

WAND SCORING EXAMPLE

(EFFICIENT QUERY EVALUATION
USING A TWO-LEVEL
RETRIEVAL PROCESS)

Query = "CATCHER IN THE RYE"

SCRITTO MOLTO BENE!

Indice Invertito

CATCHER → 140, 293, 356, 539, 463

RYE → 140, 140, 356, 400, 539, 700, 720, 763

IN → 90, 90, 356, 539, 600, 900

THE → 90, 100, 539, 600, 440, 300

0) INIZIALIZZAZIONE

Inizializzo FINGERS, UPPER BOUNDS e THRESHOLD per ogni termine che compare nella query

↓
CATCHER → 140, 293, 356, 539, 463

THRESHOLD = 0

$UB_{\text{CATCHER}} = 2,3$

↓
RYE → 140, 140, 356, 400, 539, 700, 720, 763

$UB_{\text{RYE}} = 1,8$

↓
IN → 90, 90, 356, 539, 600, 900

$UB_{\text{IN}} = 3,3$

↓
THE → 90, 100, 539, 600, 440, 300

$UB_{\text{THE}} = 4,3$

Ad ogni iterazione dell'algoritmo posso accedere le seguenti due cose:

- Selezione in DOC-ID e mi calcolo il $\text{max FULL RANK}^{\text{SCORE}}$.
In questo caso è possibile che la THRESHOLD e un UPPER BOUND si modificano.
- NON selezione nessun DOC-ID. In questo caso il THRESHOLD non cambia ma solo un UPPER BOUND potrebbe cambiare (diminuisce)

L'algoritmo si basa sulla seguente ITERAZIONE, che viene ripetuta fin a quando non ci sono più DOC-ID da processare

1) SORTING DEI TERMINI

I termini vengono ordinati rispetto al DOC-ID partendo dal finger

	THRESHOLD = 6
IN → 70, 90, 356, 539, 600, 900	$UB_{IN} = 3.3$
THE → 90, 100, 539, 600, 440, 300	$UB_{THE} = 4.3$
CATCHER → 140, 273, 356, 539, 763	$UB_{CATCHER} = 2.3$
RYE → 140, 140, 356, 400, 539, 700, 720, 763	$UB_{RYE} = 1.8$

2) CALCOLO DEL TERMINE PIVOT

Si calcola il primo termine che ci permette di superare il valore di THRESHOLD.

THRESHOLD = 6

IN → 90, 90, 356, 539, 600, 900

UB_{IN} = 3.3

THE → 90, 100, 539, 600, 440, 300

UB_{THE} = 4.3

TERMINE PIVOT

CATCHER → 140, 293, 356, 539, 463

UB_{CATCHER} = 2.3

RYE → 140, 140, 356, 400, 539, 700, 720, 763

UB_{RYE} = 1.8

Notiamo infatti che

$$3.3 + 4.3 = 7.6 > 6$$

3) VERIFICA ESISTENZA DOC-ID

Si verifica che il DOC-ID puntato dal FINGER del TERMINE PIVOT esiste nelle porting lists dei termini precedenti al TERMINE PIVOT

THRESHOLD = 6

IN → 90, 90, 356, 539, 600, 900

UB_{IN} = 3.3

THE → 90, 100, 539, 600, 440, 300

UB_{THE} = 4.3

TERMINE PIVOT

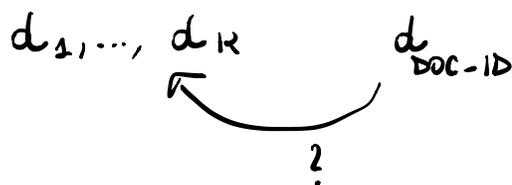
CATCHER → 140, 293, 356, 539, 463

UB_{CATCHER} = 2.3

RYE → 140, 140, 356, 400, 539, 700, 720, 763

UB_{RYE} = 1.8

Se il DOC-ID esiste allora lo si seleziona e ci si calcola lo SCORE COMPLETO. A questo punto confrontiamo lo score del doc. calcolato con lo score dei K doc scelti fino a questo punto, eventualmente rimpiazzando il nuovo doc con un vecchio.



Alla fine di questa operazione abbiamo K docs d'_1, d'_2, \dots, d'_K . Se nuovo THRESHOLD è quindi così def.

(IL THRESHOLD HA UN COMPORTAMENTO NON-DECRESCENTE)

$$\text{THRESHOLD} = \min_{i=1, \dots, K} \text{SCORE}(d'_i, q)$$

(QUESTA SCELTA GARANTISCE IL SAFE RANKING)

Nel nostro particolare caso aumentiamo la seguente modifica

(PRIMA DI AVER SELEZIONATO IL DOC 90)

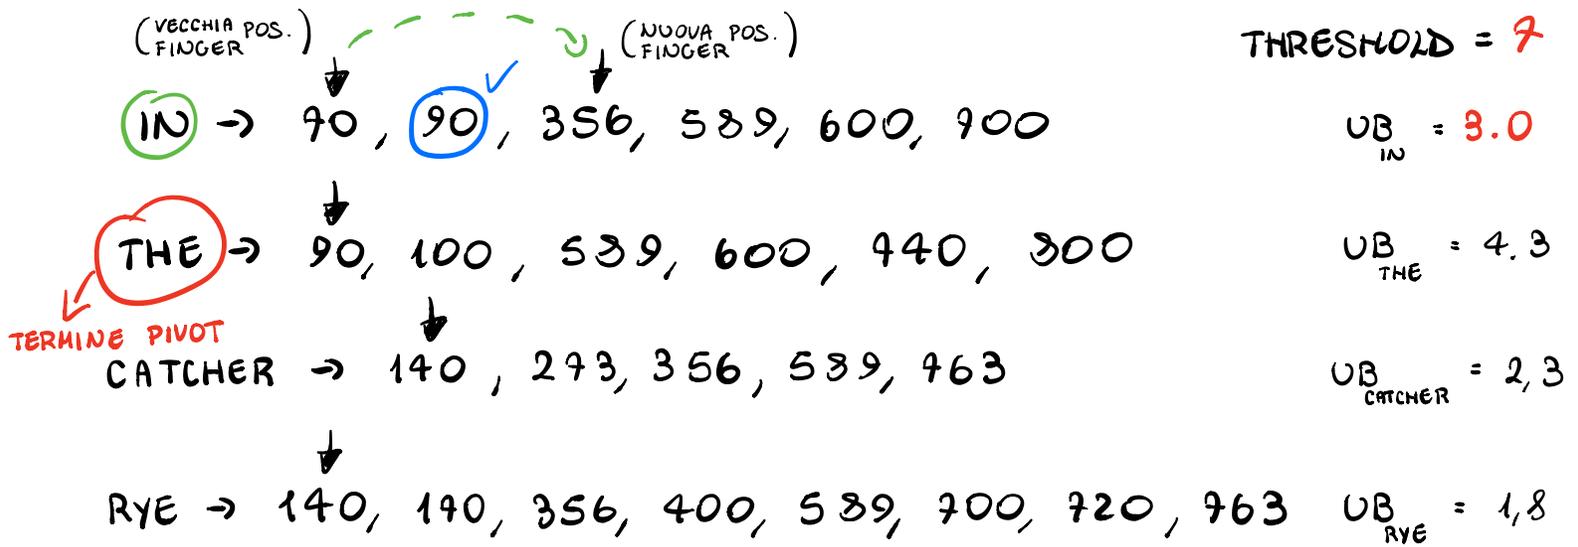
$$\text{THRESHOLD} = 6 \rightarrow \text{THRESHOLD} = 7$$

(DOPO AVER SELEZIONATO IL DOC 90)

4) SPOSTAMENTO FINGER

Come ultimo step, per prepararci all'iterazione successiva, si sceglie UN TERMINE tra quelli che precedono il TERMINE PIVOT e si muove il FINGER del termine scelto al primo DOC-ID x t.c. $x > \text{DOC-ID}$

Questo è il DOC-ID puntato dal FINGER del PIVOT



Dopo aver mosso il FINGER del termine scelto dobbiamo aggiornare l'UPPER BOUND

$$\left(\begin{array}{l} \text{PRIMA DI AVER} \\ \text{SPOSTATO IL FINGER} \end{array} \right) UB_{IN} = 3.3 \xrightarrow{\text{SPOSTO IL FINGER}} UB_{IN} = 3.0 \left(\begin{array}{l} \text{DOPO AVER} \\ \text{SPOSTATO IL FINGER} \end{array} \right)$$

L'UPPER BOUND dei termini ha un comportamento NON-CRESCENTE.

La scelta di quale termine scegliere è arbitraria ai fini della CORRETTEZZA del metodo. Alcune EURISTICHE potrebbero essere più efficienti di altre.

Questo TERMINA la singola iterazione



Schematicamente quindi ogni ITERAZIONE effettua i seguenti
i seguenti passi:

- 1) SORTING DEI TERMINI (RISPETTO AI DOC-IDS PUNTATI DAI FINGERS)
- 2) CALCOLO TERMINE PIVOT
- 3) VERIFICA ESISTENZA DOC-ID
- 4) SPOSTAMENTO FINGER

Per finire, vediamo anche una seconda iterazione.
In questa iterazione però, a differenza della prima,
il metodo non sceglie nessun doc.

Iniziamo dalla seguente situazione

		THRESHOLD = 7
IN	→ 90, 90, 356, 589, 600, 900	$UB_{IN} = 3.0$
THE	→ 90, 100, 589, 600, 440, 300	$UB_{THE} = 4.3$
CATCHER	→ 140, 273, 356, 589, 463	$UB_{CATCHER} = 2.3$
RYE	→ 140, 140, 356, 400, 589, 700, 720, 763	$UB_{RYE} = 1.8$

Procediamo quindi con i vari steps.

1) SORTING DEI TERMINI

↓	THRESHOLD = 7
THE → 90, 100, 539, 600, 440, 300	$UB_{THE} = 4.3$
↓	
CATCHER → 140, 273, 356, 539, 463	$UB_{CATCHER} = 2.3$
↓	
RYE → 140, 140, 356, 400, 539, 700, 720, 763	$UB_{RYE} = 1.8$
↓	
IN → 90, 90, 356, 539, 600, 900	$UB_{IN} = 3.0$

2) CALCOLO TERMINE PIVOT

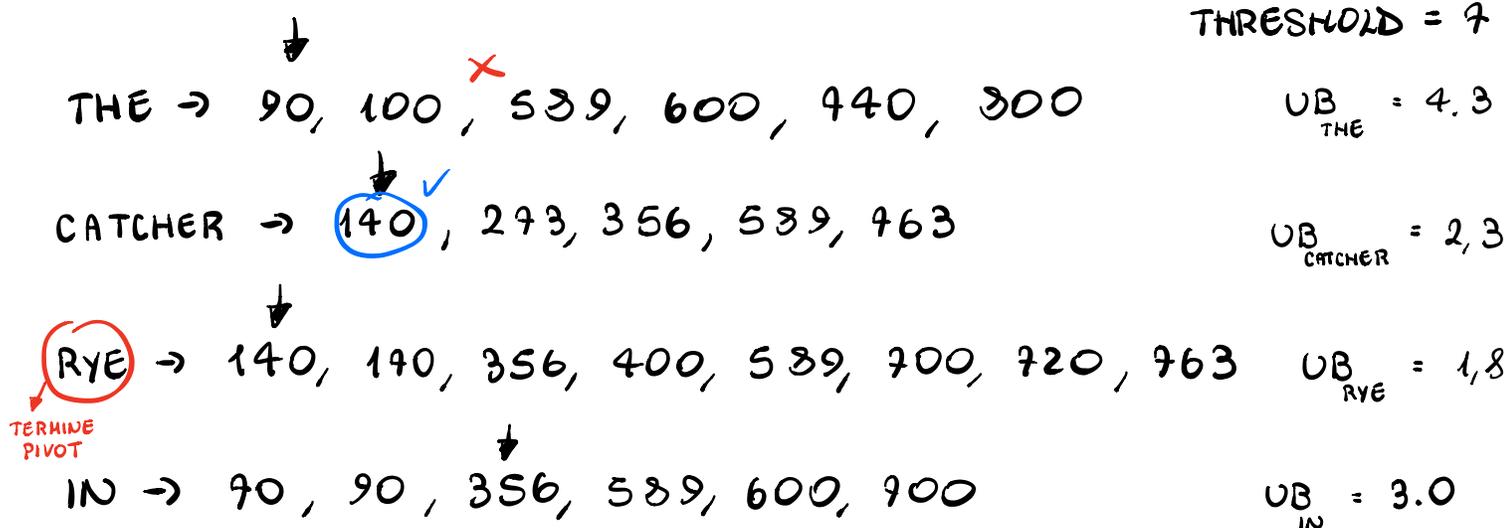
↓	THRESHOLD = 7
THE → 90, 100, 539, 600, 440, 300	$UB_{THE} = 4.3$
↓	
CATCHER → 140, 273, 356, 539, 463	$UB_{CATCHER} = 2.3$
↓	
RYE → 140, 140, 356, 400, 539, 700, 720, 763	$UB_{RYE} = 1.8$
↓	
IN → 90, 90, 356, 539, 600, 900	$UB_{IN} = 3.0$

TERMINI
PIVOT

Sinfatti,

$$4.3 + 2.3 + 1.8 = 8.4 > 7$$

3) VERIFICA ESISTENZA DOC-ID



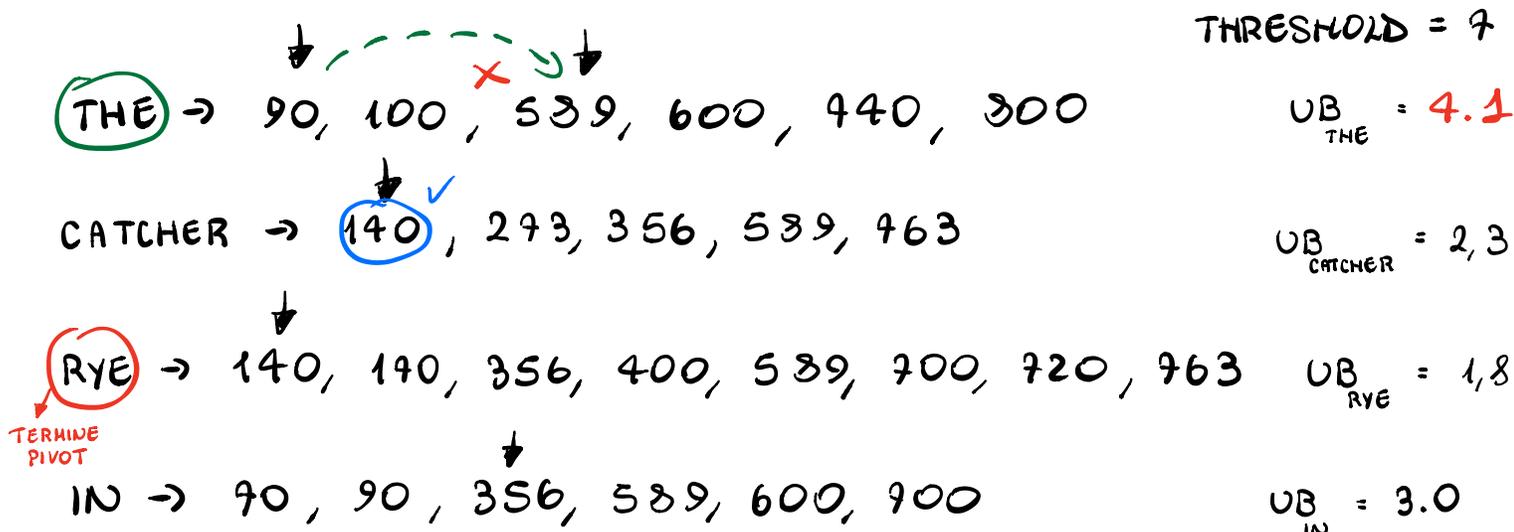
Im questo caso il DOC-ID 140 non è presente in tutte le sorting lists dei termini che precedono il termine pivot.

Perche non viene selezionato, il THRESHOLD non cambia e si passa al passo successivo

4) SPOSTAMENTO FINGER

Im questo caso moviamo l'indice da THE che CATCHER.

Se scegliamo THE otteniamo



Se invece scegliamo CATCHER otteniamo

THRESHOLD = 7

THE → 90, 100, 539, 600, 440, 300

$UB_{THE} = 4.3$

CATCHER → 140, 273, 356, 539, 463

$UB_{CATCHER} = 2.3$

RYE → 140, 140, 356, 400, 539, 700, 720, 763

$UB_{RYE} = 6.8$

TERMINE
PIVOT

IN → 70, 90, 356, 539, 600, 900

$UB_{IN} = 3.0$

L'importante è che mostriamo il FINGER del termine
sotto al minimo valore x che sia STRETTAMENTE MAGGIORE
del DOC-ID puntato dal FINGER del TERMINE PIVOT.

E questo è tutto.

MADE WITH ❤ BY LEONARDO TAHIANO.