

Aritmetisk kodning

Seksjon 7.4.

Ex. 7.21.


$x = ACBBCAABAA$, $P(A) = \frac{1}{2}$, $P(B) = 0.3$

$P(C) = 0.2$

A skal assosieres med et intervall av bredde 0.5

B skal ass - - - - , bredde 0.3


C - - - - - , bredde 0.2



Første tegn er A så vi skal være i $[0, 0.5]$
Dette deles på samme måte

Observasjon 7.18. La $[a, b]$ være et intervall med $a < b$. Funksjonen $g(z) = a + z(b-a)$ avbilder ethvert tall i $[0, 1]$ til intervallet $[a, b]$. Spesielt så er

$$g(0) = a, \quad g\left(\frac{1}{2}\right) = \frac{a+b}{2}, \quad g(1) = b$$




Algoritme for aritmetisk koding.

Vi har tekst $x = \{x_1, x_2, \dots, x_m\}$ hvor x_i er hentet fra $\mathcal{A} = \{\alpha_1, \alpha_2, \dots, \alpha_n\}$ med sannsynligh.

$$P(\alpha_1) P(\alpha_2) \dots P(\alpha_n)$$

Vi skal assosiere α_i med et delintervall av $[0,1]$ med bredde $P(\alpha_i)$.



Vi innfører notasjonen

$$F(\alpha_j) = \sum_{i=1}^j P(\alpha_i), \quad L(\alpha_j) = \sum_{i=1}^{j-1} P(\alpha_i) = F(\alpha_j) - P(\alpha_j)$$

Alg.


Hvis $x_1 = \alpha_i$ så skal vi starte med intervallt til α_i , dvs $[a_1, b_1]$, der

$$a_1 = P(\alpha_1) + \dots + P(\alpha_{i-1}) = L(\alpha_i) = L(x_1)$$

$$b_1 = P(\alpha_1) + \dots + P(\alpha_{i-1}) + P(\alpha_i) = F(\alpha_i) = F(x_1)$$

Hva blir nå neste delintervall?

Neste tegn er x_2 , la oss si α_k . Dette tegnet hører til intervallt $[L(x_2), F(x_2)] = [L(\alpha_k), F(\alpha_k)]$



Trukket $[0,1]$ inn på $[a_1, b_1]$ ved hj. av

$$g_1(z) = a_1 + z(b_1 - a_1)$$

Da hører $[L(x_2), F(x_2)]$ i intervallt

$$[a_2, b_2] = [g_1(L(x_2)), g_1(F(x_2))]$$

Vi ser et

$$a_2 = g_1(L(x_2)) = a_1 + L(x_2)(b_1 - a_1)$$

$$b_2 = g_1(F(x_2)) = a_1 + F(x_2)(b_1 - a_1)$$

Algoritme 7.20.

1. Sett $[a_1, b_1] = [0, 1]$

2. For $k=1, 2, \dots, m$

(a) Definer $g_k(z) = a_{k-1} + z(b_{k-1} - a_{k-1})$

(b) Sett $[a_k, b_k] = [g_k(L(x_k)), g_k(F(x_k))]$

Den aritmetiske koden til teksten x er
midtpunktet $C(x)$ i $[a_m, b_m]$, trunkert til

$$\lceil -\log_2(P(x_1) \dots P(x_m)) \rceil + 1$$

linære cifre.

Egenskaper ved aritmetisk koding 7.4.3

Thm. Bredden av $[a_m, b_m]$ er

$$b_m - a_m = P(x_1) P(x_2) \dots P(x_m) \quad (*)$$

og den aritmetiske koden ligger i $[a_m, b_m]$

Bewis. Bewis for (*) ved induksjon.

Når $m=1$ så er $b_1 - a_1 = F(x_1) - L(x_1) = P(x_1)$

Anta ok for $k-1$, \Rightarrow :

$$b_{k-1} - a_{k-1} = P(x_1) P(x_2) \dots P(x_{k-1}).$$

Hva da med $b_k - a_k$?

$$b_k - a_k = g_k(F(x_k)) - g_k(L(x_k))$$

$$= (F(x_k) - L(x_k)) (b_{k-1} - a_{k-1}) = P(x_k) P(x_1) \dots P(x_{k-1}). \quad Ok$$

Må også vise at den aritmetiske koden hører i intervalllet $[a_m, b_m]$.

Definer μ ved relasjonen $\frac{1}{2^\mu} = b_m - a_m$
 $2^\mu = P(x_1) \dots P(x_m)$


Vanlig vis er ikke μ et heltall så vi setter $\alpha = \lceil \mu \rceil$.

$$\lceil 100.1 \rceil = 101$$

$$\lceil 100.9 \rceil = 100$$

Dette betyr at $\frac{1}{2^\alpha}$ er mindre enn $b_m - a_m$

Se på tallene $i/2^\alpha$, $i=1, 2, \dots, 2^\alpha$



Aritmetisk koding er optimalt (for lange tekster).

Minner om at

$$\log_2(P(x_1) \cdot \dots \cdot P(x_m)) = \sum_{i=1}^n f(\alpha_i) \log_2 P(\alpha_i)$$

La oss se på antall bit nr. tegn for aritmetisk koding:

$$\begin{aligned} & \frac{1}{m} \left(\lceil -\log_2(P(x_1) P(x_2) \dots P(x_m)) \rceil + 1 \right) \\ & \leq -\frac{1}{m} \log_2(P(x_1) P(x_2) \dots P(x_m)) + \frac{2}{m} \\ & = -\frac{1}{m} \sum_{i=1}^n f(\alpha_i) \log_2 P(\alpha_i) + \frac{2}{m} \\ & = -\sum_{i=1}^n \frac{f(\alpha_i)}{m} \log_2 P(\alpha_i) + \frac{2}{m} \\ & \approx -\sum_{i=1}^n P(\alpha_i) \log_2 P(\alpha_i) \\ & = H(P_1, \dots, P_n) \end{aligned}$$