

平均情報量で見るデータ量の理論値

実際の符号化方式の話へと入る前に、前節でやった平均情報量（エントロピー）で理論的な情報量の平均値を求めてみましょう。

ABCDがそれぞれこのような出現頻度だとすると…?



A 事象A₁の情報量 → $-\log_2 0.5 = 1$ ビット

B 事象A₂の情報量 → $-\log_2 0.3 \approx 1.74$ ビット

C 事象A₃の情報量 → $-\log_2 0.1 \approx 3.32$ ビット

D 事象A₄の情報量 → $-\log_2 0.1 \approx 3.32$ ビット

試験では対数(log)の細かい計算が求められることはありませんので

この計算自体はざらりと流して大丈夫です



この場合の平均情報量は

$$(0.5 \times 1) + (0.3 \times 1.74) + (0.1 \times 3.32) + (0.1 \times 3.32) = \underline{\underline{1.686}} \text{ ビット}$$

単純に各文字2ビットずつを割り当てた場合、当然1文字あたりのデータ量は2ビットとなります。これは、ABCD各文字が均等に出現するとした場合の平均情報量（ $-\log_2 0.25 = 2$ ビット）と等しいものです。しかし、その出現頻度にバラつきがある場合は、個々の確率を元に情報量を算出することで、1文字あたりの平均的なデータ量を1.686ビットにまで圧縮できる可能性があることがわかります。

その差は約16%。決して小さい値ではありません。



…というところで、それでは実際の符号化方式を見てみましょう。