

tesi di laurea

# **Sviluppo di un tool a supporto del recupero del modello dei contenuti di pagine Web**

**relatore**

Ch.mo prof. Porfirio Tramontana


**candidato**

Claudio Quaranta

Matr. 534/1468


# Ubiquitous Web Applications

- Grazie all'enorme sviluppo di internet sempre un maggior numero di applicazioni vengono sviluppate per offrire servizi via Web
- Il progetto **UWA ( Ubiquitous Web Applications )** ha come obiettivo quello di definire un'insieme di metodologie, notazioni, e strumenti per assistere la progettazione veloce delle future applicazioni Web
- Si desidera analizzare applicazioni già esistenti per ricavare con quali oggetti relativi alla metodologia **UWA** esse sono state realizzate




# Candidati Label e Output

- L'obiettivo è ricavare i candidati Label e Output ( gergo UWA ) di progettazione da applicazioni già esistenti
- Una delle strade possibili è quella di ricavare i pattern da applicazioni già esistenti, confrontando tra di loro pagine HTML che svolgono funzioni simili.
- Problemi :
  - Quando due pagine HTML si dicono "simili"?
  - In che modo raggruppare le pagine "simili" tra di loro?



# Distanza di Levenshtein


- La distanza di Levenshtein tra due stringhe A e B è il numero minimo di modifiche elementari che consentono di trasformare A in B.
- Per modifica elementare si intende :
  - inserimento di un carattere
  - eliminazione un carattere
  - sostituzione di un carattere con un altro
- Sostituendo ad ogni Tag di una pagina html un carattere è possibile ricavare la distanza di Levenshtein tra pagine HTML




# Classificazione pagine HTML

- In che modo suddividere le pagine Html di un'applicazione?
- Tre i criteri proposti :


$$x_i \in G \Leftrightarrow \exists x_j \in G : d(x_i, x_j) < d_{\max}$$



$$x_i \in G \Leftrightarrow \forall x_j \in G : d(x_i, x_j) < d_{\max}$$




$$x_i \in G \Leftrightarrow \exists x_j \in G : d(x_i, x_j) < d_{\min} \wedge \forall x_j \in G : d(x_i, x_j) < d_{\max}$$




# Use Case Diagram

Si è creato un tool scritto in Java in grado di supportare l'identificazione di tali oggetti.

In particolare il software implementa i tre tipi di raggruppamenti esposti e provvede all'estrazione automatica delle stringhe di testo dalle pagine html




Sviluppo di uno strumento a supporto del recupero del modello dei contenuti di pagine Web




# Casi di studio

- Sono stati effettuati 3 casi di studio
- Si sono analizzati alcuni set di pagine provenienti da queste tre applicazioni Web, estraendone le stringhe e verificando la loro correttezza confrontando i risultati con un'insieme di dati corretti


## Ebay.it



## Nga.gov



## Chl.it



# Conclusioni

- **Verificando i risultati ottenuti dai tre criteri di confronto si evince che:**
  - Il primo criterio è il meno adatto all'identificazione delle label e output in quanto molti candidati risultano essere errati
  - I restanti due criteri risultano equivalenti per quanto riguarda la correttezza dei candidati proposti, ma il secondo criterio permette di suggerire un valore di soglia "di default".
  - Per futuri esperimenti quindi si consiglia di utilizzare il secondo criterio proposto, impostando come soglia un valore compreso tra 30 e 50. Tale scelta deve essere fatta in base al set di pagine che si desidera analizzare e da quanto sono diverse tra di loro le pagine.