction of production costs for new videos, through the reuse of existing material
  - Diffusion of knowledge
- In general, it will enable the access to information that could have been lost.

## Advantages of A/V DLs

- ◆ **Nowadays, video is present in many situations**
  - TV broadcasting
  - Professional applications, such as medicine, journalism, advertising, education, training, surveillance, etc.
  - Movies
  - Historical videos
  - Personal videos
- ◆ **The combination of audio and video is a very powerful communication channel**
  - approximately 50% of what is seen and heard simultaneously is retained
- ◆ **A large video library of distributed and network searchable videos would enable**
  - Preservation of precious and expensive material
  - Reduction of production costs for new videos, through the reuse of existing material
  - Diffusion of knowledge
- In general, it will enable the access to information that could have been lost.

Pasquale Savino – ISTI-CNR

85

Biblioteche Digitali

86

## Who may use A/V DLs?

- ◆ We consider four main categories
  - Large companies
    - ➔ Large corporations that may use Digital Video for their internal business, for advertising, promotion, etc.
  - Media and entertainment
    - ➔ The most traditional area. Video is one of the key assets.
  - Education
    - ➔ Video recording of courses
    - ➔ Video used as course material
  - Others
    - ➔ Health and medicine
    - ➔ Government
    - ➔ Surveillance
    - ➔ Etc.

## Applications of Audio/Video DL

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	89
Pasquale Savino – ISTI-CNR	Biblioteche Digitali	90

## Large companies

- ◆ **Audio/video digital libraries are used for**
  - Sales
  - Product Launches
  - Marketing
  - Relation with investors
  - Product design (acquisition and analysis of customer's needs)
  - Support for online sales
  - Video archives for internal use
  - Special services for customers, such as web access to specialized video archives, e.g.
    - ➔ News
    - ➔ Economic Information
    - ➔ Products
    - ➔ Materials
    - ➔ Etc.

## Media & Entertainment [1/3]

- ◆ **Broadcasting companies**
  - Many broadcasters are creating and distributing video programs on the web. A video archive is very helpful to them to add a new service for accessing old video material.
  - Examples:
    - ➔ ABC News
    - ➔ Mediaset
    - ➔ RAI

- Archive of old programs
- Archive of daily programs
- Additional material w.r.t. tv programs

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	91
Pasquale Savino – ISTI-CNR	Biblioteche Digitali	92

## Media & Entertainment [2/3]

### ◆ Video archives

- Many national and private organizations own old video material. The digitalization and archiving of this material is beneficial for content owners (for example, they can promote the use of their material) and for users belonging to different categories: e.g. professional users (that need the material to produce their video programs) or researchers or general public.
- Examples:  
→ Istituto Luce

## Media & Entertainment [3/3]

### ◆ Movie production companies

- Many large movie production companies own a large amount of video material, composed of the films and of related material, such as cuts not used in the final film version, interview, video trials, etc. This material is very helpful for many purposes, from the production of DVD version of the film up to the critical study of the video. Providing access to the general public of this material is also a powerful promotion and advertising channel.
- Examples:  
→ MGM  
→ 20th Century Fox

## Education

### ◆ Digital video used for different purposes

- Promotion and advertising  
→ Online preview of training content
- Store and distribute the video courses  
→ Remote access of the courses  
→ Keep track of classroom discussion  
▪ Used as course material  
→ Delivery of video clips to students, either online or in the classroom  
→ From remote sites, provide students and teachers with on-demand, searchable access to whole programs and video clips  
→ Free search and access to the video library can be used by students to find answers to specific questions, to study in depth some topics, etc.
- Production of new courses  
→ Improve the course production procedures, allowing teachers and producers to remotely access the video library
- Examples:  
→ Princeton University  
→ Harvard Business School  
→ University of Arizona

## Other Applications [1/2]

### ◆ Health and medicine

- Health and social care info to the general public
- Information to physicians for special purpose medical procedures
- Training

## Other Applications [2/2]

- ◆ **Government**
  - Enhancement of the governmental decision making process, by recording and archiving of public meetings and discussion.
- ◆ **Surveillance**
  - A large amount of video is produced for surveillance purposes.
    - ➔ Required automatic video analysis
    - ➔ Archiving for successive search

## The characteristics of Digital video

## Types of data managed

- ◆ A digital video is composed of a sequence of frames plus possibly an audio track.
- ◆ In general, it is possible to view an audio/video document from different perspectives
  - The audio part can be separated into
    - ➔ Speech
    - ➔ Sound
  - Sequence of frames (video shot and sequence)
  - Single frames as images
- ◆ From all of them is possible to extract information that can be used for indexing and retrieval purposes

## Digital video characteristics

- ◆ Sequence of frames with a certain frame rate
  - NTSC 30 frames/sec, PAL 25 f/s, HDTV 60 f/s
  - Minimal change between frames
- ◆ Single frames resolution
  - 768 x 576 PAL, 720 x 480 NTSC
- ◆ Uncompressed video requires high storage space and bandwidth
  - For example, one second of uncompressed PAL video requires 768 x 576 x 16 x25 ~ 172 MByte

## Digital video storage and transmission [1/3]

- ◆ The high storage requirements of video imposes the adoption of compression techniques.
- ◆ High compression rates are possible with video signals, due to the following reasons:
  - Spatial correlation: correlation among neighboring pixels
  - Temporal correlation: correlation among pixels in different frames
  - A significant part of video data is not perceived

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	101
Pasquale Savino – ISTI-CNR	Biblioteche Digitali	102

## Digital video storage and transmission [2/3]

- ◆ Compression can be divided in two broad categories
  - Lossless compression, that allows one to compress/decompress video without any degradation
    - ➔ Lossless compression provides low compression factors
    - ➔ An example of lossless compression is MJPEG, where each frame is compressed using the JPEG format
    - ➔ Examples of lossless coding techniques are run-length coding, Huffman coding

## Digital video storage and transmission [3/3]

- ◆ Lossy compression, where the complete cycle of compression and decompression introduces some degradation of the original video
  - ➔ Lossy compression allows to obtain high compression factors
  - ➔ Examples are the MPEG compression family (MPEG1, MPEG2)
  - ➔ Example of lossy coding is DPCM
    - DPCM compares adjacent pixels and stores only their difference
- ◆ MPEG (Moving Pictures Experts Groups)
  - MPEG1 has a bit-rate up to 1.5Mb/sec
    - ➔ Designed for storage and retrieval of VHS quality video on CD-ROM
  - MPEG2 Designed for broadcast video quality
    - ➔ Bit rate: 2Mbps or higher
    - ➔ Used for DVD, cable TV, etc.
  - MPEG4 is object-based, multi stream
    - ➔ Variable bit-rates, from <64 kbps, up to 4Mbps and more (in the future)


## MPEG

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	103
----------------------------	----------------------	-----

## MPEG-1 [1/2]

- ◆ Compression based on intra-frame and inter-frame encoding
- ◆ Intra-frame coding
  - Each frame is subject to compression
  - Uses DCT compression schema
- ◆ Inter-frame coding
  - Exploits temporal redundancy
  - Predictive coding
    - ➔ current picture is modeled as a transformation of picture at some previous time
  - Interpolative coding
    - ➔ Uses past and future pictures for reference

- ◆ MPEG uses three types of frame coding
  - I frames: intra-frame coding
    - ➔ Moderate compression
    - ➔ Access points for random access
  - P frames: predictive-coded frames
    - ➔ Coded with reference to I or P frames
  - B frames: bi-directionally predictive coded
    - ➔ Coded using previous/next I and P frames
    - ➔ High compression



## MPEG-1 [2/2]

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	105
----------------------------	----------------------	-----

## MPEG-4 [1/4]

- ◆ Scalability of bit rate vs quality
- ◆ Better Audio/Video compression than MPEG-1
- ◆ Content based coding
- ◆ Support for efficient streaming


- ◆ Content based coding
  - Reusability of object coding
  - Adaptation (different coding for different objects)
  - High quality for interesting parts
  - Possibility of scene composition
    - ➔ Integration of natural and synthetic content
    - ➔ Tele-presence

## MPEG-4 [2/4]

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	106
----------------------------	----------------------	-----

Pasquale Savino – ISTI-CNR	Biblioteche Digitali	108
----------------------------	----------------------	-----

## MPEG-4 [4/4]




110

## Operations of an A/V Digital Library

- ◆ Video archiving and indexing
- ◆ Video storage
- ◆ Content-based search
- ◆ Video access (visualization and copy)

Pasquale Savino - ISTI-CNR

109



Pasquale Savino - ISTI-CNR

110

## Digital Video representation

- ◆ Video is composed of a sequence of frames
- ◆ Video is separated into shots
  - A shot is a sequence of frames separated by a transition
    - Transitions between shots are given by
      - Camera break
      - Dissolve
      - Wipe
      - Fade-in, fade-out
- ◆ A video can be separated into sequences, that are semantically meaningful groups of shots, possibly non consecutive

## MPEG-4 [3/4]

112

Biblioteche Digitali

Pasquale Savino - ISTI-CNR


111

Biblioteche Digitali


Pasquale Savino - ISTI-CNR

## Summary of all phases & operations

### Informedia – an example



### Informedia – an example



Pasquale Savino – ISTI-CNR

### ECHO Retrieval Interface

Screenshot of the ECHO Retrieval Interface showing a detailed view of an item. The item details include:

- Title:** Nelle sedi provvisorie del Reichstag cancelliere Hitler spie su programma di governo
- Subject:** Cancelliere, Hitler
- Genre:** Newsreel
- Series Number:** BI242
- Language:** English
- Themes:** 1945, Eventi Principali
- Description:** Discorso
- Language:** Italiano
- Provider:** IPR
- Production Date:** 01/01/1933
- Producer Name:** FOX Movietone
- Producer Nationality:** USA

Integration of Clients and Services in GUI

Views on the material

Attribute Search

Retrieval interface

Search for category level of material (Work, Expression, Manifestation, Item)

Detailed view on an item corresponding to the full ECHO data model (structures, links, ...)

List of retrieved items

Pasquale Savino – ISTI-CNR

Biblioteche Digitali

114

Pasquale Savino - ISTI-CNR

Biblioteche Digitali 117

Biblioteche Digitali

Pasquale Savino – ISTI-CNR

Biblioteche Digitali 119

Biblioteche Digitali



InformaticaUmanistica

## Sommario

- ◆ **Cenni storici**
  - Vannevar Bush
  - Dalle Biblioteche ai Cataloghi Automatizzati
  - Gli OPAC accessibili via Web
  - Le Biblioteche Digitali
  
- ◆ **Cos'è una Biblioteca Digitale**
  - Definizione
  - Confronto tra BD e database, sistemi IR, WWW, biblioteca tradizionale
  - Vantaggi delle BD
  - Alcuni esempi di Biblioteche Digitali

## Sommario della prima parte



UNIVERSITÀ DI PISA

- Pasquale Savino – ISTI-CNR
- Biblioteche Digitali
- 122

## Sommario (cont.)

- ◆ **Cosa ha permesso la nascita delle Biblioteche Digitali**
  - Evoluzioni tecnologiche
  
- ◆ **Tipologie di Biblioteche Digitali**
  - Biblioteche Pubbliche e Biblioteche Specializzate
  - Tipi di documenti trattati
    - Libri
    - Documenti testuali
    - Immagini
    - Audio/video
    - .....