

(M. Dietzfelbinger, June 1, 2018)

Offen geblieben: Summation der Terme der mittleren Summe

$$S = \sum_{1 \leq i < k < j \leq n} \frac{1}{j-i+1}.$$

Wir stellen sie in der nachfolgenden  $(k-1) \times (n-k)$ -Matrix dar (für  $k \leq n/2$ ):

$$\begin{pmatrix} \frac{1}{k+1} & \frac{1}{k+2} & \cdots & \frac{1}{n-k} & \frac{1}{n-k+1} & \frac{1}{n-k+2} & \cdots & \cdots & \frac{1}{n-1} & \frac{1}{n} \\ \frac{1}{k} & \frac{1}{k+1} & \frac{1}{k+2} & \cdots & \frac{1}{n-k} & \frac{1}{n-k+1} & \frac{1}{n-k+2} & \cdots & \frac{1}{n-2} & \frac{1}{n-1} \\ \vdots & \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots & \vdots \\ \frac{1}{4} & \frac{1}{5} & \cdots & \frac{1}{k+1} & \frac{1}{k+2} & \cdots & \frac{1}{n-k} & \frac{1}{n-k+1} & \frac{1}{n-k+2} & \cdots \\ \frac{1}{3} & \frac{1}{4} & \cdots & \frac{1}{k} & \frac{1}{k+1} & \frac{1}{k+2} & \cdots & \frac{1}{n-k} & \frac{1}{n-k+1} & \frac{1}{n-k+2} \end{pmatrix}$$

Einteilung in drei Teile:

Teil I, Summe  $B_1$ : Einträge strikt unterhalb der Diagonalen mit den  $\frac{1}{k+1}$ -Einträgen,

Teil II, Summe  $B_2$ : Einträge ab der Diagonalen mit den  $\frac{1}{k+1}$ -Einträgen (startet in linker oberer Ecke) bis zur Diagonalen mit den  $\frac{1}{n-k}$ -Einträgen (endet zwei Positionen links von rechter unterer Ecke),

Teil III, Summe  $B_3$ : Einträge strikt oberhalb der Diagonalen mit den  $\frac{1}{n-k}$ -Einträgen.

Setze  $\alpha := k/n$ . Dann gilt  $0 < \alpha \leq \frac{1}{2}$ . Offenbar gilt:

$$B_1 = \frac{k-2}{k} + \frac{k-3}{k-1} + \frac{k-4}{k-2} + \cdots + \frac{1}{3} < k-2.$$

Weiter gilt (beachte  $\frac{1}{u+1} + \frac{1}{u+2} + \cdots + \frac{1}{v} \leq \int_u^v \frac{dt}{t} = \ln(v) - \ln(u) = \ln\left(\frac{v}{u}\right)$ )

$$\begin{aligned} B_3 &= \frac{1}{n} + \frac{2}{n-1} + \frac{3}{n-2} + \cdots + \frac{k-1}{n-k} + \frac{k-1}{n-k+1} \\ &\leq \left(\frac{n+1}{n} - 1\right) + \left(\frac{n+1}{n-1} - 1\right) + \cdots + \left(\frac{n+1}{n-k+1} - 1\right) \\ &= (n+1) \left(\frac{1}{n} + \frac{1}{n-1} + \cdots + \frac{1}{n-k+1}\right) - k \\ &\leq (n+1) \ln\left(\frac{n}{n-k}\right) - k \end{aligned}$$

Wir erhalten, weil  $\ln(1/(1-\alpha)) \leq \ln 2 < 1$ :

$$B_1 + B_3 < (n+1) \ln\left(\frac{n}{n-k}\right) - 2 = (n+1) \ln\left(\frac{1}{1-\alpha}\right) - 2 < -n \ln(1-\alpha).$$

(Achtung: Der Logarithmus ist negativ!) Schließlich:

$$\begin{aligned}
 B_2 &= (k-1) \left( \frac{1}{k+1} + \frac{1}{k+2} + \frac{1}{k+3} + \cdots + \frac{1}{n-k} \right) \\
 &\leq (k-1) \ln \left( \frac{n-k}{k} \right) < \alpha n \ln \left( \frac{n-k}{k} \right) \\
 &= \alpha n \ln \left( \frac{1-\alpha}{\alpha} \right) = n \cdot (\alpha \ln(1-\alpha) - \alpha \ln(\alpha)).
 \end{aligned}$$

Also:

$$\begin{aligned}
 S &= B_1 + B_2 + B_3 \\
 &\leq n \cdot (-\ln(1-\alpha) + \alpha \ln(1-\alpha) - \alpha \ln(\alpha)) \\
 &= n \cdot (-(1-\alpha) \ln(1-\alpha) - \alpha \ln(\alpha)) \\
 &= n \cdot H_e(\alpha),
 \end{aligned}$$

wobei  $H_e(\alpha)$  die Entropie der Verteilung  $(\alpha, 1-\alpha)$  zur Basis  $e$  ist. Bezüglich der in der Informatik üblichen binären Entropie  $H_2(\alpha) = -(1-\alpha) \log_2(1-\alpha) - \alpha \log_2(\alpha)$  ergibt sich mit Hilfe der Beziehung  $H_e(\alpha) = (\ln 2)H_2(\alpha)$ :

$$S \leq n \cdot (\ln 2)H_2(\alpha).$$

Insgesamt, weil  $\alpha \leq \frac{1}{2}$ :

$$\mathbf{E}(C_k) \leq n \cdot (2 + (2 \ln 2)H_2(\alpha)).$$

Der schlechteste Fall tritt für  $\alpha = \frac{1}{2}$ , also  $k = n/2$ , auf. Dies ist der Fall des Medians. Dann ist  $H_2(\frac{1}{2}) = 1$ , und  $\mathbf{E}(C_{n/2}) \leq (2 + (2 \ln 2))n \approx 3.3863n$ .

**Theorem** Die erwartete Vergleichszahl von Quickselect mit  $k = \alpha n$  ist  $\leq (2 + (2 \ln 2)H_2(\alpha)) \cdot n$ .

Der nächste Abschnitt 4.4 zeigt, dass mit einem anderen Algorithmus die Vergleichszahl auf etwa  $\frac{3}{2}n$  verbessert werden kann.