

## Ex 1

$S_p \rightarrow$  pitow  
 $it \rightarrow$  pitow  
 $to \rightarrow$  pitow  
 $pl \rightarrow$  pitow  
 $ou \rightarrow$  pitow, zoom  
 $sd \rightarrow$  dad, daddy  
 $da \rightarrow$  dad, daddy  
 $ad \rightarrow$  dad, daddy  
 $dd \rightarrow$  daddy  
 $dy \rightarrow$  daddy  
 $sz \rightarrow$  zoom  
 $zo \rightarrow$  zoom  
 $oo \rightarrow$  zoom

Soft intersection over 2-gram of  $P$  gives  $\{ \text{pitow} : 2, \text{zoom} : 1 \}$

Since  $|P| = 4$  we get  $L \cdot K \cdot e = 4 - 2 \cdot 1 = 2$  so only 'pitow' satisfy the condition

~~Edit distance~~ But the edit distance between  $P$  and 'pitow' is 2, so also 'pitow' is discarded and no results are returned

## Ex 2

rsync: sia  $C$  in possesso di  $F_{old}$ ,  $S$  di  $F_{new}$ ,  $C$  partiziona  $F_{old}$  in blocchi di dimensione  $B = 3$ , ne calcola la funzione hash ed invia tali valori ad  $S$

"cow"  $\rightarrow$   $h_1$ , "eg"  $\rightarrow$   $h_2$ , "att"  $\rightarrow$   $h_3$ , "oo"  $\rightarrow$   $h_4$ , "rs"  $\rightarrow$   $h_5$

$S$  calcola un rolling hash di  $F_{new}$ , ogni volta che un valore corrisponde lo invia a  $C$  e salta  $B$  caratteri in avanti, altrimenti invia il primo carattere del blocco

risposta di  $S$ :  $w, h_3, o, ' ; h_1, e, ' , r, h_3, o$

zsync:  $S$  partiziona  $F_{new}$  in blocchi di dimensione  $B$ , ne calcola hash e salva tali valori su file. zsync  $C$  richiede tale file e calcola rolling hash di  $F_{old}$ , per poi inviare ad  $S$  una bitmap dei valori condivisi

hash  $F_{new}$ : "wat"  $\rightarrow$   $h_1$ , "to"  $\rightarrow$   $h_2$ , "cow"  $\rightarrow$   $h_3$ , "er"  $\rightarrow$   $h_4$ , "att"  $\rightarrow$   $h_5$ , "oss"  $\rightarrow$   $h_6$

~~Bitmap di risposta: 011011~~

~~$S$  utilizza quindi algoritmo della compressione su  $F_{new}$  a partire da blocchi condivisi~~

~~to cowatto\$\$ | watto cowe ratto  $\rightarrow$   $\langle 0, 0, w \rangle$~~   
~~to cowatto\$\$ | watto cowe ratto  $\rightarrow$   $\langle 7, 4, ' \rangle$~~   
~~to cowatto\$\$ | watto | cowe ratto  $\rightarrow$   $\langle 15, 3, e \rangle$~~   
~~to cowatto\$\$ | watto cowe | ratto  $\rightarrow$   $\langle 5, 1, r \rangle$~~   
~~to cowatto\$\$ | watto cowe | ratto  $\rightarrow$   $\langle 11, 4, o \rangle$~~

~~$C$  riceve tale elenco di tuple e a partire da esso e dall'informazione sui blocchi condivisi ricostruisce  $F_{new}$~~

### Ex 3

Outdegree (15) = 11 ; Ref = 1

Copy-list : 011011110

Copy-blocks : 0, 0, 1, 0, 3

Additional docID : 5, 12, 20, 24, 33

### Ex 5

La struttura dati per la risoluzione di 1-gram match su query consiste, oltre al dizionario di potenza  $D$ , di un dizionario ausiliario  $D_1$  contenente tutte le possibili stringhe ottenibili dagli elementi di  $D$  a seguito della cancellazione di un carattere : tali stringhe punteranno ciascuna al proprio (o propri) elemento di digue in  $D$

La query di una stringa  $P$ ,  $|P| = p$ , consiste di  $2p + 2$  ricerche

- 1 Una ricerca esatta di  $P$  in  $D$
- 2 Inserzione : una ricerca esatta di  $P$  in  $D_1$
- 3 Cancellazione :  $p$  ricerche in  $D$ , una per ciascuna stringa ottenibile da  $P$  a seguito di una cancellazione
- 4 Sostituzione :  $p$  ricerche in  $D_1$ , una per ciascuna stringa ottenibile da  $P$  a seguito di una cancellazione

### Ex 4

Ricordando che  $J(P, Q) = |P \cap Q| / |P \cup Q|$  ricaviamo

$$J(A, B) = 3/8, \quad J(B, C) = 1/9, \quad J(A, C) = 0$$

Sapendo che, data una permutazione casuale  $\pi$  degli elementi  $\{0, 1, \dots, 11, 12\}$ , ed indicando con  $\pi_m(A) = \min \pi(A)$ ,  $P(\pi_m(A) = \pi_m(B)) = J(A, B)$ , possiamo stimare la Jaccard similarity tra i due insiem utilizzando a volte una permutazione differente osservando se  $\pi_m(A) = \pi_m(B)$  ottenendo  $\Phi_u(A) = \{\pi_{1u}(A), \dots, \pi_{nu}(A)\}$ ,  $\Phi_u(B) = \{\pi_{1u}(B), \dots, \pi_{nu}(B)\}$  e calcolando  $|\Phi_u(A) \cap \Phi_u(B)| / u$  dove l'intersezione è operata componente per componente

Sia  $\pi_1(x) = 5x + 1 \pmod{12}$  allora  $\pi_1(A) = \{6, 9, 7, 5, 10\}$ ,  $\pi_1(B) = \{11, 4, 9, 7, 0, 5\}$ ,  $\pi_1(C) = \{11, 2, 8, 1\}$  quindi  $\pi_{1u}(A) = 5$ ,  $\pi_{1u}(B) = 0$ ,  $\pi_{1u}(C) = 1$  ciascuno diverso dall'altro

Sia  $\pi_2(x) = 7x + 3 \pmod{12}$  allora  $\pi_2(A) = \{10, 7, 9, 11, 6\}$ ,  $\pi_2(B) = \{5, 0, 7, 9, 4, 6\}$ ,  $\pi_2(C) = \{5, 2, 8, 3\}$  quindi  $\pi_{2u}(A) = 6$ ,  $\pi_{2u}(B) = 0$ ,  $\pi_{2u}(C) = 2$  ciascuno diverso dall'altro

La stima della Jaccard similarity tra gli insiem dati è dunque pari a zero per ciascuna coppia valce corretto per  $J(A, C)$ , approssimativo per  $J(B, C)$ , 'scorretto' per  $J(A, B)$

La casualità' esegua degli skatole, in questo caso, impedisce una stima accurata della Jaccard similarity

Ex 2 (cont.)

bitmap di risposta : 011001

ciene anche "att" = 15

S calcola delta compressione dei blocchi non suddivisi di F\_new a partire dall'informazione nella bitmap

to caso \$\$ | wate | att -> < 0, 0, w >

to caso \$\$ | w | ate | att -> < 6, 1, t >

to caso \$\$ | wate | e | att -> < 0, 0, e >

to caso \$\$ | wate | | att -> < 11, 1, 1 >

~~to caso \$\$ | wate | | att -> < 5, 2, t >~~



C riceve tale elenco di triple, opera la decompressione e sfruttando l'informazione precedentemente ottenuta ricostruisce F\_new