



**HAL**  
open science

## **Raisonnement par Cas applique aux Interfaces Cerveau-Machines : Etude pilote**

Grégoire Cattan, Alexandre Quemy

### ► **To cite this version:**

Grégoire Cattan, Alexandre Quemy. Raisonnement par Cas applique aux Interfaces Cerveau-Machines : Etude pilote. IBM; Poznan University of Technologies. 2021. ⟨hal-03359078v2⟩

**HAL Id: hal-03359078**

**<https://hal.science/hal-03359078v2>**

Submitted on 2 Dec 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire HAL, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons CC BY-NC 4.0 - Attribution - Non-commercial use - International License

***Raisonnement par Cas applique aux Interfaces Cerveau-Machines :***  
***Etude pilote***

~

*Hypergraph Case-based Reasoning applied to Brain-Computer*  
*Interfaces: A Pilot Study*

~

Grégoire Cattan<sup>1</sup>, Alexandre Quemy<sup>2</sup>

<sup>1</sup>IBM, Cloud and Cognitive Software, Poland

<sup>2</sup>Faculty of Computer Sciences, Poznan University of Technologies, Poznan, Poland

*Mots-clés : Interaction Homme-Machine (IHM), Interface Cerveau-Machine (ICM), Interface Cerveau-Ordinateur (ICO), Électroencéphalographie (EEG), P300, Potentiels Evoqués Cognitifs (PEC), Classification Non Structurée, Apprentissage de Métrique, Apprentissage Supervisé, Hypergraph Case-based Reasoning (HCBR)*

*Keywords: Human-Computer Interaction (HCI), Brain-Computer Interface (BCI), Electroencephalography (EEG), P300, Event-Related Potential (ERP), Unstructured Classification, Metric Learning, Supervised Learning, Hypergraph Case-based Reasoning (HCBR)*

**Résumé** – L'analyse du signal des interfaces cerveau-machines (ICM) basée sur l'électroencéphalographie (EEG) est complexe et constitue un obstacle pour les développeurs d'applications et les créateurs de contenus. Dans cette étude, nous évaluons l'utilisation du classifieur HCBR, qui évolue dans un espace non-structuré (raisonnement par cas) afin de simplifier l'analyse EEG en réduisant le nombre d'étapes de prétraitement. Des données directes et prétraitées ont été fournies en entrée du classifieur. La performance du classifieur était meilleur avec les données prétraitées, invalidant par conséquent notre hypothèse initiale. La précision maximale obtenue par le classifieur était respectivement de 71.10 % et 52.04 % lors de la phase d'entraînement et de test (sur des données prétraitées). Ceci indique que HCBR est capable d'apprendre à partir des données, mais que davantage d'efforts restent nécessaires pour obtenir une meilleure précision lors de la phase de test - par exemple en augmentant le nombre d'essais grâce au transfert d'apprentissage.

**Abstract** – Signal analysis of brain-computer interface (BCI) based on electroencephalography (EEG) is complex and, therefore constitutes a practical impediment for application developers and content providers. In this study, we evaluate the use of the hypergraph case-based reasoning (HCBR) classifier to simplify EEG analysis, by reducing the number of pre-processing steps. Direct and preprocessed data were given as input to HCBR. Maximal performance was achieved with preprocessed data, thereby invalidating our initial hypothesis. Best training (testing) accuracy was 71.10 (52.04) %. This shows that the classifier was able to learn from the data, but that more research is required to obtain better testing accuracy. This could be achieved by enlarging the number of trials through transfer learning.

## Introduction

Les potentiels évoqués cognitifs (PEC) sont de faibles potentiels émis par le cerveau après le début d'une stimulation. Les interfaces cerveau-machine (ICM) basées sur les PEC reposent sur la détection de potentiels dans l'électroencéphalogramme (EEG), en réponse à une stimulation planifiée, dans le but de détecter l'intention de l'utilisateur d'interagir avec une action proposée. Ce type d'interface, imaginée dès le début des années 1970 par Vidal (1), permet à des personnes souffrant de paralysie généralisée d'interagir avec un ordinateur, puisque l'utilisation de ces interfaces ne nécessite aucune action musculaire (p.ex. (2)). Depuis le début des années 2010, l'utilisation des ICM en dehors du cadre clinique est régulièrement discutée, ainsi que ses possibles applications dans les domaines du jeu vidéo et de la réalité virtuelle (3–7). L'utilisation des ICM dans le cadre clinique reste cependant peu performante, et ce pour deux raisons. D'abord, parce qu'un pourcentage variant entre 20 et 30 % des personnes n'arrivent pas à se servir des ICM (voir une analyse de ce phénomène, et sa critique, dans (8)). Ensuite, parce que le taux d'information transmise par ces interfaces est très faible, avec une vitesse d'écriture d'environ cinq mots par minute pour certains paradigmes (p.ex. (2)), ce qui limite fortement l'intérêt de ces interfaces pour les patients ayant une activité musculaire résiduelle, et pouvant, par exemple, bénéficier d'un oculomètre. Le faible rapport signal sur bruit des PEC explique en partie ce faible taux d'information transmise. C'est pourquoi de précédentes études se sont consacrées au débruitage du signal (p.ex. (9,10)) et au développement de classifieurs fiables, tels que l'analyse discriminante, les classifieurs à vecteurs de support (SVC), les réseaux neuronaux (11), les forêts d'arbres décisionnels (12) ou la géométrie riemannienne (13). À notre connaissance, l'approche s'appuyant sur la géométrie riemannienne et utilisant les classifieurs dit MDM (pour « Minimum Distance to Means » en anglais, soit littéralement, distance minimum aux moyennes) a obtenu les meilleures performances lors de compétitions internationales, avec des précisions de l'ordre de 90 % atteintes en quelques secondes (13–15).

Le nombre d'étapes de prétraitement et la compréhension des concepts mathématiques qui sous-tendent la classification des PEC constituent une barrière à l'entrée pour les développeurs d'applications et créateurs de contenus, qui sont donc réticents à intégrer des ICM dans leurs produits (7). Dans cette étude, nous étudions l'utilisation de HCBR (pour Hypergraph Case-Based Reasoning en anglais, soit littéralement, raisonnement par cas basé sur un hypergraphe) (16) afin de rendre plus abordable la classification des PEC et faciliter l'intégration des ICM par les développeurs, notamment pour des applications destinées au grand public.

HCBR est en effet présenté comme une solution pour réduire les étapes de prétraitement lors des tâches de classification dans un espace non structuré. Dans ce travail, nous avons mesuré la balanced accuracy (BA, soit littéralement, précision équilibré) et le score f1 de HCBR, puis les avons comparés aux valeurs obtenues avec SVC et MDM, qui sont deux classifieurs reconnus par la littérature scientifique sur les ICM. Les performances de HCBR ont été évaluées à la fois avec des données directes et prétraitées. Les résultats montrent que HCBR atteint une meilleure précision avec des données prétraitées. Ils soulignent également que HCBR atteint une précision raisonnable lors de la phase d'entraînement ( $> 60\%$ , tout type de données confondues), mais avec davantage d'efforts nécessaires pour améliorer la précision lors de la phase de test (précision proche de  $50\%$ ).

Le présent document est structuré comme suit. La section 2 présente HCBR. La section 3 décrit les données que nous utilisons pour cette analyse. La section 4 évoque les méthodes que nous avons employées pour évaluer la performance de HCBR. La section 5 détaille le résultat de ces expériences. La section 6 expose notre discussion et conclusion.


## **Hypergraph Case-based Reasoning**

HCBR est une méthode dédiée à la classification binaire et pouvant travailler dans des espaces sans métriques. C'est une méthode bayésienne d'apprentissage de métrique. En particulier, elle a été conçue pour travailler avec tout type de donnée (textuelle, numérique, etc.) et ne pas être sensible aux valeurs manquantes.

HCBR modélise un jeu de données comme un hypergraphe où chaque vecteur (appelé « cas », car ce ne sont pas des vecteurs à proprement parler<sup>1</sup>) est une arête. La partition des cas forme une tribu sur laquelle la modélisation probabiliste s'appuie. Cette partition est transformée en graphe d'interaction grâce à une opération de projection. Intuitivement, la construction du modèle essaye de répondre aux questions suivantes : quelle est l'importance d'un élément  $e$  de la partition par rapport à un cas  $x$  ? Quel est le potentiel d'analogie et contre-exemple entre un cas  $x$  et les autres cas contenant l'élément  $e$  ? (Figure 1).

---

<sup>1</sup> La dimension des cas peut varier au sein d'un même jeu de données, soit parce qu'il y a des données manquantes ou parce que certains cas sont constitués de plus d'information.



**Figure 1.** Représentation schématique du fonctionnement de HCBR. On note  $x_i$  un cas et  $e_i$  un élément de la partition des cas.

Contrairement à la vaste majorité des méthodes d'apprentissage de métrique, HCBR ne cherche pas une seule matrice ou un seul vecteur, mais à la fois un vecteur  $\mu$ , représentant la « force intrinsèque » des éléments de la partition, et une matrice représentant l'importance de chaque élément de la partition pour chaque cas. Partant d'une probabilité a priori pour  $\mu$ , un algorithme itératif va ajuster  $W$  et  $\mu$  pour augmenter la cohérence d'intégralité des décisions. La prédiction pour un nouveau cas se fait en projetant le cas sur l'hypergraphe et en calculant son support défini comme la combinaison convexe entre  $\mu$ , pondérée par la proportion des intersections avec les éléments de la partition. C'est une méthode locale, dans la mesure où si le nouveau cas n'intersecte pas l'hypergraphe, le modèle ne peut pas prendre de décision.

$$\begin{cases} \mathbf{s} &= W\mu & W \in \mathcal{M}(\mathbb{R})_{N \times M}, \mu \in \mathbb{R}^M \\ \|\mathbf{w}_j\|_1 &= 1 & \forall 1 \leq j \leq N \\ \|\mu\|_1 &= 1 \end{cases}$$

Il a été montré que l'algorithme d'entraînement converge en temps fini et que le modèle construit par HCBR converge en loi vers la distribution sous-jacente, avec le nombre d'exemples dans le jeu d'entraînement, notamment en montrant que la modélisation s'apparente à un modèle mixte. Enfin, si théoriquement la complexité temporelle de la construction de l'hypergraphe est exponentielle, nous montrons qu'en pratique une borne supérieure est donnée par la cardinalité du nombre de bits dans le jeu de données. L'entraînement et la prédiction sont linéaires, respectivement en ce qui concerne le nombre de cas et d'itérations, et la cardinalité du cas à prédire.

HCBR a été développé initialement pour être appliqué au domaine judiciaire, c'est-à-dire avec des contraintes d'expertise limitée en data science par les utilisateurs, et avec une forte contrainte de justification de chaque décision. La structure en graphe permet de justifier immédiatement un cas à la fois, par l'importance des éléments qui le composent, et leur support respectif envers une classe ou une autre, mais aussi via des citations par analogie et contre-exemples avec les cas immédiatement adjacents ; comme des avocats pourraient le faire lors d'un procès. En pratique, sans optimisation des hyperparamètres, HCBR est la méthode la plus robuste (resp. seconde) sur sept jeux de données différents, au regard de la précision (resp. coefficient de corrélation de Matthew). Elle a aussi largement amélioré les résultats sur la prédiction des décisions de la Cour européenne des droits de l'homme par rapport à l'étude de référence (17).

## **Données**

Nous avons utilisé les données enregistrées au GIPSA-lab (Saint-Martin-d'Hères, France), et disponibles gratuitement sur Zenodo (Genève, Suisse) à partir du lien <https://zenodo.org/record/2649069>. L'ensemble de données contient les enregistrements EEG de 26 sujets (sept femmes) avec un âge moyen (std) de 24,4 (2,76) ans, participant à une expérience visuelle P300 de type cible/non-cible. Le P300 visuel est un PEC culminant entre 240 à 600 ms après l'apparition d'une stimulation visuelle à l'écran. Les participants jouaient à « Brain Invaders » une version BCI du célèbre jeu vintage « Space Invaders » (Taito, Tokyo, Japon). La version que nous avons utilisée comporte 36 extraterrestres affichés dans une matrice 6 x 6. La tâche des participants consistait à compter le nombre de flashes d'un extraterrestre cible, lequel était désigné toutes les huit répétitions. Dans le paradigme P300 de « Brain Invaders », une répétition est composée de 12 flashes, dont deux (dix) incluent l'extraterrestre cible (non-cible). Pour chaque participant, l'expérience comportait huit extraterrestres cibles prédéfinis au hasard. Par conséquent, un total de (resp.) 128 (8 x 8 x 2) et 640 (8 x 8 x 10) essais cibles et non-cibles ont été enregistrés pour chaque participant au cours de l'expérience.

Les signaux EEG ont été acquis au moyen du NeXus-32 (MindMedia, Herten, Allemagne), équipé de 16 électrodes humides, placées selon le système international 10 - 20. Les signaux ont été enregistrés à une fréquence d'échantillonnage de 128 Hz. Une description complète de l'ensemble des données est disponible dans (18).

## Méthodes

Les données ont été filtrées entre 1 et 24 Hz à l'aide d'un filtre IR zéro-phase, avec fenêtre de Hamming. Nous avons extrait toutes les époques cibles ( $n = 128$ ) et non-cibles ( $n = 640$ ) entre 100 ms et 700 ms, après le début de chaque stimulation, et appliqué un filtre spatial xDAWN (nombre de filtres = 1) (10). L'utilisation d'un filtre spatial permet de réduire la dimensionnalité des époques (et donc le temps de calcul), tout en améliorant le rapport signal sur bruit. Nous avons transformé ces époques en matrices de corrélation symétriques définies positives (SPD) en utilisant la méthode décrite dans (14). Les matrices contenaient seize éléments ( $4 \times 4$ ). En considérant la géométrie riemannienne des matrices SPD, nous avons vectorisé ces matrices par projection dans l'espace tangent à la variété riemannienne (19). Tous les vecteurs contenaient dix éléments.


Les vecteurs résultants ont été donnés en entrée à HCBR. Étant donné que la seule hypothèse d'HCBR est que les valeurs sont indexables, et parce qu'il n'utilise aucune métrique sur l'espace vectoriel d'entrée, les valeurs très proches sont considérées comme potentiellement différentes. Afin d'augmenter l'occurrence des cas, les vecteurs d'entrée ont donc été arrondis aux quatre premiers chiffres décimaux, et les matrices de corrélation ont été préférées aux matrices de covariance, car elles contenaient des entrées normalisées. Lors des tests de configuration, un nombre plus élevé de chiffres significatifs a diminué les performances du classifieur (Tableau 1). À l'inverse, un nombre inférieur de chiffres a empêché la convergence de HCBR. Tous les hyperparamètres pour HCBR sont restés intacts et égaux à zéro, excepté  $l0$  qui a été initialisé à 1.

**Tableau 1.** BA\* obtenue avec HCBR pour un seul sujet, en fonction du nombre de chiffres significatifs et du nombre de filtres pour xDAWN.

		Nombre de chiffres significatifs		
		4	6	8
Nombre de filtres	1	0.5367	0.5087	0.4976
	2	0.4914	0.4625	0.5030
	4	0.4950	0.4567	0.4982

\*Les valeurs sont mises en surbrillance à l'aide d'une échelle de couleurs allant du jaune (mesures les plus basses) au vert (mesures les plus élevées).

La performance du classifieur a été évaluée par validation croisée à 5 volets, puis mesurée avec la métrique BA, définie par  $\frac{1}{2} \left( \frac{A}{A+B} + \frac{C}{C+D} \right)$  où A et B (respectivement C et D) représentent le nombre d'époques cibles (resp. non-cibles) correctement et incorrectement classées. En outre, nous avons également calculé lors de la phase de test le score F1 défini par  $\frac{2A}{2A+B+D}$ . Pour tester l'impact des étapes de traitement sur les performances de HCBR, deux autres exécutions ont été effectuées à l'aide d'époques vectorisées et de matrices de corrélation. Afin d'atteindre la convergence, les informations redondantes entre les matrices de corrélation ont été supprimées. Les informations redondantes se composent du bloc supérieur droit et de la diagonale des matrices de corrélation (14) (Figure 2).




**Figure 2.** Schéma d'une matrice de corrélation de taille n. Nous avons mis en évidence en orange (blanc) les informations qui sont supprimées (conservées) de la matrice de corrélation, avant vectorisation.

Les valeurs de BA obtenues avec HCBR ont été comparées aux valeurs obtenues par SVC et MDM. Pour être objectif dans notre comparaison, les performances des deux classifieurs ont été mesurées avec la métrique BA et le score f1, en utilisant le même ensemble de données. Le prétraitement et la validation croisée étaient également similaires à HCBR.

Le traitement du signal a été effectué grâce à MNE (20), et nous avons utilisé pyRiemann (21) pour le filtrage spatial et la manipulation des matrices de covariance, en utilisant la géométrie de Riemann. La bibliothèque de code pour HCBR se trouve dans (22). L'évaluation des classifieurs a été effectuée à l'aide de scikit-learn (23).

## Résultats

Les BA moyennes (std) de HCBR obtenues pendant la phase d'entraînement étaient de : 71,10 % (1,31 %) avec des vecteurs tangents, 73,13 % (14,10 %) avec des matrices de corrélation, et 60,5 % (1,50 %) avec des données directes. La Figure 3 compare pour l'exemple la distribution des BA obtenues avec vecteurs tangents entre HCBR et SVC.

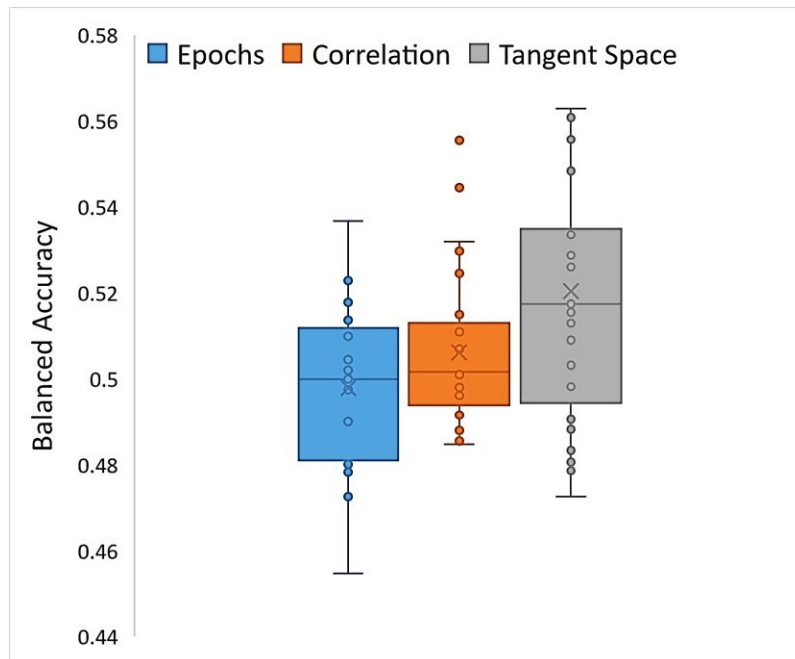


**Figure 3.** Boîte à moustaches des valeurs de BA pour HCBR et SVC obtenues après la phase d'entraînement.

Bien que la précision obtenue par HCBR soit inférieure à celle obtenue avec SVC (Figure 3), les deux distributions sont excellentes (premier quartile  $> 0,7$ ). La section suivante détaille les résultats obtenus pendant la phase de test pour HCBR.


Les BA moyennes (std) de HCBR obtenues pendant la phase de test étaient de : 52,04 % (3,1 %) pour la classification des vecteurs tangents, 50,61 % (1,84 %) pour les matrices de corrélation, et 49,78 % (1,52 %) pour les données directes. Le score f1 moyen (std) était quant à lui de 24,55 % (1,70 %) pour les vecteurs tangents, 26,90 % (1,60 %) pour les matrices de corrélation et 21,24 % (3,84 %) pour les données directes. Ainsi, si nous observons les valeurs de BA, la classification des époques EEG prétraitées (c'est-à-dire des matrices de corrélation projetées dans l'espace tangent) a obtenu un résultat légèrement meilleur que les matrices de corrélation vectorisées et les époques brutes (classification directe), mais avec une variabilité intersujet plus élevée (Figure 4). Cependant, dans tous les cas, les valeurs de BA sont toutes comprises entre 0,4 et 0,6, ce qui indique que les époques cibles et non-cibles sont en général

regroupées dans la même classe, indépendamment des étapes de prétraitement. Les valeurs de score f1, prises en relation avec les mesures de BA, indiquent que HCBR possède une grande spécificité et une faible sensibilité. La Figure 5 compare les mesures de BA obtenues par HCBR, SVC et MDM dans le meilleur des cas, c'est-à-dire avec des vecteurs tangents en entrée de HCBR.



**Figure 4.** Boîte à moustaches des mesures de BA obtenues lors de l'exécution de HCBR avec en entrée : des époques EEG vectorisées (en bleu), des matrices de corrélation vectorisées (en orange) et des matrices de corrélation projetées dans l'espace tangent (en gris).

L'évaluation d'un seul volet (entraînement plus prédiction) a pris environ 15 minutes dans un processus mono thread s'exécutant sur un ordinateur équipé d'un processeur i7 (2.6 GHz) et de 32 Go de RAM. En comparaison le processus de classification avec SVC et MDM se termine en moins de 2 secondes.



**Figure 5.** BA (a) et score f1 (b) moyens obtenus par SVC, MDM et HCBR (vecteurs tangents en entrée) lors de la prédiction. Les barres noires verticales représentent l'écart type.

## Discussion and conclusion

Les résultats préliminaires présentés dans ce document suggèrent que HCBR n'est pas adapté à la classification des signaux EEG pour les ICM basées sur les PEC. En effet, les mesures de BA et du score f1 obtenues par HCBR (indépendamment du traitement des données en entrée) sont inférieures à celles obtenues par les classifieurs de l'état de l'art MDM et SVC. De plus, les temps d'entraînement et de prédiction sont significativement plus élevés.

Invalidant notre hypothèse initiale, HCBR a obtenu de meilleurs résultats avec des données préalablement traitées par géométrie riemannienne. Ce résultat semble conforme à la littérature, qui fait état de l'adéquation des méthodes de classification basées sur la géométrie riemannienne pour la classification des PEC avec des matrices de covariance (13).

Cependant, notons que la précision de HCBR lors de la phase d'entraînement était élevée. Par conséquent, il est possible que l'entraînement ait été trop spécifique aux données d'apprentissage pour être utile lors de la prédiction. En d'autres termes, HCBR nécessite certainement un plus grand nombre d'échantillons pour atteindre une plus grande précision lors de la prédiction. Étant donné que les enregistrements EEG ne sont valables que pour une seule session et un seul sujet, le nombre d'échantillons qui pourraient être collectés au cours d'une session expérimentale est limité, sauf si nous utilisons une approche d'apprentissage par

transfert (p.ex. (24)). Cette approche permettrait d'atteindre un compromis entre les performances de HCBR et la simplicité nécessaire pour une intégration plus répandue des ICM.

## Références

1. Vidal JJ. Toward Direct Brain-Computer Communication. *Annu Rev Biophys Bioeng.* 1973;2(1):157–80.
2. Guy V, Soriani MH, Bruno M, Papadopoulo T, Desnuelle C, Clerc M. Brain computer interface with the P300 speller: Usability for disabled people with amyotrophic lateral sclerosis. *Ann Phys Rehabil Med.* 2018 Jan 1;61(1):5–11.
3. Nijholt A. BCI for Games: A ‘State of the Art’ Survey. In: *Entertainment Computing - ICEC 2008* [Internet]. Springer, Berlin, Heidelberg; 2008 [cited 2017 Aug 4]. p. 225–8. Available from: [https://link-springer-com.gaenomade-2.grenet.fr/chapter/10.1007/978-3-540-89222-9\\_29](https://link-springer-com.gaenomade-2.grenet.fr/chapter/10.1007/978-3-540-89222-9_29)
4. Nijholt A, Plass-Oude Bos D, Reuderink B. Turning Shortcomings into Challenges: Brain-Computer Interfaces for Games. *Entertain Comput.* 2009 Apr 1;1:85–94.
5. Lotte F, Faller J, Guger C, Renard Y, Pfurtscheller G, Lécuyer A, et al. Combining BCI with Virtual Reality: Towards New Applications and Improved BCI. In: Allison BZ, Dunne S, Leeb R, Del R, Millán J, Nijholt A, editors. *Towards Practical Brain-Computer Interfaces: Bridging the Gap from Research to Real-World Applications* [Internet]. Berlin, Heidelberg: Springer Berlin Heidelberg; 2013 [cited 2019 Jan 30]. p. 197–220. (Biological and Medical Physics, Biomedical Engineering). Available from: [https://doi.org/10.1007/978-3-642-29746-5\\_10](https://doi.org/10.1007/978-3-642-29746-5_10)
6. Cattan G, Andreev A, Visinoni E. Recommendations for Integrating a P300-Based Brain–Computer Interface in Virtual Reality Environments for Gaming: An Update. *Computers.* 2020 Dec;9(4):92.
7. Cattan G. The Use of Brain-Computer Interfaces in Games Is Not Ready for the General Public. *Front Comput Sci* [Internet]. 2021 Mar [cited 2021 Jun 2];3. Available from: <https://hal.archives-ouvertes.fr/hal-03182066>
8. Thompson MC. Critiquing the Concept of BCI Illiteracy. *Sci Eng Ethics.* 2019 Aug;25(4):1217–33.
9. Barachant A, Andreev A, Congedo M. The Riemannian Potato: an automatic and adaptive artifact detection method for online experiments using Riemannian geometry. In: *TOBI Workshop IV* [Internet]. Sion, Switzerland; 2013 [cited 2018 Apr 30]. p. 19–20. Available from: <https://hal.archives-ouvertes.fr/hal-00781701>
10. Rivet B, Souloumiac A. Optimal linear spatial filters for event-related potentials based on a spatio-temporal model: Asymptotical performance analysis. *Signal Process.* 2013 février;93(2):387–98.

11. Lotte F, Congedo M, Lécuyer A, Lamarche F, Arnaldi B. A review of classification algorithms for EEG-based brain–computer interfaces. *J Neural Eng.* 2007;4(2):R1.
12. Steyrl D, Scherer R, Faller J, Müller-Putz GR. Random forests in non-invasive sensorimotor rhythm brain-computer interfaces: a practical and convenient non-linear classifier. *Biomed Eng Biomed Tech.* 2015;61(1):77–86.
13. Congedo M, Barachant A, Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces; a primer and a review. *Brain-Comput Interfaces.* 2017;4(3):155–74.
14. Congedo M. EEG Source Analysis [Internet] [thesis]. Université de Grenoble; 2013. Available from: <https://tel.archives-ouvertes.fr/tel-00880483>
15. Corsi MC, Yger F, Chevallier S, Noûs C. Riemannian Geometry on Connectivity for Clinical BCI. In: ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). 2021. p. 980–4.
16. Quemy A. Binary classification in unstructured space with hypergraph case-based reasoning. *Inf Syst.* 2019 Nov 1;85:92–113.
17. Aletras N, Tsarapatsanis D, Preotiuc-Pietro D, Lampos V. Predicting judicial decisions of the European Court of Human Rights: a Natural Language Processing perspective. *PeerJ Comput Sci.* 2016 Oct 24;2:e93.
18. Van Veen GFP, Barachant A, Andreev A, Cattan G, Coelho Rodrigues PL, Congedo M. Building Brain Invaders: EEG data of an experimental validation [Internet]. GIPSA-lab; 2019 mai. Report No.: 1. Available from: <https://hal.archives-ouvertes.fr/hal-02126068>
19. Barachant A, Bonnet S, Congedo M, Jutten C. Classification of covariance matrices using a Riemannian-based kernel for BCI applications. *Neurocomputing.* 2013 Jul;112:172–8.
20. Gramfort A, Luessi M, Larson E, Engemann DA, Strohmeier D, Brodbeck C, et al. MNE software for processing MEG and EEG data. *NeuroImage.* 2014 février;86:446–60.
21. Barachant A. pyRiemann [Internet]. pyRiemann; 2015. Available from: <https://github.com/pyRiemann/pyRiemann>
22. Quemy A. HCBR [Internet]. 2020. Available from: <https://github.com/aquemy/HCBR>
23. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, et al. Scikit-learn: Machine Learning in Python. *J Mach Learn Res.* 2011;12(85):2825–30.
24. Rodrigues PLC, Jutten C, Congedo M. Riemannian Procrustes Analysis: Transfer Learning for Brain–Computer Interfaces. *IEEE Trans Biomed Eng.* 2019 Aug;66(8):2390–401.