

## COMPLEXITÉ DE KOLMOGOROV

↓ J'AI LANCÉ UNE PIÈCE 20 FOIS ET J'AI OBTENU :

① 1010101010101010101010

QU'EN DITES VOUS ? VOUS NE ME CROYEZ PAS.

② 11100101100100011101

QU'EN DITES VOUS ? PEUT-ÊTRE ...

POURQUOI ? PROBABILITÉ IDENTIQUE :  $2^{-20}$

LA THÉORIE CLASSIQUE DES PROBABILITÉS NE CAPTIVE PAS NOTRE NOTION INTUITIVE DE "ALÉATOIRE".

REMARQUE : ON PEUT GÉNÉRER ① AVEC UN PROGRAMME "RÉPÉTER '10' 10 FOIS" DE LONGUEUR  $c + \log_2(10)$ , MAIS POUR ② CELA SEMBLE IMPOSSIBLE ... INCOMPRESSIBLE ?

LA COMPLEXITÉ DE KOLMOGOROV EST UNE DES FAÇONS DE DÉFINIR L'INFORMATION, ET LA QUANTIFIER : LA PLUS PETITE DESCRIPTION ALGORITHMIQUE.

DÉFINITION : SOIT  $x \in \{0,1\}^*$ . LA DESCRIPTION MINIMALE DE  $x$ , NOTÉE  $d(x)$ , EST LE PLUS PETIT MOT  $\langle \pi \rangle, w$  AVEC  $\pi$  UNE M.T. QUI SUR L'ENTRÉE  $w$ , S'ARRÊTE AVEC  $x$  ÉCRIT SUR SON RUBAN. LA COMPLEXITÉ DE KOLMOGOROV DE  $x$  EST  $K(x) = |d(x)|$ .

TAIPE + LEX

ENCODAGE DES COUPLES  $(u, v)$ , PAR EXEMPLE DOUBLÉ  $(|u|)01uv$

EN  $2 \log_2(|u|) + 2 + |u| + |v|$  BITS.

EXERCICE : UN ENCODAGE ASYMPTOTIQUEMENT MEILLEUR ?

double  $(\log_2(|u|))01uv$

EN  $2 \log_2(\log_2(|u|)) + 2 + \log_2(|u|) + |u| + |v|$  BITS.

DÉFINITION ALTERNATIVE :  $K'(x) = \min \{ |\langle \pi \rangle| \mid M(\varepsilon) = x \}$  MAIS LA DÉFINITION AVEC  $\langle \pi \rangle, w$  EST PRATIQUE POUR HARD-CODER DES VALEURS AVEC  $\pi$  CONSTANTE.

THM :  $\exists c, \forall x, K'(x) \leq c \cdot K(x) + c$  IDÉE : SUR  $\varepsilon$  ON AJOUTE  $|w|$  TRANSITIONS POUR ÉCRIRE  $w$

$\forall x, K(x) \leq K'(x) + 2 \log_2(K'(x)) + 2$  IDÉE :  $\langle \pi \rangle \mapsto (\langle \pi \rangle, \varepsilon)$ .

THM:  $\exists c: \forall x: K(x) \leq |x| + c$ .

PREUVE: AVEC LA M.T. M QUI S'ARRÊTE IMMÉDIATEMENT SUR TOUTE ENTRÉE ET  $w=x$ .  $\square$

THM:  $\exists c: \forall x: K(xx) \leq K(x) + c$ .

PREUVE: SOIT LA M.T. M QUI, SUR L'ENTRÉE  $(\langle n \rangle, w)$ :

1. S'ARRÊTE N SUR L'ENTRÉE  $w$  (S'ARRÊTE AVEC  $x$  SUR LE RUBAN)
  2. DUPLOME LE CONTENU DU RUBAN (S'ARRÊTE AVEC  $xx$  SUR LE RUBAN).
- UNE DESCRIPTION DE  $xx$  EST  $(\langle n \rangle, d(x))$ .  $\square$

COMPLEXITÉ DE LA CONCATÉNATION.

THM:  $\exists c, \forall x, y: K(xy) \leq 2 \cdot \log_2(K(x)) + K(x) + K(y) + c$ .

PREUVE:  $(\langle n \rangle, (d(x), d(y)))$  AVEC M LA M.T. QUI SIMULE  $d(x)$  PUIS  $d(y)$  POUR ÉCRIRE  $xy$ .  $\square$

THM:  $\forall c: \exists x, y: K(xy) > K(x) + K(y) + c$ .

PREUVE: ON A BESOIN DU RÉSULTAT SUIVANT:

THM:  $\forall k \in \mathbb{N}$ , POUR TOUT  $x \in \{0,1\}^*$  SUFFISAMMENT LONG IL EXISTE UN PRÉFIXE  $y \sqsubseteq x$  TEL QUE  $K(y) < |y| - k$ .

PREUVE: SOIT  $f$  UNE BIJECTION STANDARD (LONGUEUR-LOG) ENTRE  $\{0,1\}^*$  ET  $\mathbb{N}$ .

SOIT  $z \sqsubseteq x$  ET  $f(z) = n$ .

SOIT  $y$  L'EXTENSION DE LONGUEUR  $n$  DE  $z$  SELON  $x$ ,

C'EST-À-DIRE  $y = z0 \sqsubseteq x$  AVEC  $|0| = n$ .

IL EXISTE UNE M.T. M TELLE QUE  $M(\sigma) = z\sigma$ , EN UTILISANT  $f^{-1}(|0|) = z$ .

DONC  $K(y) \leq |0| + c$  AVEC  $c$  INDÉPENDANTE DE  $y$  (DE  $z$  ET DE  $\sigma$ ).

EN PRENANT  $|z| > k + c$  ON OBTIENT

$$K(y) \leq |0| + c = |y| - |z| + c < |y| - k - c + c = |y| - k. \quad \diamond$$

SOIT  $c'$  TELLE QUE  $\forall x: K(x) \leq |x| + c'$ .

SOIT  $z$  SUFFISAMMENT LONG ET VÉRIFIANT  $K(z) \geq |z|$  (INCOMPRESSIBLE, EXISTENCE PAGE SUIVANTE).

SOIT  $k = c + c'$ . PAR LE THM IL EXISTE  $x \sqsubseteq z$  TEL QUE  $K(x) < |x| - c - c'$ .

ALORS POUR  $y$  TEL QUE  $z = xy$  ON A:

$$K(x) + K(y) + c < \underbrace{|z| - c - c'} + \underbrace{|y| + c'} + c = |x| + |y| = |z| \leq K(z) = K(xy). \quad \square$$

OPTIMALITÉ DE LA DESCRIPTION.

DEF:  $K_p(x)$  LA COMPLEXITÉ DE KOLMOGOROV RELATIVE AU LANGAGE DE PROGRAMMATION P. (DE DESCRIPTION)

THM:  $\forall P: \exists c: \forall x: K(x) \leq K_p(x) + c.$

PREUVE: IL FAUT QUE LA M.T. INTERPRÈTE (COMPTE + EXÉCUTE) LE PROGRAMME EN P.  $\square$

K N'EST PAS CALCULABLE

THM:  $K: \{0,1\}^* \rightarrow \mathbb{N}$  N'EST PAS CALCULABLE.

PREUVE AVEC AUTO-RÉFÉRENCE:  $\Upsilon$  (1f. PROGRAMME)

PAR L'ABSURDE, SUPPOSONS QUE K SOIT CALCULABLE.

ALORS ON PEUT CONSTRUIRE M COMI, SUR TOUTE ENTRÉE:

1. OBTIENT SON PROPRE CODE  $\langle M \rangle$
2. ÉNUMÈRE LES MOTS BINAIRES JUSQU'À TROUVER  $x$  TEL QUE  $K(x) > |\langle M \rangle|$
3. ÉCRIT  $x$  ET S'ARRÊTE. (ou  $K(x) > 2 \log_2(K(n)) + 2 + |n|$ )

ALORS M DÉCRIT  $x$  MAIS EST PLUS PETITE QUE  $K(x)$ .  $\leq \square$   
 $(\langle M \rangle, \varepsilon)$

PREUVE SANS AUTO-RÉFÉRENCE:

PAR L'ABSURDE, SUPPOSONS QUE K SOIT CALCULABLE.

ALORS ON PEUT CONSTRUIRE M COMI, SUR L'ENTRÉE  $w$ :

1. ÉNUMÈRE LES MOTS BINAIRES JUSQU'À TROUVER  $x$  TEL QUE  $K(x) > 2|w|$ .
2. ÉCRIT  $x$  ET S'ARRÊTE.

ALORS  $(\langle M \rangle, w)$  DÉCRIT  $x$  MAIS LA TAILLE DE CETTE DESCRIPTION EST  $c + |w|$

DONC POUR  $w$  SUFFISAMMENT GRAND ON A  $|\langle M \rangle, w| = c + |w| \leq 2|w| < K(x)$ .  $\leq \square$   
 $(|w| \geq c)$

THM:  $K: \{0,1\}^* \rightarrow \mathbb{N}$  EST APPROXIMABLE "PAR AU-DESSUS":

$\exists (K_i: \{0,1\}^* \rightarrow \mathbb{N})_{i \in \mathbb{N}}$  CALCULABLES TELLES QUE  $\forall x: \lim_{i \rightarrow +\infty} K_i(x) = K(x)$  et  $\forall i: K_i(x) \geq K(x)$ .

PREUVE: SOIT  $c$  TELLE QUE  $\forall x: K(x) \leq |x| + c.$

$K_i$  EXÉCUTE TOUTES LES DESCRIPTIONS DE TAILLE  $< |x| + c$  POUR  $i$  ÉTAPES DE TEMPS, ET DONNE EN SORTIE LA TAILLE DE LA PLUS COURTE QUI A DONNÉ  $x$  EN SORTIE (SI AUCUNE ALORS  $|x| + c$ ).  $\square$

MOTS INCOMPRESSIBLES.

DEF:  $x$  EST  $c$ -COMPRESSIBLE LORSQUE  $K(x) \leq |x| - c$ .

$x$  EST INCOMPRESSIBLE = 1-INCOMPRESSIBLE =  $K(x) \geq |x|$   
(PAS DE DESCRIPTION PLUS PETITE QUE LUI-MÊME).

THM: IL EXISTE DES MOTS BINAIRES INCOMPRESSIBLES DE TOUTE TAILLE.

PREUVE: COMPTAGE POUR UNE TAILLE  $n$ :

NOMBRE DE MOTS BINAIRES DE TAILLE  $n := 2^n$

NOMBRE DE DESCRIPTIONS DE LONGUEUR  $< n := \sum_{i=0}^{n-1} 2^i = 2^n - 1$ .

OR CHAQUE DESCRIPTION NE DÉCRIT QU'UN SEUL MOT.  $\square$

EXERCICE: COMBIEN DE MOTS BINAIRES DE TAILLE  $n$  SONT  $c$ -INCOMPRESSIBLES ?

AU MOINS  $2^n - 2^{n-c+1} + 1$ .

SOIT  $L_k = \{x \mid K(x) \geq |x|\}$  LES INCOMPRESSIBLES.

EXERCICE: AUCUN SOUS-ENSEMBLE INFINI DE  $L_k$  (MÊME  $L_k$  LUI-MÊME) N'EST SEMI-DÉCIBLÉ.

PREUVE: PAR L'ABSURDE, SOIT  $M$  QUI SUR L'ENTRÉE  $w$ :

1. ÉNUMÈRE LES INCOMPRESSIBLES JUSQU'À TROUVER UN TEL  $x$  AVEC  $|x| > 2|w|$ ,
2. ÉCRIT  $x$  ET S'ARRÊTE.

ALORS  $(\langle \pi \rangle, w)$  DÉCRIT  $x$  ET LA TAILLE DE CETTE DESCRIPTION EST  $c + |w|$ .

DONC POUR  $|w| \geq c$  ON AURA  $|(\langle \pi \rangle, w)| = c + |w| \leq 2|w| < |x| \leq K(x)$ .  $\zeta \square$

THM: LES DESCRIPTIONS MINIMALES SONT  $c$ -INCOMPRESSIBLES:

$\exists c: \forall x \in \{0,1\}^*: K(d(x)) \geq |d(x)| - c$ .

PREUVE: SOIT  $M$  LA RT. QUI, SUR L'ENTRÉE  $(\langle R \rangle, y)$ , CALCULE  $R(y) = (\langle S \rangle, z)$

(REJETTE SI PAS DE LA BONNE FORME) PUIS  $S(z)$  ET LAISSE CE RÉSULTAT SUR SON RUBAN.

SOIT  $c = 2 \log_2(K(\pi)) + |\langle M \rangle| + 3$ .

PAR L'ABSURDE, SI  $d(x)$  EST  $c$ -COMPRESSIBLE ALORS  $|d(d(x))| \leq |d(x)| - c$

MAIS  $(\langle M \rangle, d(d(x)))$  DÉCRIT  $x$  AVEC LONGUEUR

$\underbrace{2 \log_2(K(\pi)) + 2 + |\langle \pi \rangle|}_{c-1} + |d(d(x))| \leq c-1 + |d(x)| - c = |d(x)| - 1$

CE QUI CONTRADICT LA MINIMALITÉ DE  $d(x)$ .  $\zeta \square$

APPLICATION À LA DENSITÉ DES NOMBRES PREMIERS

IDÉE : LA DÉCOMPOSITION EN FACTEURS PREMIERS PERMET DE REPRÉSENTER SUCCEINTEMENT CERTAINS ENTIERS (NOTS BINAIRES) MAIS LES INCOMPRÉHENSIBLES RESTENT INCOMPRÉHENSIBLES.

DEF : SOIT  $\pi(n)$  LE NOMBRE D'ENTIERS PREMIERS  $\leq n$ .  $\pi(11) = 5$ .

THM :  $\pi(n) \geq \frac{\log n}{\log \log n} - o(1)$  AVEC  $o(1)$  UNE FONCTION QUI TEND VERS 0 QUAND  $n \rightarrow +\infty$ .

PREUVE : SOIT  $n \in \mathbb{N}$  AVEC  $n = p_1^{e_1} \cdot p_2^{e_2} \cdot \dots \cdot p_m^{e_m}$  SA DÉCOMPOSITION EN FACTEURS PREMIERS.

ALORS ON PEUT REPRÉSENTER  $n$  AVEC  $(\langle n \rangle, (e_1, \dots, e_m))$  OÙ :

- $e_i \leq \log n$  DONC  $\log \log n$  BITS DONC  $(e_1, \dots, e_m)$  PEUT ÊTRE ENCODÉ PAR  $\underbrace{0^{\log \log \log n} 1 e_1 e_2 \dots e_m}_{\text{POUR DÉCODER LA SUITE}}$
- $M$  EST UNE MACHINE CONSTANTE QUI DÉCODE  $e_1, \dots, e_m$ , CALCULE  $p_1, \dots, p_m$ , PUIS  $n$ .

DONC  $K(n) \leq c + m \cdot \log \log n + \log \log \log n$

POUR  $n$  INCOMPRÉHENSIBLE ON A  $K(n) \geq \log n$  D'OU

$$\log n \leq c + m \cdot \log \log n + \log \log \log n$$

$$\Rightarrow \frac{\log n - c - \log \log \log n}{\log \log n} \leq m$$

$$\Rightarrow \frac{\log n}{\log \log n} - o(1) \leq m \leq \pi(n). \quad \square$$

NB : HADAMARD ET DE LA VAUÉE REUSON 1896 :  $\pi(n) \sim \frac{n}{\ln n}$ .

THM:  $\forall t \in \mathbb{N}, \exists x \in \{0,1\}^* : K(x) > t$ .

PREUVE: soit  $t \in \mathbb{N}$ .

IL Y A  $\leq 2^t$  PROGRAMMES DE TAILLE  $\leq t$ .

CHACUN D'EUX DÉCRIT AU PLUS UNE NOUVELLE CHAÎNE,

DONC CES  $\leq 2^t$  PROGRAMMES DÉCRIVENT  $\leq 2^t$  CHAÎNES.

C'EST UNE QUANTITÉ FINIE DONC  $\exists x$  QUI N'EST

PAS PARMI ELLES. CETTE CHAÎNE  $x$  N'EST DÉCRITE

PAR AUCUN PROGRAMME DE TAILLE  $\leq t$ ,

C'EST  $\bar{A}$ -BINAIRE  $K(x) > t$ .  $\square$