

SOUTENANCE DE THÈSE DE DOCTORAT

Annotation automatique du sommeil par classifieurs définis sur la variété des matrices SDP

Doctorant : Mathieu SERAPHIM¹

**Directeurs : Luc BRUN² & Olivier ETARD¹,
avec le concours d'Alexis LECHERVY¹**

Rapporteurs : Sophie ACHARD³ & Sylvain CHEVALLIER⁴

Membre : François-Xavier DUPÉ⁵

¹Université de Caen Normandie ; ²ENSICAEN ; ³Université Grenoble Alpes ; ⁴Université Paris-Saclay ;

⁵Aix-Marseille Université



COMETE
UMR 1075 UNICAEN / INSERM



Normandie Université



Inserm anr[®]



Le sommeil

Diagnostic médical

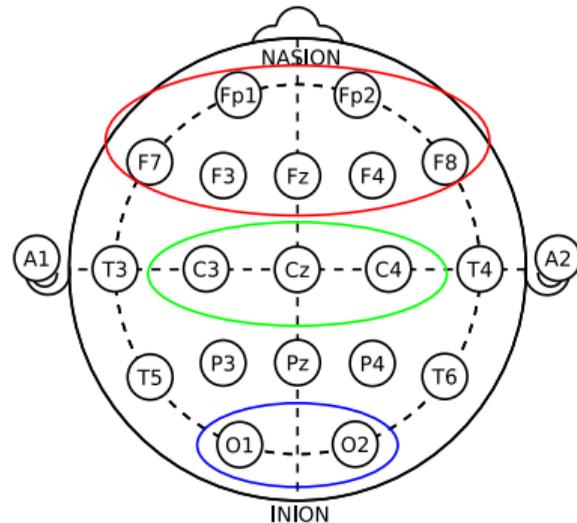
- ▶ **Insomnie, narcolepsie**
- ▶ Dérèglements du **rythme circadien**
- ▶ Troubles de la vigilance / **microsommeils**

Recherche liée au sommeil

- ▶ Mécanismes de **cognition** (mémoire...)
- ▶ **Métabolisme**
- ▶ **Approbation** de certains **médicaments**

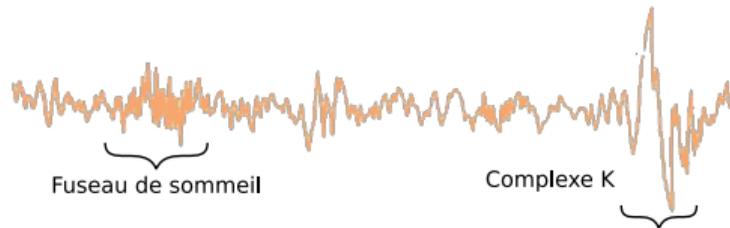
5 états [Troester et al., 2023] :

- ▶ **Éveil**
- ▶ Sommeil paradoxal / **REM**
- ▶ Sommeil lent léger (**N1** ou **N2**)
- ▶ Sommeil lent profond (**N3**)



Annotation :

- ▶ **EEG frontal, central & occipital**
- ▶ Propriétés des signaux → annotation
- ▶ **Contexte temporel** important



Signal : [Dutt et al., 2023]. Sous licence CC BY 4.0 (creativecommons.org/licenses/by/4.0/).

Annotation manuelle : coûteuse (**temps / expertise**)

→ **Automatisation** par **apprentissage**

- ▶ Modèles **profonds**, entrée : **séquences d'époques**
- ▶ Souvent **mono-signal**

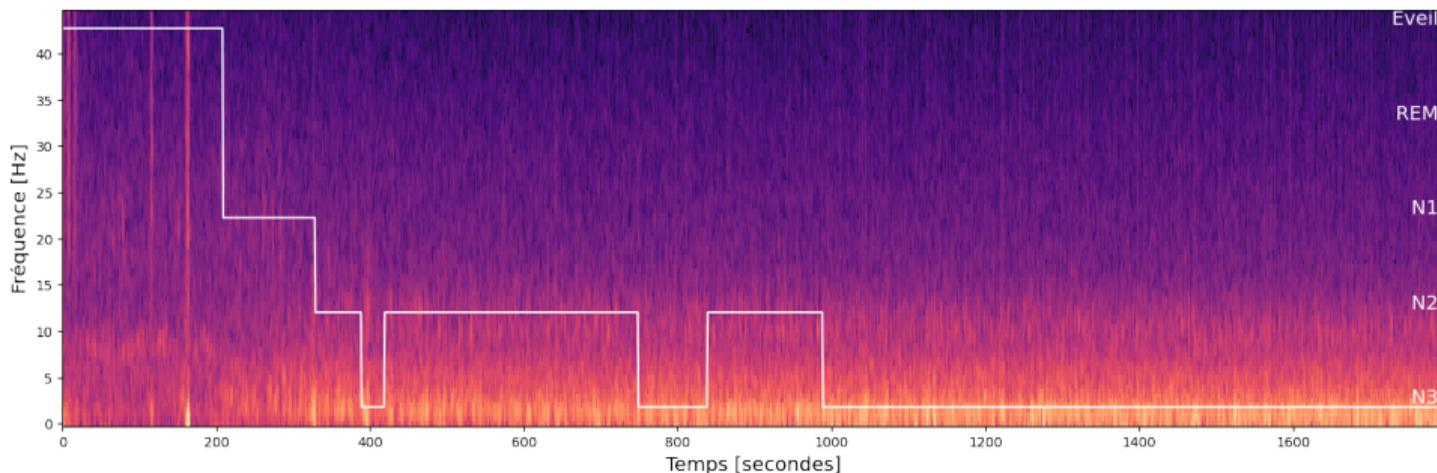
Obstacles : **nature des signaux**

- ▶ **Déséquilibre** des classes, et donc **différence des performances** par classe
 - ▶ Ex. : état **N1** - **difficile à annoter & minoritaire**
- ▶ **Variabilité** inter-sujet / inter-bases → **transfert** difficile

Analyse **mono-signal** : **perte d'information**

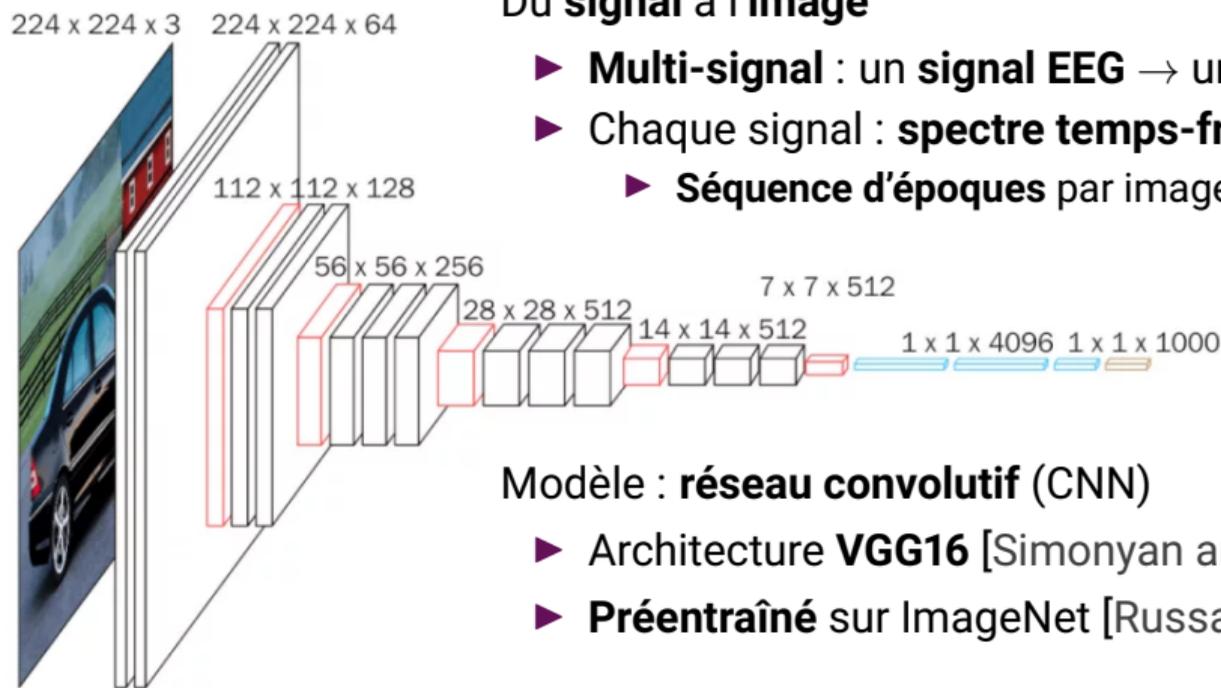
⇒ Privilégier une **approche multi-signal**

Représentation temps-fréquence pertinente



SleepVGG16 : classification visuelle multi-signal

Dequidt, P., Seraphim, M., Lechervy, A., Gaez, I. I., Brun, L., et Etard, O. (AIME 2023)
Automatic sleep stage classification on EEG signals using time-frequency representation



Du signal à l'image

- ▶ **Multi-signal** : un **signal EEG** → un **canal de l'image**
- ▶ Chaque signal : **spectre temps-fréquence**
 - ▶ **Séquence d'époques** par image → **contexte**

Modèle : réseau convolutif (CNN)

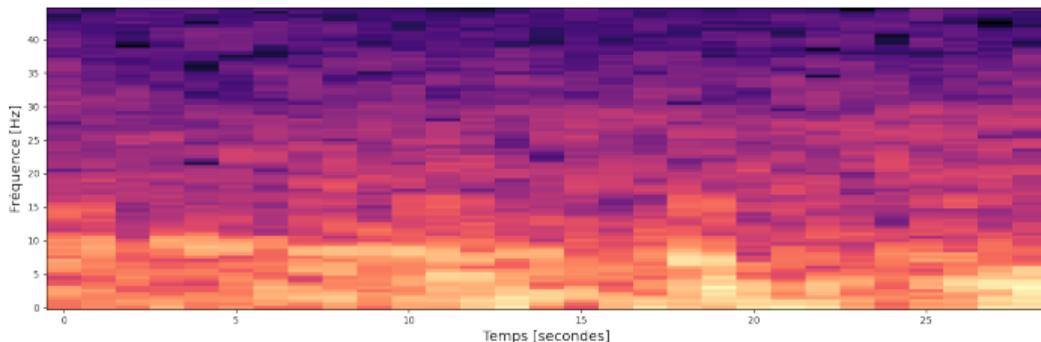
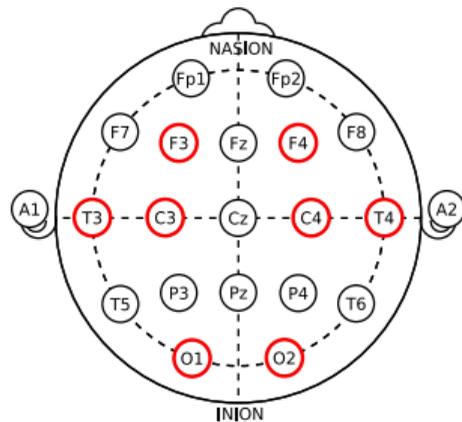
- ▶ Architecture **VGG16** [Simonyan and Zisserman, 2015]
- ▶ **Préentraîné** sur ImageNet [Russakovsky et al., 2015]

Signaux choisis :

- ▶ **F, C, O** sur **deux hémisphères**
- ▶ **Signal temporel** → activité latérale

Spectres temps-fréquence

- ▶ **30 colonnes / époque** ($\delta t = 2s$, 50 % recouv.)



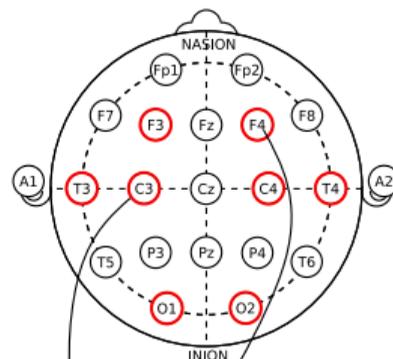
CNN : pas de mesure explicite des relations entre régions

CF : estimation de l'état du cerveau

- ▶ **Co-évolution de l'activité** entre régions
- ▶ Représentation commune : **matrices de covariance**
- ▶ Lien avéré entre **CF par EEG** et **état de sommeil**
 - ▶ [Bouchard et al., 2019]

Pour **capturer cette information** :

- ▶ **Matrices de covariance** comme **canaux d'entrée**



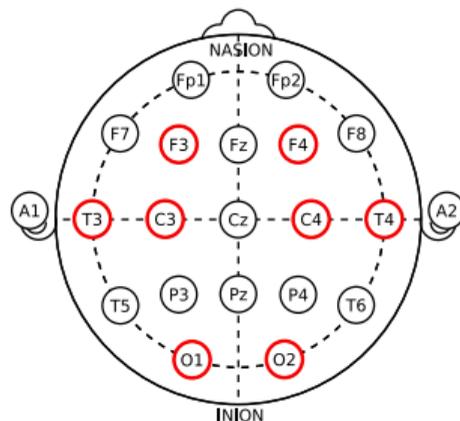
	F3	F4	C3	C4	T3	T4	O1	O2
F3	0.39	0.33	0.24	0.2	0.24	0.17	-0.071	-0.074
F4	0.33	0.34	0.21	0.24	0.17	0.22	-0.044	-0.034
C3	0.24	0.21	0.22	0.18	0.2	0.12	0.087	0.037
C4	0.2	0.24	0.18	0.24	0.13	0.19	0.073	0.062
T3	0.24	0.17	0.2	0.13	0.29	0.062	0.069	0.0067
T4	0.17	0.22	0.12	0.19	0.062	0.19	0.0099	0.01
O1	-0.071	-0.044	0.087	0.073	0.069	0.0099	0.4	0.26
O2	-0.074	-0.034	0.037	0.062	0.0067	0.01	0.26	0.23

Prétraitement des signaux

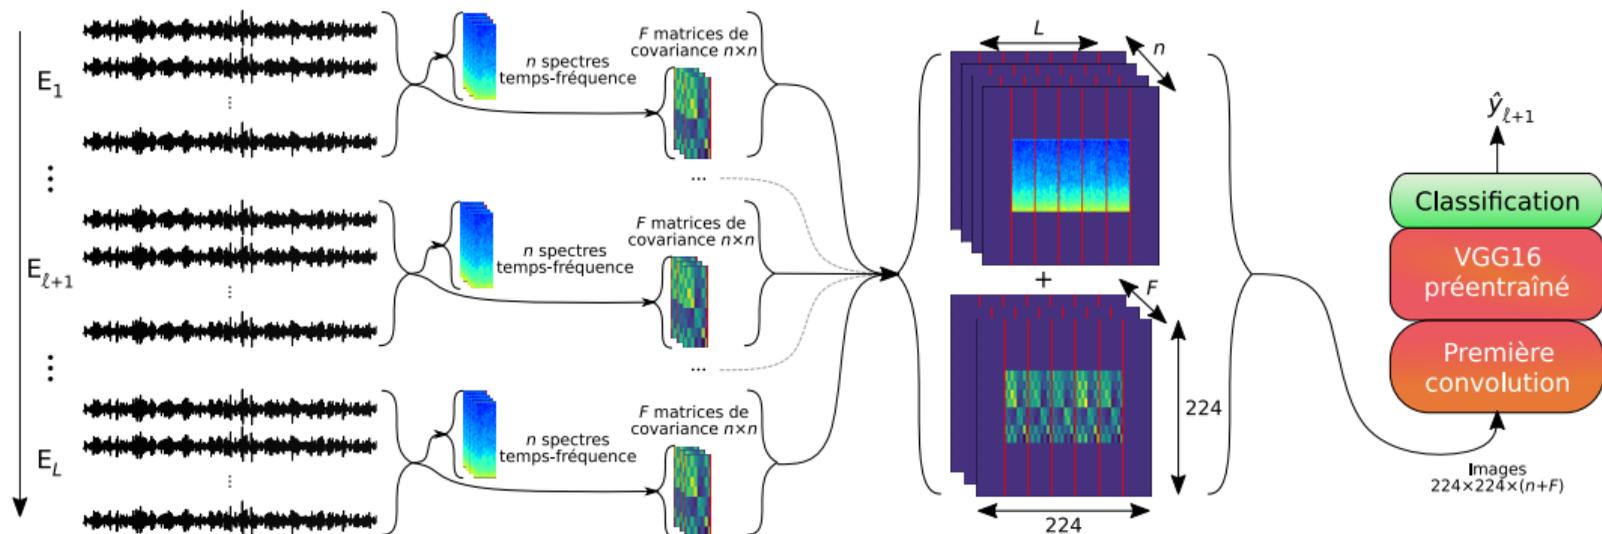
- ▶ **Z-score** ($\mu = 0, \sigma = 1$)
- ▶ Filtrage par **bande de fréquence**

Une matrice de covariance par **époque** / **bande**

- ▶ Y compris le signal non filtré



	Delta	Thêta	Alpha	Bêta _{bas}	Bêta _{haut}	Gamma
Hz	[0,5 ; 4[[4 ; 8[[8 ; 12[[12 ; 22[[22 ; 30[[30 ; 45[



Chaque image d'entrée : **séquence temporelle de L époques**

- ▶ $n = 8$ canaux (un par signal) : **spectres temps-fréquence**
- ▶ $F = 7$ canaux (un par "bande") : **matrices de covariance**

Base de données : **MASS SS3** [O'reilly et al., 2014]

- ▶ **62 enregistrements**, nuits complètes
- ▶ **Fort déséquilibre** entre les 5 classes

Objectif : maximiser les **performances par classe**

- ▶ **Entraînement** : rééquilibrage par **sur-échantillonnage**
- ▶ **Performance** via métrique équilibrée : **MF1**

Validation croisée (31 blocs)

- ▶ **Deux sujets** par ensemble de **test**
- ▶ **Performance finale** : **moyenne** des performances **par bloc**

Forte variation entre **ensembles de test** \Rightarrow **écart-type élevé**

	MF1	Macro-exactitude	Kappa
SleepVGG16	81,79 \pm 2,95	82,96 \pm 2,88	0,809 \pm 0,038
Sans covariances	80,88 \pm 2,94	81,81 \pm 3,41	0,798 \pm 0,039

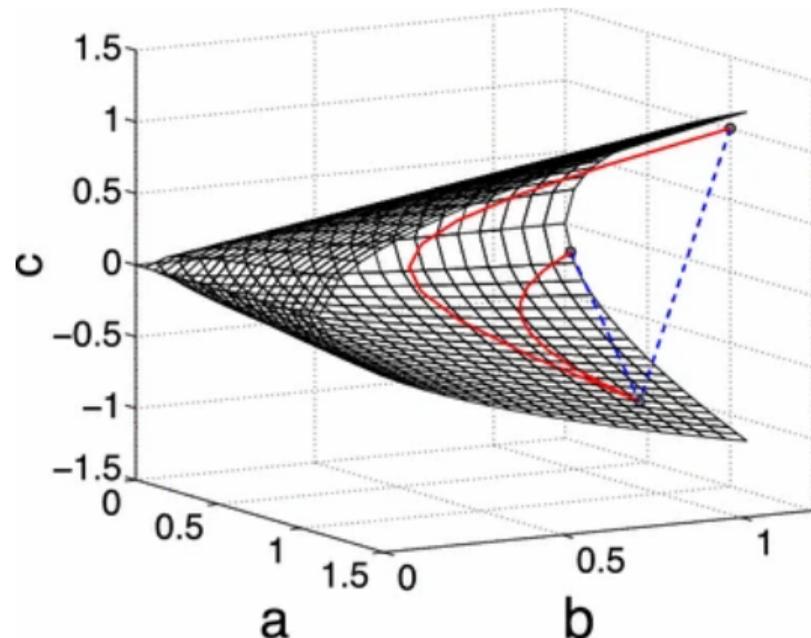
Une analyse par la connectivité fonctionnelle

Matrices de covariance

- ▶ **Symétriques définies positives (SDP)**

$SDP(n)$: **variété riemannienne**

- ▶ Espace courbe
- ▶ $\subset Sym(n)$ (matrices **symétriques**)



Définir opérations adaptées :

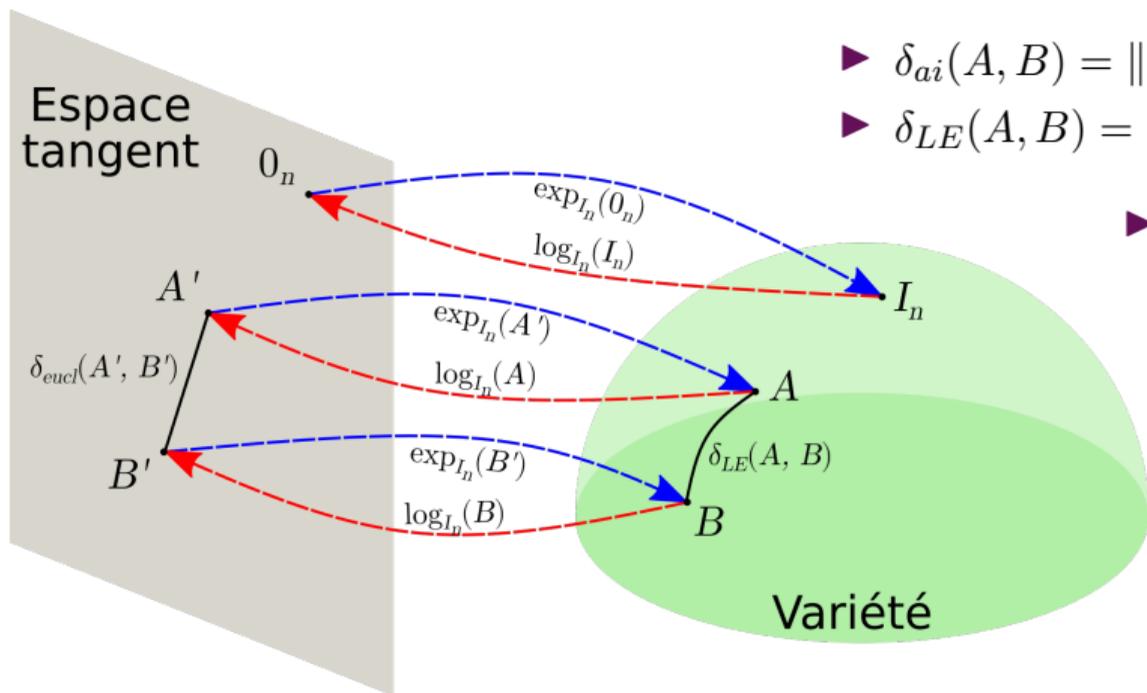
- ▶ **Géodésique** \rightarrow distance \rightarrow opérations riemanniennes

Ex. : **moyenne pondérée** $\tilde{X} = \operatorname{argmin}_{X \in SDP(n)} \sum_{i=0}^{d-1} w_i \delta^2(X_i, X)$

Distances et moyennes sur $SDP(n)$

Distance **affine-invariante** : bonnes propriétés, moyenne approximée

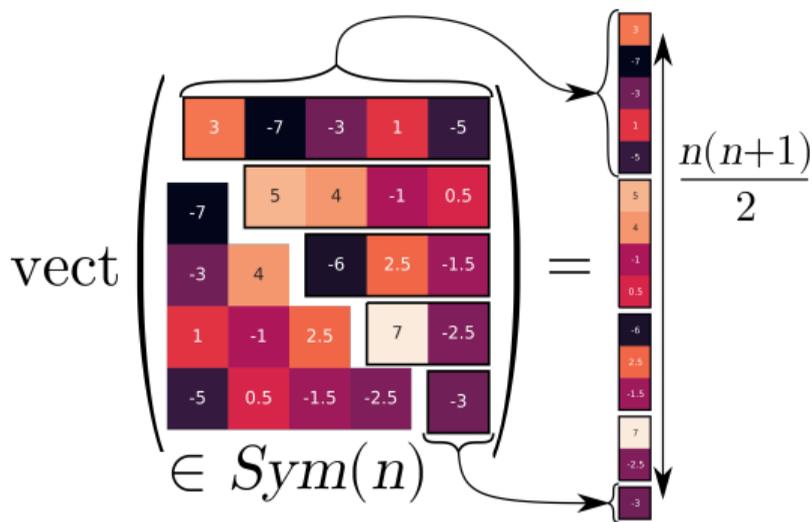
Distance **LogEuclidienne** : calcul facile, moyenne analytique



► $\delta_{ai}(A, B) = \|\log_{I_n}(A^{-1/2} \cdot B \cdot A^{-1/2})\|_F$

► $\delta_{LE}(A, B) = \|\log_{I_n}(A) - \log_{I_n}(B)\|_*$

► $\log_{I_n}(\cdot)$: **bijective**



$Sym(n)$: **espace euclidien**
 \Rightarrow vect(\cdot) : **isomorphisme**

Vectorisation logarithmique : $\text{vect}_{\log}(\cdot) = \text{vect} \circ \log_{I_n}(\cdot)$

► $SDP(n) \rightarrow \mathbb{R}^{\frac{n(n+1)}{2}}$ **sans perte d'information**

Construire une analyse riemannienne du sommeil

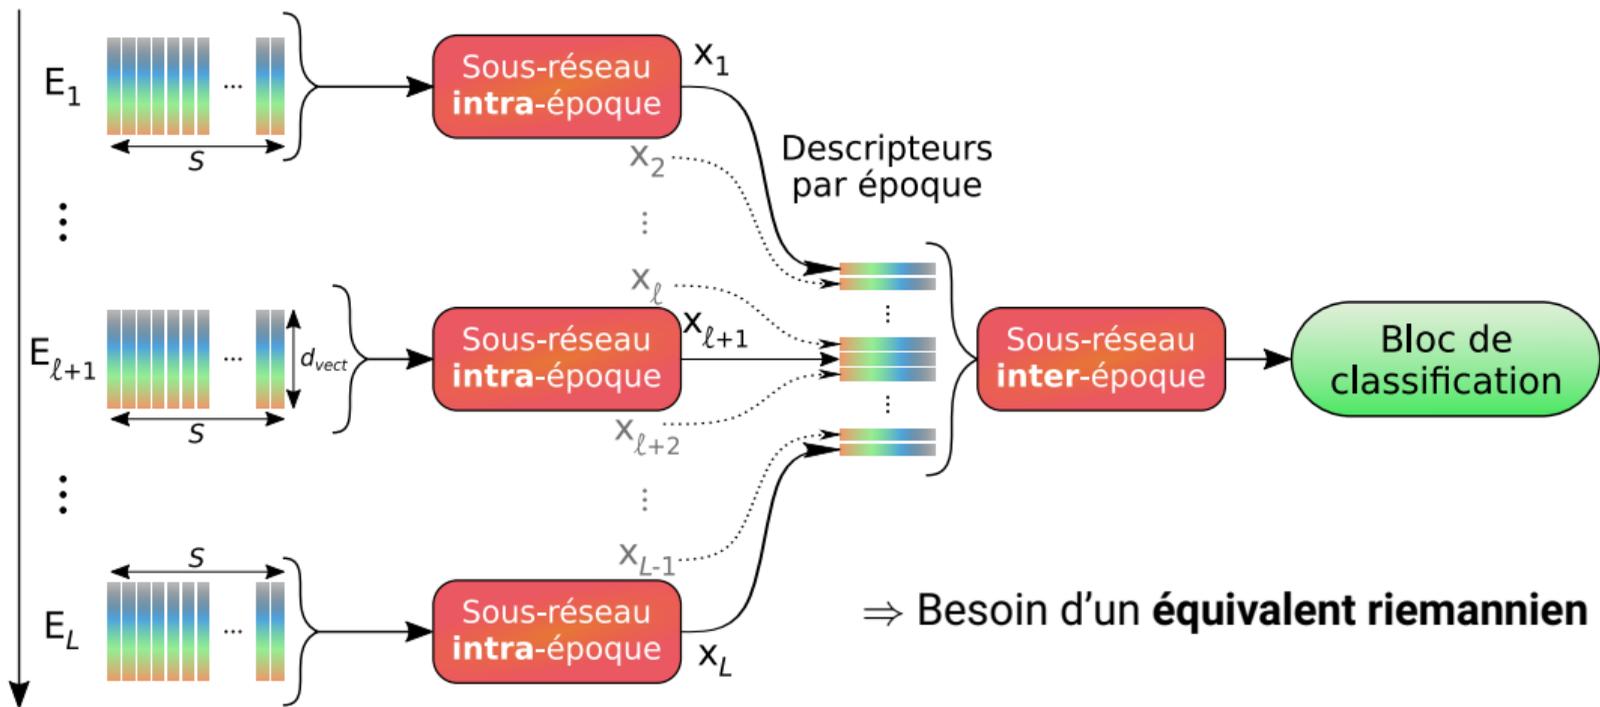
Seraphim, M., Dequidt, P., Lechervy, A., Yger, F., Brun, L., et Etard, O. (CAIP 2023)
Temporal sequences of EEG covariance matrices for automated sleep stage scoring with attention mechanisms

Seraphim, M., Lechervy, A., Yger, F., Brun, L., et Etard, O. (EUSIPCO 2024)
Structure-preserving Transformers for sequences of SPD matrices

Seraphim, M., Lechervy, A., Yger, F., Brun, L., et Etard, O. (2024)
Automatic classification of sleep stages from EEG signals using Riemannian metrics and Transformer networks, SN Computer Science, 5(7):953

Choisir une architecture adaptée

Modèles de l'État de l'Art, experts humains : **analyse à deux échelles**



Couches SDP-à-SDP : calculs **directement sur la variété**

- ▶ **SRU** riemannien [Chakraborty et al., 2018]
- ▶ **Auto-attention** riemannienne [Pan et al., 2022, Qin et al., 2024]

Opérations coûteuses → **architectures simples**

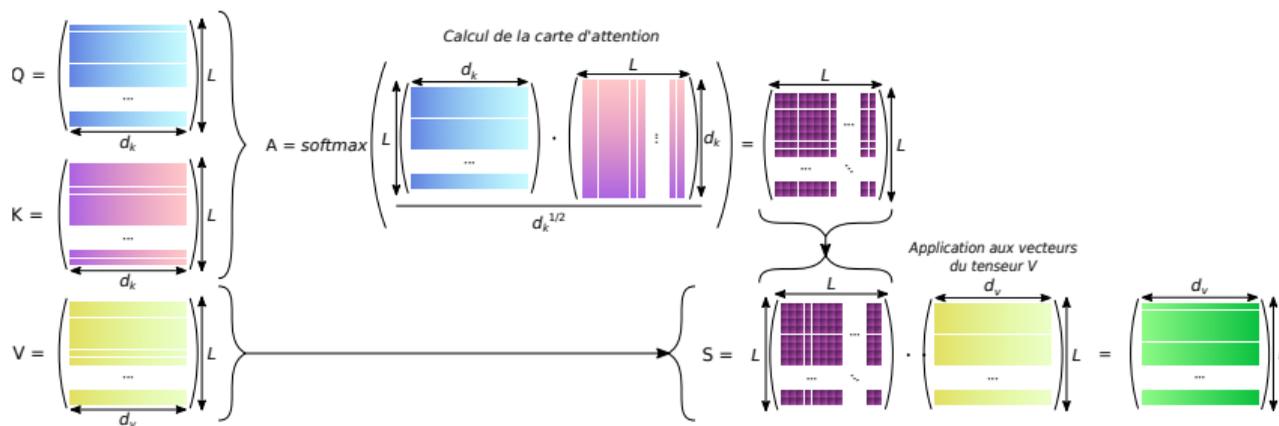
Couches LogEuclidiennes : calculs **dans l'espace tangent** (euclidien)

- ▶ Couches euclidiennes après $\text{vect}_{\log}(\cdot)$
- ▶ **Modèles sophistiqués** possibles

Exemple : somme de vecteurs \Leftrightarrow **moyenne LogEuclidienne** ($w_i = 1$)

Analyse **LogEuclidienne** à base de **Transformers** [Vaswani et al., 2017]

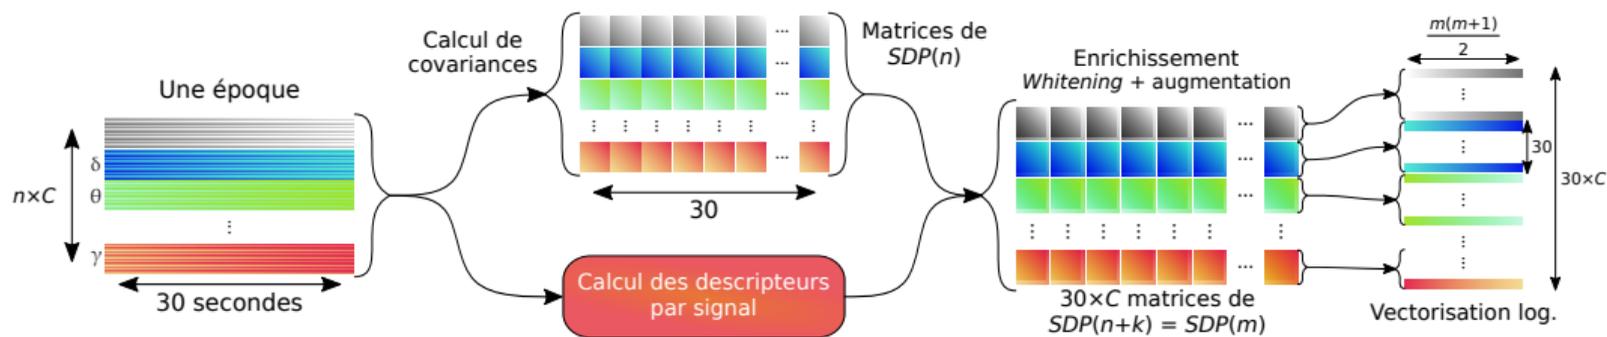
- ▶ **Très performant** en analyse de **séquences vectorielles**
- ▶ Emploient des mécanismes d'**auto-attention**
- ▶ **À adapter** (couches problématiques)



Des signaux à l'espace tangent

Prétraitement des EEG : Z-score, filtrages passe-bande (cf. SleepVGG16)

- ▶ $n = 8$ signaux, $C = 7$ canaux
- ▶ Par canal : segments de 1s, sans recouvrement → 30 matrices



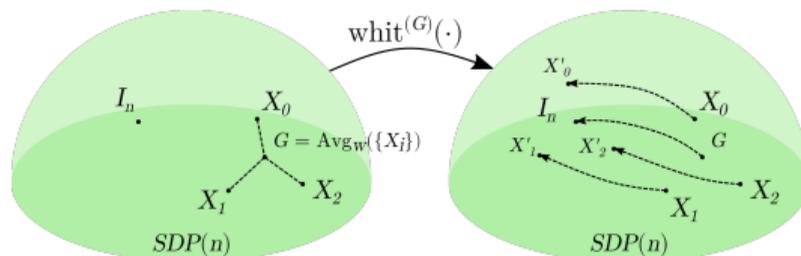
Signaux biologiques : encodent spécificités du sujet

- ▶ Par canal : **estimées** par **moyenne** $\text{Avg}_w(\{X_i\}) = G \in \text{SDP}(n)$

Suppression de l'influence de G sur X :

$$\text{whit}^{(G)}(X) = G^{-1/2} \cdot X \cdot G^{-1/2}$$

⇒ **Transport riemannien** de chaque G à I_n :



Matrice de covariance sur tout l'enregistrement

- ▶ Équivalent à une **moyenne euclidienne** ($\text{Avg}_w(\cdot) = \text{Avg}_E(\cdot)$)
- ▶ **Ne respecte pas la géométrie riemannienne**

Alternativement : **moyenne riemannienne** des matrices concernées

- ▶ **Ici** : moyenne **affine-invariante** ($\text{Avg}_w(\cdot) = \text{Avg}_{AI}(\cdot)$)
- ▶ **Précalculée** avant entraînement → **coût non problématique**

Bonne performance des approches signal

- Présence **d'information pertinente** non capturée via covariances

$\forall X \in \text{SDP}(n), A \in \mathbb{R}^{n \times k} :$

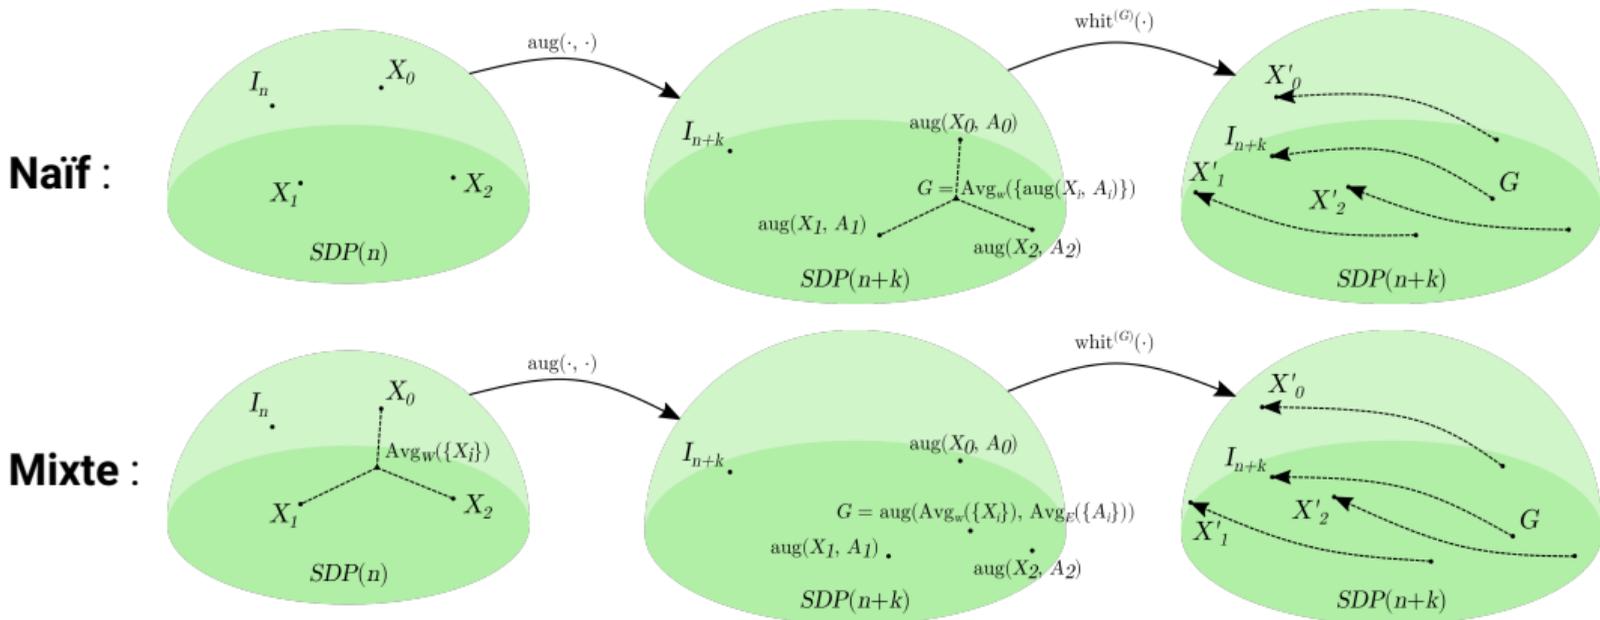
$$\text{aug}(X, A) = \left(\begin{array}{c|c} X + A \cdot A^T & A \\ \hline A^T & I_k \end{array} \right) \in \text{SDP}(n+k) = \text{SDP}(m)$$

Approche choisie : **densité spectrale de puissance (DSP) par signal**

- $A \in \mathbb{R}^n, k = 1$

Combinaison des opérations matricielles

Configurations d'**enrichissement** des matrices :



Enrichissement **mixte privilégié**

- **Séparation** de la moyenne des X_i et des A_i

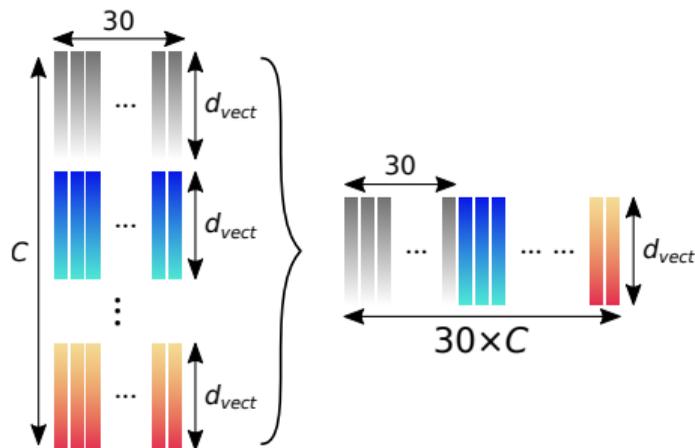
Le modèle SPDTransNet

Particularités des *Transformers* :

- ▶ Apprennent mal si d_{vect} est trop petit
- ▶ Pas de combinaison native des canaux

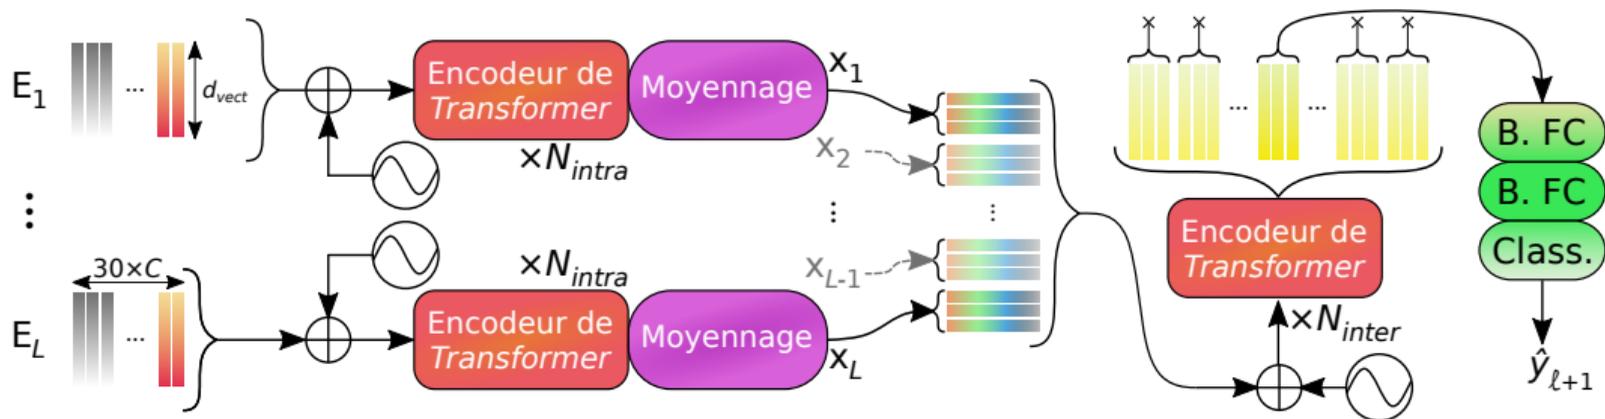
⇒ Projection linéaire des vecteurs d'entrée

- ▶ $\mathbb{R}^{\frac{m(m+1)}{2}} \rightarrow \mathbb{R}^{d_{vect}} = \mathbb{R}^{\frac{p(p+1)}{2}}$
- ▶ **Vecteur** de sortie \Leftrightarrow matrice **SDP**
 - ▶ Préserve les relations de **proximité**



⇒ Combinaison des canaux **par succession**

Adaptée du modèle **SleepTransformer** [Phan et al., 2022]



Entrée : $L = 21$ époques

Projections linéaires :

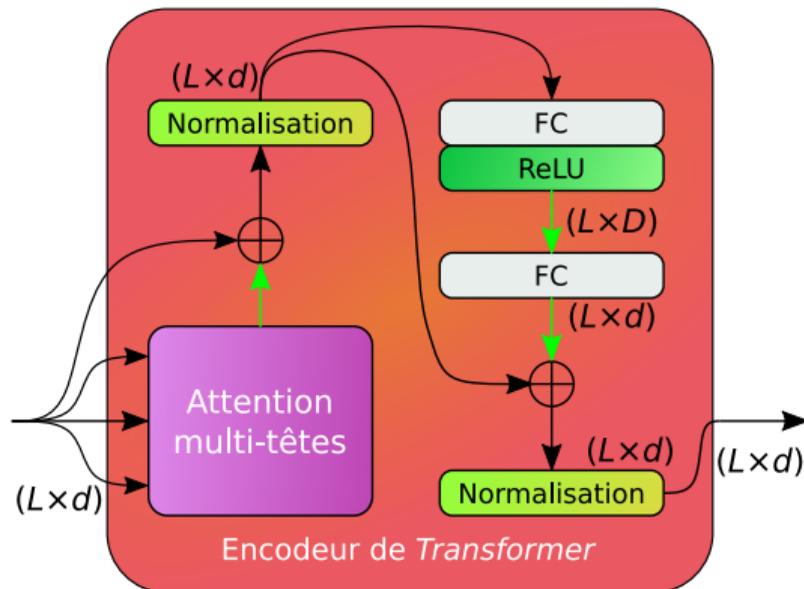
- ▶ Dimensions de sortie **triangulaires**

Sommes pondérées :

- ▶ Déjà **LogEuclidiennes**

Non-linéarités :

- ▶ Préserve le **caractère SDP** de l'entrée
- ▶ **Non-linéarités sur la variété**



⇒ **Nature SDP conservée** jusqu'à la classification

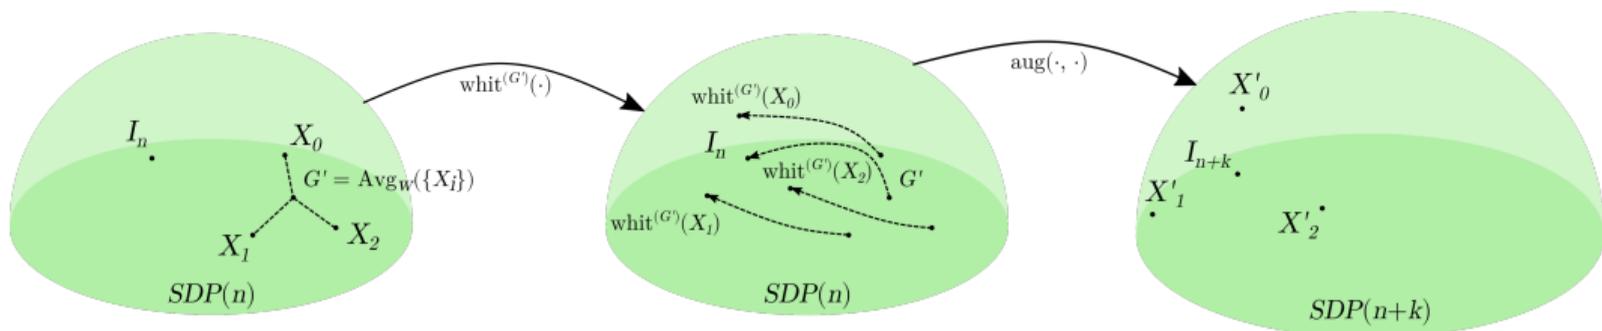
Descripteurs par signal **appris** > manuels

Sous-réseau : CNN **préexistant** [Seo et al., 2020] (ResNet 1D) **modifié**

► **Sortie** : $30 \times k$ descripteurs par signal ($k = 3$)

⇒ Matrices d'augmentation $A_i \in \mathbb{R}^{n \times k}$

$\{A_i\}_{i < N}$ **dynamiques** → enrichissement **inverse**



Modèles considérés :

- ▶ Nos modèles : **SleepVGG16**, **SPDTransNet**, **SPDTransNet+**
- ▶ État de l'Art : **DeepSleepNet** [Supratak et al., 2017], **IITNet** [Seo et al., 2020]
 - ▶ **Mono-signal**, réentraînés avec **notre méthodologie**

Bases de données :

- ▶ **MASS SS3** [O'reilly et al., 2014] : **62** enregistrements (cf. SleepVGG16)
- ▶ **MASS SS1** : **53** enregistrements, mêmes 8 signaux
 - ▶ **Sujets plus âgés** ($63,6 \pm 5,3$ ans)
- ▶ **Dreem DOD-H** [Guillot et al., 2020] : **25** enregistrements
 - ▶ Seulement **7 signaux** EEG
 - ▶ **1 enregistrement** par base de **test** \Rightarrow **écart-type plus élevé**

Comparaison à l'État de l'Art

Apprentissage sur MASS SS3

BDD	Modèle	MF1	F1 N3	F1 N1
SS3	DeepSleepNet	78,14 ± 4,12	80,38 ± 9,35	53,52 ± 8,24
	IITNet	78,48 ± 3,15	81,97 ± 8,91	56,02 ± 6,54
	SleepVGG16	81,23 ± 2,56	82,02 ± 8,76	58,29 ± 5,01
	SPDTransNet	81,24 ± 3,29	78,81 ± 11,17	60,50 ± 6,18
	SPDTransNet+	81,64 ± 2,88	80,15 ± 10,46	60,29 ± 5,52

Comparaison à l'État de l'Art

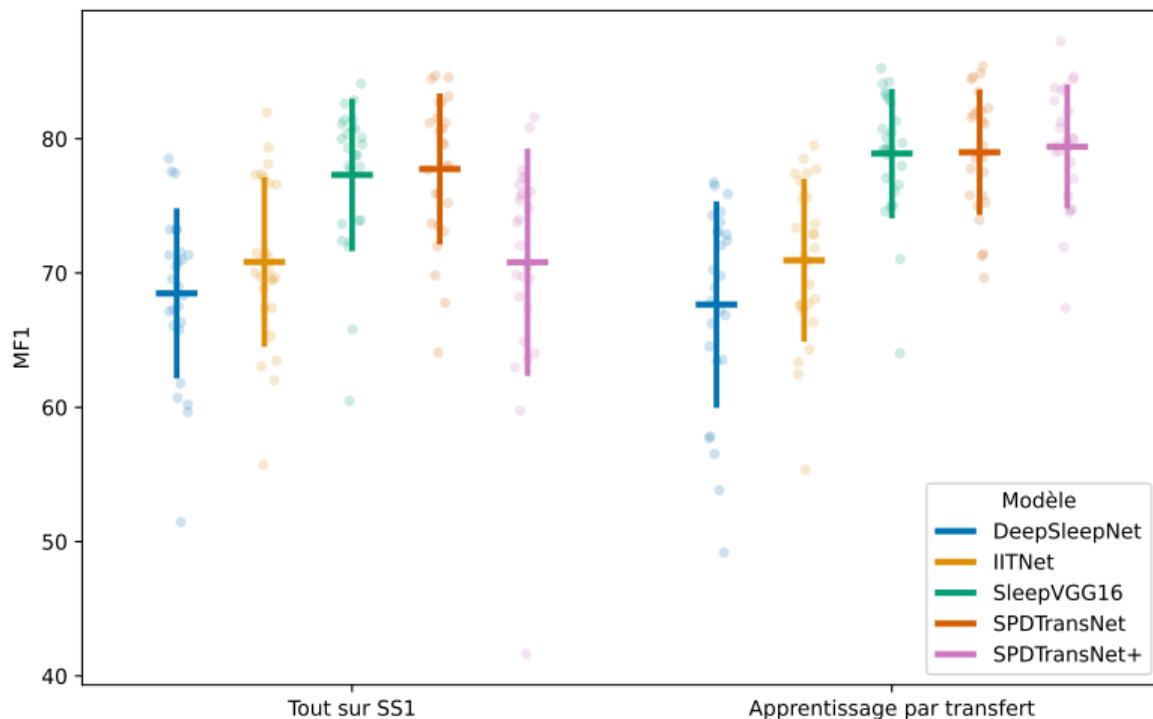
Apprentissage sur les autres bases de données

BDD	Modèle	MF1	F1 N3	F1 N1
SS1	DeepSleepNet	68,49 ± 6,12	53,47 ± 21,59	50,81 ± 8,19
	IITNet	70,82 ± 6,09	56,40 ± 21,76	52,29 ± 6,47
	SleepVGG16	77,31 ± 5,46	66,75 ± 20,76	62,59 ± 5,34
	SPDTransNet	77,75 ± 5,41	63,08 ± 20,96	63,29 ± 6,02
	SPDTransNet+	70,80 ± 8,25	54,81 ± 21,71	54,93 ± 10,26
DOD-H	DeepSleepNet	73,07 ± 13,66	75,98 ± 23,58	48,40 ± 16,86
	IITNet	73,55 ± 9,36	76,67 ± 24,21	49,68 ± 12,53
	SleepVGG16	75,80 ± 10,60	76,87 ± 24,15	51,30 ± 12,00
	SPDTransNet	77,48 ± 8,74	77,75 ± 24,04	56,99 ± 11,93
	SPDTransNet+	73,10 ± 8,67	76,07 ± 24,14	49,73 ± 12,03

Comparaison à l'État de l'Art

Apprentissage par transfert

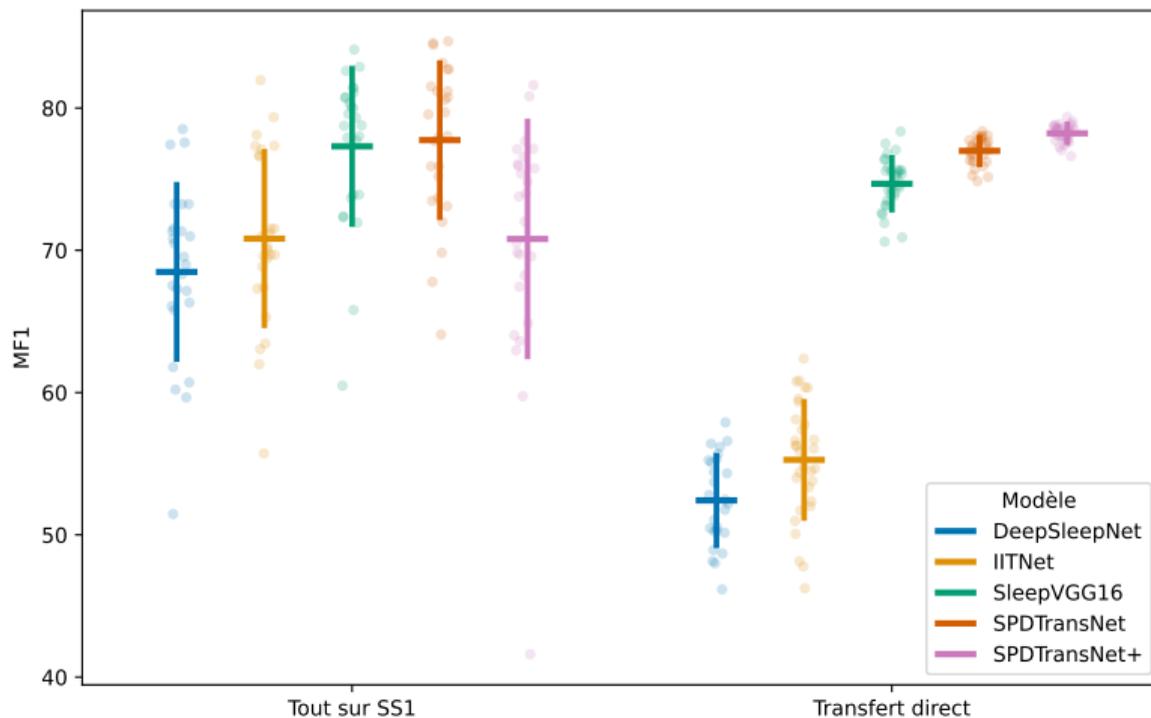
- Apprentissage sur SS3 (1 bloc), valid. croisée sur SS1



Comparaison à l'État de l'Art

Transfert direct

- **Valid. croisée sur SS3, test sur tout SS1**



En conclusion

SleepVGG16

- ▶ Modèle standard \Rightarrow **léger et rapide**
- ▶ Conserve de **bonnes performances**

\Rightarrow **Utilisation embarquée ?**

SPDTransNet / SPDTransNet+ :

- ▶ Un **nouveau paradigme** en **apprentissage sur matrices SDP**
 - ▶ En particulier : **Transformers riemanniens** sophistiqués
- ▶ **Analyse SDP du sommeil** \Rightarrow particulièrement **robuste**
 - ▶ Raisons potentielles :
 - \rightarrow **Connectivité fonctionnelle**
 - \rightarrow Notre **normalisation riemanienne** (*whitening*)

Optimisations

- ▶ Faire **varier** les **signaux d'entrée** utilisés
- ▶ **Estimation itérative** du **logarithme** matriciel [Fasi and Higham, 2018]
- ▶ **Apprentissage** des **bandes de fréquence** [Ravanelli and Bengio, 2018]
- ▶ **Classifieur riemannien** en fin de modèle

Explicabilité

- ▶ **SleepVGG16** → **motifs** pertinents
- ▶ **SPDTransNet/+** → **signaux** et **bandes** privilégiées

⇒ Permettrait de **mieux comprendre le sommeil** via notre modèle

Collecte de données supplémentaires

- ▶ **Partenariats** avec centres d'étude du sommeil
- ▶ **Alignement** des distributions de **différentes bases** [Rodrigues et al., 2021]

Merci de votre attention.

Avez-vous des questions ?

Ce travail a été cofinancé par la Région Normandie et l'Agence Nationale de la Recherche (ANR) au travers d'une bourse de thèse HAISCoDE. Il a bénéficié d'un accès aux moyens de calcul de l'IDRIS au travers de l'allocation de ressources 2022-AD010613618 attribuée par GENCI, et du mésocentre CRIANN (Centre Régional Informatique et d'Application Numériques de Normandie).

Annexes

1. Clarifications

- 1.1 Classification en *many-to-one*
- 1.2 Bases de données et blocs de validation croisée
- 1.3 Harmonisation des bases de test
- 1.4 Mesures de performance
- 1.5 Recherche d'hyperparamètres
- 1.6 Augmentation par la densité spectrale de puissance
- 1.7 Logarithme matriciel
- 1.8 Projection linéaire triangulaire
- 1.9 Sous-modèle de classification
- 1.10 Augmentation apprise

2. Modèle préliminaire - avant SPDTransNet

- 2.1 Modèle préliminaire - Architecture
- 2.2 Modèle préliminaire - Configuration

3. Tableaux supplémentaires

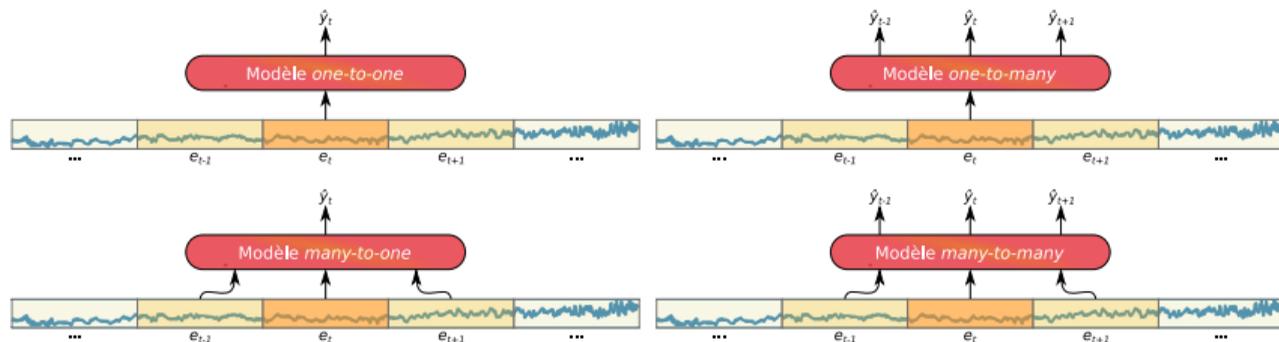
Annexes II

- 3.1 SleepVGG16 - Étude d'ablation
- 3.2 Modèle préliminaire - Étude d'ablation
- 3.3 SPDTransNet - Configurations d'enrichissement
- 3.4 SPDTransNet - Autres résultats
- 3.5 Apprentissage par transfert - Tableau
- 3.6 Transfert direct - Tableau

4. Analyse de données

- 4.1 Matrices moyennes par classe
- 4.2 Valeurs propres avant / après *whitening*

5. Bibliographie



État de l'Art : *many-to-many*

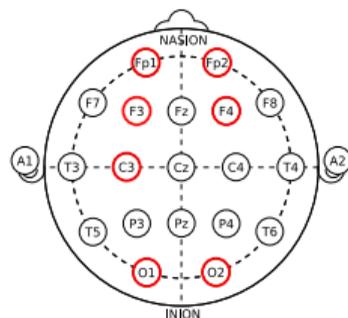
- ▶ Plus grande prise en compte du contexte
- ▶ **Plusieurs labels** par entrée → **pas de suréchantillonnage**

D'où notre choix de classification en *many-to-one*

Base	Âge moy.	# époques	% N3	% N2	% N1	% REM	% Éveil
SS1	63,6 \pm 5,3	51292	6,64	43,22	13,87	12,41	23,87
SS3	42,5 \pm 18,9	59317	12,90	50,24	8,16	17,84	10,86
DOD-H	35,32 \pm 7,51	24662	14,25	48,17	6,10	19,17	12,31

Blocs de **validation croisée**, et **division** entraînement / validation / test :

- ▶ **MASS SS1** (53 sujets) :
 - ▶ 25 blocs avec division 42 / 9 / 2
 - ▶ 1 bloc avec division 42 / 8 / 3
- ▶ **MASS SS3** (62 sujets) : 31 blocs, division : 50 / 10 / 2
- ▶ **Dreem DOD-H** (25 sujets) : 25 blocs, division : 20 / 4 / 1



Bases de test : partition de la base toute entière

Modèles en *many-to-one* : certaines **époques de bord non classifiées**

- ▶ Servent uniquement de **contexte**

Problème : **tailles de séquence différentes** entre modèles

- ▶ Donc **bases de test** légèrement **différentes**
- ▶ Résultats **pas strictement comparables**

Solution : harmonisation par **suppression des bords**

- ▶ **Uniquement** pour les bases de **test**
- ▶ Analyse initiale de SleepVGG16 non concernée

Problème de l'**exactitude** (*accuracy*) ici : **favorise classes majoritaires**

⇒ **Solution** : **moyenne des performances binaires par classe**

Exactitude binaire :

$$\text{acc} = \frac{VP + VN}{VP + FP + VN + FN} = \frac{\#correctes}{\#total}$$

Score F1 :

$$F_1 = \frac{2 \cdot VP}{2 \cdot VP + FP + FN} = \frac{\textit{precision} \times \textit{rappel}}{\textit{precision} + \textit{rappel}}$$

▶ **Précision** : valeur prédictive positive = $\frac{VP}{VP+FP} = \frac{TP}{PP}$

▶ **Rappel** : sensibilité = $\frac{VP}{VP+FN} = \frac{VP}{BC}$

→ **Score F1** : **insensible aux vrais négatifs**, souhaitable pour mesures mono-classe

Pour **chaque configuration** : valid. croisée précédée d'une **recherche d'hyperparamètres**

- ▶ Sur **un bloc** de valid. croisée **choisi au hasard**
- ▶ **Paramètres de rétropropagation** (taux d'apprentissage, etc.)
- ▶ **SPDTransNet / SPDTransNet+** :
 - ▶ **Augmentation** : statistique utilisée, facteur multiplicatif
 - ▶ **Architecture** : sorties des couches FC, nb. d'encodeurs, h, t

À noter : pas de recherche d'hyperparamètres pour **DeepSleepnet / IITNet**

- ▶ Choix des hyperparamètres non justifié par les auteurs
- ▶ Impossible de répliquer leur prise de décision

Augmentation manuelle : plusieurs statistiques testées sur segments de 1s

- ▶ Moyenne, amplitude maximale, densité spectrale de puissance (DSP)...
- ▶ Calculés **après z-score** (moyenne sur 1s généralement $\neq 0$)

Meilleurs résultats : DSP moyenne sur 1s

- ▶ Surprenant, car **DSP proportionnelle à la variance**
- ▶ $\text{DSP}(x) = \beta \text{var}(x) \Rightarrow \{\text{aug}(X, A)\}_{i,j} = \text{cov}(x_i, x_j) + \beta^2 \text{var}(x_i) \text{var}(x_j)$
- ▶ Hypothèse : introduction de **moments d'ordre supérieur**

Logarithme matriciel au voisinage de I_n :

$$\forall X \in SDP(n), \log_{I_n}(X) = U_X \cdot \text{diag}(\log(\Lambda_X)) \cdot U_X^T \in \text{Sym}(n)$$

Logarithme matriciel au voisinage de $P \in SDP(n)$:

$$\forall X \in SDP(n), \log_P(X) = P^{1/2} \cdot \log_{I_n}(P^{-1/2} \cdot X \cdot P^{-1/2}) \cdot P^{1/2}$$

De là, on définit :

$$\begin{aligned} \delta_{LE}^{(P)}(A, B) &= \|\log_P(A) - \log_P(B)\|_* \\ &= \|\log_{I_n}(P^{-1/2} \cdot A \cdot P^{-1/2}) - \log_{I_n}(P^{-1/2} \cdot B \cdot P^{-1/2})\|_*^{(P)} \end{aligned}$$

avec $\|X\|_*^{(P)} = \|P^{1/2} \cdot X \cdot P^{1/2}\|_*$.

Notons que : $\delta_{LE}^{(G)}(A, B) = \delta_{LE}^{(I_n)}(\text{whit}^{(G)}(A), \text{whit}^{(G)}(B))$.

Posons $\mathcal{L}_{m,p}(A) = B \Leftrightarrow \text{vect}(B) = W_{m,p} \cdot \text{vect}(A)$; $W_{m,p} \in \mathbb{R}^{\frac{p(p+1)}{2} \times \frac{m(m+1)}{2}}$

► Projection linéaire de $Sym(m)$ vers $Sym(p) \Leftrightarrow$ de $\mathbb{R}^{\frac{m(m+1)}{2}}$ vers $\mathbb{R}^{\frac{p(p+1)}{2}}$

Posons $\mathcal{L}_{m,p}^{\mathcal{R}}(\cdot) = \exp_{I_p} \circ \mathcal{L}_{m,p} \circ \log_{I_m}(\cdot)$: de $SDP(m)$ à $SDP(p)$

► Conserve **relations de proximité** :

$$\begin{aligned} \|\mathcal{L}_{m,p}(\log_{I_m}(X)) - \mathcal{L}_{m,p}(\log_{I_m}(Y))\|_2 &\leq \|W\|_{\bullet} \times \|\text{vect}_{\log}(X) - \text{vect}_{\log}(Y)\|_2 \\ \Leftrightarrow \delta_{LE}^{(I_p)}(\mathcal{L}_{m,p}^{\mathcal{R}}(X), \mathcal{L}_{m,p}^{\mathcal{R}}(Y)) &\leq \|W\|_{\bullet} \times \delta_{LE}^{(I_m)}(X, Y) \end{aligned}$$

Sous-modèle de classification :

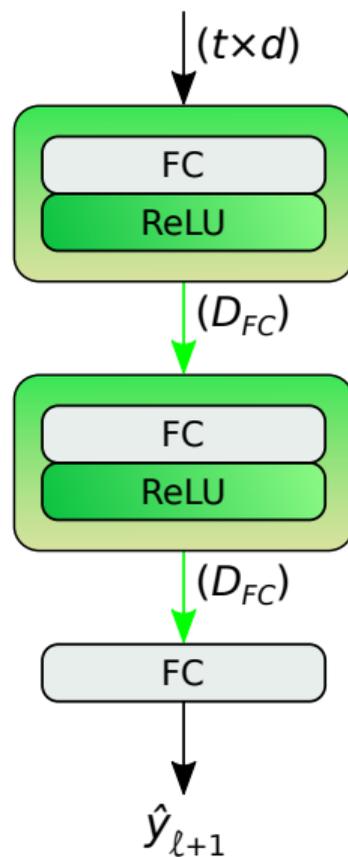
- ▶ Deux blocs FC, couche FC finale
- ▶ **Projections** des blocs FC **choisies triangulaires**
- ▶ **Couche FC finale** : sortie dans \mathbb{R}^5

Si $t = 1$ **vecteur descripteur** par époque :

- ▶ **Opérations SDP** jusqu'à la **dernière couche FC**

Si **plusieurs vecteurs descripteurs** par époque ($t > 1$) :

- ▶ **Opérations SDP** jusqu'à **l'entrée du sous-modèle**



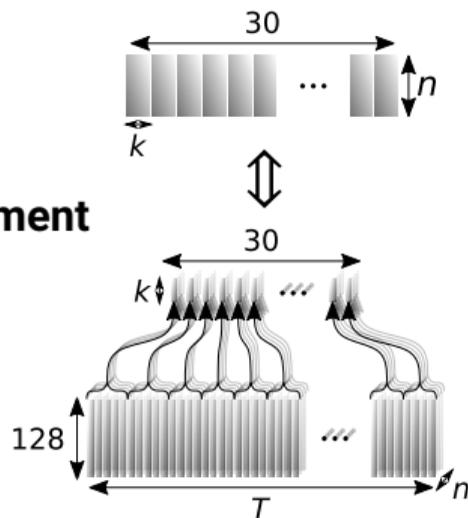
Modèle ResNet 1D utilisé [Seo et al., 2020] :

- ▶ **Sortie : série temporelle** de T vecteurs de taille 128
 - ▶ Dépend de la taille de l'entrée
 - ▶ $T = 120$ pour MASS SS1 / SS3 (120 Hz)
- ▶ **Champs réceptifs : segments** de l'époque **avec recouvrement**

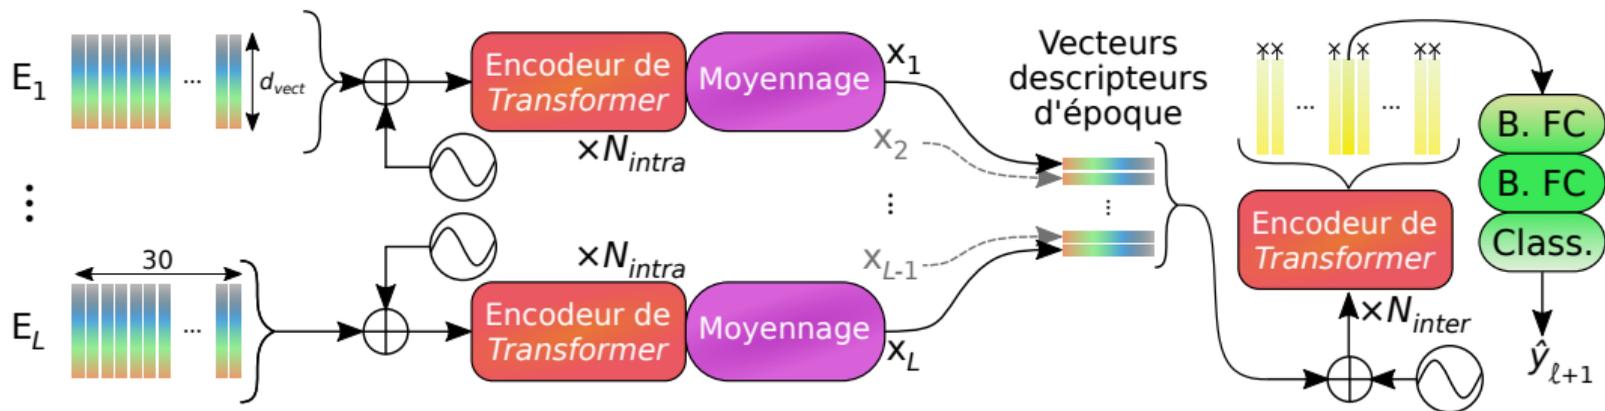
Nos modifications :

- ▶ Appliqué aux $n \times C$ signaux de chaque époque
 - ▶ **Poids séparés par canal**
 - ▶ **Poids partagés** pour les n signaux d'un canal
 - ▶ **Moyennage** des vecteurs de **sortie** : $T \times 128 \rightarrow 30 \times k$

⇒ Les **champs réceptifs contiennent le segment de 1s correspondant**



L'architecture utilisée :



▶ Entrée : $L = 21$ époques

▶ Transformers inchangés \Rightarrow **modèle non riemannien**

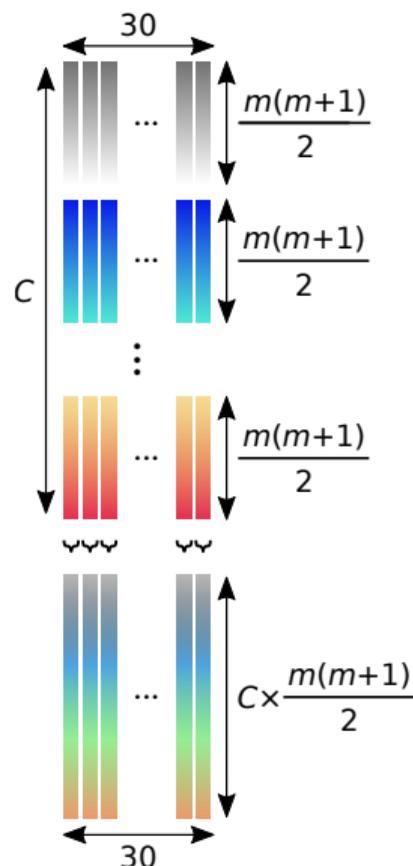
Matrices de **whitening** G : covariances du **signal entier**

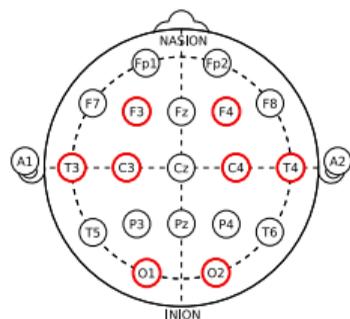
- ▶ $\text{Avg}_w(\cdot) = \text{Avg}_E(\cdot)$ (moyenne **euclidienne**)

Combinaison des canaux :

- ▶ **Concaténation des vecteurs** par canal
- ▶ $d_{vect} = C \times \frac{m(m+1)}{2} = 315$
 - ▶ **Assez grande** pour que les *Transformers* apprennent

⇒ **Pas d'interprétation SDP**





	MF1	Macro-exactitude	Kappa
8 signaux EEG	81,79 ± 2,95	82,96 ± 2,88	0,809 ± 0,038
Hémisphère gauche	79,82 ± 3,81	81,38 ± 3,58	0,788 ± 0,046
Hémisphère droit	80,71 ± 3,01	82,07 ± 3,25	0,798 ± 0,039
F4, C4, O2	81,49 ± 3,21	83,11 ± 3,37	0,802 ± 0,043
8 signaux, sans cov.	80,88 ± 2,94	81,81 ± 3,41	0,798 ± 0,039

	MF1	Macro-exactitude	Kappa
Modèle préliminaire	79,78 ± 4,56	81,76 ± 4,61	0,776 ± 0,069
Covariances nulles	77,39 ± 5,82	79,76 ± 4,95	0,741 ± 0,081
Sans augmentation	78,14 ± 4,10	80,56 ± 3,95	0,753 ± 0,060
SleepVGG16	81,23 ± 2,56	82,39 ± 2,57	0,803 ± 0,038

Augmentation	<i>Whitening</i>	Enrich.	MF1	F1 N1
DSP	Euclidien	Mixte	79,46 ± 3,06	57,40 ± 5,78
DSP	Riemannien	Mixte	81,24 ± 3,29	60,50 ± 6,18
DSP	Riemannien	Naïf	79,66 ± 3,68	56,47 ± 8,74
DSP	Riemannien	Inverse	80,97 ± 3,06	59,21 ± 7,06
Apprise ($k = 3$)	Riemannien	Inverse	81,64 ± 2,88	60,29 ± 5,52

	MF1	F1 N3	F1 N1
Référence (aug. par DSP)	81,24 \pm 3,29	78,81 \pm 11,17	60,50 \pm 6,18
Entrée de $L = 13$ époques	81,06 \pm 3,49	78,79 \pm 11,13	60,39 \pm 6,77
Entrée de $L = 29$ époques	80,45 \pm 3,87	77,70 \pm 11,83	59,57 \pm 5,86
Augmentation par zéros	80,58 \pm 3,86	78,45 \pm 11,52	59,09 \pm 7,28
MHA classique	80,82 \pm 3,40	76,96 \pm 12,79	60,16 \pm 7,20

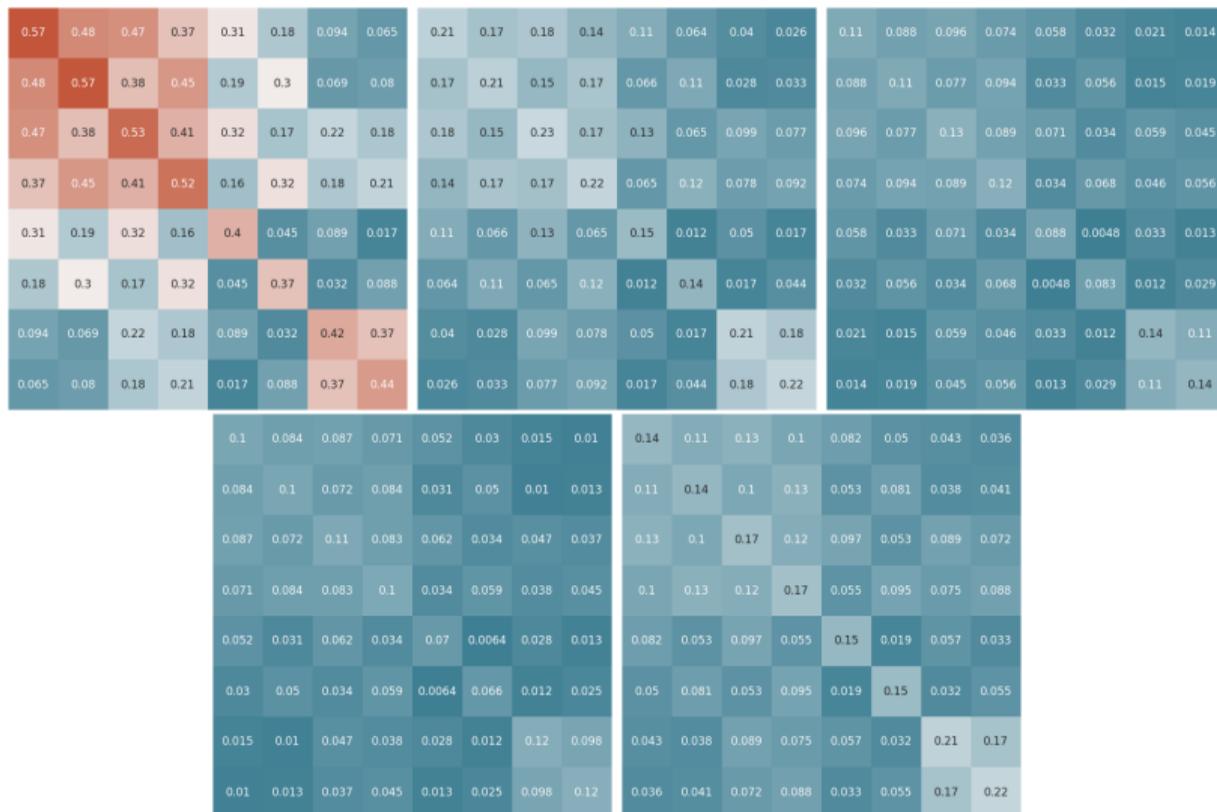
- **Apprentissage** sur **SS3** (1 bloc), **valid. croisée** sur **SS1**

Modèle	MF1	F1 N1
DeepSleepNet	67,65 ± 7,47	47,48 ± 7,03
IITNet	70,95 ± 5,85	53,85 ± 5,90
SleepVGG16	78,90 ± 4,61	64,15 ± 6,19
SPDTransNet	78,99 ± 4,45	64,60 ± 5,46
SPDTransNet+	79,41 ± 4,40	65,16 ± 6,24

- **Valid. croisée sur SS3, test sur tout SS1**

Modèle	MF1	F1 N1
DeepSleepNet	52,41 ± 3,15	32,11 ± 3,75
IITNet	55,27 ± 4,08	36,54 ± 4,42
SleepVGG16	74,68 ± 1,82	55,79 ± 2,36
SPDTransNet	76,99 ± 0,94	57,92 ± 1,85
SPDTransNet+	78,23 ± 0,62	59,68 ± 1,72

Matrices moyennes par classe



Matrices moyennes par classe (suite)

Matrices moyennes issues de **MASS SS3** (signal non filtré)

- ▶ Moyenne affine-invariante
- ▶ De gauche à droite, puis de bas en haut : N3, N2, N1, REM, Éveil

Fortes variances / covariances en **N3**

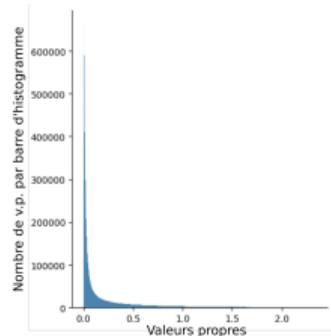
- ▶ Sommeil profond : ondes très lentes
 - ▶ Synchronisées sur l'ensemble de l'encéphale
 - ▶ Éveil / REM : moins synchronisés

Éveil : (co)variances relativement élevées en **régions occipitales**

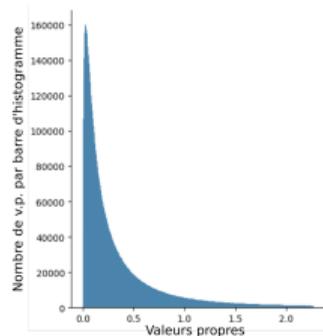
- ▶ Activité en bande alpha générée dans ces régions

Valeurs propres avant / après whitening

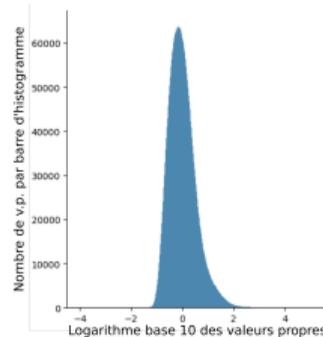
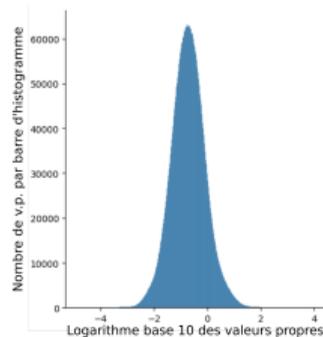
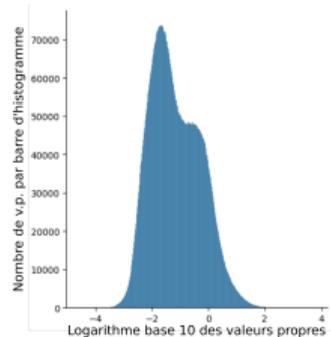
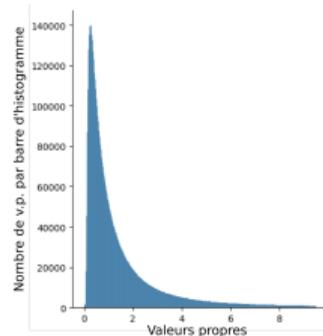
Sans whitening



Whitening euclidien



Whitening riemann.



-  Bouchard, M., Lina, J.-M., Gaudreault, P.-O., Dubé, J., Gosselin, N., and Carrier, J. (2019). EEG connectivity across sleep cycles and age. *Sleep*, 43(3).
-  Chakraborty, R., Yang, C.-H., Zhen, X., Banerjee, M., Archer, D., Vaillancourt, D., Singh, V., and Vemuri, B. (2018). A statistical recurrent model on the manifold of symmetric positive definite matrices. In Bengio, S., Wallach, H., Larochelle, H., Grauman, K., Cesa-Bianchi, N., and Garnett, R., editors, *Advances in Neural Information Processing Systems*, volume 31. Curran Associates, Inc.

-  Dequidt, P., Seraphim, M., Lechervy, A., Gaez, I. I., Brun, L., and Etard, O. (2023). Automatic sleep stage classification on eeg signals using time-frequency representation.
In Juarez, J. M., Marcos, M., Stiglic, G., and Tucker, A., editors, *Artificial Intelligence in Medicine*, pages 250–259, Cham. Springer Nature Switzerland.
-  Dutt, M., Redhu, S., Goodwin, M., and Omlin, C. W. (2023). Sleepxai: An explainable deep learning approach for multi-class sleep stage identification.
Applied Intelligence, 53(13):16830–16843.
-  Fasi, M. and Higham, N. J. (2018). Multiprecision algorithms for computing the matrix logarithm.
SIAM Journal on Matrix Analysis and Applications, 39(1):472–491.

-  Guillot, A., Sauvet, F., During, E. H., and Thorey, V. (2020).
Dreem open datasets: Multi-scored sleep datasets to compare human and automated sleep staging.
IEEE Transactions on Neural Systems and Rehabilitation Engineering, 28(9):1955–1965.
-  O'reilly, C., Gosselin, N., Carrier, J., and Nielsen, T. (2014).
Montreal archive of sleep studies: an open-access resource for instrument benchmarking and exploratory research.
Journal of sleep research, 23(6):628–635.
-  Pan, Y.-T., Chou, J.-L., and Wei, C.-S. (2022).
MAtt: A manifold attention network for EEG decoding.
In Oh, A. H., Agarwal, A., Belgrave, D., and Cho, K., editors, *Advances in Neural Information Processing Systems*.

-  Phan, H., Mikkelsen, K., Chén, O. Y., Koch, P., Mertins, A., and De Vos, M. (2022). Sleeptransformer: Automatic sleep staging with interpretability and uncertainty quantification.
IEEE Transactions on Biomedical Engineering, 69(8):2456–2467.
-  Qin, R., Song, Z., Ren, H., Pei, Z., Zhu, L., Shi, X., Guo, Y., Liu, H., Zhang, M., and Zhang, Z. (2024). Bnmtrans: A brain network sequence-driven manifold-based transformer for cognitive impairment detection using eeg.
In ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pages 2016–2020.
-  Ravanelli, M. and Bengio, Y. (2018). Speaker recognition from raw waveform with sincnet.
In 2018 IEEE Spoken Language Technology Workshop (SLT), pages 1021–1028.

-  Rodrigues, P. L. C., Congedo, M., and Jutten, C. (2021). Dimensionality transcending: A method for merging bci datasets with different dimensionalities.
IEEE Transactions on Biomedical Engineering, 68(2):673–684.
-  Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., et al. (2015). Imagenet large scale visual recognition challenge.
International journal of computer vision, 115(3):211–252.
-  Seo, H., Back, S., Lee, S., Park, D., Kim, T., and Lee, K. (2020). Intra- and inter-epoch temporal context network (iitnet) using sub-epoch features for automatic sleep scoring on raw single-channel eeg.
Biomedical Signal Processing and Control, 61:102037.

-  Seraphim, M., Dequidt, P., Lechervy, A., Yger, F., Brun, L., and Etard, O. (2023). Temporal sequences of eeg covariance matrices for automated sleep stage scoring with attention mechanisms. In Tsapatsoulis, N., Lanitis, A., Pattichis, M., Pattichis, C., Kyrkou, C., Kyriacou, E., Theodosiou, Z., and Panayides, A., editors, *Computer Analysis of Images and Patterns*, pages 67–76, Cham. Springer Nature Switzerland.
-  Seraphim, M., Lechervy, A., Yger, F., Brun, L., and Etard, O. (2024a). Automatic classification of sleep stages from eeg signals using riemannian metrics and transformer networks. *SN Computer Science*, 5(7):953.
-  Seraphim, M., Lechervy, A., Yger, F., Brun, L., and Etard, O. (2024b). Structure-preserving transformers for sequences of spd matrices. In *2024 32nd European Signal Processing Conference (EUSIPCO)*, pages 1451–1455.

-  Simonyan, K. and Zisserman, A. (2015).
Very deep convolutional networks for large-scale image recognition.
In International Conference on Learning Representations.
-  Supratak, A., Dong, H., Wu, C., and Guo, Y. (2017).
Deepsleepnet: a model for automatic sleep stage scoring based on raw single-channel eeg.
IEEE Transactions on Neural Systems and Rehabilitation Engineering, 25(11):1998–2008.
-  Troester, M., Quan, S., of Sleep Medicine, A. A., and Berry, R. (2023).
The AASM Manual for the Scoring of Sleep and Associated Events, Version 3.
American Academy Of Sleep Medicine.

-  Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. u., and Polosukhin, I. (2017).
Attention is all you need.
In Guyon, I., Luxburg, U. V., Bengio, S., Wallach, H., Fergus, R., Vishwanathan, S., and Garnett, R., editors, *Advances in Neural Information Processing Systems*, volume 30. Curran Associates, Inc.