

Études, conceptions et applications des interfaces cerveau-ordinateur

Fabien Lotte¹

Au moment d'écrire ces lignes, l'électro-encéphalographie, une technique mesurant l'activité cérébrale sous forme de microcourants électriques à l'aide d'électrodes posées sur le cuir chevelu, fête ses 100 ans. Le premier électro-encéphalogramme (EEG) a en effet été mesuré en 1924 par le psychiatre allemand Hans Berger [19]. L'EEG est utilisé depuis ce temps notamment pour effectuer des diagnostics médicaux dans le domaine clinique, ou pour comprendre le fonctionnement cérébral en neurosciences [34].

Plus récemment, l'EEG est aussi utilisé pour concevoir ce qu'on appelle des interfaces cerveau-ordinateur ou BCI (de l'anglais *brain-computer interface*) [11, 48]. Une BCI est un système traduisant une mesure de l'activité cérébrale (typiquement l'EEG) en une commande ou un message pour une application interactive. Une BCI permet par exemple de déplacer une balle dans un jeu vidéo vers la gauche ou vers la droite, en imaginant des mouvements de la main gauche ou droite respectivement (cf. figure 1), ces mouvements imaginés étant reconnus dans les signaux EEG de l'utilisateur à l'aide de technique d'apprentissage artificiel [8].

Les BCI sont prometteuses pour de nombreuses applications [12], notamment pour des applications de communication et de contrôle pour des personnes gravement paralysées, pour leur permettre de sélectionner des lettres dans un éditeur de texte [6] ou bien de déplacer un fauteuil roulant vers la gauche ou vers la droite en imaginant des mouvements de la main gauche ou droite [30].

1. Centre Inria de l'université de Bordeaux, LaBRI.

Elles peuvent aussi servir pour le grand public et les personnes en bonne santé, par exemple pour contrôler des jeux vidéos ou applications de réalité virtuelle, e.g., en imaginant des mouvements des pieds pour avancer dans un environnement virtuel [29]. Encore plus récemment, les BCI se sont montrées prometteuses pour la rééducation motrice après accident vasculaire cérébral (AVC — cf. section « Applications des BCI » plus loin dans cet article) [35], ou encore pour concevoir ce qu'on appelle des technologies neuroadaptives. Ces dernières sont des systèmes qui vont estimer l'état mental de leurs utilisateurs en continu, à partir de leurs signaux cérébraux, de façon à adapter l'interaction humain-machine en fonction [53]. Par exemple, elles peuvent estimer le niveau d'attention ou d'effort mental d'un pilote d'avion de façon à adapter la quantité d'information affichée dans le cockpit en conséquence, afin d'éviter une surcharge attentionnelle [4].




Fig. 1. Un exemple de BCI permettant à un utilisateur (dont on mesure l'activité cérébrale par EEG) de déplacer la balle sur l'écran vers la gauche ou vers la droite, simplement en imaginant des mouvements de la main gauche ou droite [8] (© Inria / Photo G. Maisonneuve).

Les BCI sont ainsi très prometteuses. Malheureusement, elles souffrent aussi d'un certain nombre de problèmes et de limitations. En particulier, même si les BCI fonctionnent, elles ne fonctionnent pas bien. Elles souffrent en effet d'un taux d'erreurs élevé, et se trompent relativement souvent de commande mentale reconnue. Par exemple, pour distinguer un mouvement imaginé de la main gauche d'un mouvement imaginé de la main droite, il est estimé que les

systèmes actuels se trompent environ 1 fois sur 4 ou 5 (par exemple, la BCI reconnaît un mouvement imaginé de la main gauche alors que l'utilisateur a imaginé un mouvement de la main droite), ce qui est très élevé [7]. On estime également qu'entre 10% à 30% des utilisateurs de BCI ne peuvent pas utiliser les BCI, car celles-ci ne peuvent pas reconnaître leurs commandes mentales [1]. Enfin, les BCI souffrent d'une grande variabilité en terme de performances, à la fois entre les utilisateurs mais aussi au cours du temps pour un même utilisateur [42]. Certains utilisateurs vont pouvoir utiliser la BCI quasi parfaitement (toutes leurs commandes mentales seront bien reconnues) tandis que d'autres ne pourront pas du tout les utiliser, avec tout le spectre de performances possibles entre ces deux extrêmes. Mais, même pour un unique utilisateur, les performances peuvent varier considérablement, avec un utilisateur pouvant très bien contrôler la BCI un jour donné, mais plus le lendemain, en utilisant pourtant la même BCI. Ainsi les BCI ne sont pas encore assez fiables actuellement, et par conséquent, pas encore largement appliquées en pratique, en dehors des laboratoires. Ainsi, un des défis majeurs est de concevoir des BCI qui soient fiables [15].

La suite de cet article propose un aperçu — forcément incomplet — de nos recherches sur les BCI — en commençant par présenter nos travaux de



recherche fondamentale visant précisément à rendre les BCI plus fiables. Pour cela cet article s'intéresse tout d'abord aux aspects machine des BCI (section «Apprentissage machine dans les BCI»), puis aux aspects humains et utilisateurs de ces technologies (section «Apprentissage humain dans les BCI»). Il présente ensuite certains de nos travaux applicatifs des BCI, afin de rendre les BCI utiles (section «Applications des BCI»), et se termine par une conclusion sur ces travaux et quelques perspectives dans ce domaine en section «Conclusion».




Fig. 2. Illustration du processus de classification riemannienne de signaux EEG : les signaux EEG sont d'abord filtrés dans une bande de fréquence spécifique, avant de calculer leur matrice de covariance. Cette matrice de covariance est ensuite utilisée pour classer les signaux EEG, en assignant à la matrice de covariance la classe dont la matrice de covariance moyenne (sur les données d'apprentissage) est la plus proche, mesurée avec une distance Riemannienne [52,13].

Apprentissage machine dans les BCI

Une première façon de rendre les BCI plus fiables, est d'explorer la conception d'algorithmes de classification des signaux EEG qui soient plus robustes et plus précis, de façon à mieux reconnaître les états mentaux des utilisateurs dans leurs signaux EEG [15]. Ainsi, une part significative de la recherche sur les BCI porte sur la conception et l'étude d'algorithmes d'apprentissage artificiel et d'intelligence artificielle pour la classification de signaux EEG [25, 24]. Une part importante de nos travaux s'est donc naturellement portée sur ce sujet également (cf., par exemple, [54, 28, 27]). Dans la suite de cet article, nous nous intéresserons plus particulièrement à nos travaux plus récents sur le sujet, portant sur les classifieurs de signaux EEG dits «riemanniens».

Les classifieurs riemanniens (CR) — qui ont été introduits dans les BCI par Alexandre Barachant et ses collègues — sont des classifieurs qui représentent les signaux EEG sous forme de matrices symétriques définies positives — généralement des matrices de covariance — et qui manipulent et classifient ces matrices avec une géométrie particulière : la géométrie riemannienne [52, 13]. Un exemple typique de CR est le « minimum distance to the riemannian mean » (MDRM). Pour l'utiliser, les signaux EEG sont tout d'abord classiquement filtrés par un passe-bande dans une bande de fréquence d'intérêt (par exemple dans les fréquences EEG sensorimotrices α (8–12 Hz) et β (16–24 Hz) pour détecter des mouvements imaginés). Ensuite, la matrice de covariance de ces signaux EEG est calculée. Cette matrice possède autant de lignes et de colonnes que le nombre d'électrodes EEG utilisées. Elle contient en diagonale la variance du signal mesuré par chaque électrode (qui est équivalente à la puissance du signal EEG dans la bande de fréquences dans laquelle il est filtré). Hors diagonale, elle contient la covariance entre les signaux de chaque paire d'électrodes, indiquant donc si ces signaux varient simultanément. La géométrie riemannienne permet de manipuler directement ces matrices de covariance et, par exemple, de calculer la moyenne d'un ensemble de matrices de covariance. Cela permet notamment de calculer la matrice de covariance moyenne pour chaque classe de signaux EEG (par exemple des mouvements imaginés de la main gauche ou des mouvements imaginés de la main droite), à partir de données d'apprentissage. Un classifieur peut ensuite être construit en utilisant ces matrices de covariance moyennes comme prototypes pour chaque classe. Ainsi, lorsque l'on veut classer de nouveaux signaux EEG avec un MDRM, on filtre d'abord ces signaux EEG puis on calcule leur matrice de covariance. On attribue ensuite à cette matrice de covariance la classe dont la matrice de covariance moyenne est la plus proche, selon une distance spécifique : la distance riemannienne (cf figure 2). Ce classifieur est très simple, mais déjà très efficace, car 1) il ne requiert que peu de paramètres, et peut donc être appris à partir de peu de données d'apprentissage (et les expériences BCI ne permettent généralement de récolter qu'un petit nombre de données) et 2) la distance riemannienne possède des propriétés d'invariance intéressantes (elle est invariante par transformation linéaire de rang plein), qui rendent les BCI qui utilisent les CR plus robustes à certaines des variabilités affectant les signaux EEG.

Ces dernières années, de tels CR, et leurs variantes, se sont révélés particulièrement efficaces. Ce fut par exemple le cas lors d'une compétition internationale de classification de signaux EEG que nous avons organisée en 2021 [40]. Lors de cette compétition, les participants devaient estimer le niveau de charge mentale de personnes (c'est-à-dire les efforts mentaux qu'ils fournissent, parmi trois niveaux ou classes: charge mentale basse, moyenne ou élevée) à partir de leurs signaux EEG. Pour cela les participants avaient à leur disposition deux jours de signaux EEG pour chaque participant, avec les niveaux de charge mentale

correspondants. Ils devaient se servir de ces données comme ensemble d'apprentissage, pour entraîner et optimiser leurs classifieurs et leurs algorithmes d'apprentissage artificiel, qu'ils devaient ensuite utiliser pour estimer la charge mentale des mêmes personnes mais pour un jour différent. C'est un problème difficile car les signaux EEG sont connus pour changer beaucoup d'un jour à l'autre. Lors de cette compétition, les pires performances de classification obtenues (bonne reconnaissance des niveaux de charge mentale), qui étaient au niveau de la chance (c'est-à-dire que le classifieur était incapable d'estimer la charge mentale mieux qu'en devinant au hasard), ont toutes été obtenues, de manière surprenante, par des algorithmes d'apprentissage profond (*deep learning*). Contrairement à d'autres domaines tels que l'image ou la parole, l'apprentissage profond n'a pas encore révolutionné les BCI, probablement parce que ces algorithmes ont besoin d'un très grand nombre de données d'apprentissage (typiquement des millions), alors que les bases de données BCI ont seulement des centaines ou milliers de données en moyenne. Cela pourrait cependant changer dans le futur. Pour cette compétition, le gagnant a utilisé des CR, et parmi les 4 meilleures performances, 3 ont utilisé des CR [40]. Plus généralement, ces dernières années, parmi les 9 compétitions internationales de classification de signaux EEG que nous connaissons, 8 ont été gagnées par des CR, et une seule par de l'apprentissage profond. Ainsi, actuellement les classifieurs riemanniens sont considérés comme l'état de l'art pour la classification de signaux EEG en BCI.

Les CR étant l'état de l'art pour les BCI, nous les avons récemment beaucoup étudiés, et avons proposé de nombreuses variantes et améliorations pour ceux-ci. Par exemple, nous avons proposé des algorithmes pour sélectionner automatiquement les meilleures électrodes pour les CR [41], ainsi que des CR adaptatifs, capables de mettre à jour leurs paramètres de manière dynamique et automatique quand de nouvelles données sont disponibles [5, 23], des classifieurs multimodaux plus robustes aux bruits et variabilités [51], de l'apprentissage par transfert riemannien [9], une identification automatique des meilleures bandes de fréquence EEG pour les CR [3, 49], ou encore l'utilisation de mesures d'interactions entre bandes de fréquences EEG dans les CR [50]. Ainsi, il existe de nombreuses approches d'apprentissage artificiel qui permettent d'améliorer la fiabilité et la stabilité des BCI. Cependant, si celles-ci sont nécessaires, elles ne sont pas nécessairement suffisantes pour obtenir des BCI complètement robustes.

Apprentissage humain dans les BCI

Un autre élément clé de la boucle d'interaction cerveau-ordinateur est l'utilisateur lui-même. En effet, contrôler une BCI est une compétence qui s'apprend : plus on pratique le contrôle d'une BCI, meilleur on devient, et plus précisément nos commandes mentales sont reconnues par la BCI [39]. Ainsi, pour obtenir

une BCI robuste, il ne faut pas seulement de bons algorithmes de classification, il faut aussi un utilisateur qui soit bien entraîné. Pour cela il faut s'intéresser au feedback et aux tâches d'entraînement qui sont fournies aux utilisateurs de BCI, pour s'assurer d'un entraînement efficace et efficient.

L'entraînement classique au contrôle de BCI basées sur l'imagination de mouvements, qui est utilisé tel quel depuis une vingtaine d'années, consiste tout d'abord à indiquer à l'utilisateur à quel moment imaginer un mouvement, à l'aide d'une flèche affichée à l'écran (par exemple, une flèche à gauche ou à droite pour indiquer d'imaginer un mouvement de la main gauche ou droite, respectivement). Ensuite, lorsque l'utilisateur imagine ce mouvement, il reçoit un feedback sous forme d'une barre, grandissant vers la gauche ou vers la droite, dont la direction indique le mouvement qui est reconnu (gauche ou droite pour un mouvement imaginé de la main gauche ou droite, respectivement), et la taille indique la confiance du classifieur dans cette reconnaissance (cf. figure 1, par exemple). Cet entraînement est répété tel quel plusieurs fois par jour, pendant plusieurs jours, semaines voir mois. Si on étudie cette forme d'entraînement de manière plus formelle, on peut cependant se rendre compte qu'elle est sous-optimale, à la fois théoriquement mais aussi en pratique. En effet, d'un point de vue théorique, ce type d'entraînement ne respecte pas les principes et recommandations venant de la psychologie de l'apprentissage humain [26]. Par exemple, cet entraînement n'est pas adapté aux compétences et au profil de chaque utilisateur : il est le même pour tous, toujours. Cet entraînement est également sous-optimal en pratique. En effet, si on fournit à des utilisateurs le même exercice et le même feedback, mais pour apprendre autre chose que le contrôle de BCI, par exemple des tâches motrices simples, de nombreux utilisateurs vont également échouer à apprendre, car le feedback n'est pas assez informatif [20]. Ainsi, il est nécessaire de mieux comprendre, de modéliser et d'optimiser cet entraînement utilisateur en BCI.

Pour ce faire, à l'aide de nombreuses expérimentations couplées à une étude de la littérature, nous nous sommes intéressés à comprendre qui pouvait utiliser une BCI. En particulier, y a-t-il certains profils d'utilisateurs, en termes de personnalité ou de capacités cognitives, qui arrivent mieux que d'autres à contrôler une BCI? Nos études nous ont permis d'identifier trois grandes familles de facteurs qui peuvent expliquer des différences entre utilisateurs [22, 21]. La première famille est formée des habiletés spatiales: capacité à créer, manipuler et transformer des images mentales, ce qui peut se mesurer avec un test de rotation mentale. Les utilisateurs avec de meilleures habiletés spatiales ont généralement de meilleures performances de contrôle des BCI. De manière similaire, les utilisateurs avec de bonnes capacités attentionnelles ou qui portent plus attention aux tâches d'entraînement, ont, eux aussi, de meilleures performances de contrôle des BCI. A l'inverse, les utilisateurs qui ont des problèmes de relations avec les technologies, par exemple qui souffrent d'anxiété

informatique ou qui ne se sentent pas en contrôle avec des technologies, ont généralement de moins bonnes performances de contrôle des BCI. Cela montre qu'il est nécessaire de prendre en compte le profil de l'utilisateur dans la conception de BCI et dans l'entraînement utilisateur.

En plus d'essayer de comprendre l'apprentissage humain en BCI, nous avons aussi cherché à l'optimiser, pour que les utilisateurs de BCI puissent apprendre à les contrôler plus rapidement ou plus efficacement. Nous avons ainsi exploré différents types de feedbacks et de tâches d'entraînement, par exemple [31, 37]. Pour ne détailler qu'un seul exemple, nous avons notamment proposé PEANUT (*Personalized emotional agent for neurotechnology user training*), un compagnon d'apprentissage artificiel pour guider et aider les utilisateurs dans leur apprentissage du contrôle d'une BCI [36] (cf. figure 3).



Fig.3. Notre compagnon d'apprentissage au contrôle de BCI, PEANUT (le petit humanoïde en bas à gauche sur l'image), lors d'un entraînement au contrôle de BCI [36] (© Inria / Photo C. Morel).

Ce compagnon a accès à des mesures de performance et de progression de l'utilisateur, et en fonction de celles-ci, va pouvoir interagir avec cet utilisateur durant son entraînement pour le guider. Il va par exemple pouvoir féliciter l'utilisateur quand il progresse, l'encourager à persévérer ou encore lui suggérer de changer de stratégie mentale quand ses performances et sa progression ne sont pas bonnes. Nous avons comparé un entraînement BCI avec et sans PEANUT, et les résultats se sont avérés particulièrement intéressants. En effet, PEANUT permet bien d'améliorer les performances de contrôle d'une BCI, mais pas pour

tout le monde. En particulier, PEANUT améliore les performances de contrôle des utilisateurs qui ont une personnalité dite *non-autonome* en psychologie, c'est-à-dire qui préfèrent travailler en groupe. Par contre, PEANUT diminue les performances de ceux qui ont une personnalité *autonome*, qui préfèrent travailler seuls. Pour ces derniers, PEANUT n'aide pas, mais est plutôt un compagnon qui les dérange et les ennuie. Une de fois de plus, cela montre bien que l'entraînement au contrôle des BCI doit être personnalisé, et prendre en compte le profil des utilisateurs, c'est-à-dire leurs personnalités et leurs capacités cognitives.

Applications des BCI

Au delà de recherches plus fondamentales visant à améliorer la robustesse et l'utilisabilité des BCI, que ce soit en s'intéressant aux aspects machine ou aux aspects humains des BCI, nous nous intéressons aussi à leurs applications concrètes. Dans la suite de cette section, nous allons illustrer deux familles d'applications que nous explorons : 1) en santé numérique et 2) en neuroergonomie, c'est-à-dire dans l'étude du cerveau hors du laboratoire, dans des tâches de la vie quotidienne, par exemple pour l'étude de l'expérience utilisateur dans les signaux EEG [4].

BCI pour la santé numérique

Historiquement, les BCI ont vu le jour principalement pour devenir une technologie d'assistance ou de rééducation pour les personnes gravement paralysées [30, 35]. Nos travaux s'intéressent ainsi naturellement à ce domaine d'application.

Nous avons ainsi conçu une BCI pour un utilisateur tétraplégique — paralysé des 4 membres donc — que nous avons entraîné pendant plusieurs mois pour qu'il puisse contrôler un jeu vidéo de course de voiture entièrement grâce à ses signaux EEG avec une BCI [5]. Nous avons effectué ces travaux dans le cadre d'une compétition du Cybathlon, qui se veut être des jeux olympiques des technologies d'assistances, où des personnes en situation de handicap s'associent avec des concepteurs de technologies pour relever des défis d'assistance, tels que du contrôle d'exosquelette, de prothèses ou encore de BCI [47]. Même si nous n'avons pas gagné cette compétition, notre participation nous a permis de développer de nouveaux algorithmes de traitement des signaux EEG, ainsi que d'identifier un nouveau type d'apprentissage humain dans les BCI [5].

Nous nous sommes aussi intéressés à la rééducation motrice après un accident vasculaire cérébral (AVC) à l'aide de BCI. En effet, suite à un AVC, qui peut donner lieu à des lésions cérébrales dans les aires motrices du cerveau, des personnes peuvent se retrouver paralysées d'un membre. Et cette paralysie peut les empêcher de participer à de nombreux exercices de rééducation. Par contre,

même si ces patients post-AVC ne peuvent pas bouger physiquement, il est possible de détecter qu'ils veulent bouger, dans leurs signaux EEG, à l'aide d'une BCI. Quand une BCI détecte une telle intention de mouvement dans les signaux EEG, elle peut déclencher un feedback pour l'utilisateur, en lui montrant une main en train de bouger ou en bougeant physiquement la main de l'utilisateur à l'aide d'une orthèse robotisée, par exemple [35]. Des travaux et métaanalyses ont ainsi montré qu'un tel feedback, lié à l'intention de mouvement détectée dans les signaux EEG, permettait d'améliorer la récupération motrice, en aidant les participants à utiliser l'aire cérébrale touchée par l'AVC, stimulant ainsi la plasticité cérébrale dans cette aire [35, 10]. Nous cherchons donc aussi à contribuer à cette ligne de recherche, et avons proposé, en collaboration avec le CHU de Bordeaux, une BCI qui peut détecter des intentions de mouvement de la main gauche ou droite, et, suite à une telle détection, montrer sur un écran une image 3D de la main correspondante en train de bouger, et fournir des vibrations tactiles sur la main réelle du patient [37] (cf. figure 4). Ce système a été validé sur des personnes en bonne santé (sans AVC) et va prochainement être testé dans un essai clinique avec des patients AVC, afin d'identifier les profils de patients qui peuvent bénéficier d'une rééducation post-AVC à l'aide de BCI [43].

BCI pour la neuroergonomie

Au delà des applications médicales, les BCI peuvent aussi s'avérer très prometteuses pour le grand public, notamment en neuroergonomie. En particulier les BCI peuvent estimer, dans les signaux EEG de leurs utilisateurs, certains états mentaux de ceux-ci (par exemple un niveau attentionnel), de façon à pouvoir évaluer des systèmes interactifs ou adapter le contenu de l'application ou son interaction à l'état de l'utilisateur [4, 15]. On parle alors de BCI dites « passives » [53].

Ainsi nous avons développé des algorithmes et des BCI pour estimer le niveau de charge mentale des utilisateurs dans leurs signaux EEG [3, 32], et avons utilisé ces BCI pour évaluer où et quand des dispositifs ou tâches d'interaction 3D étaient cognitivement difficiles à utiliser [46, 17]. En collaboration avec l'ISAE-SupAéro, nous avons également pu montrer que l'on pouvait estimer la charge mentale de pilotes d'avion en plein vol, dans leurs signaux EEG [14]. Dans le même ordre d'idée, nous avons montré que l'on pouvait estimer (avec cependant des performances de reconnaissance modestes), dans les signaux EEG, des aspects du confort visuel lorsqu'un utilisateur regarde des images stéréoscopiques (i.e., des images perçues comme étant en relief) [16]. Tout cela fournit ainsi de nouveaux outils, complémentaires à ceux existants (par exemple, des questionnaires ou interviews des utilisateurs), pour évaluer l'expérience utilisateur (UX) avec des dispositifs d'interaction humain-machine [18].

Plus récemment, et au delà de l'interaction humain-machine, nous avons exploré si l'on pouvait estimer d'autres types d'états mentaux dans les signaux




Fig. 4. Notre BCI pour la rééducation motrice post-AVC, fournissant un feedback visuel réaliste (mouvement d'une main en 3D) et un feedback vibrotactile sur la main, suite à la détection d'une intention de mouvement dans les signaux EEG [37] (© Inria / Photo C. Morel).

EEG. Nous avons ainsi étudié la curiosité, que l'on peut estimer — avec des performances modestes (on peut distinguer si un utilisateur est curieux ou pas avec une précision de l'ordre de 65 %) — dans les signaux EEG [2], ou encore l'expérience esthétique dans des musées virtuels (i.e. un utilisateur apprécie-t-il une œuvre d'art ou pas) [44, 45]. La possibilité de décoder de tels états mentaux dans les signaux EEG ouvre des perspectives intéressantes pour le futur, par exemple pour personnaliser des musées virtuels automatiquement pour chaque utilisateur (chaque utilisateur verra des œuvres d'arts différentes, qui maximiseront son expérience esthétique) ou pour personnaliser des dispositifs éducatifs pour chaque apprenant (chaque apprenant aura des séquences d'exercices différentes, qui maximiseront son engagement et sa curiosité pour améliorer l'apprentissage et la mémorisation).

Conclusion

Globalement, cet article a proposé un bref panorama de la recherche sur les interfaces cerveau-ordinateur (BCI) en général, et de nos travaux sur ce sujet en particulier. Il a notamment mis en avant le fait que les BCI sont très prometteuses pour de nombreuses applications, mais encore trop peu fiables pour être utilisées largement en pratique. Cet article a ainsi illustré nos travaux pour rendre ces BCI plus fiables, que ce soit en travaillant sur les aspects machine (algorithmes de

classification des signaux EEG), ou les aspects humains (comprendre et optimiser l'entraînement utilisateur). Il a enfin présenté quelques-uns de nos travaux applicatifs en BCI, dans le domaine de la santé numérique (pour les technologies d'assistance ou la rééducation motrice post-AVC) ou de la neuroergonomie (pour évaluer des états mentaux liés à l'expérience utilisateur, tels que la charge mentale ou la curiosité). Bien entendu, ce panorama est loin d'être complet, et n'est qu'un aperçu. Le lecteur intéressé pourra se référer notamment à [33, 11, 12] pour plus d'informations sur le sujet. Pour ceux qui souhaiteraient aller encore plus loin, et essayer les BCI ou les utiliser dans leurs travaux et recherches, nous pouvons leur recommander d'essayer le logiciel OpenViBE, un logiciel libre et gratuit que nous codéveloppons et qui permet de concevoir et d'utiliser des BCI en temps réel, et ce, sans programmer une seule ligne de code [38].

Malgré l'accélération des travaux sur les BCI, et tous les résultats de recherche récents sur le sujet, les BCI actuelles restent cependant encore insuffisamment fiables, notamment pour une utilisation hors des laboratoires. Il y a donc toujours besoin de recherches sur tous les composants des BCI, pour les rendre plus robustes, fiables et utilisables. Une direction de recherche potentiellement intéressante sur le sujet serait de développer des théories de l'interaction cerveau-ordinateur. En effet, la recherche actuelle en BCI est une recherche très expérimentale, procédant le plus souvent par essais et erreurs : un nouvel algorithme ou un nouveau protocole d'entraînement est proposé et testé, et on observe expérimentalement s'il donne satisfaction ou pas. Cette approche est déjà très utile, mais n'est pas très efficace. De plus, qu'une nouvelle méthode fonctionne ou pas, très souvent on ne sait pas pourquoi. Cela empêche d'accumuler les résultats et les savoirs et de pouvoir proposer des solutions optimales. Il y a donc un besoin de théories, pouvant expliquer et prédire le comportement des BCI et de ses composantes, par exemple, d'expliquer et prédire pourquoi et quand un algorithme de classification va pouvoir classer les signaux EEG de manière fiable. De telles théories permettraient ensuite de concevoir de nouvelles approches et de nouveaux algorithmes qui soient optimaux par rapport à ces théories, et donc des BCI qui soient enfin fiables. C'est ce que nous nous attellerons à faire dans les années à venir.

Remerciements

Le travail présenté dans cet article a été financé en partie par les projets ANR REBEL (ANR-15-CE23-0013-01), ANR PROTEUS (ANR-22-CE33-0015-01), ERC BrainConquest (ERC-2016-STG-714567) et CHIST-ERA BITSCOPE (ANR-21-CHRA-0003-01). Je souhaite aussi remercier très chaudement tous mes nombreux collaborateurs et collaboratrices (trop nombreux pour être tous cités ici) qui ont permis à ces travaux de voir le jour.

Références

- [1] Brendan Allison and Christa Neuper. 2010. Could anyone use a BCI? In *Brain-Computer Interfaces: Human-Computer Interaction Series*. 35–54. https://doi.org/10.1007/978-1-84996-272-8_3.
- [2] Aurélien Appriou, Jessy Ceha, Smeety Pramij, Dan Dutartre, Edith Law, Pierre-Yves Oudeyer, and Fabien Lotte. 2020. Towards measuring states of epistemic curiosity through electroencephalographic signals. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (smc)*, 4006–4011.
- [3] Aurélien Appriou, Andrzej Cichocki, and Fabien Lotte. 2020. Modern machine-learning algorithms for classifying cognitive and affective states from electroencephalography signals. *IEEE Systems, Man, and Cybernetics Magazine* 6, 3:29–38.
- [4] Hasan Ayaz and Frédéric Dehais. 2018. *Neuroergonomics: The brain at work and in everyday life*. Academic Press.
- [5] Camille Benaroch, Khadijeh Sadatnejad, Aline Roc, Aurélien Appriou, Thibaut Monseigne, Smeety Pramij, Jelena Mladenovic, Léa Pillette, Camille Jeunet, and Fabien Lotte. 2021. Long-Term BCI Training of a Tetraplegic User: Adaptive Riemannian Classifiers and User Training. *Frontiers in Human Neuroscience* 15. <https://doi.org/10.3389/fnhum.2021.635653>.
- [6] N Birbaumer, N Ghanayim, Thilo Hinterberger, Iver Iversen, Boris Kotchoubey, Andrea Kübler, J Perelmouter, E Taub, and H Flor. 1999. A spelling device for the paralysed. *Nature* 398:297–8. <https://doi.org/10.1038/18581>.
- [7] Benjamin Blankertz, Claudia Sannelli, Sebastian Halder, Eva M Hammer, Andrea Kübler, Klaus-Robert Müller, Gabriel Curio, and Thorsten Dickhaus. 2010. Neurophysiological predictor of SMR-based BCI performance. *Neuroimage* 51, 4:1303–1309.
- [8] Laurent Bonnet, Fabien Lotte, and Anatole Lécuyer. 2013. Two brains, one game: Design and evaluation of a multiuser BCI video game based on motor imagery. *IEEE Transactions on Computational Intelligence and AI in games* 5, 2:185–198.
- [9] Laurent Bougrain, Sébastien Rimbart, Pedro LC Rodrigues, Geoffrey Canron, and Fabien Lotte. 2021. Guidelines to use transfer learning for motor imagery detection: An experimental study. In *2021 10th international IEEE/EMBS conference on neural engineering (NER)*, 5–8.
- [10] Maria A Cervera, Surjo R Soekadar, Junichi Ushiba, José del R Millán, Meigen Liu, Niels Birbaumer, and Gangadhar Garipelli. 2018. Brain-computer interfaces for post-stroke motor rehabilitation: A meta-analysis. *Annals of clinical and translational neurology* 5, 5:651–663.
- [11] Maureen Clerc, Laurent Bougrain, and Fabien Lotte. 2016. *Les interfaces cerveau-ordinateur 1 : Fondements et méthodes*. ISTE Group.
- [12] Maureen Clerc, Laurent Bougrain, and Fabien Lotte. 2016. *Les interfaces cerveau-ordinateur 2 : Technologie et applications*. ISTE Group.
- [13] Marco Congedo, Alexandre Barachant, and Rajendra Bhatia. 2017. Riemannian geometry for EEG-based brain-computer interfaces; a primer and a review. *Brain-Computer Interfaces* 4, 3:155.
- [14] Frédéric Dehais, Alban Duprès, Sarah Blum, Nicolas Drougard, Sébastien Scannella, Raphaëlle N Roy, and Fabien Lotte. 2019. Monitoring pilot’s mental workload using ERPs and spectral power with a six-dry-electrode EEG system in real flight conditions. *Sensors* 19, 6:1324.
- [15] Stephen H Fairclough and Fabien Lotte. 2020. Grand challenges in neurotechnology and system neuroergonomics. *Frontiers in Neuroergonomics* 1, 602504.

- [16] Jérémy Frey, Aurélien Appriou, Fabien Lotte, and Martin Hachet. 2016. Classifying EEG signals during stereoscopic visualization to estimate visual comfort. *Computational intelligence and neuroscience* 2016, 1:2758103.
- [17] Jérémy Frey, Maxime Daniel, Julien Castet, Martin Hachet, and Fabien Lotte. 2016. Framework for electroencephalography-based evaluation of user experience. In *Proceedings of the 2016 CHI conference on human factors in computing systems*, 2283–2294.
- [18] J Frey 1 2, M Hachet 2, and F Lotte 2. 2017. EEG-based neuroergonomics for 3D user interfaces: Opportunities and challenges. *Le travail humain* 80, 1:73–92.
- [19] Rümeyşa İnce, Saliha Seda Adanır, and Fatma Sevmez. 2021. The inventor of electroencephalography (EEG): Hans Berger (1873–1941). *Child's Nervous System* 37:2723–2724.
- [20] Camille Jeunet, Emilie Jahanpour, and Fabien Lotte. 2016. Why standard brain-computer interface (BCI) training protocols should be changed: An experimental study. *Journal of Neural Engineering* 13. <https://doi.org/10.1088/1741-2560/13/3/036024>.
- [21] Camille Jeunet, Fabien Lotte, Jean-Marie Batail, Pierre Philip, and Jean-Arthur Micoulaud Franchi. 2018. Using recent BCI literature to deepen our understanding of clinical neurofeedback: A short review. *Neuroscience* 378:225–233.
- [22] C. Jeunet, B. N’Kaoua, and F. Lotte. 2016. Advances in user-training for mental-imagery-based BCI control: Psychological and cognitive factors and their neural correlates. In *Brain-computer interfaces: Lab experiments to real-world applications*, Damien Coyle (ed.). Elsevier, 3–35. <https://doi.org/https://doi.org/10.1016/bs.pbr.2016.04.002>.
- [23] Satyam Kumar, Florian Yger, and Fabien Lotte. 2019. Towards adaptive classification using riemannian geometry approaches in brain-computer interfaces. In *2019 7th international winter conference on brain-computer interface (BCI)*, 1–6.
- [24] Fabien Lotte, Laurent Bougrain, Andrzej Cichocki, Maureen Clerc, Marco Congedo, Alain Rakotomamonjy, and Florian Yger. 2018. A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update. *Journal of neural engineering* 15, 3:031005.
- [25] Fabien Lotte, Marco Congedo, Anatole Lécuyer, and Lamarche Fabrice. 2007. A review of classification algorithms for EEG-based brain-computer interfaces. *Journal of Neural Engineering* 4.
- [26] Fabien Lotte, Larrue Florian, and Christian Mühl. 2013. Flaws in current human training protocols for spontaneous brain-computer interfaces: Lessons learned from instructional design. *Frontiers in human neuroscience* 7:568. <https://doi.org/10.3389/fnhum.2013.00568>.
- [27] Fabien Lotte and Cuntai Guan. 2011. Regularizing common spatial patterns to improve BCI designs: Unified theory and new algorithms. *IEEE Transactions on biomedical Engineering* 58, 2:355–362.
- [28] Fabien Lotte, Anatole Lécuyer, Fabrice Lamarche, and Bruno Arnaldi. 2007. Studying the use of fuzzy inference systems for motor imagery classification. *IEEE transactions on neural systems and rehabilitation engineering* 15, 2:322–324.
- [29] Fabien Lotte, Aurelien Van Langenhove, Fabrice Lamarche, Thomas Ernest, Yann Renard, Bruno Arnaldi, and Anatole Lécuyer. 2010. Exploring large virtual environments by thoughts using a brain-computer interface based on motor imagery and high-level commands. *Presence: teleoperators and virtual environments* 19, 1:54–70.
- [30] J d R Millán, Rüdiger Rupp, Gernot R Müller-Putz, Roderick Murray-Smith, Claudio Giugliemma, Michael Tangermann, Carmen Vidaurre, Febo Cincotti, Andrea Kübler, Robert Leeb, and others. 2010. Combining brain-computer interfaces and assistive technologies: State-of-the-art and challenges. *Frontiers in neuroscience* 4:161.

- [31] Jelena Mladenović, Jérémy Frey, Smeety Pramij, Jérémie Mattout, and Fabien Lotte. 2022. Towards Identifying Optimal Biased Feedback for Various User States and Traits in Motor Imagery BCI. *IEEE Transactions on Biomedical Engineering* 69, 3:1101–1110.
- [32] Christian Mühl, Camille Jeunet, and Fabien Lotte. 2014. EEG-based workload estimation across affective contexts. *Frontiers in neuroscience* 8:114.
- [33] Chang S Nam, Anton Nijholt, and Fabien Lotte. 2018. *Brain–computer interfaces handbook: Technological and theoretical advances*. CRC Press.
- [34] Ernst Niedermeyer. 2011. *Niedermeyer's electroencephalography: Basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins.
- [35] Floriana Pichiorri, Giovanni Morone, Manuela Petti, Jlenia Toppi, Iolanda Pisotta, Marco Molinari, Stefano Paolucci, Maurizio Inghilleri, Laura Astolfi, Febo Cincotti, and others. 2015. Brain–computer interface boosts motor imagery practice during stroke recovery. *Annals of neurology* 77, 5:851–865.
- [36] Léa Pillette, Camille Jeunet, Boris Mansencal, Roger N’Kambou, Bernard N’Kaoua, and Fabien Lotte. 2020. A physical learning companion for mental-imagery BCI user training. *Int. J. Hum.-Comput. Stud.* 136, C. <https://doi.org/10.1016/j.ijhcs.2019.102380>.
- [37] Léa Pillette, Bernard N’kaoua, Romain Sabau, Bertrand Glize, and Fabien Lotte. 2021. Multi-session influence of two modalities of feedback and their order of presentation on MI-BCI user training. *Multimodal Technologies and Interaction* 5, 3:12.
- [38] Yann Renard, Fabien Lotte, Guillaume Gibert, Marco Congedo, Emmanuel Maby, Vincent Delannoy, Olivier Bertrand, and Anatole Lécuyer. 2010. OpenViBE: An open-source software platform to design, test, and use brain–computer interfaces in real and virtual environments. *Presence* 19, 1:35–53.
- [39] Aline Roc, Léa Pillette, Jelena Mladenović, Camille Benaroch, Bernard N’Kaoua, Camille Jeunet, and Fabien Lotte. 2021. A review of user training methods in brain computer interfaces based on mental tasks. *Journal of Neural Engineering* 18, 1:011002. <https://doi.org/10.1088/1741-2552/abca17>.
- [40] Raphaëlle N. Roy, Marcel F. Hinss, Ludovic Darmet, Simon Ladouce, Emilie S. Jahanpour, Bertille Somon, Xiaoqi Xu, Nicolas Drougard, Frederic Dehais, and Fabien Lotte. 2022. Retrospective on the First Passive Brain-Computer Interface Competition on Cross-Session Workload Estimation. *Frontiers in Neuroergonomics* 3. <https://doi.org/10.3389/fnrgo.2022.838342>.
- [41] Khadijeh Sadatnejad and Fabien Lotte. 2022. Riemannian channel selection for BCI with between-session non-stationarity reduction capabilities. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 30:1158–1171.
- [42] Simanto Saha and Mathias Baumert. 2020. Intra- and inter-subject variability in EEG-based sensorimotor brain computer interface: A review. *Frontiers in Computational Neuroscience* 13.
- [43] David Trocellier, Bernard N’kaoua, and Fabien Lotte. 2022. Identifying factors influencing the outcome of BCI-based post stroke motor rehabilitation towards its personalization with artificial intelligence. In *2022 IEEE international conference on metrology for extended reality, artificial intelligence and neural engineering (MetroX-RAINE)*, 151–156.
- [44] Marc Welter and Fabien Lotte. 2024. Ecological decoding of visual aesthetic preference with oscillatory electroencephalogram features—a mini-review. *Frontiers in Neuroergonomics* 5. <https://doi.org/10.3389/fnrgo.2024.1341790>.
- [45] Marc Welter, J Casal Martínez, E Redmond, Jonathan Baum, Tomas Ward, and Fabien Lotte. 2024. EEG-based art interest decoding. In *Neuroergonomics conference 2024*.

- [46] Dennis Wobrock, Jérémy Frey, Delphine Graeff, Jean-Baptiste de La Rivière, Julien Castet, and Fabien Lotte. 2015. Continuous mental effort evaluation during 3D object manipulation tasks based on brain and physiological signals. In *Human-computer interaction-INTERACT 2015: 15th IFIP TC 13 international conference, bamberg, germany, september 14-18, 2015, proceedings, part i 15*, 472–487.
- [47] Peter Wolf and Robert Riener. 2018. Cybathlon: How to promote the development of assistive technologies. *Science robotics* 3(17):eaat71174.
- [48] Jonathan R Wolpaw and E Winter Wolpaw. 2012. Brain-computer interfaces: Something new under the sun. *Brain-computer interfaces: principles and practice* 14:3–12.
- [49] Maria Sayu Yamamoto, Fabien Lotte, Florian Yger, and Sylvain Chevallier. 2022. Class-distinctiveness-based frequency band selection on the riemannian manifold for oscillatory activity-based BCIs: Preliminary results. In *2022 44th annual international conference of the IEEE engineering in medicine & biology society (EMBC)*, 3690–3693.
- [50] Maria Sayu Yamamoto, Apolline Mellot, Sylvain Chevallier, and Fabien Lotte. 2023. Novel SPD matrix representations considering cross-frequency coupling for EEG classification using riemannian geometry. In *2023 31st european signal processing conference (EUSIPCO)*, 960–964.
- [51] Maria Sayu Yamamoto, Khadijeh Sadatnejad, Toshihisa Tanaka, Md Rabiul Islam, Frédéric Dehais, Yuichi Tanaka, and Fabien Lotte. 2023. Modeling complex EEG data distribution on the riemannian manifold toward outlier detection and multimodal classification. *IEEE Transactions on Biomedical Engineering*.
- [52] Florian Yger, Maxime Berar, and Fabien Lotte. 2017. Riemannian approaches in brain-computer interfaces: A review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 25, 10:1753–1762.
- [53] Thorsten O Zander and Christian Kothe. 2011. Towards passive brain–computer interfaces: Applying brain–computer interface technology to human–machine systems in general. *Journal of neural engineering* 8, 2:025005.
- [54] Mingjun Zhong, Fabien Lotte, Mark Girolami, and Anatole Lécuyer. 2008. Classifying EEG for brain computer interfaces using gaussian processes. *Pattern Recognition Letters* 29, 3:354–359.