Approximate Frequency Counts over Data Streams

Gurmeet Singh Manku **Rajeev Motwani**

Näherungsweise
Häufigkeitszählung in Datenströmen

Seminarvortrag von Marco Möller

Marco.Moeller@macrolab.de, 15.11.2006

Wofür ist das gut?

- Was sind die Top Ten der Suchanfragen bei g**gle.de ?
- Lernen von Assoziationsregeln:
  - Kunden, die das neue MS Office bestellen, bestellen auch häufig zusätzlichen RAM
- IP Traffic Mangagement:
  - finden von viel genutzten Links in Netzwerken um Routen danach zu optimieren
  - „Denial of Service“ Attacken aufdecken

Marco.Moeller@macrolab.de, 15.11.2006

Worum geht's?

- In einem Datenstrom der Länge N sollen alle Elemente die häufiger als $s \cdot N$ mit $s \in (0,1)$ vorkommen extrahiert werden
- jeweils mit Angabe von Häufigkeit f
- in **einem** Durchlauf durch die Daten
  - also gut für Data Streams geeignet
- beweisbarer, möglichst kleiner Speicherbedarf

Marco.Moeller@macrolab.de, 15.11.2006

Was heißt näherungsweise ?

- dabei nicht exakt zählen, sondern mit $\epsilon \in (0,1)$ einstellbarer (garantierter) Genauigkeit
  - alle Elemente die häufiger als sN vorkommen werden gefunden
  - kein Element das seltener als $(s-\epsilon)N$ vorkommt wird ausgegeben
  - angegebene Raten sind kleiner gleich den richtigen um maximal ϵN

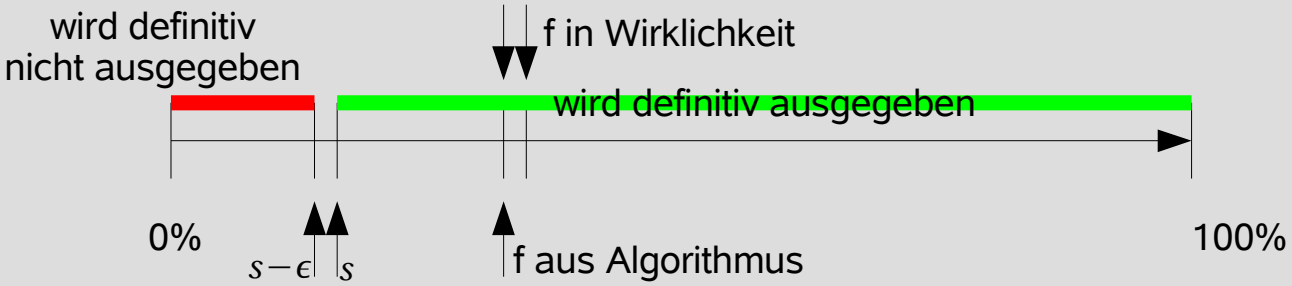

Marco.Moeller@macrolab.de, 15.11.2006

Algorithmen Grundgerüst

- Initialisierung $K = \emptyset$
- FOR_EACH neues eintreffendes Element e
  - IF bereits ein Eintrag in K für e existiert?
    - THEN in Datenstruktur Zähler für e inkrementieren
    - ELSE evtl. neuen Eintrag in K einfügen
  - IF „Zeit zum Aufräumen“ THEN
    - Elemente aus K entfernen
- **Ausgabe**: alle Elemente aus K, die häufig genug vorkamen

Marco.Moeller@macrolab.de, 15.11.2006

Sticky Sampling - Übersicht

- Stochastik bzw. Stichproben basiert
- Anforderungen nur mit wählbarer Wahrscheinlichkeit $1-\delta$ erfüllt
- Speicher maximal $\frac{2}{\epsilon}\log(s^{-1}\delta^{-1})$

Marco.Moeller@macrolab.de, 15.11.2006

Sticky Sampling - Benennung

- Datenstruktur S ist Menge von Einträgen der Form (e, f)
  - e Element im Datenstrom
  - $f \in \mathbb{N}$ genäherte Häufigkeit
- Variable r für „sampling rate“ wird mitgeführt

Marco.Moeller@macrolab.de, 15.11.2006

Sticky Sampling - Algorithmus (1)

- Initialisierung $S := \emptyset$, $r := 1$, $t := \frac{1}{\epsilon}\log(s^{-1}\delta^{-1})$
- FOR_EACH neues eintreffendes Element e
  - IF bereits ein Eintrag in S für e existiert?
    - THEN entsprechendes f um eins erhöhen
    - ELSE Mit Wahrscheinlichkeit $\frac{1}{r}$ neuen Eintrag der Form $(e,1)$ in S einfügen
  - IF $N = 2 \cdot r \cdot t$ THEN

    - $r := 2 \cdot r$
    - S ausdünnen (siehe nächste Folie)

Marco.Moeller@macrolab.de, 15.11.2006

Sticky Sampling - Algorithmus (2)

- S ausdünnen:
  - FOR_EACH $(e, f) \in S$
    - WHILE Münzwurf = „Kopf“
      - $f := f - 1$
      - IF $f = 0$ THEN lösche Element aus S
- **Ausgabe**: Alle Elemente $(e, f) \in S$ mit $f \geqslant (s - \epsilon) N$

Marco.Moeller@macrolab.de, 15.11.2006

Sticky Sampling - Beispiel

$$s=0{,}1 \quad \epsilon=0{,}01 \quad \delta=0{,}01 \quad t=\frac{1}{0{,}001}\log_2\left(\frac{1}{0{,}1}\cdot\frac{1}{0{,}01}\right)=1000$$

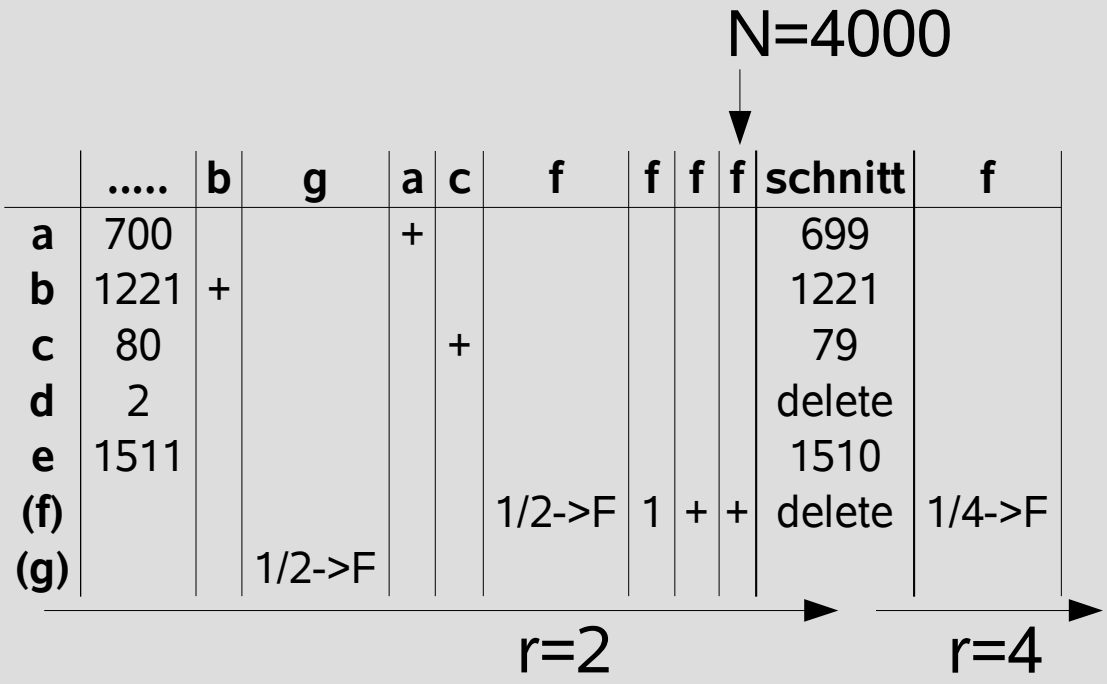

	.....	b	g	a	c	f	f	f	f	schnitt	f
a	700			+						699	
b	1221	+								1221	
c	80				+					79	
d	2									delete	
e	1511									1510	
(f)						1/2->F	1	+	+	delete	1/4->F
(g)			1/2->F								

1/4 ->f := 4-seitiger Würfel landet nicht auf der richtgen Seite

Marco.Moeller@macrolab.de, 15.11.2006

Lossy Counting - Übersicht

- deterministisch
- exakt in Anforderungsschranken
  - keinen Parameter δ
- Speicher maximal $\frac{1}{\epsilon}\log(\epsilon N)$
  - Im Gegensatz zu Sticky Sampling abhängig von N

Marco.Moeller@macrolab.de, 15.11.2006

Lossy Counting - Benennung

- Eingangsstrom in gedachte Behälter der Länge $w = \left\lceil \frac{1}{\epsilon} \right\rceil$ unterteilen
- nummeriere Behälter durch $id = 1, 2, \ldots$
- aktuelle Behälternummer ist $id_{max} = \left\lceil \frac{N}{\epsilon} \right\rceil$
- Datenstruktur D Menge von Einträgen der Form (e, f, Δ)
  - e Element im Datenstrom
  - $f \in \mathbb{N}$ genäherte Häufigkeit
  - Δ maximal möglicher Fehler

Marco.Moeller@macrolab.de, 15.11.2006

Lossy Counting - Algorithmus

- Initialisierung $D = \emptyset$
- FOR_EACH neues eintreffendes Element e
  - IF bereits ein Eintrag in D für e existiert?
    - THEN entsprechendes f um eins erhöhen
    - ELSE neuen Eintrag der Form $(e, 1, id_{max} - 1)$ in D einfügen
  - IF $N \bmod w = 0$ THEN

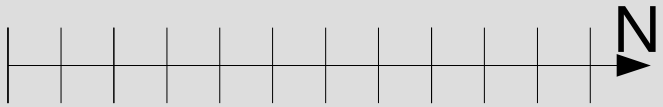

    - alle Elemente aus D löschen, für die gilt $f + \Delta \leqslant id_{max} = \frac{N}{w}$
- **Ausgabe**: alle Elemente $(e, f, \Delta) \in D$ mit $f \geqslant (s - \epsilon) N$

Marco.Moeller@macrolab.de, 15.11.2006

Lossy Counting - Beispiel

$$s=0{,}1 \quad \epsilon=0{,}01 \qquad w=\left\lceil \frac{1}{\epsilon} \right\rceil = 100$$

N=4000 -> id_{max}=100

	(f,Δ)		.....	b	g	a	c	f	f	f	schnitt	f	a
a	(700,12)					+					(701,12)		+
b	(1221,1)			+							(1222,1)		
c	(80,20)						+				(81,20)		
d	(2,98)										--		
e	(1511,0)										(1511,0)		
f	--							1	+	+	(3,98)	+	
g	--				1						--		

Vergleich - Memory

Sticky Sampling

$$\frac{2}{\epsilon}\log\left(s^{-1}\delta^{-1}\right)$$

Lossy Counting

$$\frac{1}{\epsilon}\log\left(\epsilon N\right)$$

- **Uniq**: Alle Elemente Einzigartig
- **Zipf**: Zipf-Verteilung mit Parameter 1,25
  Häufigkeit proportional zu
  1 / (Rangfolge der Elements in der Gesamtmenge)

$s = 10‰ \quad \epsilon = 1‰ \quad \delta = 0{,}1‰$

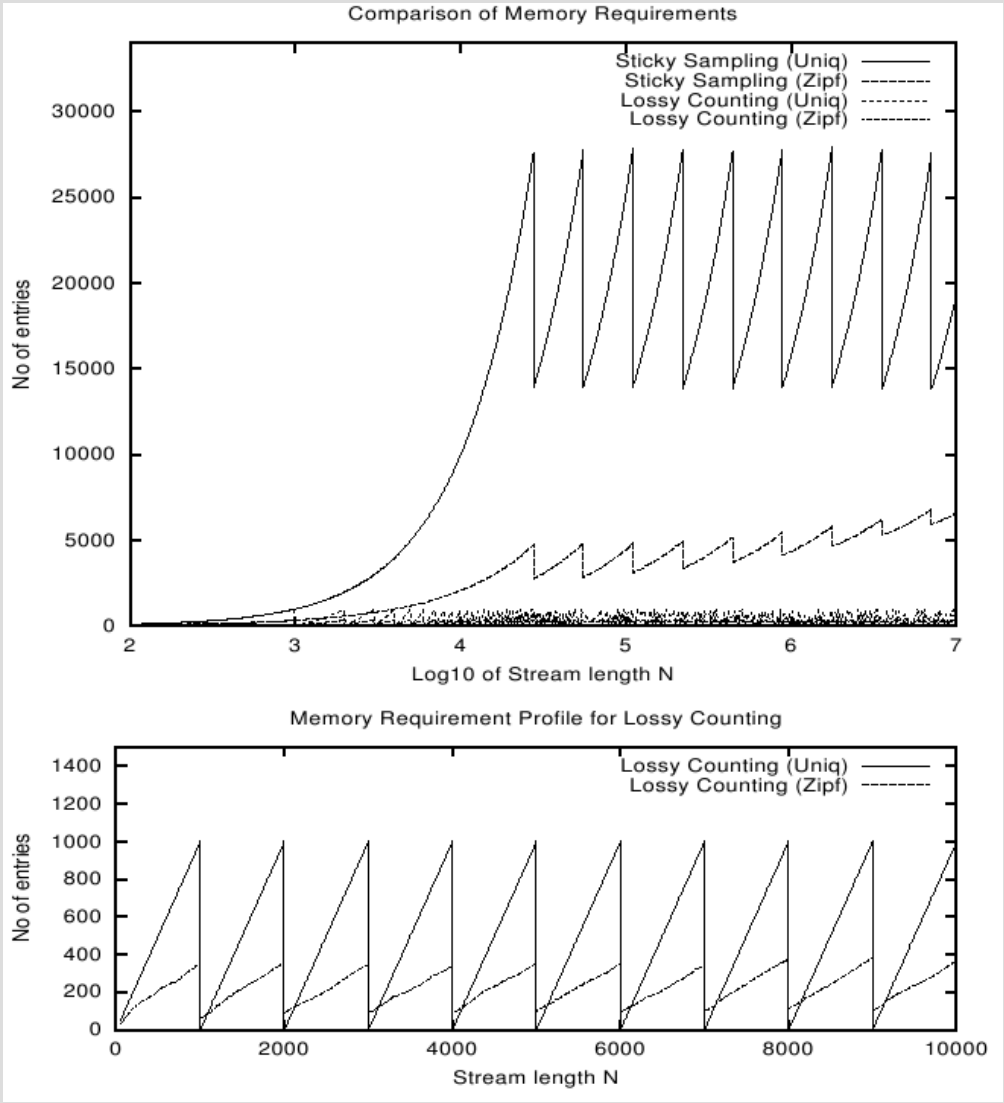

Marco.Moeller@macrolab.de, 15.11.2006

Praxis

- Lossy Counting benötigt wesentlich weniger Speicher und ist praktisch nicht abhängig von N
- Beide Algorithmen arbeiten wesentlich genauer als die Angegebene Schranke es verlangt
  - Lossy Counting: Falls im ersten Fenster alle wichtigen Elemente vorkommen, ist die Zählung sehr warscheinlich exakt
- Lossy Counting prozessorlastig
  - geeignet um Daten direkt von Platte zu lesen ohne Performance Einbuße

Marco.Moeller@macrolab.de, 15.11.2006

Literatur

- J. Fürnkranz, G. Grieser. Vorlesungsskript „Maschinelles Lernen: Symbolische Ansätze“. WS2006/07
- G. S. Manku and R. Motwani. Approximate Frequency Counts over Streaming Data. In Proceedings of VLDB 2002, Aug. 2002
- Wikipedia. 11.11.2006 http://en.wikipedia.org/wiki/Zipf%27s_law
- Cordula Nimz. Seminarvortrag. 15.12.2005 http://www.inf.fu-berlin.de/lehre/WS05/Seminar-Algorithmen/Vortrag20051215.pdf

Marco.Moeller@macrolab.de, 15.11.2006