

Analisi critica delle metodologie e tecniche di selezione e composizione personalizzata per l'e-commerce

Survey

Nel presente documento si riassumono i contenuti del deliverable *D-C.1_1 Analisi critica delle metodologie e tecniche di selezione e composizione personalizzata per l'e-commerce* relativo all'obiettivo realizzativo C del progetto InViMall.

Il documento in questione rappresenta uno studio approfondito ed un'analisi critica delle principali tecniche di selezione personalizzata, rating avanzato e composizione automatica dei pacchetti suggeriti, ed ha lo scopo di individuare gli strumenti più idonei a soddisfare le specifiche delle innovative funzionalità di personalizzazione previste dalla piattaforma InViMall.

Personalizzazione e profilazione utente

Negli ultimi anni i sistemi di e-commerce si stanno sempre più orientando verso strategie di personalizzazione, puntando su soluzioni software adattative, che siano in grado di tenere conto delle diverse caratteristiche di utenti distinti e di fornire contenuti customizzati. La personalizzazione è in tal caso intesa come adeguamento della navigazione, dei contenuti e della loro rappresentazione alle caratteristiche ed al comportamento di utilizzo di ogni singolo utente, in modo da migliorare l'efficienza e l'efficacia dell'interazione. Le fasi del processo in questione prevedono l'identificazione del contenuto che si vuole mostrare all'utente, del come mostrarlo, del come assicurare ai clienti il rispetto della privacy e del come creare uno schema di personalizzazione globale, il cui utilizzo possa assicurare il massimo giovamento. Pertanto, complessivamente la personalizzazione è tesa alla creazione di offerte su misura (come contenuti, servizi, raccomandazioni di prodotti, comunicazioni ed interazioni di e-commerce) da parte di fornitori (come siti web di e-Commerce) per consumatori (come clienti e visitatori), basate sull'informazione acquisita su di essi, contenuta nei profili utente. Il concetto di profilo utente si riferisce ad un insieme di preferenze, informazioni, regole ed impostazioni che sono usate per fornire all'utente un prodotto o un servizio adattato e personalizzato. Le informazioni che in esso risiedono possono essere di varia natura e vengono suddivise in quattro categorie principali: informazioni esplicite a lungo termine (dati anagrafici del cliente, elenco dei prodotti acquistati, elenco delle azioni effettuate dall'utente durante le interazioni con il sistema); informazioni esplicite a breve termine (riferite ai contenuti visionati in corso di navigazione); informazioni implicite a lungo termine (interessi e preferenze a lungo termine per uno specifico modello di dominio e per un particolare modello di vendita); informazioni implicite a breve termine (predizione del prodotto che l'utente intende acquistare nella corrente sessione di navigazione e dell'azione successiva). Acquisiti i dati e le informazioni necessarie, si pone il problema di rappresentarli in una forma che sia il più possibile utile e chiara e poi di gestirli in maniera ottimale. Un primo approccio alla rappresentazione è quello basato su ontologie, che può consistere in due tecniche principali: la prima fa corrispondere ad ogni profilo utente un'ontologia, la seconda, invece, descrive il profilo tramite concetti nell'ontologia. Entrambe le metodologie presentano vantaggi e

svantaggi. L'una, dal momento che l'intera ontologia risiede nel profilo, consente di fare elaborazioni all'interno del profilo stesso, accrescendone l'efficienza. Lo svantaggio è la ridondanza dei dati che può portare ad un problema di inconsistenza degli stessi. L'altra tecnica, invece, assicura la consistenza dei dati, ma è meno efficiente. Una strategia diversa è quella che descrive i profili attraverso metadati, ciascuno dei quali associa ad ogni attributo un insieme fuzzy. Ogni elemento è definito da una collezione di metadati fuzzy, ad esempio un insieme di coppie < attributo, valoref >, dove "attributo" è una stringa e "valoref" è un insieme fuzzy definito nel dominio dell'attributo. Un esempio di metadato fuzzy è:

(Complessità {Bassa/1, Media/0.8, Alta/0.2})

dove "Complessità" è il nome dell'attributo, "Bassa", "Media" e "Alta" sono i valori con gradi di appartenenza 1, 0.8, 0.2 rispettivamente.

I dati contenuti in un profilo utente, però, verosimilmente cambiano nel tempo. L'aggiornamento è, dunque, un requisito indispensabile per consentire l'erogazione di un servizio idoneo e personalizzato, che tenga conto delle evoluzioni delle abilità dell'utente, della storia delle interazioni che egli ha con il sistema e degli interessi personali che possono cambiare. A tal proposito, è stato analizzato un approccio semantico, proposto nell'articolo "Updating User Profile using Ontology-based Semantic Similarity" che, partendo da una rappresentazione ontologica e sfruttando l'analisi dei web log, applica un aggiornamento automatico su due fronti: esso, infatti, da un lato aggiorna gli elementi già presenti nel profilo, che hanno subito variazioni, e dall'altro inserisce nella lista preferenze nuove ed emergenti, non ancora presenti. Il sistema in questione va ad identificare nelle pagine web visionate dall'utente le parole legate ad uno specifico dominio di interesse e, per ognuna di esse, valuta la rilevanza rispetto alle sue preferenze. Viene pertanto fissata una soglia che permette di stabilire il valore di rilevanza di un termine di una pagina web rispetto a quelli contenuti nel profilo utente e solo quelli il cui valore di rilevanza supera la soglia sono aggiunti.

Le URL visitate rappresentano il punto di partenza di un altro approccio, basato su un sistema multiagente dal nome Carcarà, che effettua periodicamente il processo di profilazione. Ad ogni accesso dell'utente ad una particolare URL, un agente di interfaccia invia l'informazione ad un agente di profilo che va ad aggiornare la lista delle pagine web visionate dall'utente. Queste liste sono l'input della rete neurale ART, che ha il compito di raggruppare periodicamente gli utenti in cluster, creare una lista delle pagine web più cliccate dai rispettivi membri ed inviarla all'agente di profilo, che andrà a modificare le proprie liste. In questo modo sono garantiti suggerimenti di gruppo, in linea con le preferenze correnti dell'utente.

Selezione dei prodotti

La selezione dei prodotti nell'ambito del commercio elettronico è un'operazione lunga e complessa, il cui obiettivo è filtrare le liste degli articoli disponibili per attributi, caratteristiche specifiche o bisogni dichiarati dall'utente, tenendo conto delle diverse esigenze e delle differenti situazioni di vendita. Ad esempio, nell'articolo intitolato "Rainbow Product Ranking for Upgrading E-Commerce" gli autori Qinyuan Feng, Kai Hwang e Yafei Dai propongono un Rainbow ranking system che effettua una classificazione basata su attributi come il prezzo, la quantità ordinata, il tempo di consegna, la fedeltà verso il venditore e la qualità del prodotto. Il sistema si traduce in uno schema di ottimizzazione multilivello, descrivibile mediante quattro parametri $\{n, m, q, k\}$, dove n sono gli elementi disponibili in risposta ad una

particolare richiesta dell'utente, m sono gli attributi che caratterizzano ogni prodotto, k sono i livelli coinvolti nel modello e q è il numero di venditori. A partire da tale modello, quando l'utente desidera acquistare pochi prodotti, il sistema seleziona gli elementi sui livelli più bassi, selezionando i prodotti che risultano più rispondenti alle richieste, altrimenti, il sistema sceglie più livelli verso l'alto, offrendo una maggiore versatilità tra le possibili scelte.

In generale, un importante strumento di valutazione e di conseguente selezione degli articoli proposti è rappresentato dal rating, ossia dall'associazione di due elementi, un utente ed un prodotto, per mezzo di un certo valore, che può essere fornito esplicitamente od implicitamente. Nel primo caso si tratta di una valutazione rilasciata coscientemente dall'utente e può essere di tre tipi: scalare (può consistere in valori numerici o numeri cardinali che esprimono diversi livelli di gradimento o rifiuto), binario (è una scelta esclusiva tra piacere/dispiacere o buono/cattivo) ed unario (può indicare che un utente ha osservato o acquistato un oggetto, o altrimenti che lo ha valutato positivamente). Il rilascio di rating da parte dell'utente, sebbene costituisca una fonte più affidabile ai fini della selezione personalizzata, presenta degli svantaggi non trascurabili. Ad esempio, esso può causare l'interruzione delle normali attività di lettura e consultazione delle pagine e può arrecare disturbo all'utente, il quale non sempre è convinto di ricevere un vantaggio nell'assegnare rating. È questo il motivo per cui risulta preferibile operare con sistemi che siano in grado di elaborare rating impliciti, ossia valutazioni desunte a partire dal comportamento dell'utente. Questi nascono, infatti, dall'esigenza di trovare una soluzione ai predetti problemi, garantendo la rimozione del costo di valutazione per l'utente, e l'acquisizione di una maggiore quantità di informazioni sulle sue preferenze.

Sistemi di raccomandazione

Data la crescita costante del numero di prodotti disponibili online, la scelta di un acquisto sul web diventa di giorno in giorno un'operazione sempre più complessa. Pertanto, i sistemi di raccomandazione possono rappresentare un supporto valido per gli utenti, guidandoli in maniera personalizzata verso oggetti utili e di interesse in un ampio ventaglio di possibili opzioni.

I vantaggi derivanti dall'applicazione dei sistemi di raccomandazione ad uno scenario di e-commerce sono molteplici. È innanzitutto garantita una più alta conversione dei visitatori di un sito web in acquirenti. Talvolta, infatti, gli utenti visitano un sito solo per dare uno sguardo ai contenuti, senza avere intenzione di acquistare; in tal caso, questi sistemi possono guidare i consumatori verso articoli di interesse, invogliandoli all'acquisto. Risultano inoltre incentivate le vendite di tipo cross-sell, in quanto il sistema, basandosi sugli acquisti effettuati dal cliente, può suggerirgli articoli appartenenti a categorie differenti ma correlati ai prodotti acquistati. Infine, il livello di fidelizzazione verso il sito risulta potenziato. Un sistema di raccomandazione può, infatti, essere in grado di attirare consumatori che visitano il sito, garantendo una consistente richiesta da parte dei clienti per un'informazione personalizzata.

Grazie a questi importanti vantaggi offerti, oggi tali sistemi sono ampiamente adottati tanto che diversi siti web si stanno focalizzando nel raccomandare un contenuto personalizzato, come Amazon.Com, che suggerisce ai suoi utenti prodotti appartenenti ad un'ampia gamma di categorie merceologiche (libri, elettronica, prodotti per la casa, etc.), MovieLens e Netflix (film e dvd) e Yahoo!Music (canzoni e cantanti). Gli approcci implementati da tali sistemi si differenziano molto tra loro e vanno da quelli più semplici, che generano suggerimenti sulla base delle sole statistiche, a quelli più complessi, che combinano differenti tecniche e procedure di selezione personalizzata. In generale, le

tecnologie impiegate per la selezione personalizzata costituiscono il fattore cruciale nel processo di raccomandazione dei prodotti, in quanto ne determinano le prestazioni e la soddisfazione derivante dal risultato. I principali approcci adottati in tal senso corrispondono al Collaborative Filtering, al Content-Based Filtering, al Trust-Aware Filtering, al Mining Associate Rules, Demography-Based Filtering ed al Knowledge-Based Filtering.

Il collaborative filtering è stato introdotto nel 1992 dallo staff di ricerca Xerox, nell'ambito del progetto Tapestry. Esso parte dall'assunzione secondo cui, se due utenti valutano n elementi similmente, o esibiscono comportamenti simili, allora giudicheranno o agiranno rispetto ad altri elementi in modo analogo. Pertanto, la strategia più frequente consta nel selezionare gli utenti più vicini a quello cui deve essere rivolta la raccomandazione e, a partire da questi, calcolare la media dei rating, pesata per la somiglianza con l'utente attivo. Per evitare di considerare i cosiddetti fake neighborhoods, Yolanda Blanco-Fernández, Martín López-Nores in "Avoiding Fake Neighborhoods in e-Commerce Collaborative Recommender Systems: A Semantic Approach" propongono un interessante approccio ontologico al collaborative filtering, in cui la selezione della regione di vicinanza avviene dinamicamente, considerando in ogni caso il gruppo di utenti più appropriato al tipo di prodotto che si vuole raccomandare (libri, musica, attrezzatura sportiva, etc.). L'algoritmo si basa su un'ontologia di prodotto che formalizza la conoscenza del dominio di applicazione ed i profili degli utenti che contengono le loro preferenze. Stabilito il tipo di prodotto si individuano la relativa gerarchia di appartenenza nell'ontologia e le preferenze degli utenti che corrispondono ad essa, e si determinano le regioni di vicinanza. Durante il processo, ogni qual volta il target di prodotto cambia, le vicinanze rispetto ad un utente attivo varieranno di conseguenza, selezionando gli utenti più simili. Risulta in questo modo migliorata la precisione delle raccomandazioni nonché ridotto il costo computazionale dell'intero processo, in quanto i dati oggetto di calcolo sono solo quelli appartenenti alla gerarchia considerata.

In generale, il collaborative filtering è applicabile seguendo diverse strategie. I principali approcci utilizzati sono suddivisibili in due tipologie: memory-based e model-based.

Tra le tecniche memory-based rientrano:

- User-to-User Collaborative Filtering
- Item-to-Item Collaborative Filtering
- Item-to-Item Slope One Collaborative Filtering

Tra le tecniche model-based, invece, rientrano:

- Clustering Collaborative Filtering
- Bayesian Belief networks Collaborative Filtering
- Fuzzy C-Means Collaborative Filtering
- Semantic Collaborative Filtering

La principale differenza tra i due tipi di algoritmi è che il primo utilizza l'intero database di ogni utente per fare predizioni, mentre il secondo, a partire dall'intera base di dati elabora un modello sul quale saranno successivamente basate le predizioni.

Al fine di eseguire un confronto critico delle diverse tecniche di collaborative filtering, sono state confrontati degli algoritmi MBCF (Memory Based item-to-item CF), KMCF (K-means CF) e IFCCF (Item Fuzzy C-means CF). Per il confronto sono stati considerati 3 sottoinsiemi dai dataset di MovieLens e Jester (M indica MovieLens, mentre J Jester) in maniera tale da garantire un minimo numero di rating espressi per ogni utente e selezionare gli item più

votati. I dataset sono stati randomicamente divisi in un insieme di training (90% dei rating per utente) e insieme di testing (10% dei rating per utente). Partendo dall'insieme di training, l'algoritmo di raccomandazione predice i rating sconosciuti, mentre l'insieme di testing è usato per valutare il livello di accuracy della predizione.

La Figura 1 illustra i valori di RMSE dei metodi memory-based e model-based ottenuti sui 3 diversi dataset di dimensioni crescenti in termini di numero di rating espressi (M1: subset del dataset di MovieLens, J1 e J2: subset del dataset di Jester).

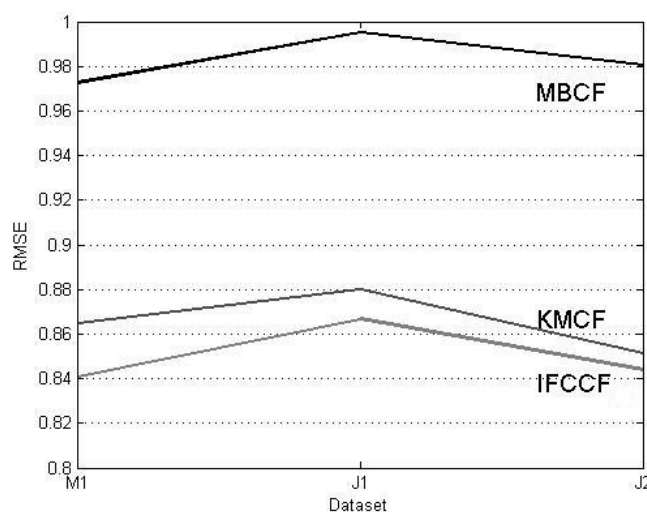


Figura 1: Comparazione metodi Memory-Based e Model-Based

Dal grafico si evince che la tecnica memory-based offre risultati sempre peggiori rispetto alle tecniche model-based. Di seguito quindi, è stato effettuato un confronto delle principali tecniche di clustering applicate al collaborative filtering, ovvero SOM (Self Organizing Map), IFCCF e KMCF.

Sono stati analizzati i parametri dei vari algoritmi proposti, ponendo attenzione alla funzione di similarità adottata e al numero di item considerati in ogni predizione di rating.

La comparazione dei risultati ottenuti utilizzando diverse funzioni di similarità¹ ha confermato la tesi di Jeong, che afferma che la funzione di similarità influenza la qualità della raccomandazione. Sebbene Jeong abbia provato questa tesi per il metodo memory-based, l'analisi condotta ha confermato tale tesi anche per il dominio model-based CF. La correlation similarity sembra essere la migliore similarità tra le tre analizzate. In Figura 2, in Figura 3 ed in Figura 4 si mostrano i valori dell'RMSE ottenuti con i vari metodi proposti utilizzando tre differenti funzioni di similarità: cosine (COS) similarity, adjusted cosine (ACOS) similarity, e Pearson correlation (COR).

¹ Esistono diversi metodi che possono essere utilizzati per calcolare la similarità tra item. Normalmente, $sim(i, j) = 1$ quando $i = j$, mentre negli altri casi $sim(i, j)$ indica la similarità tra gli item i e j .

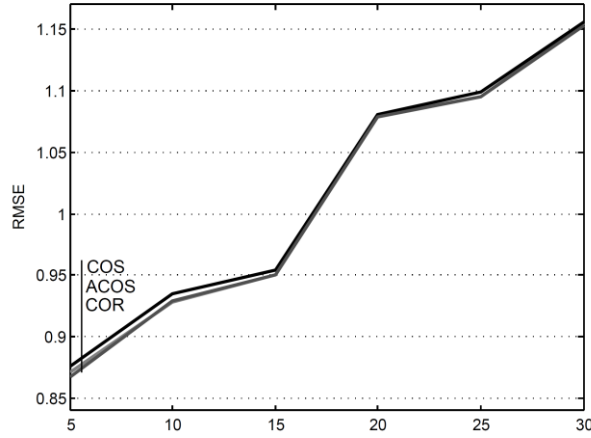


Figura 2: RMSE ottenuto con k-means su MovieLens




Figura 3: RMSE ottenuto con SOM su MovieLens

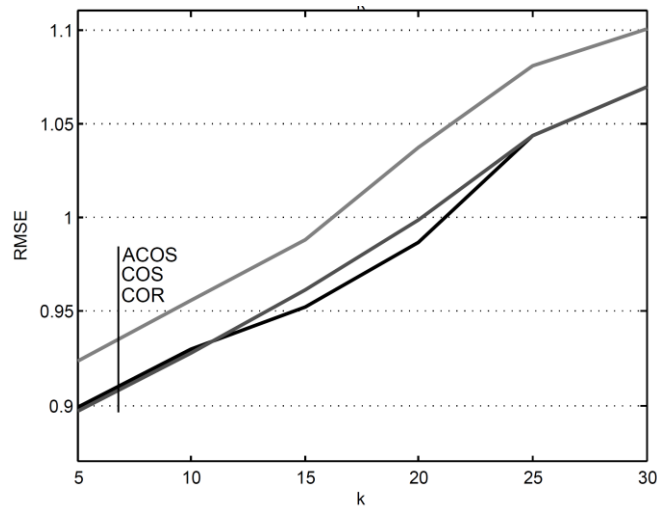


Figura 4: RMSE ottenuto con IFCCF su MovieLens

La Figura 5 mostra come la qualità della raccomandazione migliora all'aumentare del numero di item considerati (t) nell'algoritmo IFCCF. È stato scelto $t = 20$, in quanto rappresenta un buon trade-off tra qualità della predizione e costi computazionali.




Figura 5: RMSE ottenuto con IFCCF al variare di t

Sono stati quindi analizzati i risultati ottenuti con i vari algoritmi IFCCF, SOM e K-means Collaborative Filtering (KMCF).

La Figura 6 e la Figura 7 mostrano i risultati ottenuti con i vari algoritmi IFCCF, SOM e K-means Collaborative Filtering (KMCF), in particolare sono stati confrontati i valori dell'RMSE al variare del numero di cluster. Si mostra come IFCCF offre raccomandazioni che comportano un RMSE minore rispetto a K-means mentre SOM supera K-means in un dataset sparso (MovieLens) ma non in un dataset denso (Jester). In definitiva, si dimostrano significativi benefici in termini di minore RMSE attraverso l'utilizzo di IFCCF (Figura 6) e di SOM (Figura 7). Risultati che confermano gli studi di Jing Wang, Nai-Ying Zhang e Jian Jin, i quali hanno confrontato il Fuzzy C-Means Collaborative Filtering (basato sempre sul raggruppamento degli utenti in cluster) il k-Means Collaborative Filtering ed il memory-based.

Nei confronti eseguiti da tali autori le prestazioni dell'approccio fuzzy risultano essere sempre superiori a quelle del k-Means Collaborative Filtering e del memory-based.

Figura 6: RMSE dei tre algoritmi su Jester





Figura 7: RMSE dei tre algoritmi su MovieLens



Il Content-based filtering, invece, si basa sulle somiglianze tra i prodotti e sulle loro relazioni. L'obiettivo è quello di individuare una classificazione specifica per ogni utente, sulla base dei suoi rating e degli attributi di ogni elemento, in modo da poter suddividere i vari articoli in interessanti e non interessanti. Partendo dall'analisi delle caratteristiche comuni tra gli oggetti che l'utente ha valutato in maniera elevata, l'algoritmo suggerisce solo gli articoli simili alle sue preferenze passate. Nessun tipo di informazione sociale è pertanto richiesto.

Accanto agli algoritmi tradizionali è stato analizzato un approccio ontologico in grado di evitare raccomandazioni su prodotti che l'utente conosce già (overspecialized recommendation). Anziché utilizzare le tradizionali metriche di somiglianza sintattica, la strategia content-based formulata, infatti, inferisce associazioni semantiche tra le preferenze dell'utente ed i prodotti disponibili, formalizzati nell'ontologia di dominio, insieme alle relative descrizioni semantiche. Talune associazioni permettono così di confrontare le preferenze dell'utente con i prodotti in maniera più flessibile, ottenendo come risultato una strategia indipendente dal dominio, che consente di suggerire articoli che interessano realmente i consumatori.

Il Trust-Aware Filtering, invece, sfrutta i legami sociali che si instaurano online tra gli utenti. Le relazioni interpersonali online stanno affermandosi come una delle caratteristiche salienti del Web 2.0, risultando utili anche in aspetti sociali (MySpace, MSN, Facebook), lavorativi (LinkedIn) e informativi (Slashdot.org, Epinions.com) oltre che, ovviamente, commerciali (eBay.com, Amazon.Com). Sebbene questi legami online non sono stabiliti allo scopo di favorire l'*advice taking*, i sistemi di raccomandazione possono sfruttarli per collegare un utente con delle sorgenti di informazioni pertinenti. Un elemento saliente che impatta sul decision making di un utente è la Trust (fiducia): essa rappresenta il grado di fiducia che un utente ripone nella sorgente di una raccomandazione. Il concetto di fiducia include sia la dimensione cognitiva che quella affettiva e viene utilizzato in diversi sistemi di raccomandazione, tra cui Epinions e il sito italiano di scialpinismo Moleskiing.

Le web of trust (reti di fiducia) sono reti per le quali un sistema trust-aware può chiedere ad un utente di valutare altri utenti con i quali egli ha già interagito. Ad esempio Epinions consiglia ai suoi utenti di inserire nella propria web of trust "quei recensori le cui recensioni e rating sono risultate essere estremamente preziose". Esse, pertanto, rappresentano la base dei TaRS (Trust-aware Recommender System), ovvero sistemi che combinano le potenzialità

di un sistema di raccomandazione tradizionale, basato sul collaborative filtering puro, con un sistema trust-aware. I problemi principali di un RS trust-based sono il tempo richiesto agli utenti per definire esplicitamente le loro relazioni online e, soprattutto, il numero ridotto di link sociali definiti dagli stessi che risulta in una scarsa qualità delle raccomandazioni.

Tra le altre strategie di raccomandazione si distinguono le regole associative, in grado di individuare il livello di confidenza con cui una certa percentuale di utenti acquisterà un prodotto Y, avendo acquistato X; il demography-based filtering che, partendo da una classificazione degli utenti, basata sulle informazioni personali, effettua le raccomandazioni sfruttando i dati demografici ed infine, il knowledge-based filtering che effettua raccomandazioni a partire dai bisogni e dalle preferenze dell'utente e non dai rating a disposizione.

Un confronto dei vantaggi/svantaggi offerti dai diversi approcci di raccomandazione è di seguito mostrato:

Tecnologia di raccomandazione	Vantaggi	Svantaggi
<i>Collaborative filtering</i>	Miglioramento delle performance nel tempo; raccomandazioni personalizzate; elevato grado di automazione; non necessita della conoscenza del dominio; trattamento di oggetti complessi non strutturati.	Cold start problem; sparsity problem; problemi relativi all'introduzione di nuovi utenti; la qualità dipende dal dataset storico; la qualità iniziale delle raccomandazioni è bassa.
<i>Content-based filtering</i>	Raccomandazioni intuitive, facili da spiegare; non necessita della conoscenza del dominio.	Sparsity problem; analisi scarna degli attributi più complessi; problemi relativi ad i nuovi utenti.
<i>Trust-aware filtering</i>	Sfrutta il concetto di fiducia per effettuare raccomandazioni; può essere integrato con il collaborative filtering	Tempo richiesto agli utenti per definire esplicitamente le loro relazioni online ; scarsa qualità delle raccomandazioni.
<i>Mining associate rules</i>	Trova nuovi spunti di interesse; non richiede la conoscenza del dominio.	L'estrazione di regole associative è complicata; problemi relativi ai sinonimi dei nomi dei prodotti; basso grado di personalizzazione.
<i>Demography-based filtering</i>	Rintraccia nuovi interessi; non presenta problemi legati ad i nuovi utenti; non richiede la conoscenza del dominio.	I dati demografici dell'utente sono utili all'informazione statistica.
<i>Knowledge-based filtering</i>	Mappa i bisogni degli utenti; considera anche attributi non legati al prodotto.	È difficile reperire informazione; le raccomandazioni sono statiche.

Tabella 1: Confronto vantaggi/svantaggi delle principali tecnologie di raccomandazione

Inoltre, nell'ambito dei sistemi di raccomandazione di gruppo, che hanno l'obiettivo di formulare suggerimenti per gruppi di persone, è stato analizzato l'approccio proposto da Luis M. de Campos, Juan M. Fernández-Luna, Juan F. Huete e Miguel A. Rueda-Morales in "Group Recommending: A methodological Approach based on Bayesian Networks". L'obiettivo dell'articolo è quello di sviluppare una metodologia generale, basata sul formalismo delle reti bayesiane (BN), per modellare le incertezze che appaiono nelle interazioni tra i membri di un gruppo ed i processi che portano alla raccomandazione finale.

Bisogna però considerare che, in generale, a causa della struttura del sito, della complessità dei contenuti e del numero crescente di utenti, gli algoritmi di raccomandazione di e-commerce sono soggetti a diverse problematiche, quali la presenza di matrici sparse, la scalabilità, il cold start problem e la preservazione della privacy.

I siti di e-commerce, solitamente, presentano un gran numero di prodotti, e talvolta la percentuale di rating assegnati è molto piccola se confrontata con quella che il sistema si trova a dover predire. Di conseguenza le matrici che devono essere gestite sono solitamente sparse. Ad esserne affetto in modo particolare è il collaborative filtering, per il quale, se due utenti non hanno valutato gli stessi oggetti, pur essendo simili negli interessi manifestati, il sistema non è in grado di calcolare la somiglianza tra loro e pertanto non è possibile fare raccomandazioni.

Dall'altro lato, un'eccessiva presenza di dati è comunque fonte di problematiche dal momento che un incremento importante dei dati registrati nel database di riferimento può tradursi in un incremento esponenziale della complessità computazionale. Pertanto, la scansione dell'intero database può portare ad un marcato declino delle performance del sistema di raccomandazione, sollevando il cosiddetto problema della scalability (scalabilità).

Il problema della cold start, invece, si verifica quando un nuovo utente o prodotto è aggiunto al sistema. In tal caso effettuare raccomandazioni risulta essere problematico o addirittura impossibile. Infine la privacy e gli strumenti posti in essere per la tutela ed il rispetto della riservatezza dell'utente è un problema tipico degli anni recenti. A conferma di ciò, Netflix ha recentemente chiuso il database che metteva a disposizione della community per lo sviluppo di algoritmi di raccomandazione sempre più performanti. Infatti, nell'ambito di Netflix Prize, venivano confrontati i diversi algoritmi presentati dai diversi centri di ricerca che aderivano alla competizione e veniva premiato l'algoritmo che migliorava l'accuracy delle predizioni dei rating di almeno il 10%.

Testing delle performance degli algoritmi di raccomandazione

Ai fini della valutazione finale di un sistema di raccomandazione, risulta particolarmente interessante comprendere fino a che punto esso sia in grado di soddisfare una specifica esigenza e quindi determinare la qualità delle raccomandazioni fornite, confrontandole con quelle degli altri sistemi esistenti.

In generale, il problema del rilascio di un'esperienza efficace e soddisfacente si traduce nella necessità di generare raccomandazioni non soltanto precise ma anche rispondenti a criteri di usefulness (utilità). A tal proposito, sono state rintracciate una serie di metriche che permettono di verificare e quantificare la bontà dei suggerimenti inoltrati all'utente:

- Accuracy. Le metriche basate sull'accuracy misurano empiricamente quanto un ranking predetto si discosti da uno reale: in pratica esse stimano quanto bene sia stata predetta la classifica di gradimento dell'utente. Herlocker et al. hanno individuato tre classi di metriche di accuracy: predittive (ad es. l'errore assoluto medio (MAE), che considera la somma delle differenze tra i rating reali assegnati dagli utenti e quelli predetti e la divide per il numero di oggetti considerati), di classificazione (ad es. la precision, che è definita come il rapporto tra gli oggetti rilevanti suggeriti dal sistema ed il numero totale di oggetti suggeriti) e basate sui rank (ad es. la Half-life Utility Metric, che stima l'utilità attesa di una lista ordinata per un utente).

- Coverage (copertura). È la misura della percentuale di oggetti per la quale il sistema di raccomandazione può effettuare predizioni o fornire raccomandazioni. Può essere misurata prendendo dal dataset un campione casuale di coppie utente-oggetto e chiedendo all'RS di fornire una raccomandazione per ognuna, ma non può essere considerata indipendentemente dall'accuracy.
- Confidence. Indica quanto il sistema è sicuro della precisione di una raccomandazione.
- Diversity (diversità). È generalmente definita come l'opposto della similarity (similarità). Talvolta, suggerire un set di oggetti simili potrebbe non essere utile all'utente. Il metodo più utilizzato per misurare la diversity sfrutta la item-item similarity che calcola la diversity di una lista sulla base delle somme, medie, minimi o massimi delle distanze tra coppie tra oggetti, o misura il valore che si ha aggiungendo un oggetto ad una lista di raccomandazioni preesistente.
- Learning rate (tasso di apprendimento). È una misura di quanto velocemente un algoritmo riesca a fornire "buone" raccomandazioni. Poiché la qualità delle raccomandazioni non può crescere indefinitamente, il learning rate può essere descritto da funzioni asintotiche. Inoltre esso rappresenta un importante indicatore della capacità di un sistema di raccomandazione di affrontare il problema della cold start.
- Novelty e Serendipity. La prima rappresenta la capacità del sistema di raccomandare all'utente oggetti che non conosce, mentre la seconda esprime la capacità di essere di aiuto all'utente nel trovare oggetti sorprendentemente interessanti che non avrebbe potuto scoprire altrimenti
- Robustness (robustezza). Rappresenta la stabilità della raccomandazione in presenza di false informazioni, tipicamente inserite coscientemente da alcuni utenti in modo da influenzare le raccomandazioni.
- Adaptivity (adattività). È il tasso al quale il sistema si adatta alle preferenze personali dell'utente, o ai cambiamenti nel suo profilo.
- Utility. In generale, è possibile definire vari tipi di funzioni di utility (utilità) che il sistema di raccomandazione deve ottimizzare, che possono essere più significativi dell'accuracy stessa. La utility rappresenta quindi il valore che il sistema o l'utente guadagnano dalla raccomandazione.
- User satisfaction. È definita come il grado nel quale un utente è supportato nell'affrontare il problema del sovraccarico di informazioni. Tutte le metriche descritte nelle precedenti sezioni in qualche modo aiutano o inibiscono la user satisfaction.

Per poter invece condurre la sperimentazione di nuovi algoritmi di raccomandazione e confrontare le prestazioni con quelle degli algoritmi già esistenti, risulta molto comune l'utilizzo di dataset pubblici. Particolarmente utilizzata a tale scopo è, ad esempio, la cross-validation, che suddivide randomicamente il dataset in un training set, utilizzato per costruire il modello, ed in un test set, che serve a confermare e validare l'analisi iniziale.. In generale, i dataset possono contenere feedback impliciti o espliciti, che vengono rilasciati dall'utente in diverse forme, tramite rating, misure di interesse e dati di utilizzo. Ad esempio, nel caso dei sistemi di collaborative filtering i feedback sono i voti che l'utente rilascia per un articolo visionato, mentre per i sistemi di raccomandazione content-based essi sono recensioni o semplici tag espressi sui prodotti. Tra i dataset espliciti più estesi ed utilizzati in letteratura

figurano MovieLens (per i film), Jester (per le barzellette), Book-Crossing (per i libri), FilmTrust (per i film) e Netflix (per i film).

Infine, per completezza, sono state confrontate le caratteristiche di diversi framework disponibili allo stato dell'arte per l'implementazione di un sistema di raccomandazione.

Framework	Anno	Licenza	Linguaggio	Algoritmi di RS	Altri algoritmi
Apache Mahout v0.4	2010	Apache Software license	Java	Item-based CF	Clustering (k-Means, fuzzy k-Means, Canopy, Dirichlet, Mean-Shift, Spectral e MinHash) Classificazione (Naive Bayes, Vector Model, Stochastic Gradient Descent)
Duine Framework	2009	GNU LGPLv3	Java	User Average, Already Known, Top-N Deviation, Collaborative Filtering, Information Filtering, Case-Based Reasoning, Interest LMS	Algoritmi di validazione delle tecniche di raccomandazione
MyMedia Lite v0.10	2011	GNU GPL	C#	CF, Content-Based Filtering	kNN, Algoritmi di stima della prediction accuracy
MultiLens	2002	GNU GPL	Java	Automated CF	kNN User-Item, kNN Item-Item
Suggest v1.0	2000	GNU GPL	Ansi C	Top-N User-based CF Top-N Item-based CF	-
EPOQ	2010	GNU GPL		CF	Integrazione con Magento
Easyrec v0.95	2011	GNU GPL	Java	Other users also viewed, Other users also bought, Items rated good by other users, Related items	Community Rating (most viewed items, most bought items, most rated items, best rated items, worst rated items)

Tabella 2: Confronto principali librerie per sistemi di raccomandazione

Apache Mahout, Duine Framework, MultiLens ed Easyrec sono le principali librerie analizzate in ambiente Java. Tali librerie implementano diversi algoritmi a supporto dei sistemi di raccomandazione: dal tradizionale CF item-based ad algoritmi di tipo content. A supporto delle raccomandazione di tipo model-based Apache Mahout implementa algoritmi di classificazione e clustering, mentre per superare le problematiche legate al cold start-up, Duine ed Easyrec implementano strategie di predizioni alternative come ad esempio quelle basate sulla popolarità degli oggetti (Top-N Deviation o Most viewed items, Most bought items, Most rated items, Best rated items), che per quanto possano essere non accurate, come altre tecniche di predizione più complesse, permettono sempre di effettuare raccomandazioni. Infine, l'architettura della libreria di MultiLens offre la possibilità di effettuare raccomandazioni on-line attraverso il modulo Compute Recommendations.

Generazione e composizione automatica di pacchetti di offerta

Per un sistema di e-Commerce la capacità di gestire la creazione di pacchetti di prodotti personalizzati, i cosiddetti bundle, può risultare particolarmente utile ai fini del



InViMall - Intelligent Virtual Mall
Progetto MSE MI01 – 123

soddisfacimento delle esigenze dei consumatori. Grazie alla convenienza del commercio online, infatti, gli utenti di un sito di eCommerce sono spesso tentati dall'idea di acquistare più prodotti contemporaneamente, ma nella pratica si trovano confusi e rallentati dall'ingente varietà di prodotti e di informazioni disponibili. La creazione di bundle, bundling problem, rappresenta pertanto una strategia valida, in quanto si propone l'individuazione di una configurazione ottimale, interpretabile sia dalla prospettiva del fornitore, suggerendo ad esempio la composizione con il più alto margine di profitto, e sia dalla prospettiva dell'acquirente, proponendo il bundle di prodotti che meglio risponde alle preferenze ed esigenze personali del cliente.

In generale, le strategie perseguibili sono due: si può decidere di approcciare al cosiddetto product bundling, che prevede l'integrazione e vendita di due o più prodotti separati ad un prezzo unico, o al price bundling, che invece consiste nell'offerta di un pacchetto ad un prezzo scontato, senza alcuna integrazione tra i prodotti. Un'ulteriore distinzione vede la suddivisione in pure bundling, in cui la vendita è vincolata esclusivamente ai bundle e non ai prodotti separatamente, ed in mixed bundling in cui invece essa è rivolta congiuntamente a bundle e prodotti individuali. Per quanto concerne la generazione di bundle, è possibile scegliere tra un approccio esplicito ed uno implicito. Il primo, adottato ad esempio dalla piattaforma Magento, prevede che la creazione dei bundle sia gestita direttamente dal venditore che crea in maniera esplicita gli abbinamenti dei prodotti, secondo criteri di compatibilità propri. Per quanto riguarda, invece, la generazione automatica, allo stato dell'arte, esistono tre tecniche principali: CSP problem, knowledge based bundling, web-based collaborative filtering.

Il problema del bundling di prodotti può, infatti, essere formulato come un Constraint Satisfaction Problem (CSP), il quale è definito da una tupla $\langle X, D, C \rangle$, dove $X = \{x_1, \dots, x_n\}$ è un insieme di variabili di interesse, $D = \{d_1, \dots, d_n\}$ è un insieme di variabili di dominio corrispondenti e $C = \{c_1, \dots, c_m\}$ è un insieme di constraint, che restringono gli assegnamenti validi alle variabili, in maniera più o meno stringente, a seconda che essi siano soft o hard. I primi possono anche essere violati, ma va considerato che ad ogni violazione sono associati dei penalty values, la cui somma deve essere minimizzata quando si è alla ricerca della soluzione ottimale. Gli hard constraint, al contrario, non ammettono violazioni. È dunque questo l'approccio impiegato da Markus Zanker, Markus Aschinger e Markus Jessenitschnig in "Constraint-based personalized bundling of products and services", per implementare un constraint-based Web configurator, dall'architettura service-oriented, capace di esplorare le preferenze dell'utente ed indirizzarlo efficacemente verso la soluzione di bundle ottimale. L'intero processo risulta separato in una fase di progetto, nella quale il modello è definito e gestito, ed una di esecuzione, demandata alla Java Choco Open Source constraint library, che ha la funzione di trovare la giusta assegnazione a tutte le variabili del modello che non violi nessun hard constraint e minimizzi i penalty values. Tale strumento è in grado di seguire due differenti strategie per il calcolo dei bundle di prodotto. La prima è detta 1-different ed assicura che ogni tupla nell'insieme di n soluzioni contenga almeno un'istanza di prodotto differente da tutte le altre soluzioni. L'altra, invece, chiamata all-different garantisce che l'intersezione tra due bundle sia vuota, ossia una istanza di prodotto può essere parte di una sola tupla. Il sistema consente, comunque, all'utente una costante interazione, in quanto quest'ultimo può tanto accettare una soluzione quanto richiedere una nuova configurazione e può fornire dei feedback accettando esplicitamente o rigettando alcune componenti del bundle proposto che si traducono in constraint che vengono aggiunti

al processo. Le due strategie sono messe a confronto in un esempio che costruisce creati 5 differenti CSP model di dimensione crescente.

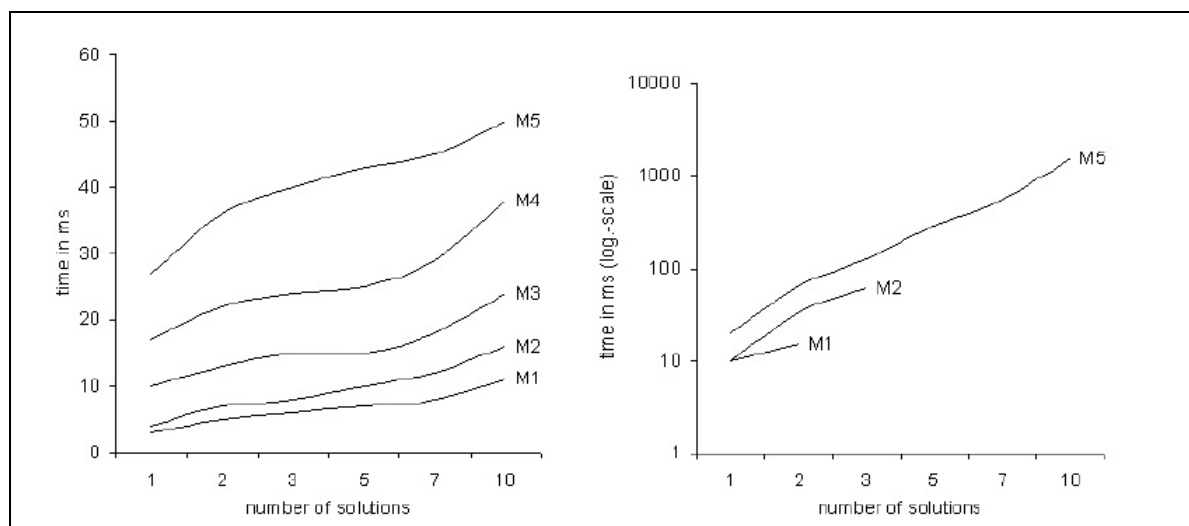


Figura 8: Confronto tra due strategie di product bundling, 1-different e all-different

I tempi della strategia all-different sono rappresentati in scala logaritmica, omettendo per leggibilità i risultati di M3 e M4, e sono significativamente più lunghi della strategia 1-different, che, essendo meno complessa, ha tempi non superiori ai 50 ms. Tuttavia, le performance della prima sono ancora soddisfacenti. Il valore più alto del modello M5 è stato ottenuto in circa 1.5 secondi per dieci soluzioni, pertanto se, generalmente, in un tipico scenario di e-commerce si richiedono al massimo 10 suggerimenti di bundle di prodotto, seguendo l'approccio proposto, 100 tuple sono ottenibili come soluzione entro un periodo di tempo accettabile.

Un secondo approccio perseguibile è quello del knowledge-based bundling introdotto da Tobias Kowatsch, Wolfgang Maass, Andreas Filler e Sabine Janzen e definito come la vendita di due o più prodotti separati a partire dalla conoscenza dell'oggetto stesso e del contesto. Tale approccio è stato applicato dagli autori a prodotti di tipo smart, ossia ad oggetti dotati di informazioni proprie dettagliate ed in grado di riconoscere il contesto di appartenenza attraverso l'informazione tecnologica incorporata. Gli smart product sono, in questo caso, provvisti di RFID tag per identificarli ed inviare l'informazione relativa ad un'interfaccia di prodotto dinamica. Quest'ultima, quando l'RFID tag di un prodotto è scansionato da un consumatore, informa il Tip'n Tell web service (Java & Axis2), il quale gestisce i dati utilizzando un framework semantico (Jena2) per consentire all'utente di porre domande sul prodotto e sulle relazioni con altri oggetti come accessori. Il vantaggio è che, ad esempio, ad un utente che richiede un dispositivo smart di navigazione mobile potranno essere rapidamente suggeriti diversi accessori compatibili.

Una diversa strategia di costruzione dei bundle si basa su un meccanismo web-based del collaborative filtering, che genera bundle di prodotti e raccomanda gli N elementi in vetta alla lista (raccomandazioni top-N), raggruppando gli utenti con attributi e comportamenti simili mediante una rete ART, ed individuando le relazioni tra i prodotti tramite regole associative. Queste ultime vanno a ad instaurare relazioni tra coppie di insiemi nell'intero transaction database, in maniera tale che la preferenza per i prodotti di un insieme implica la preferenza

per quelli dell'insieme ad esso associato. Infine, viene attuata una strategia di product bundling in accordo alle vendite. Sulla base di queste, infatti, ogni prodotto può innanzitutto essere classificato come hot sale, general sale o dull sale e le diverse categorie possono essere incrociate o meno, a seconda della specifica strategia impiegata. Pertanto, un articolo hot sale può essere allocato in un bundle con uno di tipo dull sale, oppure due general sale possono comporre insieme il bundle, e così via.

L'algoritmo è stato infine sperimentato sul database FoodMart 2000 Microsoft SQL, che ha fornito i dati di vendita di e-Commerce, raccolti dal 1 Gennaio 1997 al 30 Giugno 1997. Utilizzando regole di associazione e strategie di bundling a ciascun utente si forniscono i top N oggetti raccomandati. I risultati ottenuti sono stati confrontati con quelli forniti dall'approccio tradizionale ed complessivamente è stata quantificata una probabilità di vincita della strategia proposta pari a 0,6748.

Siti e piattaforme di eCommerce

L'attività di scouting sui siti web che praticano il commercio online ha evidenziato la presenza di diverse soluzioni che offrono funzionalità di selezione personalizzata e raccomandazione. In particolare sono stati analizzati quattro tra i siti web che sembrano riscuotere più successo in ambito di e-commerce: Youtube, Amazon.com, Netflix e Yahoo! Music. Nello specifico, Youtube implementa un algoritmo di raccomandazioni personalizzate di tipo item-based CF e si rivolge sia agli utenti registrati che a quelli non registrati, seppur per questi ultimi la qualità delle stesse sia minore, poiché è chiaramente minore la quantità delle informazioni che ha a disposizione su gusti e preferenze. Amazon.com implementa lo stesso tipo di algoritmo e fornisce raccomandazioni non personalizzate basate sul CF sia agli utenti registrati che a quelli non registrati (Customers Who Bought This Item Also Bought): le raccomandazioni personalizzate, invece, sono proposte solo agli utenti registrati e che hanno acquistato/valutato positivamente almeno un prodotto. Netflix implementa CineMatch, un algoritmo di item-based CF, per fornire ai suoi utenti raccomandazioni personalizzate (chiamate Suggestions o Movies You'll Love) riguardo i film da noleggiare o guardare in streaming. A differenza degli altri due siti, Netflix impone ai suoi utenti, all'iscrizione, di valutare 20 film tramite la classica scala da 1 a 5 stelle, in modo da poter effettuare sin da subito suggerimenti di buona qualità. Infine, Yahoo.com offre ai suoi utenti un sistema di raccomandazioni personalizzate, implementato in Yahoo! Music. L'utente registrato può valutare tramite la classica scala di valori da 1 a 5 stelle ogni video musicale, canzone, album o artista presente nel database, ricevendo raccomandazioni per ciascuna delle quattro categorie. A valle del confronto tra i siti, è interessante notare come essi siano caratterizzati da punti di forza e di debolezza molto simili. I primi sono rappresentati dal comune utilizzo di algoritmi di tipo item-based CF, che, partendo dalla somiglianza tra prodotti, fornisce suggerimenti soddisfacenti anche in presenza di un numero limitato di rating assegnati da un utente, al contrario di ciò che avviene per lo user-based CF. Analogamente un fattore comune che appare influenzare la qualità delle raccomandazioni è la registrazione utente. Nei casi in cui questa manca, la bontà dei suggerimenti scende più o meno drasticamente.

Nome	Anno	Prodotti	Raccomandazioni per utenti non registrati	Costi	Algoritmo di RS
Amazon .com	1994	Libri Elettronica Alimentari Prodotti per la casa	Parziale	Nessuno	Item-based CF
Youtube	2005	Video	Si	Nessuno	Item-based CF
Netflix	1997	Streaming Video Noleggio DVD e Blu-ray	No	Canone mensile (streaming)	Item-based CF
Yahoo! Music	1995	Musica	No	Nessuno	Info non disponibile

Tabella 3: Confronto dei principali siti che forniscono un sistema di RS

Infine, si è proceduto con lo scouting delle piattaforme di e-Commerce che presentano caratteristiche interessanti e tematiche pertinenti al progetto InViMall. Dall'analisi condotta ATG Commerce, Fry e PosteCommerce si sono dimostrate 3 piattaforme attive sul mercato, ognuna con una spiccata funzionalità di interesse per il progetto InViMall. La prima infatti si afferma per le funzionalità di personalizzazione, la seconda per quelle di usabilità e la terza per quelle di profilazione.

In particolare, ATG Commerce è una piattaforma in grado di customizzare l'esperienza del consumatore, supportando diverse categorie di personalizzazione online: esplicita (sfrutta l'informazione esplicita racchiusa nei profili dei visitatori e condivisa); implicita (utilizza il comportamento esibito, i clickstream correnti e le passate interazioni dell'utente); multi-stage (aggiunge una dimensione temporale che consente di coinvolgere, monitorare e comunicare con i clienti, durante il processo di decisione e successivamente all'acquisto); predittiva (consente di rilasciare in maniera automatica raccomandazioni intelligenti e vendite più efficienti del tipo cross-sell ed up-sell). La piattaforma dispone, inoltre di un motore predittivo ed automatizzato, l'ATG Recommendations, che suggerisce i prodotti più rilevanti del catalogo per ogni acquirente. Bilanciando la rilevanza predittiva con il controllo del merchant, esso seleziona in maniera automatica gli articoli che soddisfano congiuntamente i bisogni correnti dell'utente e quelli di business, presentandoli sul canale più opportuno e dimostrandone l'impatto positivo sulle performance. Il risultato consiste in una più alta conversione dei visitatori in acquirenti, nell'incremento dei volumi delle ordinazioni, nel consolidamento della fidelizzazione e degli acquisti ripetuti ed in una maggiore efficienza ed affidabilità. Le peculiarità della piattaforma Fry risiedono, invece, nell'alto grado di usabilità da cui è contraddistinta. Creata al fine di essere facilmente usata e gestita da persone che non fossero ingegneri specializzati, Fry si basa, infatti, su un toolset, che è stato progettato e disegnato da esperti di usabilità. La piattaforma in questione presenta a tal proposito numerosi metodi di analisi e di testing dell'usabilità, tra cui Expert Heuristic Evaluation, Formal Usability Testing, Guerrilla Usability Testing e Prototype Testing. PosteCommerce, infine, offre funzionalità di personalizzazione che si esplicano nella creazione di cataloghi di prodotti che vengono associati a gruppi di utenti, definiti sulla base delle caratteristiche di profilo, dei comportamenti di acquisto o per scelta del merchant.

Legenda: ✓ = Elemento presente ; ✗ = Elemento non presente; - = Elemento non specificato

Nome	Descrizione	Usability Testing	User Profiling	Intelligent Recommendation	User wish list	Other features
ATG Commerce	Piattaforma J2EE multi-channel di e-Commerce component-based e scalabile in grado di automatizzare l'esperienza dei clienti on-line.	✓	✓	✓	✓	4 categorie di profilazione online: Explicit, Implicit, Multi-stage, Predictive Natural Language Processing
FRY	Open Commerce Platform J2EE-complaint flessibile scalabile e robusta	✓	✓	-	✓	Cross-selling, up-selling
PosteCommerce	Piattaforma di e-Commerce basata su tecnologia Microsoft con moduli aggiuntivi per la creazione di vetrine personalizzate	✗	✓	✗	✓	Creazione dei Catalog Set (viste logiche sui suoi cataloghi) Definizione e gestione di gruppi di utenti
Commerce Server	Multi-layer framework Microsoft per la progettazione di sistemi di e-Commerce basata su tecnologia .NET e secondo una architettura modulare	-	✓	-	✓	Filtro per la selezione personalizzata dei contenuti pubblicitari (Content Selection Framework) Cross-selling, up-selling
iCongo	Piattaforma cross-channelling per la ricerca e la catalogazione di prodotti di e-Commerce	✗	✓	✗	✓	Interactive Selling, Mobile Commerce
Elastic Path	Java e-Commerce platform sviluppato con metodologia Agile.	✗	✓	-	✓	Web Service approach per la riduzione dei costi
Magento	eCommerce Platform in differenti versioni (Open source ed Enterprise)	✗	✓	✗	✓	Ordinamento degli utenti, Mobile Commerce, Bundling manuale
ZenCart v1.3.9d	e-Commerce application sviluppata da Zen Cart Community	✗	-	✗	-	Gestione dei clienti e differenziazione dei prodotti
Cubecart v.4	Open Source Platform basato su tecnologia PHP e MySQL	✓	✗	-	✗	Prodotti correlati basati sullo storico degli ordini
Lite Commerce	Soluzione Open source PHP/MySQL	✗	✗	✗	✓	Generazione automatica delle icone dei prodotti

OsCommerce	Soluzione di e – Commerce Open source	-	*	*	*	Breadcrumb
VirtuMart	Soluzione Open source (estensione di Joomla)	*	✓	*	*	Shopper Groups

Tabella 4 - Confronto piattaforme di e-Commerce in riferimento alle tecniche di selezione e personalizzazione.

Conclusioni

L'analisi condotta nel deliverable "**D-C.1_1 Analisi critica delle metodologie e tecniche di selezione e composizione personalizzata per l'e-commerce**" ha consentito l'identificazione di una serie di aspetti innovativi che saranno oggetto di sperimentazione per la piattaforma InViMall. L'analisi critica condotta è stata incentrata sull'indagine di strumenti ed algoritmi per la selezione dei prodotti e la composizione personalizzata dell'offerta in ambito e-Commerce.

All'interno delle tecniche di selezione è stata data particolare enfasi al Collaborative Filtering, con le relative specializzazioni, al Content-Based Filtering, al Trust-Aware Filtering, al Mining Associate Rules, al Demography-Based Filtering ed al Knowledge-Based Filtering. Dal relativo confronto si è evinto come il collaborative filtering consenta di ottenere in generale performance migliori pur restando affetto da problemi di tipo cold start e di tipo sparsity.

Relativamente alle tecniche di collaborative filtering sono stati confrontati approcci model-based ed approcci memory-based, analizzando nel dettaglio le diverse strategie per la predizioni dei rating. L'analisi critica condotta è stata sottomessa ed accettata dal comitato tecnico scientifico IEEE. I lavori di ricerca dal titolo "Improving accuracy of recommendation system by means of Item-based Fuzzy Clustering Collaborative Filtering" e "Personalized Suggestions by means of Collaborative Filtering: A Comparison of two different Model-based Techniques" sono disponibili rispettivamente nei *Proceeding of 3rd World Congress on Nature and Biologically Inspired Computing (NaBIC 2011)* e nei *Proceeding of 11th International Conference on Intelligent Systems Design and Applications (ISDA 2011)*.

Inoltre, poiché per i sistemi di raccomandazione i database ed i framework rappresentano la base per la generazione di suggerimenti, sono stati analizzati e messi a confronto i più importanti database esistenti, tra cui MovieLens, Jester, e Netflix, nonché i principali strumenti open source per il testing delle performance degli algoritmi come Apache Mahout, Duine Framework, MultiLens ed Easyrec. Dal primo confronto si è evinto che i dataset, come Jester, le cui distribuzioni di rating non seguono l'andamento tipico della Zipf's law permettono di registrare valori di MAE, recall e rating coverage migliori che si riflettono sulle performance del sistema. Il confronto tra framework, invece, è consistito nell'individuazione degli algoritmi specifici implementati a supporto dei sistemi di raccomandazione, dal tradizionale CF item-based ad algoritmi di tipo content. L'analisi ha quindi permesso di evidenziare le caratteristiche peculiari di ognuno dei framework: Apache Mahout implementa algoritmi di classificazione e clustering a supporto delle raccomandazioni di tipo model-based, Duine ed MyMedia Lite implementano strategie di predizioni alternative per superare le problematiche legate al cold start problem, mentre MultiLens permette di effettuare raccomandazioni on-line attraverso il modulo Compute Recommendations.



InViMall - Intelligent Virtual Mall
Progetto MSE MI01 – 123



Sono state analizzate, inoltre, le tecniche di generazione e composizione automatica dell'offerta con particolare attenzione al bundling problem, di cui sono stati mostrati gli approcci espliciti, già implementati da Magento, ed impliciti, presenti allo stato dell'arte. Ulteriori approcci come Sistemi Esperti, programmazione logica e algoritmi evolutivi, pur affrontando problematiche affini, non presentano implementazioni specifiche per tale problematica. Tuttavia potrebbero essere perseguibili dato che si prestano alla risoluzione di problemi di ricerca di soluzioni ottimali in presenza di constraint. A conclusione del documento sono state introdotte le principali piattaforme di e-Commerce esistenti sul mercato, evidenziando le caratteristiche di maggior interesse per le tematiche di ricerca affrontate. Dall'analisi condotta ATG Commerce e Fry (entrambe basate su un'architettura J2EE) si sono dimostrate le due piattaforme di maggiore interesse grazie alle funzionalità relative alla personalizzazione ed all'usabilità.

Tra gli elementi innovativi individuati, nell'ambito del progetto saranno previste funzionalità di profilazione, esplicita ed implicita, e verranno sperimentati i relativi approcci ontologici. Nell'ambito delle tecniche di selezione, verranno confrontate diverse varianti dell'algoritmo item-to-item collaborative filtering, con l'aggiunta di un pre-processing basato su differenti algoritmi di clustering, al fine di fornire un miglioramento in termini computazionali ed in termini di qualità del risultato. Infine, saranno previste funzionalità di product bundling esplicito ed implicito.