

S1916 - Analyse et Compression du Signal Audionumérique - Examen Corrigé

Sébastien Boisgérault, Mines ParisTech, CC BY-NC-SA 4.0

15 mars 2018

Contents

Modalités	1
Questions	2
Voix + Texte	2
Réponse	2
Code Unaire	2
Réponse	3
421	3
Réponse	3
Réverbération	4
Réponse	4
Inaudible	5
Réponses	5
De 8 kHz à 16 kHz	6
Réponse	6
Quantification	7
Réponse	7
Prédiction Linéaire	8
Réponse	8

Modalités

- **Durée:** 1h30.
- **Autorisés:**
 - tous documents (sous forme papier ou électronique),
 - calculette, tablette, ordinateur portable, etc.

- **Interdit:**

- toute forme de communication: échanges avec le voisin, utilisation d’Internet, du téléphone, etc.

Questions

Voix + Texte

On souhaite adjoindre à un flux de voix parlée – utilisant la technologie appropriée de compression – la transcription textuelle du message. De quel pourcentage est-ce que l’on augmente le débit de données ?

On ne cherche ici qu’un ordre de grandeur (0.1% ? 1% ? 10% ? 100% ?); on pourra supposer un débit de 200 mots/min et une longueur moyenne 6 lettres par mot.

Réponse

On peut prendre 10 kbits/s comme débit de référence pour la voix parlée (soit ~1% du débit de données d’un CD audio; le débit associé au standard GSM est 9.6 kbits/s par exemple). Si un locuteur prononce 200 mots par minute et que chaque mot fait 6 lettres, en négligeant l’information associée aux espaces, ponctuations, etc. et en supposant que chaque lettre est décrite par un caractère ASCII, le débit associé est

$$\frac{200 \times 6 \times 8}{60} = 160 \text{ bits/s}$$

Soit de l’ordre de 1% du débit de la voix. Bien sûr, ces nouvelles données pourraient elle-mêmes être soumises à une compression (sans perte) si nécessaire. Différents auteurs (dont Shannon) ont estimé l’entropie associée à une lettre de la langue anglaise et obtiennent des résultats autour de 1 ou 2 bits, à comparer avec les 8 bits utilisés pour un caractère ASCII. En étant optimiste (en tablant sur 1 bit), on pourrait donc réduire le flux de données textuelles à approximativement

$$\frac{160}{8} = 20 \text{ bits/s.}$$

On est alors plus proche de 0.1% que de 1% du débit associé à la voix.

Code Unaire

Une source d’information produit aléatoirement l’entier naturel n avec une probabilité $P(N = n) = 2^{-n-1}$. Si l’on utilise un code unaire, quelle est la longueur moyenne (en bits) du code associé ?

Réponse

Le code unaire associé à l'entier n est n "1" suivi d'un "0"; la longueur $|c(n)|$ du code associé à n est donc $n + 1$ bits. Par conséquent, la longueur moyenne du code de N est fournie par la formule:

$$\langle |c(N)| \rangle = \sum_{n=0}^{+\infty} 2^{-n-1} \times (n + 1) = \sum_{n=1}^{+\infty} n2^{-n}.$$

Il existe plusieurs techniques ancestrales pour calculer cette somme. Ma préférée: remarquer que si $z = 1/2$, la somme cherchée vaut

$$\sum_{n=0}^{+\infty} nz^n = S(z)$$

(avec la convention que $z^0 = 1$, ce qui permet de sommer à partir de 0 et non de 1). Puis, comme pour tout $|z| < 1$ on a

$$\frac{d}{dz} \left(\sum_{n=0}^{+\infty} z^n \right) = \sum_{n=0}^{+\infty} nz^{n-1} = \left(\sum_{n=0}^{+\infty} nz^n \right) / z,$$

la valeur de $S(z)$ est donnée par

$$S(z) = z \times \frac{d}{dz} \left(\frac{1}{1-z} \right) = \frac{z}{(1-z)^2}.$$

On a donc

$$\langle |c(N)| \rangle = S(1/2) = \frac{1/2}{(1-1/2)^2} = 2.$$

421

Le jeu de 421 se joue avec trois dés à 6 faces. Le tirage le plus fort est le "421" (un dé a produit "4", un autre "2" et le dernier "1"). Quelle est la quantité d'information associée l'événement "tirer un 421" ? Quelle est la quantité d'information (moyenne) que l'on obtient en observant si l'on a tiré un 421 ou non ? Même questions pour le tirage le plus faible, le "221" (la "nénette").

Réponse

Les trois dés utilisés sont tous distinguables (on peut supposer par exemple qu'il y en a un rouge, un bleu et un vert). Il y a donc 6 tirages possibles pour faire un "421": le "4" peut apparaître sur l'un quelconque des trois dés et dans chacun de ces cas, il y a deux façon d'allouer le "2" et le "1" aux deux dés restants.

La probabilité associée est donc $p = 6/6^3 = 1/6^2$ et l'information associée au tirage d'un "421" est

$$I = -\log_2 p \approx 5.17 \text{ bits.}$$

L'entropie associée à l'observation "tirer un 421 ou non" est donnée par

$$H = -p \log_2 p - (1-p) \log_2 (1-p) \approx 0.183 \text{ bits.}$$

La situation pour le "221" est similaire, sauf qu'il n'existe que 3 tirages possibles: une fois que le "1" a été affecté à un dé (trois possibilités), il n'y a plus aucun choix possible; donc $p = 3/6^3$, et par conséquent

$$I \approx 6.17 \text{ bits et } H \approx 0.106 \text{ bits.}$$

Réverbération

On associe au signal digital $u_n = u(t = n\Delta t)$ un signal $y_n = y(t = n\Delta t)$ qui satisfait

$$\forall n \in \mathbb{Z}, y_{n+p} - gy_n = -gu_{n+p} + u_n$$

où $g > 0$ et $p \in \mathbb{N}^*$.

Déterminer la fonction de transfert $H(z)$ de ce filtre numérique. Pour quelles valeurs des paramètres g et p le filtre est-il stable? Quand $f > 0$ et $u(t) = \sin(2\pi ft)$, quelle est l'amplitude A du signal de sortie de la forme $y(t) = A \sin(2\pi ft + \phi)$? Indication: on pourra calculer $|H(z)|$ lorsque $|z| = 1$.

Réponse

Si l'on recherche un signal de sortie du filtre $y_n = Yz^n$ qui corresponde à un signal d'entrée $u_n = Uz^n$, on obtient

$$Yz^{n+p} - gYz^n = -gUz^{n+p} + Uz^n$$

et donc $Y = H(z)U$ avec

$$H(z) = \frac{-gz^p + 1}{z^p - g}.$$

Les pôles z de cette fonction de transfert vérifient tous $|z| = g^{1/p}$ par conséquent le filtre est stable si et seulement si $g < 1$. On a

$$|H(z)|^2 = H(z)\overline{H(z)} = H(z)H(\bar{z})$$

et par conséquent dans le cas où $|z|^2 = z\bar{z} = 1$,

$$|H(z)|^2 = \frac{-gz^p + 1}{z^p - g} \times \frac{-g\bar{z}^p + 1}{\bar{z}^p - g} = \frac{1 + g^2 - g(z^p + \bar{z}^p)}{1 + g^2 - g(z^p + \bar{z}^p)} = 1.$$

Le signal d'entrée $u(t) = e^{i2\pi ft}$ correspond à $u_n = e^{i2\pi f\Delta tn} = z^n$ pour $z = e^{i2\pi f\Delta t}$. La sortie exponentielle complexe correspondante est

$$y(t) = H(f)e^{i2\pi ft} \text{ avec } H(f) = H(z = e^{i2\pi f\Delta t}).$$

De façon similaire, au signal d'entrée $u(t) = e^{-i2\pi ft} = e^{i2\pi(-f)t}$ correspond la sortie $y(t) = H(-f)e^{-i2\pi ft} = \overline{H(f)}e^{-i2\pi ft}$ et par conséquent – le filtre étant linéaire – si $H(f) = Ae^{i\phi}$, avec $A \geq 0$ et $\phi \in \mathbb{R}$, au signal

$$u(t) = \sin 2\pi ft = \frac{e^{i2\pi ft} - e^{-i2\pi ft}}{2i}$$

correspond

$$y(t) = \frac{Ae^{i\phi}e^{i2\pi ft} - Ae^{-i\phi}e^{-i2\pi ft}}{2i} = A \sin(2\pi ft + \phi).$$

Or rappelons-nous que

$$A = |H(f)| = |H(z = e^{i2\pi f\Delta t})| \text{ et } |e^{i2\pi f\Delta t}| = 1.$$

Par conséquent, $A = 1$.

Inaudible

Le signal audio $x(t) \in [-1.0, 1.0]$ est la superposition de deux tons purs de fréquences $f_0 = 1000$ Hz et f inconnue:

$$x(t) = 0.1 \times \sin(2\pi f_0 t) + 0.0002 \times \sin(2\pi ft)$$

Lorsque ce son est joué avec l'amplification standard, la composante associée au ton pur de fréquence f n'est pas audible. Quelles sont (approximativement) les plages de valeurs possibles de f ?

Réponses

Deux phénomènes peuvent expliquer que le ton pur de fréquence f ne soit pas audible. Le premier est lié au seuil d'audition absolu. Le niveau sonore en dB du ton

$$L = 10 \log_{10} \langle (0.0002 \times \sin(2\pi ft))^2 \rangle + 96,$$

soit puisque la valeur moyenne du sinus $\langle \sin^2(2\pi ft) \rangle$ vaut $1/2$,

$$L = 10 \log_{10} 2 \times 10^{-8} + 96 \approx 19 \text{ dB}.$$

En se reportant au graphe du seuil d'audition absolu, on constate qu'avec ce niveau sonore, le ton pur ne sera pas audible si la fréquence f est inférieure à 100 Hz ou supérieure à 10000 Hz (approximativement).

Le second phénomène est un masquage possible par le ton pur de fréquence f_0 . Si l'on utilise le modèle de Fletcher, le masquage a bien lieu si f se situe dans la bande critique de largeur $\Delta(f_0)$ centrée sur f_0 . On a

$$\Delta(1000) \approx \max(100, 0.2 \times 1000) = 200 \text{ Hz},$$

donc si f_0 est entre 900 et 1100 Hz, le ton ne sera pas non plus audible.

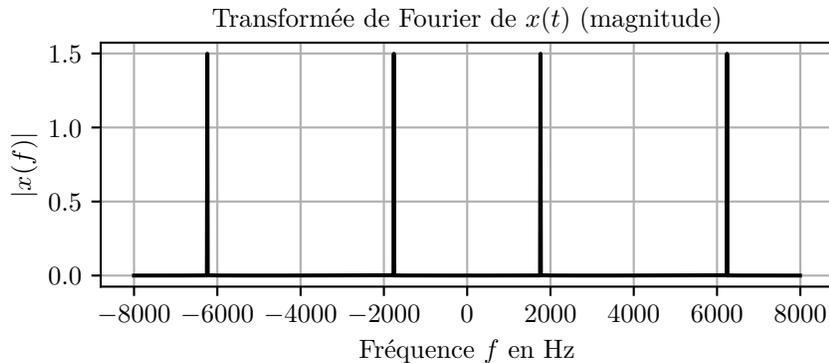
De 8 kHz à 16 kHz

```
>>> from numpy import *
>>> df = 8000; dt = 1.0 / df; T = 3.0; f = 440.0 * 2**2
>>> t = r_[0.0:T:dt]; n = len(t)
>>> x = sin(2*pi*f*t)
>>> y = zeros(2*n); y[::2] = x
>>> import audio.wave
>>> audio.wave.write(y, "y.wav", df=2*df)
```

Qu'est-ce que l'on entend lorsque l'on joue le fichier `y.wav`?

Réponse

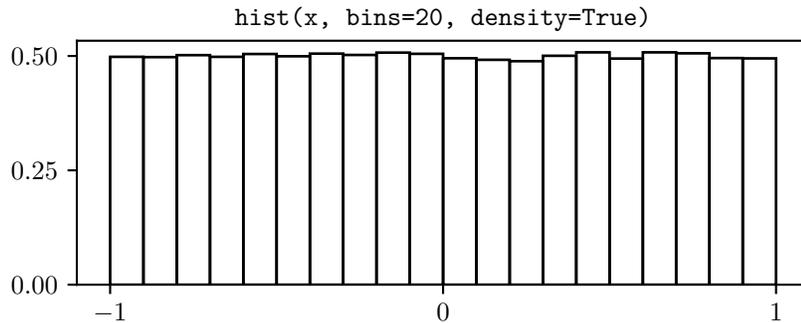
La transformée de Fourier de $x(t)$ présente un unique pic étroit – à la fréquence $f = 1760$ Hz – dans la bande de fréquences 0–4000 Hz; c'est la bande pertinente puisque le signal est échantillonné à 8000 Hz. Par symétrie (puisque le signal $x(t)$ est à valeurs réelles) et périodicité, les pics apparaissent également à $f = -1760$ Hz, $f = -1760 + 8000 = 6240$ Hz, etc.



La transformée de Fourier du signal $y(t)$ est donnée par $y(f) = x(f)/2$. Comme nous avons doublé la fréquence d'échantillonnage du signal, la bande de fréquence significative est désormais 0–8000 Hz et deux pics y apparaissent désormais: 1760 Hz et 6240 Hz. C'est cette combinaison de deux tons purs que l'on entend en jouant le fichier `y.wav`.

Quantification

```
>>> from numpy import *
>>> x = 2.0 * random.random(size=100000) - 1.0
```



```
>>> S2 = mean(x * x)
```

Quelle est la valeur théorique de S2 ?

```
>>> from audio.quantizers import Uniform
>>> uniform = Uniform(low=-1.0, high=1.0, N=2**8)
>>> y = uniform(x)
>>> n = y - x
>>> N2 = mean(n * n)
```

Quelle est la valeur théorique de N2 ?

```
>>> SNR = 10 * log10(S2 / N2)
```

Quelle est la valeur théorique de SNR ? Combien de bits supplémentaires faudrait-il que le quantificateur uniforme alloue par échantillon pour assurer un rapport signal sur bruit SNR supérieur à 50 dB ?

Réponse

La variable aléatoire X est de densité uniforme $p(x) = 0.5$ entre -1 et 1 , donc

$$\langle X^2 \rangle = \int_{-1}^1 p(x)x^2 dx = \frac{1}{2} \left[\frac{x^3}{3} \right]_{-1}^1 = \frac{1}{3}.$$

Le pas Δ d'un quantificateur uniforme de $[-1, 1]$ utilisant 8 bits est $\Delta = 2/2^8 = 2^{-7}$, par conséquent dans le cadre d'une hypothèse de haute résolution, la puissance du bruit $N = [X] - X$ est donnée par

$$\langle N^2 \rangle = \frac{1}{12} \Delta^2 = \frac{2^{-16}}{3} \approx 5.09 \times 10^{-6}.$$

Le rapport signal sur bruit associé vaut donc

$$\text{SNR} = 10 \log_{10} 2^{16} \approx 48.2 \text{ dB.}$$

Chaque nouveau bit améliorant le rapport signal sur bruit de 6 dB, un seul bit supplémentaire suffit à atteindre l'objectif de 50 dB.

Prédiction Linéaire

On considère la suite finie de valeurs:

$$x_0 = -1, x_1 = 1$$

- Déterminer le coefficient a_1 de la prédiction linéaire à l'ordre $m = 1$ des x_n par les méthodes de covariance, puis d'autocorrélation.
- Déterminer les coefficients a_1 et a_2 de la prédiction linéaire des x_n à l'ordre $m = 2$ par la méthode d'autocorrélation ainsi que les prédictions \hat{x}_n et les résidus $x_n - \hat{x}_n$ associés.

Réponse

Par la méthode de covariance à l'ordre 1, on cherche à minimiser le critère

$$j(a_1) = (x_1 - a_1 x_0)^2 = (1 + a_1)^2$$

ce qui est réalisé par le choix de $a_1 = -1$. Avec la méthode d'autocorrélation à l'ordre 1, le critère à minimiser devient (en posant $x_{-1} = x_2 = 0$):

$$\begin{aligned} j(a_1) &= (x_0 - a_1 x_{-1})^2 + (x_1 - a_1 x_0)^2 + (x_2 - a_1 x_1)^2 \\ &= (-1)^2 + (1 + a_1)^2 + (-a_1)^2 \\ &= 2(1 + a_1 + a_1^2) \end{aligned}$$

La valeur optimale de a_1 , déterminée par

$$\frac{dj(a_1)}{da_1} = 2 + 4a_1 = 0,$$

est donc $a = -1/2$.

À l'ordre 2, puisque le signal n'est que de longueur 2, seule la méthode d'autocorrélation est applicable. On cherche alors à minimiser

$$\begin{aligned} j(a_1, a_2) &= (x_0 - a_1 x_{-1} - a_2 x_{-2})^2 + (x_1 - a_1 x_0 - a_2 x_{-1})^2 + \\ &\quad (x_2 - a_1 x_1 - a_2 x_0)^2 + (x_3 - a_1 x_2 - a_2 x_1)^2 \\ &= (-1)^2 + (1 + a_1)^2 + (-a_1 + a_2)^2 + (-a_2)^2 \\ &= 2 + 2a_1 + 2a_1^2 + 2a_2^2 - 2a_1 a_2. \end{aligned}$$

Le minimum est obtenu en annulant les dérivées partielles

$$\frac{\partial j(a_1, a_2)}{\partial a_1} = 2 + 4a_1 - 2a_2 = 0 \quad \text{et} \quad \frac{\partial j(a_1, a_2)}{\partial a_2} = 4a_2 - 2a_1 = 0.$$

La seconde équation fournit $a_1 = 2a_2$, puis la première $a_2 = -1/3$. On a donc finalement $a_1 = -2/3$ et $a_2 = -1/3$. Les prédictions associées sont donc $\hat{x}_0 = 0$, puis $\hat{x}_1 = (-2/3) \times (-1) = 2/3$, $\hat{x}_2 = (-2/3) \times 1 + (-1/3) \times (-1) = -1/3$, $\hat{x}_3 = (-1/3) \times 1 = -1/3$, puis des zéros. Les résidus $e_n = x_n - \hat{x}_n$ sont donc $e_0 = -1$, $e_1 = 1/3$, $e_2 = 1/3$, $e_3 = 1/3$, puis des zéros.