


Il progetto riguarda l'uso dei trie per la memorizzazione efficiente di dataset transazionali da analizzare in applicazioni di datamining. La realizzazione del trie si articola mediante sei classi java: *Item*, *FrequencyVector*, *HashTable*, *Quicksort*, *Node*, *Trie*, *TrieBuild*.

ANALISI DELLE CLASSI:

- ❖ *Item*: la classe item costruisce un oggetto con le caratteristiche di valore e frequenza. I metodi presenti in questa classe sono semplici metodi per:
 - restituire il parametro salvato nella variabile come i metodi: *tDato()*, *tFrequency()*
 - inserire il dato o la frequenza dall'esterno come i metodi: *insertDato()*, *insertFrequency()*
 - aggiornare la frequenza come il metodo *adFrequency* che aumenta la frequenza di una unità.
- ❖ *FrequencyVector*: ha lo scopo di implementare un vettore di *Item* mediante l'uso del metodo *insert* che riceve come parametro di ingresso un intero, e come parametro di uscita un array di *Item*.
 - Il metodo *insert* verifica che l'intero ricevuto come parametro di ingresso non sia presente nel vettore. Se è presente aggiorna la sua frequenza e termina il ciclo restituendo il vettore di item. In caso non fosse presente inserisce il nuovo elemento nell'ultima posizione indicata dall'indice, settando la frequenza a 1.
 - Anche questa classe prevede alcuni metodi necessari per accedere al contenuto del vettore.

- ❖ *Nodo*: la seguente classe implementa la struttura dei nodi del trie. I nodi sono costituiti da quattro parti:

- 1) Contiene un item
- 2) Contiene la referenza al fratello
- 3) Contiene la referenza al figlio
- 4) Contiene la referenza alla tabellahash dei figli



All'interno di questa classe sono presenti i soliti metodi

per accedere al contenuto delle varie parti del nodo quali il valore dell'item e della frequenza. Il metodo aggiuntivo riguarda la ricerca tra i fratelli, necessario nella classe *Trie* per verificare se un item è già presente tra i fratelli. Questo metodo ha come parametro di ingresso un item, scorre tutti i fratelli e se lo trova restituisce il nodo contenente l'item cercato, altrimenti restituisce l'ultimo della lista.

- ❖ *HashTable*: implementa i metodi principali per la realizzazione di un trie mediante hash table, con risoluzione delle collisioni mediante *SEPARATE CHAINING*. I metodi principali presenti sono:
 - *searchItem*: questo metodo ha come parametro di ingresso un item *v*, mentre ha come parametro di ritorno un nodo, con referenza a null se non è presente un nodo contenente l'item *v* altrimenti restituisce il nodo contenente *v*.
 - *InsertH*: questo metodo riceve come parametro di ingresso un nodo e prima di procedere con l'inserimento verifica che la Load Factors non superi il limite massimo di 1/2. Se la supera tale valore esegue il metodo di *resize*, altrimenti calcola la chiave del bucket in cui inserire il nuovo nodo. Se la locazione del bucket è vuota inserisce il nodo, altrimenti, se il bucket contiene già dei nodi scorre tutta la lista per inserire il nodo alla fine.
- ❖ *QuickSort*: questo algoritmo si basa sulla strategia "dividi e conquista". Per ordinare una porzione *a[from]...a[to]* dell'array *a*, si dispongono dapprima gli elementi in modo tale che nessun elemento della porzione *a[from]...a[p]* sia maggiore di elementi dell'altra porzione *a[p+1]...a[to]*. Questo passo viene detto *suddivisione* della porzione. Al passo successivo viene

ordinata ciascuna porzione di a applicando ricorsivamente lo stesso algoritmo alle due porzioni. Ciò ordina l'intera porzione originaria. All'interno della classe QuickSort sono presenti anche i metodi orderDecrescente e orderCrescente. Il primo prevede l'ordinamento degli Item in base alla frequenza decrescente(dall'item di frequenza maggiore a quello di frequenza minore), mentre il secondo prevede l'ordinamento contrario, cioè in ordine crescente.

- ❖ *Trie*: questa classe è la più importante in quanto implementa i due metodi principali per la costruzione del trie mediante struttura linkata e mediante hash table.
 - Il metodo *insert* è il metodo che implementa la costruzione dell'albero mediante struttura linkata. Questo metodo riceve i seguenti parametri di ingresso: 1) un array di item, che contiene la stringa letta dal file e ordinata per frequenza; 2) un intero *i*; 3) un nodo *n*. Ad ogni iterazione l'algoritmo prevede di verificare se il nodo da cui parte la generica iterazione ha figli. Se il nodo non ha figli costruisce un nuovo nodo contenente l'item *a[i]*, altrimenti verifica se il figlio contiene l'item cercato. Se lo contiene, passa all'item *a[i+1]* oppure cerca tra i fratelli del nodo *n*. Se trova l'item tra i fratelli passa ad *a[i]* successivo o lo inserisce tra i fratelli del nodo *n* nella posizione corretta in quanto i fratelli devono essere ordinati in base al valore dell'item contenuto.
 - Il metodo *createHash* è il metodo che implementa la costruzione dell'albero mediante tabella hash. *CreateHash* riceve gli stessi parametri di ingresso del metodo *insert*. Questo metodo verifica se la referenza alla tabella hash dei figli del nodo *n* è vuota e in tal caso crea una tabella hash e inserisce il nodo nel bucket corretto mediante il metodo *insertSonHash*. Se è presente una tabella hash contenente i figli di *n* verifica se l'item *a[i]* è presente mediante il metodo *searchItem*. Se è presente passa ad *a[i+1]*, altrimenti inserisce il nuovo nodo nella posizione del bucket corretta.
- ❖ *TrieBuild*: è la classe contenente il main che ha il compito di unire tutte le classi precedenti per costruire lo standard trie. La costruzione del trie prevede:
 - una scansione del file contenente i dati di ingresso per calcolare la frequenza di ogni singolo intero(il calcolo della frequenza viene svolto dai metodi contenuti nella classe *FrequencyVector*).
 - Scelta della modalità dei costruzione dell'albero che prevedeva quattro opzioni:
 - k=0* standard trie mediante ordinamento decrescente
 - k=1* standard trie mediante ordinamento crescente
 - k=2* standard trie mediante ordinamento decrescente con hash table con risoluzione delle collisioni mediante *separate chaining*
 - k=3* standard trie mediante ordinamento crescente con hash table con risoluzione delle collisioni mediante *separate chaining*

La struttura dell'algoritmo di ogni scelta è uguale e prevede subito l'operazione di ordinamento del vettore *v* in base all'ordinamento previsto. Ad una seconda lettura del file di input, ogni riga letta veniva ordinata per frequenza, passata al metodo *insert*(contenuto nella classe *trie*) che provvede a costruire il ramo dell'albero ordinato per frequenza. Solamente dopo aver costruito il ramo passa alla lettura della riga successiva.

RISULTATI OTTENUTI: (Processore Athlon 1Ghz, Ram 256MB, Windows XP)

Modalità	Tempo di esecuzione con calcolo della frequenza [ms]	Tempo di esecuzione senza calcolo della frequenza [ms]
0	6510	3796
1	2577190	254927
2	6359	4116
3	244531	242288