



Chapitre d'actes

2005

Accepted version

Public access

This is an author manuscript post-peer-reviewing (accepted version) of the original publication. The layout of the published version may differ .

---

## Analyse des mesures de débit pour interfaces cerveau-ordinateur

---

Kronegg, Julien; Alecu, Teodor; Chanel, Guillaume; Voloshynovskyy, Svyatoslav; Pun, Thierry

### How to cite

KRONEGG, Julien et al. Analyse des mesures de débit pour interfaces cerveau-ordinateur. In: 4èmes Ateliers de Traitement et Analyse de l'Information : Méthodes et Applications, TAIMA'2005. Ecole Nationale des Sciences de l'Informatique (Ed.). Hammamet (Tunisia). [s.l.] : [s.n.], 2005.

This publication URL: <https://archive-ouverte.unige.ch/unige:47808>

© This document is protected by copyright. Please refer to copyright holder(s) for terms of use.

Last deposit update in Archive ouverte UNIGE on 14.03.2023 23:59

# Analyse des mesures de débit pour interfaces cerveau-ordinateur

Julien Kronegg, Teodor Alecu, Guillaume Chanel, Svyatoslav Voloshynovskiy et  
Thierry Pun

Laboratoire de Vision par ordinateur et multimédia,  
Département d'Informatique, Université de Genève,  
24, rue Général-Dufour, 1211 Genève 4, Suisse  
{prénom.nom}@cui.unige.ch

**Résumé :** Cet article propose une comparaison entre différentes définitions de débit binaire utilisées dans la communauté des interfaces cerveau-ordinateur. Les hypothèses relatives à ces définitions et leurs limitations sont discutées. Une simulation montre que la définition du débit binaire de Nykopp est proche de la capacité discrète pour symboles équiprobables. Inversement, la définition de Wolpaw s'éloigne de cette capacité lorsque le nombre de tâches à classifier augmente, ce qui pourrait conduire à sous-estimer le débit binaire réel et à tirer des conclusions erronées au sujet du nombre de classes optimal; elle ne devrait donc pas être utilisée.

**Mots clés :** Interface cerveau-ordinateur, débit binaire, nombre de classes, théorie de l'information.

## 1 Introduction

Une interface cerveau-ordinateur (*brain-computer interface, BCI*) est un périphérique d'entrée qui permet à un utilisateur de piloter une application logicielle ou matérielle (p.ex. clavier virtuel [6], contrôle de curseur [19], contrôle de robot [15]) en utilisant les signaux EEG produits lors d'une tâche mentale spécifique (p.ex. calcul mental, imagination de mouvement, rotation mentale d'objets, comptage de stimuli pertinents). La tâche mentale est ensuite reconnue par la machine grâce à un classifieur. La première mesure de performance objective pour un BCI a été proposée par Wolpaw et al en 1998 [19]; il s'agit du débit binaire (*bit-rate* ou *information transfer rate, ITR*) qui a été défini sur la base de la théorie de l'information de Shannon, avec plusieurs hypothèses simplificatrices. Les débits binaires généralement rapportés sont de l'ordre de 5 à environ 25 bits/minute [20].

Dans cet article, nous comparons les différentes définitions de débits binaires utilisés dans le domaine du BCI et proposons des recommandations pour choisir une bonne mesure de performance. L'article est organisé comme suit: la section 2 présente les définitions de débit binaires utilisées dans la communauté BCI. Un modèle de BCI ainsi que les méthodes de comparaison sont exposés dans la section 3. La section 4 discute des hypothèses sous-jacentes à chaque définition et les compare.

## 2 Revue des définitions de débits utilisées par la communauté BCI

Farwell et Donchin ont proposé la première mesure de débit binaire (1988, [6]) en créant l'un des premiers BCI. La seconde définition est due à Wolpaw *et al* (1998, [19]), la troisième à Nykopp (2001, [13]). Toutes ces définitions sont basées sur la théorie de la capacité de canal de Shannon. Le débit ( $R$ ), quantité d'information apportée par un symbole, est exprimé en bits/symbole, et peut être converti en bits/minute en utilisant  $B=V \cdot R$ ,  $V$  étant la vitesse de classification (en symboles/minute) et  $R$  la quantité d'information apportée par un symbole (en bits/symbole). La définition la plus populaire est celle de Wolpaw en raison de sa simplicité et d'une diffusion assez large [18], [19], [20]. La définition la plus générique est celle de Nykopp, les deux autres définitions pouvant être dérivées à partir de celle-ci.

Pour comprendre ces définitions, plusieurs éléments doivent être décrits. Il est considéré qu'une tâche mentale est un symbole  $w_i$  parmi  $N$  possible, la probabilité d'apparition de ce symbole étant notée  $p(w_i)$ . Le classifieur reconnaît  $M$  tâches mentales  $\hat{w}_j$  en sortie,  $j=1..M$ , avec  $M=N$  pour les classifieurs sans capacité de rejet et  $M=N+1$  pour les classifieurs avec capacité de rejet (quand le classifieur ne prend de décision qu'à partir d'un certain niveau de confiance). La matrice de transition  $M \times N$   $p(\hat{w}_j | w_i)$ , aussi appelée matrice de confusion, est calculée durant une phase d'apprentissage. Cette matrice est composée des probabilités qu'une tâche mentale  $w_i$  soit reconnue comme une tâche mentale  $\hat{w}_j$ . Ainsi, les éléments de sa diagonale représentent les précisions de classification pour chaque tâche [13].

En 1988, Farwell et Donchin introduisent une mesure de débit binaire en faisant l'hypothèse que le classifieur est sans rejet ( $M=N$ ) et parfait (c.à.d. i.e. sans erreur de classification). Tous les symboles sont supposés avoir la même probabilité a priori  $p(w_i)=1/N$ , ce qui conduit à:  $R_{Farwell\&Donchin} = \log_2 N$ .

En 1998, Wolpaw *et al* utilisent une définition améliorée [19]. En se basant sur le débit binaire de Shannon, ils proposent plusieurs simplifications: le classifieur est sans rejet ( $M=N$ ), les symboles ont tous la même probabilité  $p(w_i)=1/N$ , la précision du classifieur est identique pour tous les symboles

( $p(\hat{w}_j|w_i)=P$  pour  $i=j$ , où  $P$  est la moyenne ou le maximum de la diagonale de la matrice de transition [14]), l'erreur de classification est distribuée de manière équiprobale sur les symboles restants ( $p(\hat{w}_j|w_i)=(1-P)/(N-1)$  pour  $i \neq j$ ). Ces simplifications conduisent à l'équation:

$$R_{\text{Wolpaw}} = \log_2 N + P \cdot \log_2 P + (1-P) \cdot \log_2 \frac{1-P}{N-1}. \quad (1)$$

En 2001, la définition de débit de Nykopp (Eq. 2) est introduite dans le contexte de l'"Adaptive Brain Interface project" [13]. Ce BCI possède une capacité de rejet modélisée par un canal à oubli<sup>1</sup>, où des symboles peuvent être perdus lors de la transmission [3]. Les probabilités à priori  $p(w_i)$  sont calculées grâce à l'algorithme d'optimisation d'Arimoto-Blahut [9].

$$C = \max_{p(x)} I(X;Y) \quad R_{\text{Nykopp}} = I(W; \hat{W}) = H(\hat{W}) - H(\hat{W}|W) \quad (2)$$

$$H(\hat{W}) = -\sum_{j=1}^M p(\hat{w}_j) \cdot \log_2 p(\hat{w}_j) \quad p(\hat{w}_j) = \sum_{i=1}^N p(w_i) \cdot p(\hat{w}_j|w_i)$$


$$H(\hat{W}|W) = -\sum_{i=1}^N \sum_{j=1}^M p(w_i) \cdot p(\hat{w}_j|w_i) \cdot \log_2 p(\hat{w}_j|w_i).$$

### 3 Méthodes

Le BCI est modélisé par un canal à bruit blanc additif gaussien (*Additive White Gaussian Noise, AWGN*) [16], [17], c.f. Figure 1. Les signaux traversant ce canal sont exprimés dans l'espace des caractéristiques utilisées pour la classification (*feature space*): une tâche mentale  $W$  (p.ex.: "calcul mental") sélectionnée parmi  $N$  tâches mentales possibles est encodée par le cerveau, produisant ainsi une caractéristique discrète  $X$ . Celle-ci est perturbée par du bruit additif gaussien  $Z \sim \mathcal{N}(0, \sigma_Z^2)$  induit par l'activité de fond du cerveau (considérée comme indépendante de  $X$ ). La caractéristique  $Y$  ainsi formée est décodée par la machine au moyen d'un classifieur reconnaissant  $M$  symboles ( $M=N+1$  pour les classifieurs avec rejet et  $M=N$  pour les classifieurs sans rejet). La caractéristique  $X$  est modulée selon une loi PAM (*Pulse Amplitude Modulation*). La probabilité d'apparition à priori d'une tâche mentale  $w_i$ ,  $p(w_i)$ , n'est pas spécifiée; par conséquent celle de la caractéristique correspondante  $x_i$ ,  $p(x_i)$ , ne l'est pas non plus. Le bruit  $Z$  étant continu, la caractéristique résultante  $Y=X+Z$  est également continue. La capacité d'un tel canal est définie par:

$$C_N = \sum_{i=1}^N \int_{y=-\infty}^{+\infty} p(y|x_i) p(x_i) \log_2 \frac{p(y|x_i)}{p(y)} dy \quad p(y) = \sum_{j=1}^N p(x_j) p(y|x_j) \quad (3)$$

La probabilité  $p(y|x_i)$  est la probabilité qu'un symbole continu  $y$  soit reconnu lorsque le symbole  $x_i$  est émis. Le bruit étant gaussien, nous avons:  $p(y|x_k) = 1/(\sqrt{2\pi}\sigma_z) e^{-(y-x_k)^2/2\sigma_z^2}$ .



<sup>1</sup> Dans la définition de Nykopp, il est considéré que la matrice de transition et la matrice décrivant le canal sont identiques.

**Figure 1:** Modèle de BCI utilisant un canal AWGN.

Le choix d'une caractéristique de type PAM est raisonnable car elle permet de modéliser un certain nombre de caractéristiques couramment utilisées dans les BCIs, p.ex.: modulation d'amplitude du rythme mu ou bêta [12], répartition fréquentielle de l'énergie [5], [14].

Pour comparer ces définitions de débit binaire, nous calculons la différence entre la capacité discrète  $C_N$  et le débit binaire calculé avec chaque définition. A cette fin, plusieurs contraintes sont ajoutées au modèle: la probabilité d'apparition a priori est définie comme équiprobable  $p(x_i)=1/N$  et un *hard-classifier* de Bayes sans rejet ( $M=N$ ) est utilisé. Le choix de symboles équiprobables est justifié parce que les définitions de débit binaire à comparer l'imposent et parce qu'il serait peu pratique de simuler toutes les distributions de symboles. Un *hard-classifier* de Bayes sans rejet est utilisé car il permet d'obtenir des résultats optimaux lorsque la distribution sous-jacente est connue (ce qui est le cas ici puisque  $Z$  est connu). Un *soft-classifier* permettrait d'obtenir encore de meilleurs résultats, mais au prix d'une complexité qui ne se justifie pas dans notre cas.

La matrice de transition nécessaire pour la définition de débit binaire de Nykopp est calculée en considérant que l'énergie de  $X$  est limitée ( $E[X^2] \leq \sigma_X$ ) et que les symboles  $x_i$  sont équidistants (optimal), ce qui permet de minimiser l'erreur selon Bayes. Notons que l'algorithme d'Arimoto-Blahut n'est pas utilisé pour des raisons de compatibilité avec les autres définitions. La matrice de transition est donc:

$$p(\hat{w}_j | w_i) = \int_{R_j} p(y | x_i) dy,$$

$R_j$  est la région de décision pour le symbole  $\hat{w}_j$ . La précision du classifieur nécessaire pour la définition de Wolpaw est calculée comme le maximum de la diagonale de la matrice de transition  $\max_i (p(\hat{w}_i | w_i))$ . L'utilisation du maximum permet de montrer le comportement de la définition dans le meilleur des cas.

## 4 Résultats et discussion


Sachant qu'un *hard-classifier* est utilisé, nous nous attendons à ce que le débit binaire soit inférieur ou égal à la capacité discrète  $C_N$  pour des symboles équiprobables. Plus cette différence sera faible, meilleure sera la définition de débit binaire. La matrice de transition étant le seul paramètre variable entre les définitions de débit binaire, elle devrait expliquer les différences éventuelles dans les résultats.

Dans la définition de Farwell & Donchin, le classifieur est considéré comme parfait. Cela ne correspond bien sûr pas à la réalité et par conséquent, cette définition ne devrait pas être utilisée en pratique. Son intérêt principal est de donner le débit binaire maximal lorsque le SNR est élevé (Figure 2a). Lorsque le SNR est faible, le débit calculé est incorrect.

Dans la définition de Wolpaw *et al.*, les hypothèses faites ne sont pas valables dans un grand nombre de situations pratiques. Premièrement, le classifieur n'est pas toujours sans rejet [11], [13], [15]. Deuxièmement, les symboles ne sont pas toujours équiprobables [7], [8], [13], [14], et ceci particulièrement pour les protocoles de type *oddball* [1], [2], [4], [6], dans le cas où l'application est un clavier virtuel (fréquence des caractères [4], [6]) ou si un protocole à essai moyen est utilisé [1], [4], [6], [10]. Troisièmement, la précision du classifieur est en général différente pour chaque symbole [2], [11], [13], [14], [15], et ne peut donc pas être réduite à un simple scalaire  $P$ . Finalement, l'erreur n'est pas distribuée équiprobablement sur les symboles restants [2], [11], [13], [14], [15]. La Figure 2b montre que la


différence absolue entre capacité et débit augmente avec le nombre de classes, en particulier pour  $N > 4$ . Par conséquent, la définition de Wolpaw n'est pas appropriée pour calculer les performances d'un BCI utilisant plus de 4 classes pour certaines valeurs de SNR.

Dans la définition de Nykopp, la probabilité des symboles  $p(x_i)$  est calculée au moyen d'un algorithme d'optimisation, ce qui ne correspond pas à la pratique (probabilités dépendantes de l'application [7], [13], [14]). La Figure 2c montre que la différence absolue entre capacité et débit est au maximum de 0.3 bits/symbole et ceci quel que soit  $N$ . Cette définition est donc meilleure que celle de Wolpaw pour certaines paires de valeurs de (SNR, N).



**Figure 2:** capacité discrète  $C_N$  à symboles équiprobables soustraite de la définition du débit binaire. (A) Farwell & Donchin, (B) Wolpaw, (C) Nykopp.

A partir du modèle proposé, le SNR a été calculé pour plusieurs études sur le nombre de classes [5], [12], [14]. La Figure 3 montre qu'il est compris environ entre -4 et 5 dB et qu'il tend à diminuer avec l'augmentation du nombre de tâches, ce qui correspond à la plage de valeurs où le débit binaire de Wolpaw diverge de la capacité discrète équiprobable. Cette définition n'est par conséquent pas adaptée pour mesurer les performances de BCIs dont le nombre de classes  $N$  est grand (typiquement  $N > 4$ ).



**Figure 3:** Rapport signal/bruit pour plusieurs BCIs.

## 5 Conclusions

Dans cet article, nous avons comparé les mesures de débit binaire utilisées dans la communauté BCI. Nous avons montré que les débits binaires calculés selon la définition de Wolpaw diminuent lorsque le nombre de classes  $N$  augmente, en particulier dans la plage de SNR correspondant aux meilleurs BCIs du domaine, ce qui pourrait conduire à des conclusions erronées lorsque l'on cherche à optimiser le nombre de classes. Par conséquent, nous pensons qu'il est préférable d'utiliser la définition de Nykopp, mais sans utilisation de l'algorithme d'optimisation d'Arimoto-Blahut. Ce changement d'habitude devrait être progressif, la définition de Wolpaw étant largement utilisée dans la littérature.

Ce travail a été réalisé avec l'appui du Centre National de Compétence suisse en Recherche (IM)2, *Interactive Multimodal Information Management* (<http://www.im2.ch/>) ainsi que du Réseau d'Excellence Européen SIMILAR (<http://www.similar.cc/>).

## Références

- [1] J. D. Bayliss, *A Flexible Brain-Computer Interface (PhD Thesis)*, University of Rochester, Department of Computer Science, Rochester, New York, 2001.
- [2] G.E. Birch, and S.G. Mason, "Brain-computer interface research at the Neil Squire Foundation", *IEEE Trans. on Rehab. Eng.*, Vol. 8, No. 2, pp. 193-195, June 2000.
- [3] T. M. Cover, and J. A. Thomas, *Elements of Information Theory*, John Wiley & Sons Inc, 1991.
- [4] E. Donchin, K. M. Spencer, and R. Wijesinghe, "The Mental Prosthesis: Assessing the Speed of a P300-Based Brain-Computer Interface", *IEEE Trans. on Rehab. Eng.*, Vol. 8, No. 2, pp. 174-179, June 2000.
- [5] G. Dornhege, B. Blankertz, G. Curio, and K.-R. Müller, "Increase information transfer rates in BCI by CSP extension to multi-class", *Advances in Neural Inf. Proc. Systems (NIPS03)*, Vol. 16, <http://books.nips.cc/>, 2003.
- [6] L.A. Farwell, and E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials", *Electroencephalography and Clinical Neurophysiology*, Vol. 70, pp. 510-523, 1988.
- [7] C. Guger, H. Ramoser, and G. Pfurtscheller, "Real-Time EEG Analysis with Subject-Specific Spatial Patterns for a Brain-Computer Interface", *IEEE Trans. on Rehab. Eng.*, Vol. 8, No. 4, pp. 447-456, Dec. 2000.
- [8] E. Haselsteiner, and G. Pfurtscheller, "Using Time-Dependent Neural Networks for EEG Classification", *IEEE Trans. on Rehab. Eng.*, Vol. 8, No. 4, pp. 457-463, Dec. 2000.
- [9] L. Ip, "The Blahut-Arimoto Algorithm for the Calculation of the Capacity of a Discrete Memoryless Channel", Technical Report, Berkeley Uni., Dec. 10 1999.
- [10] J. Kronegg, T. Alecu, and T. Pun, "Information theoretic bit-rate optimization for average trial protocol Brain-Computer Interfaces", *Proc. HCI International 2003*, Crete, Greece, pp. 1437-1440, June 22-27 2003.
- [11] J. Lehtonen, *EEG-based Brain Computer Interfaces (M.Sc diploma)*, Helsinki University of Technology, Dep. of Electrical and Comm. Eng., May 3 2002.
- [12] D. J. McFarland, W. A. Samacki, and J. R. Wolpaw, "Brain-computer interface (BCI) operation: Optimizing information transfer rates," *Biological Psychology*, Vol. 63, No. 3, pp. 237-251, July 2003.
- [13] T. Nykopp, *Statistical Modelling Issues for The Adaptive Brain Interface (M.Sc diploma)*, Helsinki University of Technology, Dep. of Electrical and Comm. Eng., June 9 2001.
- [14] B. Obermaier, C. Neuper, C. Guger, and G. Pfurtscheller, "Information Transfer Rate in a Five-Class Brain-Computer Interface", *IEEE Trans. on Neural Sys. And Rehab. Eng.*, Vol. 9, No. 3, pp. 283-288, Sept. 2001.
- [15] F. Renkens, and J. del R. Millán, "Brain-Actuated Control of a Mobile Platform", *Int. Conf. on Simulation of Adaptive Behavior, Workshop on Motor Control in Humans and Robots*, Edinburgh, Aug. 4-11 2002.
- [16] M. Sahin, "Noise tolerance as a measure of channel discrimination for multi-channel neural interfaces", *23th Annual Int. Conf. of the IEEE Eng. in Med. and Biol. Soc.*, Istanbul, Turkey, Oct 25-28 2001.
- [17] A. Schlögl, C. Neuper, G. Pfurtscheller, "Estimating the Mutual Information of an EEG.-based Brain-Computer Interface", *Biomed. Technik*, Vol. 47, pp. 3-8, 2002.
- [18] T. M. Vaughan, W. J. Heetderks, L. J. Trejo, W. Z. Rymer, M. Wdriqli, M. M. Moore, A. Kubler, B. H. Oohkin, N. Birbaumer, E. Donchin, E. W. Wolpaw, and J. R. Wolpaw, "Brain-Computer Interface Technology: A Review of the Second International Meeting", *IEEE Trans. on Neural Sys. and Rehab. Eng.*, Vol. 11, No. 2, pp. 94-109, June 2003.
- [19] J. R. Wolpaw, H. Ramoser, D. J. McFarland and G. Pfurtscheller, "EEG-Based Communication: Improved Accuracy by Response Verification", *IEEE Trans. on Rehab. Eng.*, Vol. 6, No. 3, pp. 326-333, Sept. 1998.
- [20] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. Hunter Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson, and T. M. Vaughan, "Brain-Computer Interface Technology: A Review of the First International Meeting", *IEEE Trans. on Rehab. Eng.*, Vol. 8, No 2, pp. 164-173, June 2000.