

Théorie et théories de l'Information

Qq éléments de : **Information, complexité et hasard**

Jean-Paul Delahaye

disponibles aussi sur [i\(nter\)stices](#)

Oct08

Vous avez dit information ?

Dans la suite :

00000 00000 00000 00000 00000 00000 00000 00000

il y a sûrement moins d'information que dans la suite :

26535 89793 23846 26433 83279 50288 41971 69399

qui est plus *complexe* mais . .

pourquoi ?

Serait-ce que la 2ème suite
est (complexité aléatoire) :

sans ordre, sans régularité, aléatoire, chaotique ?

ou (complexité organisée)

organisé, fortement structuré, riche en information ?

Vous avez dit information ?

Il se trouve que :

26535 89793 23846 26433 83279 50288 41971 69399
est la suite des décimales de π à partir de la sixième (après 14159).

Distinguons donc bien :

- Un contenu **brut** en information qui ne dépend pas du *sens*.
- La **valeur** d'une information dépend du *but* fixé.

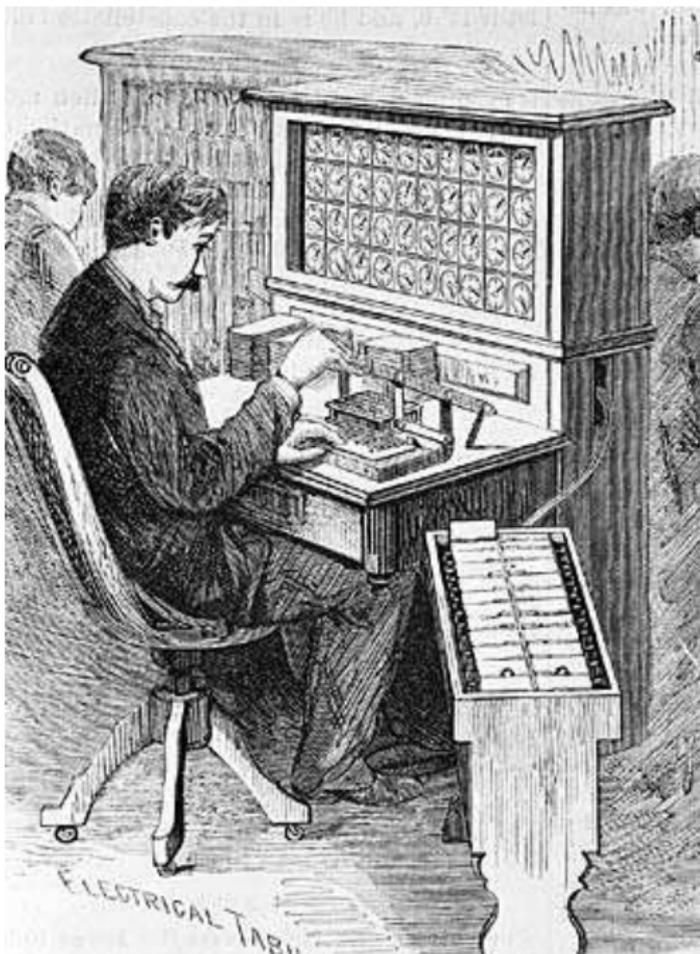
avec deux grandes théories (selon le but) :

- **Théorie probabiliste de l'information** (Shannon / thermodynamique)
- **Théorie algorithmique de l'information** (Kolmogorov / Bennett)

en lien avec :

l'informatique théorique, les neurosciences computationnelles etc..

Vous avez dit information ?



Contenu brut en information

-1- Le contenu brut en information d'un booléen

(1/0 vrai/faux oui/non yin/yang) 1.

C'est l' "atome" d'information : le "bit".

-2- Le contenu en information d'une valeur $v \in \{1, N\}$

(digits ($N = 10$), lettre de l'alphabet ($N = 26$), ..) est $\log_2(N)$.

C'est le nombre de bits pour "coder" la valeur, en cohérence avec -1-

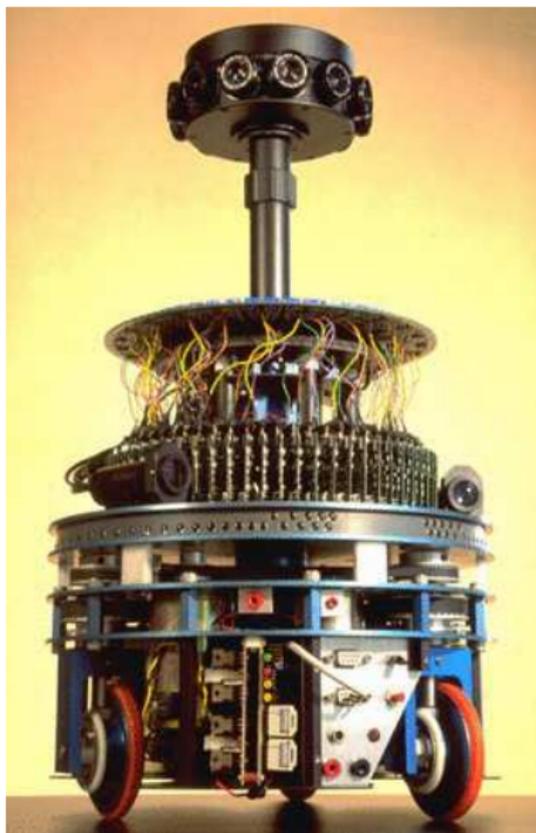
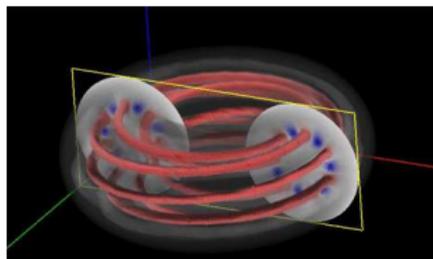
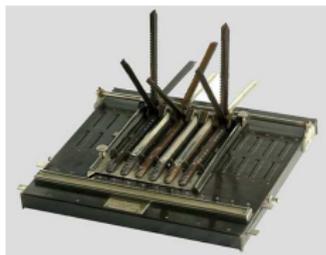
-3- Le contenu brut en information de n éléments "indépendants" est la *somme* des contenus bruts.

mais inférieure si il y a de la *redondance* (compression)

mais sans *valeur* si il n'y a aucun lien entre les éléments!

- C'est le nombre minimal de questions oui/non à poser pour trouver la valeur donnée!

Vous avez dit information ?



Contenu probabiliste en information

Pour le contenu probabiliste en information qui :

1/ N'est fonction que de la probabilité des évènements.

2/ Est additif pour deux sources indépendantes.

3/ Croît linéairement avec le nombre de réponses équiprobables.

On parle d'*entropie* au sens de Shannon et obtient une définition :

$$\mathcal{H}(p : \{1..n\} \rightarrow [0, 1]) = - \sum_n p(n) \log_2 (p(n))$$

contenu moyen en information d'une distribution de probabilité.

Contenu probabiliste en information

- Pour une *distribution binaire* $p : \{0, 1\} \rightarrow [0, 1]$
 - > $\mathcal{H} = 1$ si $p(0) = p(1) = 1/2$: hasard complet, non-redondance
 - > $\mathcal{H} = 0$ si $p(0) = 1, p(1) = 0$: valeur fixe, rien à découvrir
- Pour une *distribution uniforme* $p : \{0, N\} \rightarrow [0, 1], p(i) = 1/N$.
 - > \mathcal{H} est maximale
 - > $\mathcal{H} = \log_2(N)$: nb de bits pour coder la valeur
- Au delà :
 - > \mathcal{H} est une valeur positive, bornée.
 - > Elle se définit dans le cas continu à une *résolution donnée*.

Utilisation de l'information probabiliste : estimation

Que veut dire . . . estimer une valeur incertaine ?

- Si je sais rien de rien, j'peux qu'agir au hasard . . .
- Si je sais quelque chose, c'est moins aléatoire !

On cherche alors $p : \{0, N\} \rightarrow [0, 1]$, $\sum_n p(n) = 1$ t.q. :
 $\sum_n p(n) f_i(n) = v_i, i \in \{1, m\}$ (contraintes), $\max_p \mathcal{H}(p)$ (entropie)

Une solution vérifie à minima les contraintes (rasoir d'Occam) :

$$p(n) = \frac{1}{Z} e^{-\sum_i \lambda_i f_i(n)}$$

pour des "multiplicateurs" λ_i donnés par les contraintes (Gibbs)

Si on donne moyenne/écart-type d'un réel, c'est la Gaussienne :

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \frac{(x-m)^2}{\sigma^2}}$$

Si on donne le rythme moyen d'une série de "bips", c'est le Poisson

$$p(d) = r e^{-r} d, P\{N \text{ tops pendant } T\} = \frac{(rT)^N}{N!} e^{-rT}$$

Utilisation de l'information probabiliste : transmission

Quelle information véhiculée par une réponse \mathbf{r} à propos d'un stimulus \mathbf{s} ?

- Une source s , grâce à un codage, envoie un message à un récepteur r
→ qui effectue le décodage dans un contexte perturbé de bruit.

On utilise la probabilité conditionnelle $p(\mathbf{r}|\mathbf{s})$:

- > Si $p(\mathbf{r}|\mathbf{s}) = p(\mathbf{r}) p(\mathbf{s})$ les deux n'ont rien à voir (indépendance).
- > Si $p(\mathbf{r}|\mathbf{s}) = p(\mathbf{s})$ les deux sont fonctionnellement liées.

On définit alors l'information mutuelle (dépendance statistique)

$$\begin{aligned} \mathcal{I}(\mathbf{r}, \mathbf{s}) &= \mathcal{H}[\text{réponse}] - \mathcal{H}[\text{variabilité non due à la source}] \\ &= \mathcal{H}[\text{réponse}] - \mathcal{H}[\text{réponse}|\text{source}] \\ &\leq \mathcal{H}[\text{réponse}] + \mathcal{H}[\text{source}] \end{aligned}$$

symétrique, positive, etc..

Qui utilise la règle de Bayes :

$$p(\mathbf{r}|\mathbf{s}) = p(\mathbf{r}, \mathbf{s})/p(\mathbf{s}) = p(\mathbf{s}|\mathbf{r}) p(\mathbf{r})/p(\mathbf{s})$$

Utilisation de l'information probabiliste : autres applications

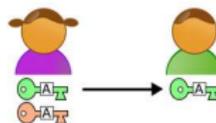


- Codage de l'information

- Compression de données

- Cryptographie

- Corrections d'erreurs



Une variable d'entropie $\mathcal{H}(x)$ sera "presque sûrement" codée avec $\mathcal{H}(x)$ bits

Théorie algorithmique de l'information

La clé :

Est riche en information un message m . . complexe à calculer.

La complexité de Kolmogorov $K(m)$:

La **longueur** du plus petit programme écrit pour une machine universelle qui génère le message.

Notion de machine universelle U

(ex : machine de turing)

Notion de machine optimale M :

$$K_M(m) \leq K_U(m) + C_U$$

universalité

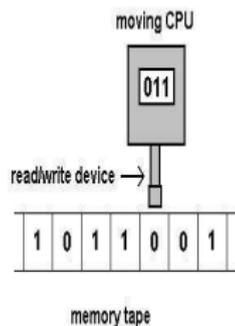
Mais : $K(m)$ n'est pas calculable !



Notion de machine universelle

Thèse de Church-Turing : Tout problème “algorithmique” peut être résolu par une machine de Turing.

- 0- Un ruban plein de '0' où on peut écrire des '1'
- 1- Une tête qui peut lire/écrire des 0/1
- 2- Et se déplacer vers la gauche ou droite
- 3- Une table d'actions
 - . qui définit en fonction du symbole lu :
 - . – quoi écrire,
 - . – comment se déplacer,
 - . – et quelle nouvelle action.



- Tou(te) *fonction calculable, programme/automate* se réduit à “ça”
- Les actions peuvent être codées sur un autre ruban pour être jouées :
machine universelle

Notion de fonctions non calculables

- Les fonctions calculables sont dénombrables (elles sont définies par un ruban) mais les fonctions sur un domaine infini contiennent \mathcal{R}
 - Il y a plein d'exemples "utiles" :
 - Pas de programme universel qui en temps fini, renvoie « oui » un programme va finir et « non » s'il va "boucler sans fin".
- et par déduction (Th. de Rice) :
- * « le programme ne termine pas par une erreur d'exécution »
 - * « le programme calcule le spécifié »
-
- La complexité de Kolmogorov n'est pas calculable :
Car si $K(n)$ est calculable, alors le programme

```
for(int n = 1; K(n) <= x; n++); print n;
```


qui est de longueur $L = O(\log_2(x))$ génère un entier n donc la complexité est au plus L .
On peut alors montrer avec x suffisamment grand on obtient $n > L$: contradiction !

A propos d'échelles de complexité

- **Récuratif** : *effectif* :

on peut déterminer son contenu par un moyen sans ambiguïté.

Classes L et P : temps de calcul logarithmique ou polynomial

Classe NP : résolu en énumérant les solutions possibles

(classifications selon temps de calcul et espace mémoire).

- **Récurativement énumérable** : *constructif* :

il se précise au fur et à mesure du temps, mais à chaque instant impossible de le cerner complètement.

- **Non récurativement énumérable** : *prospectif* :

accessible à l'intelligence humaine, mais rien ne l'épuise et rien ne pourra jamais l'épuiser.

Approximables : par une suite croissante d'ensembles récurativement énumérable.

Immunes : on ne peut en décrire récurativement que des parties finies.

Incompressibles : on ne peut aller plus loin que les axiomes de base.

Théorie algorithmique de l'information

La complexité de Kolmogorov $K(m)$:

La **longueur** du plus petit programme écrit pour une machine universelle qui génère le message.

- Elle est bornée : au pire avec : `print m` et non additive.
- Elle capture la complexité aléatoire de l'information
- On peut la relier au notions d'
incompressibilité = imprévisibilité = absence de structure
- L'entropie de Shannon correspond à la complexité de Kolmogorov moyenne (Grünwald Vitányi 2004)

Théorie algorithmique de l'information

La profondeur logique de Bennet $P(m)$:

Le **temps de calcul** du plus petit programme écrit pour une machine universelle qui génère le message.

et non le temps de calcul du programme le plus rapide : c'est $\text{print } m!$

- Capture la notion de complexité organisée :

simple et peu profond :	cristal
simple et profond :	π à 10^{-10} près
aléatoire et peu profond :	gaz parfait
aléatoire et profond :	être vivant

- Approximativement invariant à la machine (si la longueur est définie à k près)
- Non additivité (deux moutons ne sont pas deux fois plus complexes qu'un)
- Croissance lente (la profondeur augmente avec du calcul, mais lentement)
- Apparition "spontanée" de complexité organisée par le calcul
- Non calculabilité

Vous avez dit information ?

