




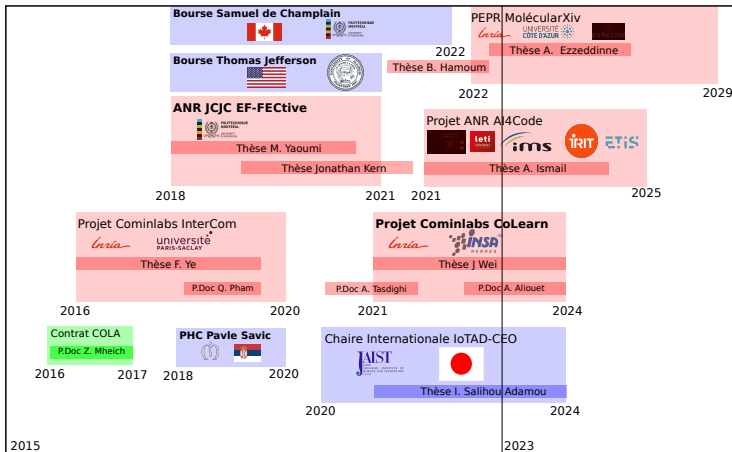
IMT Atlantique
Bretagne-Pays de la Loire
École Mines-Télécom

Habilitation à Diriger les Recherches Interactions entre Codage et Ap- prentissage

Elsa Dupraz

18 octobre 2023





Encadrement :

- ▶ 4 thèses soutenues, 4 thèses en cours
- ▶ 5 post-doc encadrés, dont 1 en cours

Publications :

- ▶ 19 articles en revue
- ▶ 44 articles en conférence internationale

Services

- ▶ Membre du “Digital Presence Online Committee” d’ITSoc

Organisation d'événements scientifiques :

- ▶ **Conférences** : ISTC 2016, 2021, 2023, ITW 2021
- ▶ **Journées GdR ISIS**
 - Codage canal efficace en énergie, Juin 2016
 - Stockage de données dans l’ADN, Juillet 2023
- ▶ **Sessions spéciales**
 - Codage canal efficace en énergie, ISTC 2021
 - Stockage de données dans l’ADN, DSP 2023

Reviews

- ▶ IEEE Trans. Comm., IEEE Comm. Letters, IEEE Trans. Inf. Theory, IEEE Trans. Wireless Comm., IEEE Wireless Comm. letters, IEEE Access, etc.
- ▶ ISIT, ITW, ISTC, ICC, Globecom, Eusipco, VTC, GRETSI, etc.
- ▶ ANR et EIC PathFinder

Responsable de la TAF MCE, depuis mai 2023

- ▶ 65 étudiants de 2A/3A, avec Lucas Drumetz, Carlos Granero Belinchon, Dominique Pastor

Responsabilité d'UE

- ▶ **UE Machine Learning**, TAF MCE, avec Lucas Drumetz, depuis 2021
- ▶ **UE Codage de sources**, TAF STAR, depuis 2018

Principaux cours

- ▶ Probabilités et Statistiques (1A)
- ▶ **Codage de sources** (2A/3A)
- ▶ **Machine Learning** (2A/3A)
- ▶ **Codage canal** (2A/3A)
- ▶ **Analyse numériques** (2A/3A)

1. Parcours
2. Introduction
3. Compression interactive
4. Apprentissage sur données codées
5. Fiabilité des systèmes d'apprentissage bruités
6. Conclusion

Différentes interactions possibles :

- ▶ Deep-Learning pour la conception de systèmes de codage source/canal



Différentes interactions possibles :

- Deep-Learning pour la conception de systèmes de codage source/canal



Différentes interactions possibles :

- ▶ Deep-Learning pour la conception de systèmes de codage source/canal



- ▶ Apprentissage sur données codées



Différentes interactions possibles :


- ▶ Deep-Learning pour la conception de systèmes de codage source/canal




- ▶ Apprentissage sur données codées




- ▶ Bruit du circuit dans les algorithmes d'apprentissage





Exemples d'applications : Codage d'images à 360°, implémentation sur circuit bruité, stockage de données dans l'ADN, etc.



Exemples d'applications : Codage d'images à 360°, implémentation sur circuit bruité, stockage de données dans l'ADN, etc.

Dans cette présentation :



1. Compression interactive (pour illustrer cette démarche)
2. Apprentissage sur données codées
3. Fiabilité des systèmes d'apprentissage bruités


3. Compression interactive

- 3.1 Analyse de théorie de l'information
- 3.2 Construction de schémas pratiques
- 3.3 Application aux images à 360°

Projet Cominlabs InterCom (2016-2020)



Collaboratrices/teurs : Aline Roumy, Thomas Maugey , Karine Amis , Michel

Kieffer 


Doctorant et Post-doctorantes : Fangping Ye, Zeina Mheich, Mai Quyen Pham

Section 3 : Compression interactive


10

Exemple d'application

Navigation dans des images à 360°




viewport




viewport

Navigation dans des images à 360°




viewport



navigation


Peut-on exploiter les blocs transmis précédemment à l'utilisateur pour **améliorer la compression** ?

Compression d'une source X sur un serveur :



- ▶ $Y_{(k)}$: **information adjacente** pour l'utilisateur k
- ▶ S : débit de **stockage** sur le serveur
- ▶ $R_{(k)}$: débit de **transmission** du serveur à l'utilisateur k

Compression d'une source X sur un serveur :



- ▶ $Y_{(k)}$: **information adjacente** pour l'utilisateur k
- ▶ S : débit de **stockage** sur le serveur
- ▶ $R_{(k)}$: débit de **transmission** du serveur à l'utilisateur k

Solutions pratiques usuelles :

- ▶ **Approche exhaustive** : Une version codée de X par $Y_{(k)}$ (**S élevé**) [4]
- ▶ **Approche pire cas** : Une seule version codée pour la pire $Y_{(k)}$ (**R élevé**) [17]

Codage sans pertes pour des sources i.i.d.

$$S \geq \max_k H(X|Y_{(k)}) \quad \text{bits/symbole}$$

$$R_{(k)} \geq H(X|Y_{(k)}) \quad \text{bits/symbole}$$

Extension à des sources **non-i.i.d.** et au cas **avec pertes** dans [PhyCom19]

Codage sans pertes pour des sources i.i.d.

$$S \geq \max_k H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{pire cas})$$

$$R_{(k)} \geq H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{exhaustif})$$

Extension à des sources **non-i.i.d.** et au cas **avec pertes** dans [PhyCom19]

Codage sans pertes pour des sources i.i.d.


$$S \geq \max_k H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{pire cas})$$

$$R_{(k)} \geq H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{exhaustif})$$

Extension à des sources **non-i.i.d.** et au cas **avec pertes** dans [PhyCom19]

Idées clé de la preuve

- **Binning** : 2^n séquences \mathbf{x}^n réparties aléatoirement dans 2^m bins



$\mathbf{y}_{(k)}^n$ permet de lever l'ambiguïté

Codage sans pertes pour des sources i.i.d.


$$S \geq \max_k H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{pire cas})$$

$$R_{(k)} \geq H(X|Y_{(k)}) \quad \text{bits/symbole} \quad (= \text{exhaustif})$$

Extension à des sources **non-i.i.d.** et au cas **avec pertes** dans [PhyCom19]


Idées clé de la preuve

- **Binning** : 2^n séquences \mathbf{x}^n réparties aléatoirement dans 2^m bins




$\mathbf{y}_{(k)}^n$ permet de lever l'ambiguïté

- **Codage incrémental** :



Cas d'une seule information adjacente Y :



Codage de sources avec des codes LDPC [14]


Matrice de parité H de dimension $m \times n$, $m < n$, $R = m/n$:

$$\mathbf{s}^m = \mathbf{x}^n H^T$$

Décodeur BP adapté au codage de sources

→ **Binning**

Cas d'une seule information adjacente Y :



Codage de sources avec des codes LDPC [14]

Matrice de parité H de dimension $m \times n$, $m < n$, $R = m/n$:

$$\mathbf{s}^m = \mathbf{x}^n H^T$$

Décodeur BP adapté au codage de sources

→ **Binning**

Cas de plusieurs informations adjacentes $Y_{(k)}$:

Codes LDPC compatibles en rendement, pour le codage de sources [TCOM19]


→ **Codage incrémental**

Section 3 : Compression interactive

Application aux images à 360°

14

Navigation dans des images à 360° :




Une solution typique : travailler sur le découpage en tuiles [5]

Section 3 : Compression interactive

Application aux images à 360°


14

Navigation dans des images à 360° :

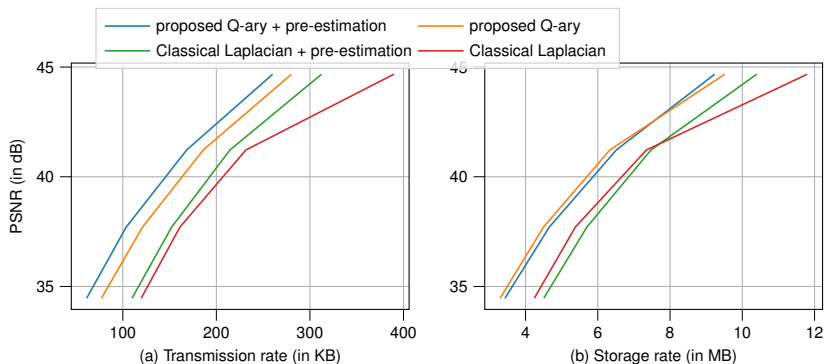


Une solution typique : travailler sur le découpage en tuiles [5]

Schéma de codage proposé [ComLet21] : collaboration avec INRIA Rennes



Résultats [ComLet21] : Codes LDPC binaires, modèle q -aire pour $(X, Y_{(k)})$



Autres contributions : Traitement d'un grand nombre de sources par l'intermédiaire d'un graphe de navigation [SIPN20], [TCOM20]

Section 4 : Apprentissage sur données codées 16

Plan de la présentation

4. Apprentissage sur données codées

- 4.1 Introduction
- 4.2 Régression
- 4.3 Perspectives

Projet Cominlabs CoLearn (2021-2024), Chaire Internationale IoTAD-CEO (2020-2024)



Collaborateurs : Philippe Mary  , Tadashi Matsumoto 



Doctorants et Post-doctorants : Ismaila Salihou Adamou, Jiahui Wei, Ahcen Aliouet, Alireza Tasdighi

Section 4 : Apprentissage sur données codées 17

Contexte


- ▶ Chaque minute :
 - 500 heures de vidéo envoyées sur YouTube
 - 240,000 images envoyées sur Facebook
- ▶ Enorme masse de données à transmettre, stocker, [traiter](#)
- ▶ **Besoin d'apprentissage sur données codées**

Section 4 : Apprentissage sur données codées 17

Contexte

- ▶ Chaque minute :
 - 500 heures de vidéo envoyées sur YouTube
 - 240,000 images envoyées sur Facebook
- ▶ Enorme masse de données à transmettre, stocker, [traiter](#)
- ▶ **Besoin d'apprentissage sur données codées**

- ▶ **Approche conventionnelle** : décoder avant d'apprendre, peu efficace !




- ▶ Une **solution triviale** : apprentissage à l'encodeur ?
- ▶ Si pas possible, [apprentissage dans le domaine compressé](#)

Section 4 : Apprentissage sur données codées 18

Objectifs

- Solution : apprentissage **et** reconstruction à partir de données codées (task-aware compression/goal-oriented communications)




Comment considérer un **objectif d'apprentissage** dans le formalisme théorie de l'information ?

Section 4 : Apprentissage sur données codées 18

Objectifs

- Solution : apprentissage **et** reconstruction à partir de données codées (task-aware compression/goal-oriented communications)



Comment considérer un **objectif d'apprentissage** dans le formalisme théorie de l'information ?

Questions fondamentales :

- Faut-il séparer le codage source/canal ?
- Est-ce qu'il existe un **compromis** entre reconstruction et apprentissage ?

$$\min D + \lambda L \text{ tel que } R \leq r$$

Section 4 : Apprentissage sur données codées 19

Théorie de l'information pour l'apprentissage

Problèmes d'apprentissage étudiés avec la théorie de l'information :

- ▶ Test d'hypothèses distribué [1], [12], [18], **[ISTC23]**
- ▶ Estimation distribuée de paramètres [6]
- ▶ Identification dans une base de données [21]
- ▶ Compromis reconstruction/perception visuelle [3]

Evaluation de performance :

- ▶ Critère spécifique à la tâche d'apprentissage
- ▶ Deux contraintes de distortion [19]
- ▶ Erreur de généralisation [16]

Tous les travaux existants montrent qu'il y a un **compromis reconstruction/apprentissage**


Section 4 : Apprentissage sur données codées 20

Analyse de théorie de l'information du problème de régression


Modèle de source pour la régression

$$X = f(Y) + \epsilon = \sum_{k=1}^K \alpha_k h_k(Y) + \epsilon$$

Entraînement :



Inférence :




Section 4 : Apprentissage sur données codées 20

Analyse de théorie de l'information du problème de régression


Modèle de source pour la régression

$$X = f(Y) + \epsilon = \sum_{k=1}^K \alpha_k h_k(Y) + \epsilon$$

Entraînement :



Inférence :



Evaluation de performance :

(Loss minimum) $L^* = \inf_f E \left[(X - f(Y))^2 \right]$

(Erreur de généralisation) $G^{(i)}(\hat{f}) = E_{\mathbf{X}, \mathbf{Y}} \left[E \left[(\tilde{X} - \hat{f}(\tilde{Y}))^2 \mid \mathbf{X}, \mathbf{Y} \right]^i \right]$

Section 4 : Apprentissage sur données codées 21

Région débit-erreur de généralisation

Régime asymptotique

- ▶ Borne existante pour un R donné [16] :

$$(L^*)^{1/2} \leq \limsup_{n \rightarrow \infty} G^{(1/2)}(\hat{f}) \leq (L^*)^{1/2} + 2\mathbb{D}_{X|Y}(R)^{1/2}$$

Résultat asymptotique [EUSIPCO23], [IZS2023sub]

Nous avons proposé un schéma qui permet d'atteindre le minimum pour tout $R > 0$:

$$\limsup_{n \rightarrow \infty} G^{(1)}(\hat{f}) = L^*$$

Section 4 : Apprentissage sur données codées 21

Région débit-erreur de généralisation

Régime asymptotique

- ▶ Borne existante pour un R donné [16] :

$$(L^*)^{1/2} \leq \limsup_{n \rightarrow \infty} G^{(1/2)}(\hat{f}) \leq (L^*)^{1/2} + 2\mathbb{D}_{X|Y}(R)^{1/2}$$

Résultat asymptotique [EUSIPCO23], [IZS2023sub]

Nous avons proposé un schéma qui permet d'atteindre le minimum pour tout $R > 0$:

$$\limsup_{n \rightarrow \infty} G^{(1)}(\hat{f}) = L^*$$

Preuve :

- ▶ Schéma d'atteignabilité basé sur **quantification** et **binning** !
- ▶ Expression de l'erreur de généralisation pour un \hat{f} particulier


Section 4 : Apprentissage sur données codées 22

Région débit-erreur de généralisation à longueur finie

Probabilité d'excès : $\epsilon = \mathbb{P}(G^{(1)}) \geq g)$

Région débit-GE à longueur finie [IZS2023sub] :

$$R(n, \epsilon, g) \leq \inf \left\{ \mathbf{M} \left(\mathbb{E}[\mathbf{i}] + \frac{\mathcal{S}(\mathbb{C}[\mathbf{i}], \epsilon)}{\sqrt{n}} + \frac{2 \log n}{n} \mathbf{I}_3 \right) \right\}$$



Section 4 : Apprentissage sur données codées 23


Conclusion

Conclusion sur la régression

- ▶ Résultats similaires pour la régression non-paramétrique
- ▶ On montre qu'il n'y a **pas de compromis reconstruction/régression**
- ▶ Problème à longueur finie... voire courte

Autres travaux

- ▶ Test d'hypothèses distribué pour des sources non-i.i.d. [IZS2023sub]



- ▶ Clustering sur données compressées [DCC18], [Access23]

Section 4 : Apprentissage sur données codées 24

Perspectives

Perspectives

- ▶ Aborder des problèmes d'apprentissage **plus complexes** : classification, apprentissage non-supervisé, etc.
- ▶ Construire des **schémas de codage pratiques** en utilisant des codes LDPC
- ▶ Comment se comparent les approches utilisant des **codes structurés** par rapport à des méthodes Deep Learning ?

- ▶ Apprentissage dans le domaine **compressé** ?

5. Fiabilité des systèmes d'apprentissage bruités

5.1 Introduction

5.2 Calcul en mémoire : étude de l'effet du bruit

5.3 Calcul en mémoire : optimisation de la puissance

5.4 Conclusion et perspectives

Projet ANR JCJC EF-FECTive (2018-2021), Bourse Samuel de Champlain (2020-2023), Bourse Thomas Jefferson (2018 - 2021)



Québec



Collaborateurs : François Leduc-Primeau, Jérémy Nadal



Lav Varshney



, Frédéric Guilloud





Doctorants : Jonathan Kern, Mohamed Yaoumi

Section 5 : Fiabilité des systèmes d'apprentissage bruités 26

Contexte

La consommation d'énergie des circuits peut-être réduite par une **réduction des tensions d'alimentation**

Problème : introduction **d'erreurs** dans les opérations de calcul





$$p_{\text{xor}} = P(\tilde{c} \neq a \oplus b)$$

Section 5 : Fiabilité des systèmes d'apprentissage bruités 26

Contexte

La consommation d'énergie des circuits peut-être réduite par une **réduction des tensions d'alimentation**

Problème : introduction **d'erreurs** dans les opérations de calcul




$$p_{\text{xor}} = P(\tilde{c} \neq a \oplus b)$$

Problèmes d'intérêt :

1. Effet du bruit dans les opérations de calcul
2. Mécanismes de correction du bruit
3. **Étude du compromis fiabilité-énergie**

État de l'art sur l'effet du bruit :


- ▶ Encodeurs LDPC bruités [8], **[ICC16]**,
- ▶ Décodeurs LDPC bruités [22], [2], [9], **[TCOM15]**, **[TCOM21]**



- ▶ Circuits logiques bruités [7], [15], [24]
- ▶ Test d'hypothèses, estimation, régression logistique [23]
- ▶ Estimation binaire récursive **[ISIT19]**, filtres de Kalman **[ICASSP21]**
- ▶ Réseaux de neurones [10]

État de l'art sur l'effet du bruit :

- ▶ Encodeurs LDPC bruités [8], **[ICC16]**,
- ▶ Décodeurs LDPC bruités [22], [2], [9], **[TCOM15]**, **[TCOM21]**



- ▶ Circuits logiques bruités [7], [15], [24]
- ▶ Test d'hypothèses, estimation, régression logistique [23]
- ▶ Estimation binaire récursive **[ISIT19]**, filtres de Kalman **[ICASSP21]**
- ▶ Réseaux de neurones [10]


Difficulté : Relier la consommation d'énergie au niveau de bruit dans les circuits
Plus facile pour les **mémoires**...

Section 5 : Fiabilité des systèmes d'apprentissage bruités


28

Calcul en mémoire

- ▶ Transfert de données dans les architectures de von Neumann :



- ▶ Calcul en mémoire :





- ▶ Mémoires résistives/memristors [20] :

The diagram shows a schematic of a memristor, which is a resistor whose resistance changes based on the amount of charge that has passed through it. The schematic consists of a zigzag line representing a resistor, with a black vertical bar on the right side. To the right of the schematic is the equation $M(q) = \frac{d\Phi}{dq}$, where $M(q)$ is the memristance, Φ is the magnetic flux, and q is the charge.

Section 5 : Fiabilité des systèmes d'apprentissage bruités 29

Multiplication matricielle en mémoire

Crossbar de memristors [13] :



Notation :

- ▶ x_i : Tensions d'entrée
- ▶ z_j : Tensions de sortie
- ▶ g_{ij} : Valeurs de conductance

$$z_j = r \sum_{i=1}^L g_{ij} x_i$$


Calcul en mémoire :

- ▶ Bruit dans les valeurs de conductance
- ▶ $\mathbb{E}[G_{i,j}] = g_{i,j}, \mathbb{V}[G_{i,j}] = \sigma^2$

Section 5 : Fiabilité des systèmes d'apprentissage bruités 30

Architecture de réseaux de neurones

Structure d'un réseau de neurones :



Opérations de calcul [11] :

$$\mathbf{z}^{(t)} = \mathcal{W}^{(t)} \mathbf{x}^{(t)} \quad (\text{Crossbar de memristors}) \rightarrow \text{Bruité}$$

$$x_k^{(t+1)} = f(z_k^{(t)}) \quad (\text{CMOS}) \rightarrow \text{Non-bruité}$$


Section 5 : Fiabilité des systèmes d'apprentissage bruités 31

Etude de l'effet du bruit

Evaluation de l'effet du bruit :

$$\text{MSE}_t = E \left[\|\mathbf{X}^{(t)} - \mathbf{x}^{(t)}\|^2 \right] = \sum_{j=1}^N \mathbb{V}(X_j^{(t)}) + (E[X_j^{(t)}] - x_j^{(t)})^2$$

Méthode de propagation des moments [ISIT20], [ITW21], [TSP23sub]




Approche :

- ▶ Calcul exact pour les couches linéaires
- ▶ Développement de Taylor à l'ordre 2 pour les couches non-linéaires

Section 5 : Fiabilité des systèmes d'apprentissage bruités 32

Précision de l'estimation MSE


- **NN Synthétique avec 7 couches**, nombre de neurones par couche : (100, 100, 200, 150, 120, 80, 10), avec poids aléatoires, fonction sigmoïde



- L'analyse théorique **prédit correctement** le MSE mesuré par simulations

Section 5 : Fiabilité des systèmes d'apprentissage bruités 33

Expression de la puissance moyenne



- ▶ Puissance consommée par un memristor :

$$P_{i,j} = \tilde{G}_{i,j}(X_i - Z_j)^2$$

- ▶ On s'intéresse à la puissance moyenne $\mathbb{E}[P_{i,j}]$

Pour l'optimisation de la puissance, on considère

- ▶ $\mathbb{E}[\tilde{G}_{i',j}] = c_j g_{i',j}$
- ▶ $\mathbb{V}[\tilde{G}_{i',j}] = \sigma^2$


Problème d'optimisation pour une couche donnée [ITW21] :

$$\min_{c_j} \sum_{i,j} \left(\mathbb{E}[P_{i,j}^{(+)}] + \mathbb{E}[P_{i,j}^{(-)}] \right) \quad \text{tel que} \quad \tilde{\rho}_j^2 \leq \bar{\rho}, \quad c_j \geq 0$$

Section 5 : Fiabilité des systèmes d'apprentissage bruités 34

Optimisation de la puissance

- Bases de données **IRIS** (NN avec 2 couches) et **MNIST** (NN avec 3 couches), $\sigma = 10^{-2}$



- Notre méthode d'optimisation **réduit fortement** la puissance de l'architecture.

Conclusion

- ▶ L'analyse théorique **prédit correctement** le MSE après chaque couche
- ▶ La méthode d'optimisation **réduit fortement la puissance** de l'architecture

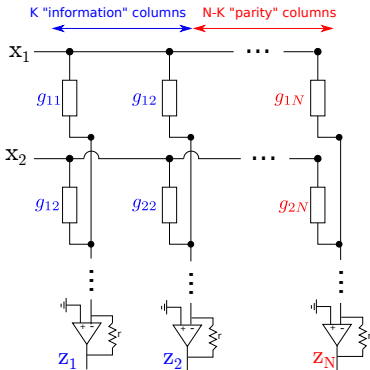
Perspectives

- ▶ Considérer d'autres **applications** : entraînement RN, logique en mémoire, etc.
- ▶ Travailler sur le **critère d'évaluation** de la performance
- ▶ Prendre en compte la totalité du système : ADC/DAC, écriture, etc.

Section 5 : Fiabilité des systèmes d'apprentissage bruités

36

- ▶ Codes correcteurs d'erreurs pour le calcul en mémoire :



- ▶ Est-ce que cela permet de réduire la consommation d'énergie des circuits ?

1. Parcours

2. Introduction

3. Compression interactive

- 3.1 Analyse de théorie de l'information
- 3.2 Construction de schémas pratiques
- 3.3 Application aux images à 360°

4. Apprentissage sur données codées

- 4.1 Introduction
- 4.2 Régression
- 4.3 Perspectives

5. Fiabilité des systèmes d'apprentissage bruités

- 5.1 Introduction
- 5.2 Calcul en mémoire : étude de l'effet du bruit
- 5.3 Calcul en mémoire : optimisation de la puissance
- 5.4 Conclusion et perspectives

6. Conclusion

De nombreux sujets autour de la théorie de l'information et du codage source/canal

Travaux en cours/perspectives

- ▶ **Calcul en mémoire**
- ▶ **Apprentissage sur données codées**, projet Cominlabs CoLearn (2021-2024)
- ▶ **Deep Learning pour la conception de codes et décodeurs LDPC**, Projet ANR AI4CODE (2021-2025)
- ▶ **Stockage de données dans des molécules d'ADN**, PEPR MoléculaireXiv (2022-2029)

Merci !

Publications citées dans la présentation :

- [ISTC23] I. Salihou Adamou, **E. Dupraz**, Z. Amin, T. Matsumoto, Error-exponent of distributed hypothesis testing for Gilbert-Elliot source models, ISTC 2023
- [Eusipco23] J. Wei, **E. Dupraz**, Philippe Mary, Asymptotic and non-asymptotic rate-loss bounds for linear regression with side information, EUSIPCO 2023
- [Access23] A. Tasdighi, **E. Dupraz**, An end-to-end scheme for learning over compressed data transmitted through a noisy channel, in IEEE Access, vol. 11, pp. 8254 – 8267, January 2023
- [TCOM21] **E. Dupraz**, F. Leduc-Primeau, Noisy density evolution with asymmetric deviation models, in IEEE Transactions on Communications, vol. 69, no. 3, pp. 1403-1416, March 2021
- [ComLet21] F. Ye, N. Mahmoudian Bidgoli, **E. Dupraz**, A. Roumy, K. Amis, T. Maugey, Bit-plane coding in extractable source coding : optimality, modeling, and application to 360° data, in IEEE Communication Letters, vol. 25, no. 5, pp. 1412-1416, May 2021
- [ICASSP21] J. Kern, **E. Dupraz**, A. Aïssa-El-Bey, F. Leduc-Primeau, Improving the energy-efficiency of a Kalman filter using unreliable memories, ICASSP 2021
- [ITW21] **E. Dupraz**, L.R. Varshney, and F. Leduc-Primeau, Power-efficient deep neural networks with noisy memristor implementation, ITW 2021
- [TCOM20] M.Q. Pham, A. Roumy, T. Maugey, **E. Dupraz**, M. Kieffer, Optimal reference selection for random access in predictive coding schemes, in IEEE Transactions on Communications, vol. 68, no. 9, pp. 5819-5833, Sept. 2020
- [ISIT20] **E. Dupraz**, L.R. Varshney, Noisy in-memory recursive computation with memristor crossbars, ISIT 2020
- [SIPN20] T. Maugey, A. Roumy, **E. Dupraz**, M. Kieffer, Incremental coding for extractable compression in the context of Massive Random Access, in IEEE Transactions on Signal and Information Processing over Networks, vol. 6, no. 1, pp. 251-260, March 2020
- [ISIT19] **E. Dupraz**, L.R. Varshney, Binary recursive estimation on noisy hardware, ISIT 2019
- [PhyCom19] **E. Dupraz**, T. Maugey, A. Roumy, M. Kieffer, Rate-storage regions for extractable source coding with side information, in Elsevier Physical Communication, December 2019
- [TCOM19] F. Ye, **E. Dupraz**, Z. Mheich, K. Amis, Optimized rate-adaptive protograph-based LDPC codes for source coding with side information, in IEEE Transactions on Communications, vol. 67, no. 6, pp. 3879-3889, June 2019
- [DCC18] **E. Dupraz**, K-means algorithm over compressed binary data, DCC 2018
- [ICC16] **E. Dupraz**, V. Savin, S. Kumar Grandhi, E. Popovici, D. Declercq, Practical LDPC encoders robust to hardware noise, ICC 2016
- [TCOM15] **E. Dupraz**, D. Declercq, B. Vasic, V. Savin, Analysis and design of finite alphabet iterative decoders robust to faulty hardware, IEEE Transactions on Communications, vol.63, no 8, pp.2797 – 2809, August 2015



Rudolf Ahlswede and Imre Csiszár.

Hypothesis testing with communication constraints.

IEEE transactions on information theory, 32(4) :533–542, 1986.



Alexios Balatsoukas-Stimming and Andreas Burg.

Density evolution for min-sum decoding of ldpc codes under unreliable message storage.

IEEE Communications Letters, 18(5) :849–852, 2014.



Yochai Blau and Tomer Michaeli.

The perception-distortion tradeoff.

In *IEEE Conference on Computer Vision and Pattern Recognition*, pages 6228–6237, 2018.



Gene Cheung, Antonio Ortega, and Ngai-Man Cheung.

Interactive streaming of stored multiview video using redundant frame structures.

IEEE Transactions on Image Processing, 20(3) :744–761, 2010.



Xavier Corbillon, Gwendal Simon, Alisa Devlic, and Jacob Chakareski.

Viewport-adaptive navigable 360-degree video delivery.
In IEEE International Conference on Communications (ICC), pages 1–7. IEEE, 2017.

 Mostafa El Gamal and Lifeng Lai.


Are slepian-wolf rates necessary for distributed parameter estimation ?

In Annual Allerton Conference on Communication, Control, and Computing (Allerton), pages 1249–1255. IEEE, 2015.

 Péter Gács and Anna Gál.

Lower bounds for the complexity of reliable boolean circuits with noisy gates.

IEEE Transactions on Information Theory, 40(2) :579–583, 1994.

 Jad Hachem, I-Hsiang Wang, Christina Fragouli, and Suhas Diggavi.

Coding with encoding uncertainty.

In IEEE International Symposium on Information Theory (ISIT), pages 276–280. IEEE, 2013.

 Chu-Hsiang Huang, Yao Li, and Lara Dolecek.

Gallager b ldpc decoder with transient and permanent errors.
IEEE Transactions on Communications, 62(1) :15–28, 2013.



Kunping Huang, Paul H Siegel, and Anxiao Jiang.

Functional error correction for robust neural networks.

IEEE Journal on Selected Areas in Inf. Th., 1(1) :267–276, 2020.



Vinay Joshi, Manuel Le Gallo, Simon Haefeli, Irem Boybat, Sasidharan Rajalekshmi Nandakumar, Christophe Piveteau, Martino Dazzi, Bipin Rajendran, Abu Sebastian, and Evangelos Eleftheriou.

Accurate deep neural network inference using computational phase-change memory.

Nature Communications, 11(1) :2473, 2020.



Gil Katz, Pablo Piantanida, and Mérouane Debbah.

Distributed binary detection with lossy data compression.

IEEE Transactions on Information Theory, 63(8) :5207–5227, 2017.



Sijia Liu, Yanzhi Wang, Makan Fardad, and Pramod K Varshney.

A memristor-based optimization framework for artificial intelligence applications.

IEEE Circuits and Systems Magazine, 18(1) :29–44, 2018.



Angelos D Liveris, Zixiang Xiong, and Costas N Georghiades.
Compression of binary sources with side information at the decoder using ldpc codes.

IEEE Communications Letters, 6(10) :440–442, 2002.



Nicholas Pippenger, George D Stamoulis, and John N Tsitsiklis.
On a lower bound for the redundancy of reliable networks with noisy gates.

IEEE Transactions on Information Theory, 37(3) :639–643, 1991.



Maxim Raginsky.

Learning from compressed observations.

In *IEEE Information Theory Workshop*, pages 420–425. IEEE, 2007.




Shinya Shimizu, Masaki Kitahara, Hideaki Kimata, Kazuto Kamikura, and Yoshiyuki Yashima.

View scalable multiview video coding using 3-d warping with depth map.

IEEE Transactions on Circuits and Systems for Video Technology, 17(11) :1485–1495, 2007.

 Sreejith Sreekumar and Deniz Gündüz.

Distributed hypothesis testing over discrete memoryless channels.
IEEE Transactions on Information Theory, 66(4) :2044–2066, 2019.

 Photios A Stavrou and Marios Kountouris.

A rate distortion approach to goal-oriented communication.
In *IEEE International Symposium on Information Theory (ISIT)*, pages 590–595. IEEE, 2022.

 Dmitri B Strukov, Gregory S Snider, Duncan R Stewart, and R Stanley Williams.

The missing memristor found.
Nature, 453(7191) :80–83, 2008.

 Ertem Tuncel and Deniz Gündüz.

Identification and lossy reconstruction in noisy databases.
IEEE Transactions on Information Theory, 60(2) :822–831, 2013.

 Lav R Varshney.

Performance of ldpc codes under faulty iterative decoding.

IEEE Transactions on Information Theory, 57(7) :4427–4444, 2011.



Yaoqing Yang, Pulkrit Grover, and Soumya Kar.

Fault-tolerant distributed logistic regression using unreliable components.

In *Allerton Conference on Communication, Control, and Computing (Allerton)*, pages 940–947. IEEE, 2016.



Yaoqing Yang, Pulkrit Grover, and Soumya Kar.

Computing linear transformations with unreliable components.

IEEE Transactions on Information Theory, 63(6) :3729–3756, 2017.