

Stéganographie par Deep Learning

Marc CHAUMONT^{1,2}
LIRMM¹, Univ Nîmes², Montpellier, France

March 8, 2020

Présentation de laboratoire. LIRMM le 9 mars 2020.


Outline

Introduction

Passons à la stéganographie / stéganalyse moderne

La stéganographie par deep-learning

La stéganographie (une histoire ancienne)



” 499 avant J-C. **Histiée** sélectionne son plus fidèle esclave, **lui fait raser la tête et tatouer un ordre de révolte** sur le crâne; Dès que les cheveux eurent repoussé, **il l’envoie à Aristagoras** qui lui rase de nouveau la tête afin de lire le message. ” Wikipedia.

Une toute petite communauté de chercheurs

Stéganographie moderne (utilisation de codes) depuis début 2000.

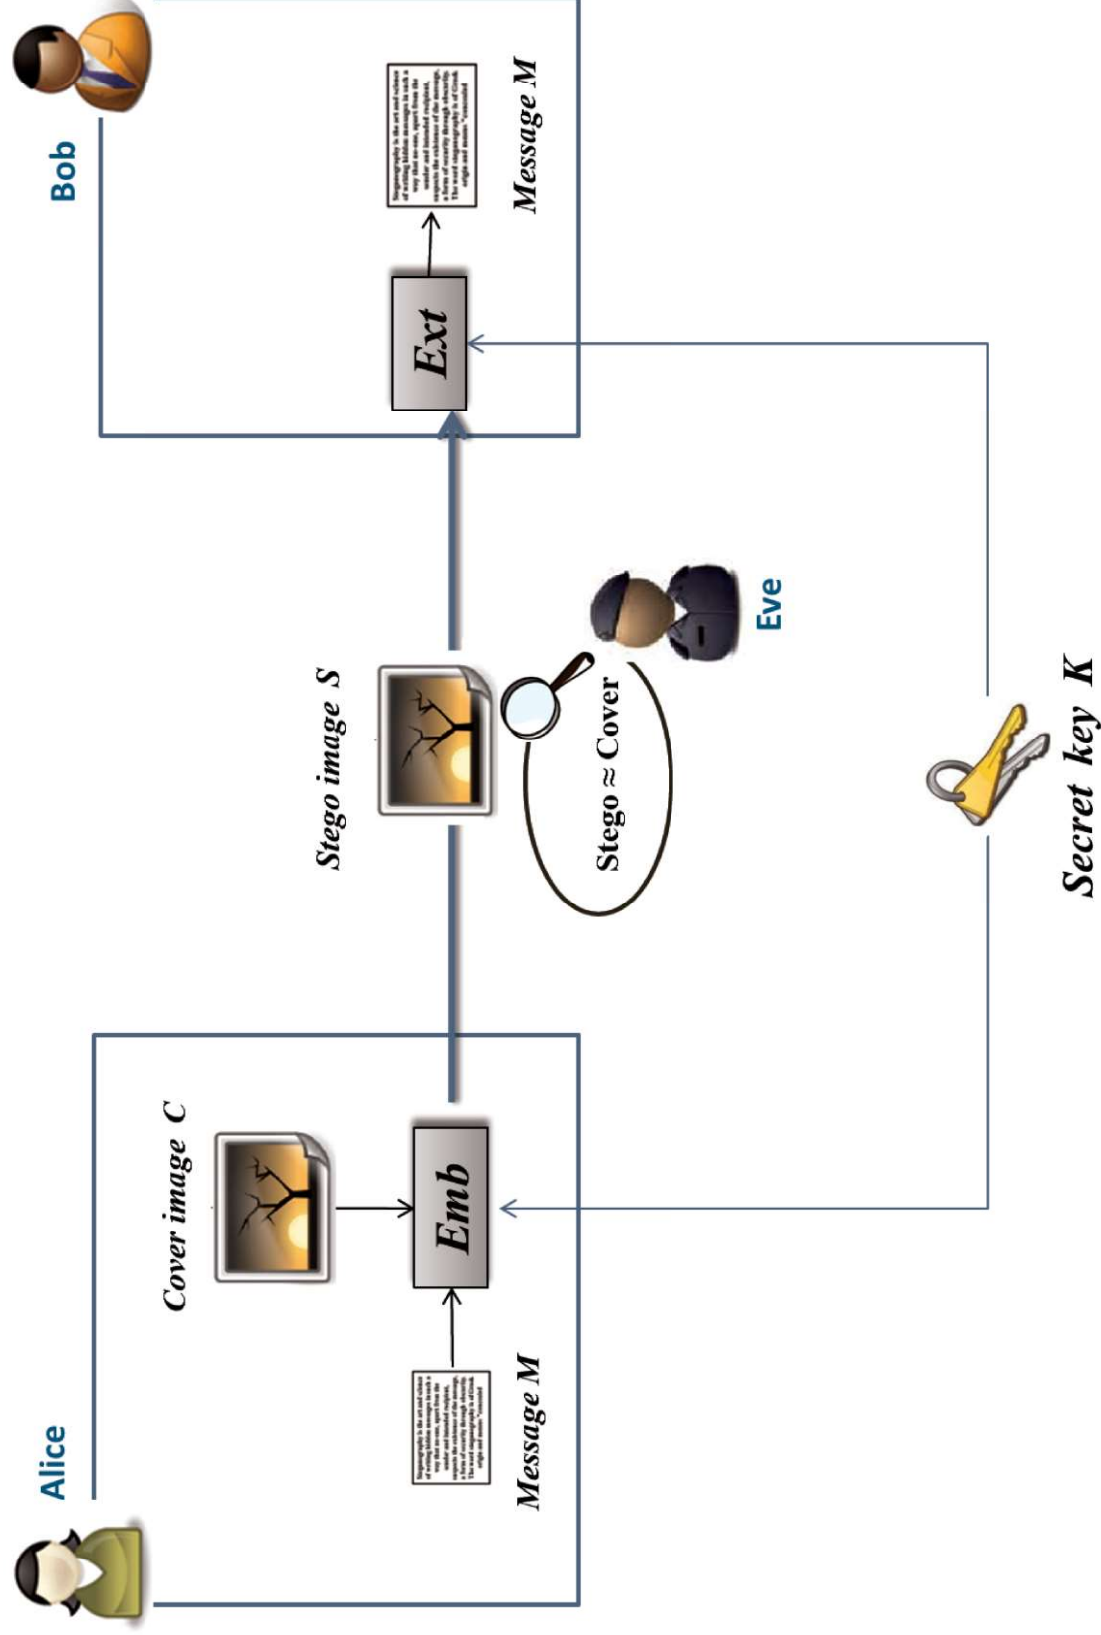
- ▶ Petit groupe au LIRMM.
- ▶ Quatre spécialistes en France.
- ▶ Une vingtaine d'équipes dans le monde.

Adossé à la société savante

IEEE Signal Processing Information Forensics & Security

<https://signalprocessingsociety.org/get-involved/information-forensics-and-security>

Stéganographie / Stéganalyse



Un exemple simpliste d'insertion (1)

EXEMPLE : INSERTION LSB

- Prenons l'exemple d'une image en niveau de gris valeur ou les valeurs des pixels appartiennent à $\{0, \dots, 255\}$:



Un exemple simpliste d'insertion (2)

EXEMPLE : INSERTION LSB



Zone de l'œil

Agrandie (15x15)

52	59	64	56	54	57	53	50	49	55	47	49	50	53	51	53	53	53
51	54	52	51	52	52	49	50	47	50	47	49	50	46	50	59	48	48
53	52	52	58	51	47	50	51	46	47	46	47	46	47	44	51	55	55
53	51	53	55	51	53	45	43	42	46	45	47	46	47	48	79	66	66
48	47	55	47	51	48	46	44	45	47	44	47	44	50	56	70	90	90
53	53	47	43	54	49	50	40	46	47	75	62	69	94	65	86	128	128
77	67	43	47	62	60	45	39	35	40	87	87	87	87	85	86	121	121
90	81	50	60	80	79	48	37	35	38	55	38	55	90	65	50	72	72
103	90	50	57	94	93	76	47	40	42	68	42	68	112	77	56	66	66
115	107	71	52	92	98	90	72	66	66	90	66	90	108	74	53	87	87
117	121	99	67	58	84	98	84	84	84	91	83	72	57	66	66	126	126
108	127	115	88	59	60	79	86	90	80	76	80	76	55	65	113	173	173
105	114	125	113	89	62	57	54	60	57	64	57	64	77	107	160	198	198
113	112	117	120	113	95	82	63	65	75	88	65	75	88	127	158	202	202
115	119	119	124	132	120	108	101	102	116	137	101	102	116	163	186	197	198

Valeur des pixels appartenant à {0, ..., 255}

Un exemple simpliste d'insertion (3)

EXEMPLE : INSERTION LSB

- Représentation en binaire des entiers de $\{0, \dots, 255\}$:


octet

ENTIER (BASE 10)	BIT 7	BIT 6	BIT 5	BIT 4	BIT 3	BIT 2	BIT 1	BIT 0
0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	1
2	0	0	0	0	0	0	1	0
3	0	0	0	0	0	0	1	1
4	0	0	0	0	0	1	0	0
...								
254	1	1	1	1	1	1	1	0
255	1	1	1	1	1	1	1	1

Un exemple simpliste d'insertion (4)

EXEMPLE : INSERTION LSB

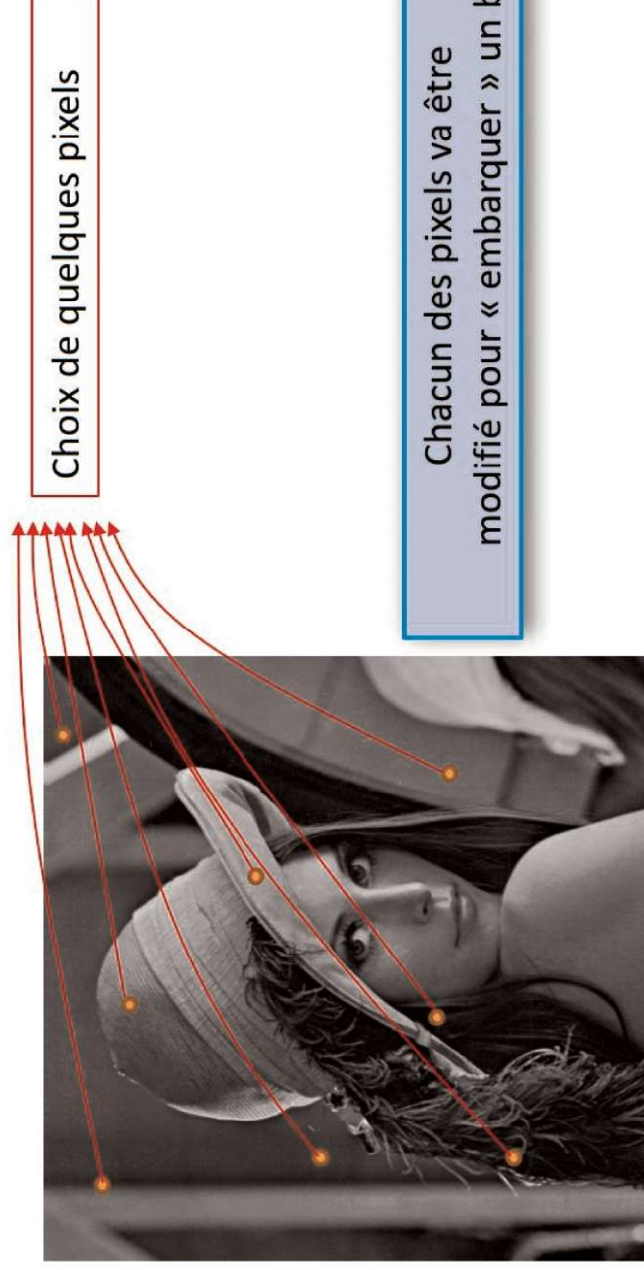
- L'insertion par substitution du bit de poids faible (LSB) :
Low Significant Bit Data-Hiding) :



Un exemple simpliste d'insertion (5)

EXEMPLE : INSERTION LSB

- L'insertion par substitution du bit de poids faible (LSB) : Low Significant Bit Data-Hiding) :



Un exemple simpliste d'insertion (6)

EXEMPLE : INSERTION LSB

- L'insertion par substitution du bit de poids faible (LSB : Low Significant Bit Data-Hiding) :




Exemple :

- Supposons que le pixel vaut 42
- Supposons que le bit à insérer vaut 1
- 42 en binaire s'écrit 101 010
- Après insertion on a 101 011
c'est-à-dire la valeur 43

... modification invisible à l'œil

La stéganographie moderne (adaptative)

Stéganographie non adaptative



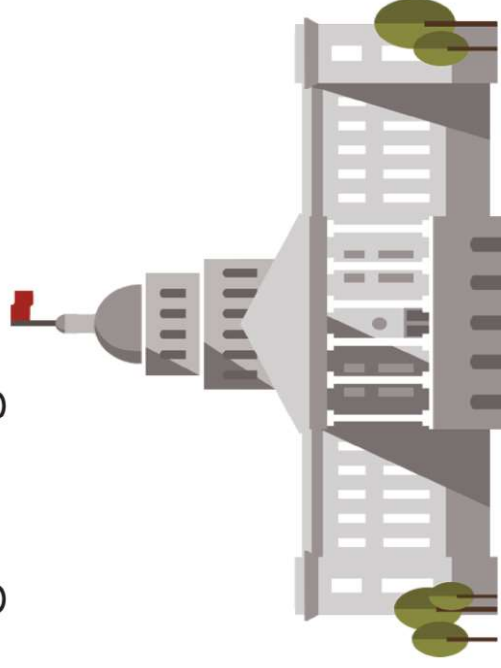
<https://stylesuxx.github.io/steganography/>

Stéganographie adaptative




Les acteurs / utilisateurs


Agences gouvernementales



Journalistes / Dissidents



Entreprises



Terroristes



La notion de sécurité...

La stéganographie :
l'art de la communication secrète

Complice

BOB



EVE

Gardien



Prisonnier

ALICE



« cet ?*! de
gardien va n'y
voir que du feu »

Prison

[Simmons, 1983]

Modèle de gardien passif

Le scénario de stéganalyse ” à clairvoyance” (pire des cas)

1. Une **unique (jetable) clef d’insertion(*)** pour chaque insertion.
2. Scénario similaire au principe de Kerckhoffs (cryptographie).
Eve connaît/dipose :
 - ▶ de l’algorithme d’insertion et d’extraction du message,
 - ▶ de l’ensemble des paramètres publics de ces deux algorithmes,
 - ▶ d’une base d’images similaires (connaît le développement) à celles utilisées par Alice et Bob,
 - ▶ on suppose souvent que les images sont de même taille et que le nombre de bits insérés est fixe.



(*) L. Pibre, J. Pasquet, D. Ienco, and M. Chaumont

Deep learning is a good steganalysis tool when embedding key is reused for different images, even if there is a cover source-mismatch

Les seuls paramètres qu’Eve ne connaît pas sont les clefs secrètes utilisées par Alice et Bob pour insérer/extraire les messages dans les images.

Le scénario de stéganalyse ”à clairvoyance” (remarque)

→ On fait rarement des attaques sur la clef.

Exemple d’attaque sur la clef quand il y a une erreur de déploiement (instantiation) de l’algorithme d’insertion/extraction :



T. Pevný and A. D. Ker.

[Steganographic key leakage through payload metadata](#)

Eve "détecte" (elle classe) si "cover" ou "stego"

Deux hypothèses :

$$\mathcal{H}_0 = \mathbf{x} \sim P_c,$$

$$\mathcal{H}_1 = \mathbf{x} \sim P_s.$$

On construit un détecteur $\delta(\cdot)$:

$$\delta : \mathbb{N}^{h \times w} \rightarrow \{0, 1\}$$

$$\mathbf{x} \rightarrow \delta(\mathbf{x})$$

- ▶ par test d'hypothèses,
- ▶ par Machine-Learning ou Deep-Learning.

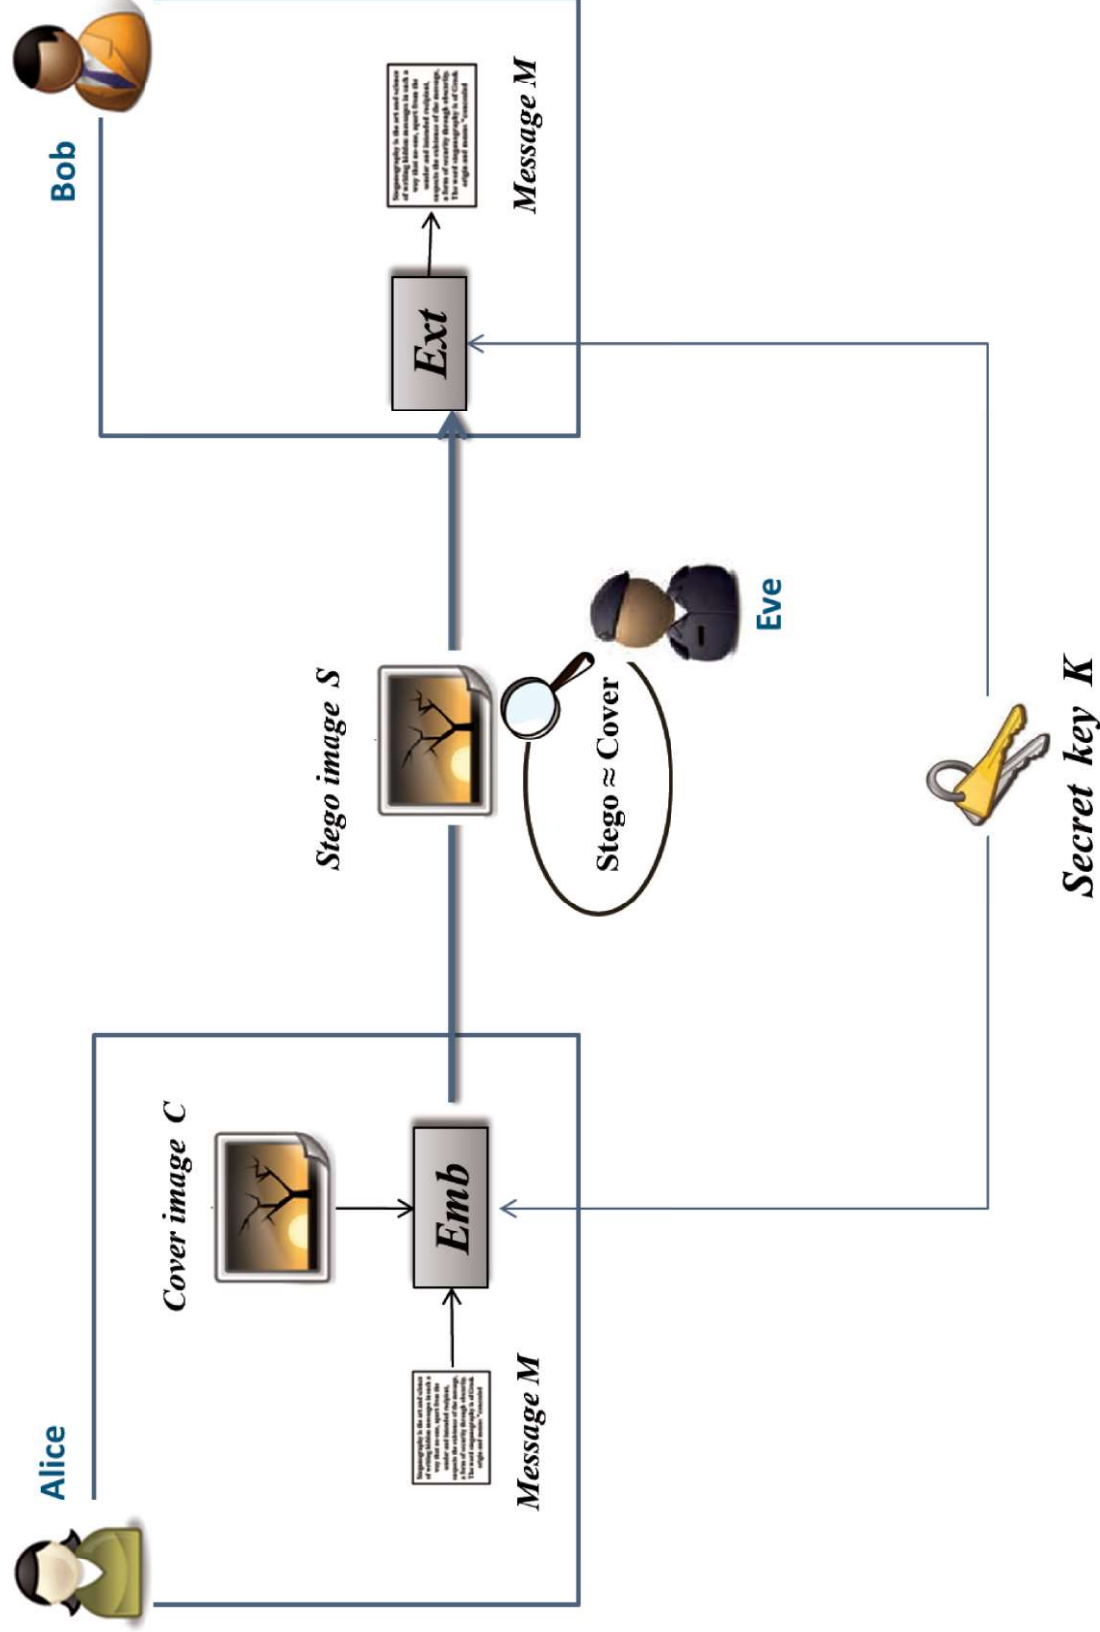
Outline

Introduction

Passons à la stéganographie / stéganalyse moderne

La stéganographie par deep-learning

Steganography / Steganalysis




Stéganographie adaptative

Protocole opérationnel

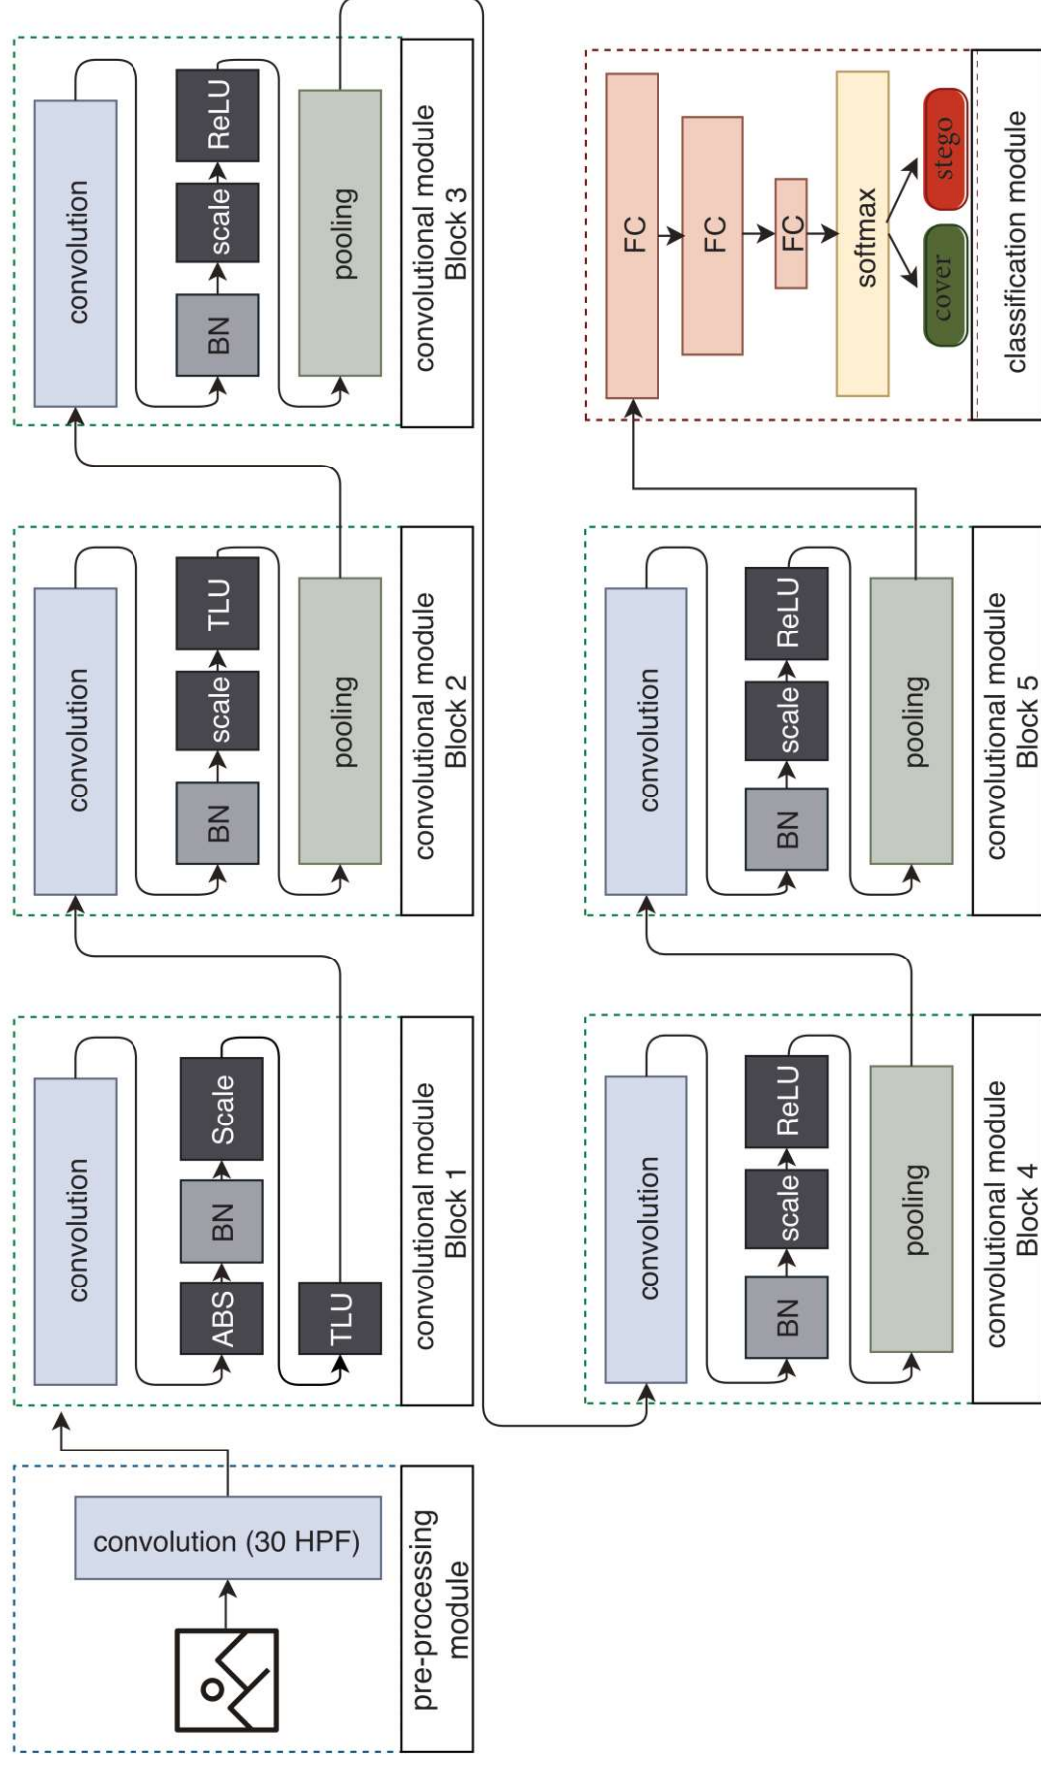
1. Génération d'une carte des coûts
2. Encodage du message
3. Insertion du message

Exemples

- ▶ WOW
- ▶ S-UNIWARD
- ▶ MIPOD
- ▶ HILL



Yedroudj-Net



Outline

Introduction

Passons à la stéganographie / stéganalyse moderne

La stéganographie par deep-learning

Les quatre familles :

Famille :

▶ **1) par synthèse (pas de modifications):**

Principe : Synthétise une image via un générateur (GAN) et extrait la "graine" / message par un "extracteur"

▶ **2) par insertion adverserielle itérée :**

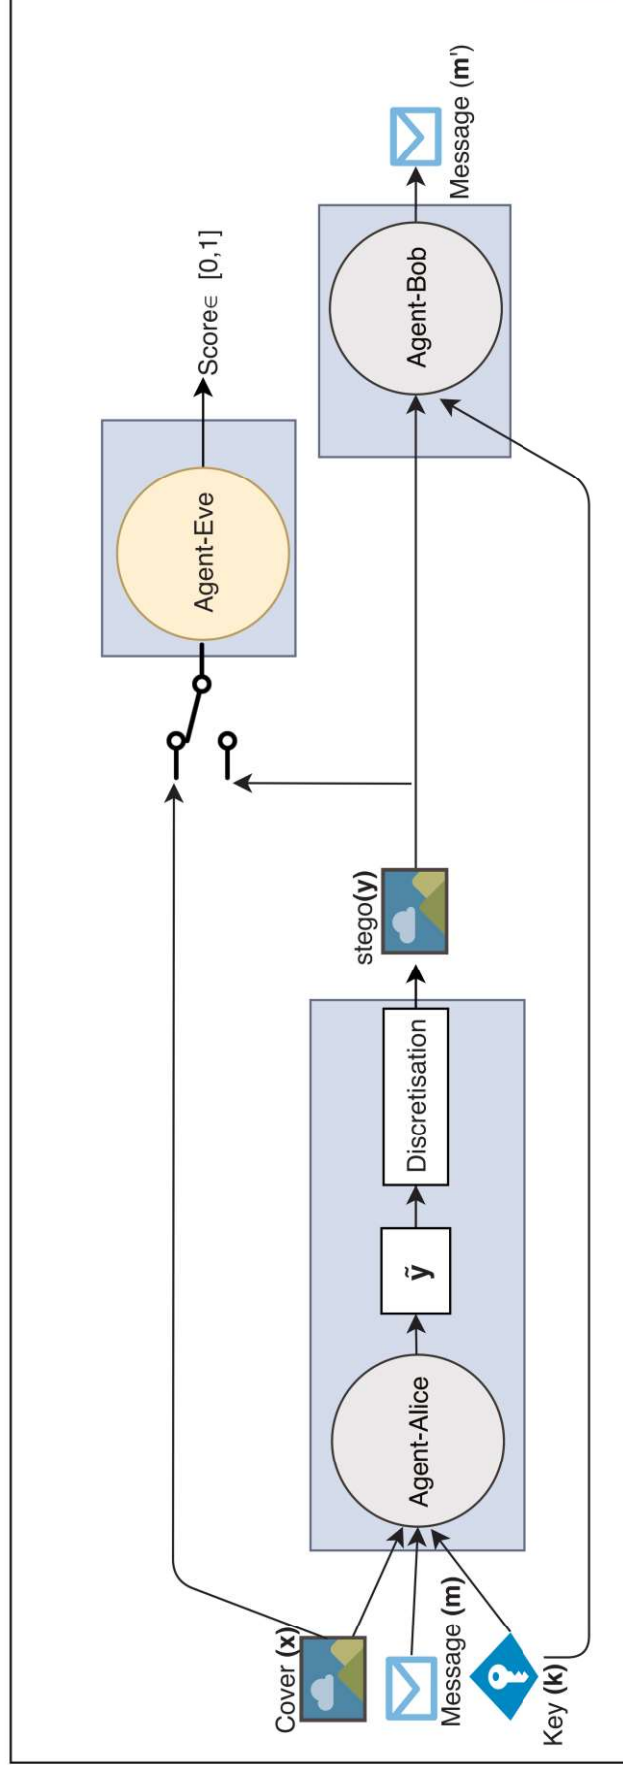
Principe : On utilise un algorithme d'insertion pour produire des exemples "adverserielles" et un réseau "discriminateur" .

▶ **3) par génération de la carte de probabilités de modifications :**

Principe : Un réseau générant une carte puis simulant l'insertion et un réseau "discriminateur" .

▶ **4) par jeu à 3 joueurs :**

Approche à 3 joueurs



Algorithm 1: 3-players game TRAINING

```

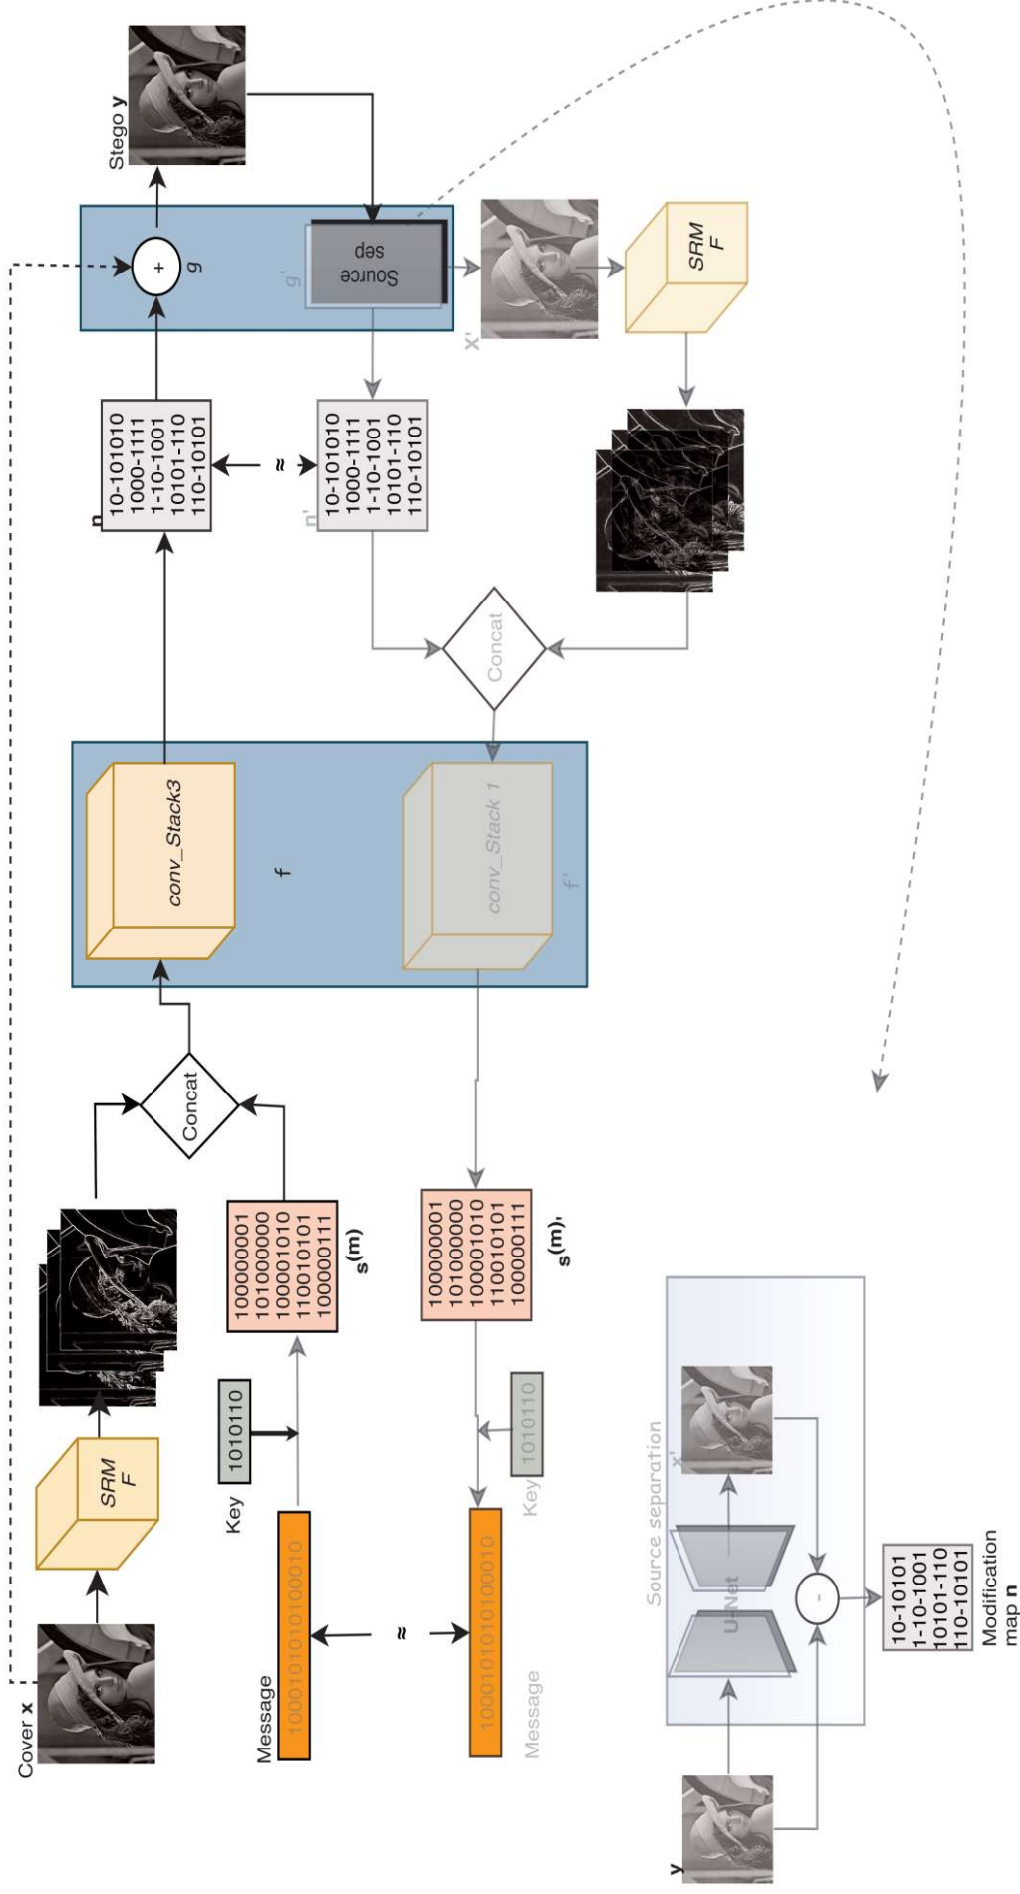
1 while not converge OR loop  $\leq$  max-iter do
2   // Agent-Alice et Agent-Bob
3   for iter_team1  $\leq$  it1 do
4     forward-propagation (cover, message, key);
5     // Minimize  $\mathcal{L}_{Bob} = (\sum_{i=1}^m (m_i - m'_i)^2) / m$ 
6     update_Agent-Bob ( $\mathcal{L}_{Bob}$ );
7     // Minimize  $\mathcal{L}_{Alice} = \lambda_A \cdot (\text{dist}(\mathbf{x}, \mathbf{y}) - \beta) + \lambda_B \cdot \mathcal{L}_{Bob} - \lambda_E \cdot \mathcal{L}_{Eve}$ ,
8     update_Agent-Alice ( $\mathcal{L}_{Alice}$ );
9   end
10  // Agent-Eve
11  for iter_team2  $\leq$  it2 do
12    forward-propagation (cover, stego);
13    // Minimize  $\mathcal{L}_{Eve} = \text{dist}(z - \text{Agent-Eve}(z))$ 
14    update_Agent-Eve ( $\mathcal{L}_{Eve}$ );
15  end
16 end

```

Stéganographie par Deep Learning

La stéganographie par deep-learning

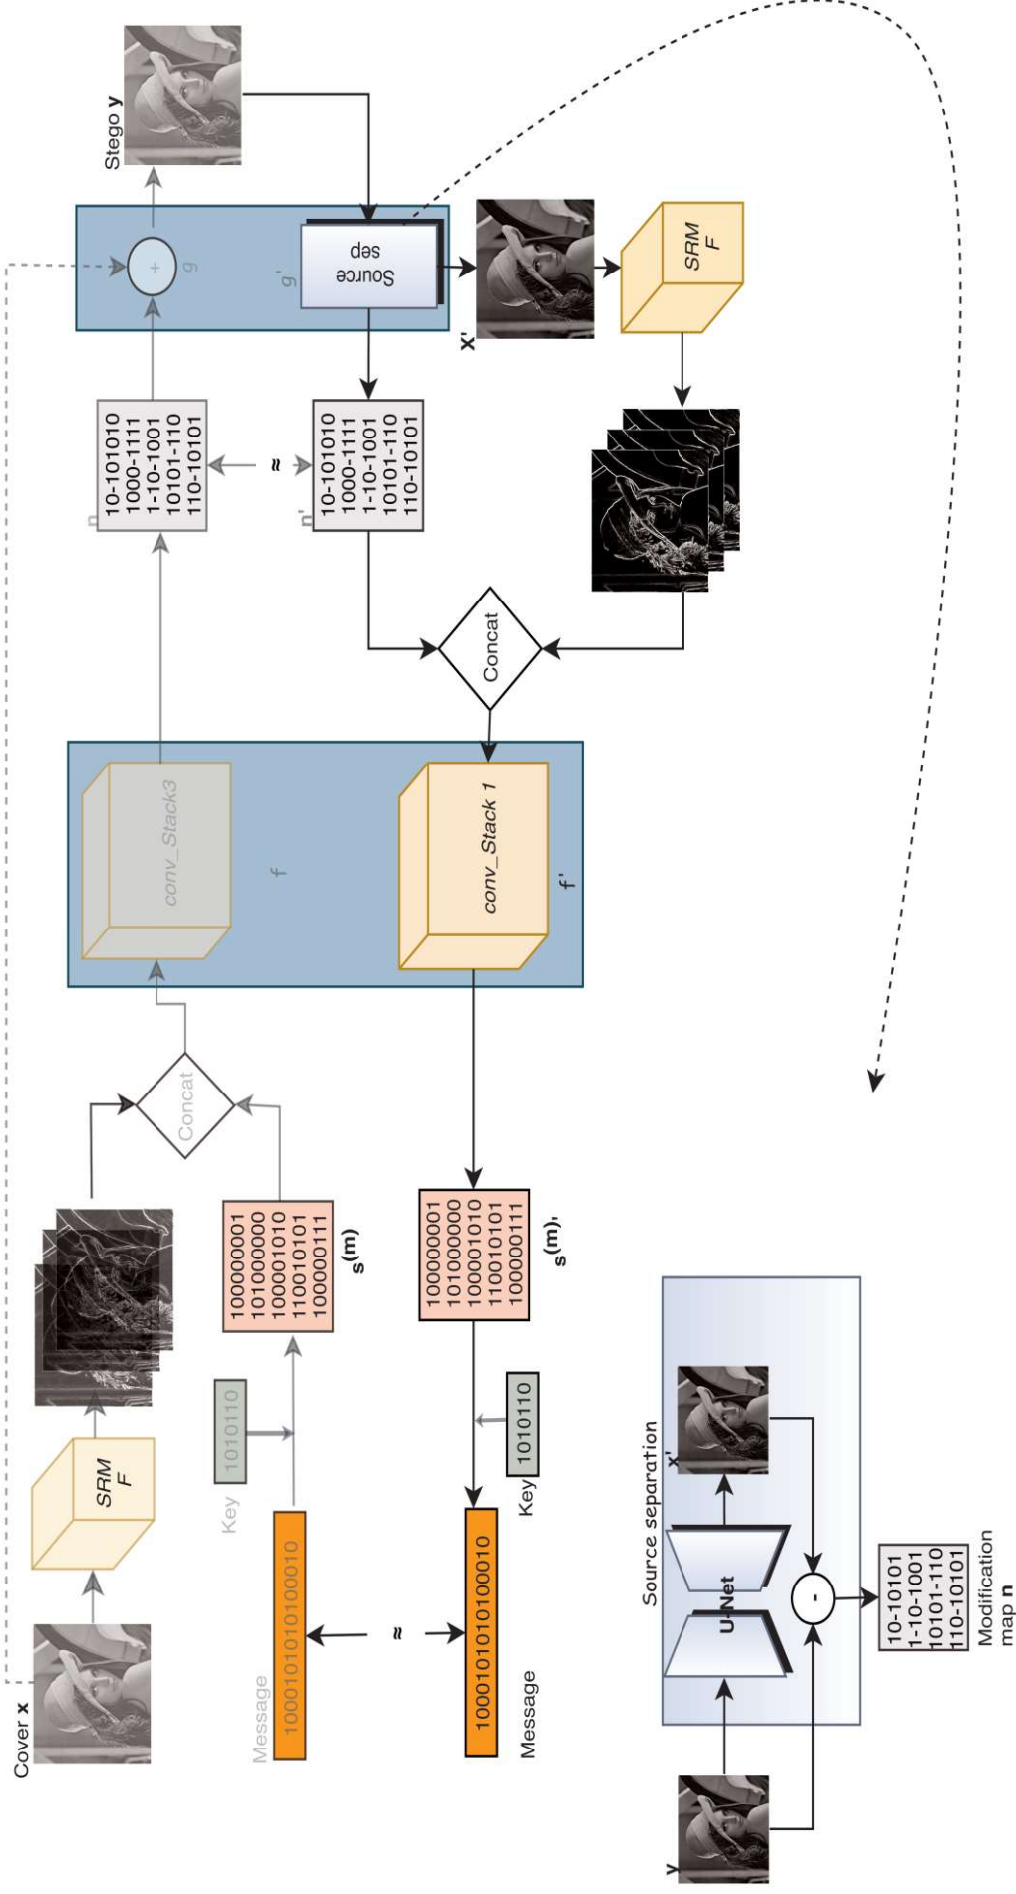
Agent-Alice et Agent-Bob



Stéganographie par Deep Learning

└ La stéganographie par deep-learning

Agent-Alice et Agent-Bob




Stéganographie par Deep Learning

└ La stéganographie par deep-learning

Résultats

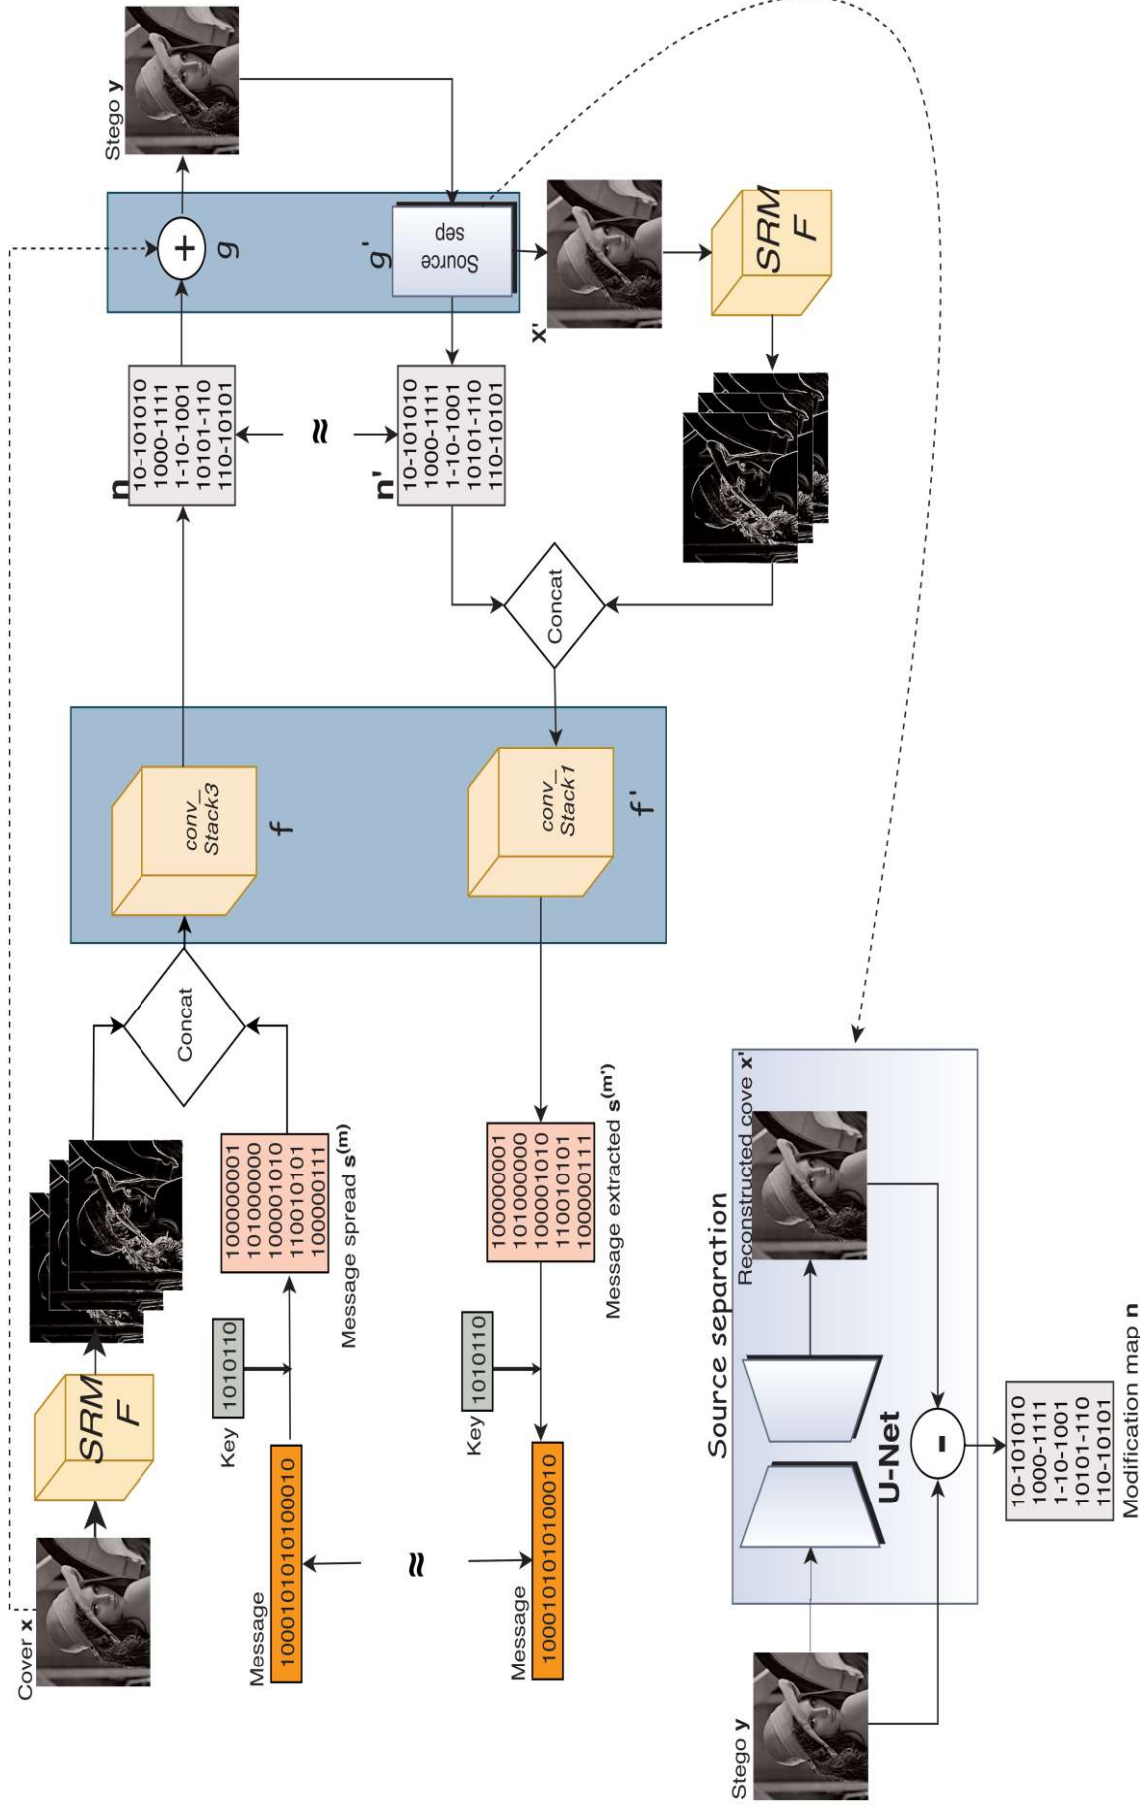


Résultats



- ▶ Pour $\beta = 0.1$
 - ▶ **BER = 6%**
 - ▶ Payload réel = 0.3 bpp
 - ▶ $Pe = 11.2\%$
- ▶ WOW
 - ▶ Payload réel = 0.3 bpp
 - ▶ $Pe = 20.9\%$

Reflexion sur l'absence d'un bloc de codage/décodage



Points forts de la méthode

Avantage de la méthode proposée

- ▶ Clé secrète
- ▶ Stegos avec des valeurs entières
- ▶ Adaptative / la quantité d'information à insérer
- ▶ Images de taille scalable (256×256)
- ▶ Stéganalysseur efficace
- ▶ Pas d'hypothèse sur l'additivité de la fonction de distortion
- ▶ Simulation d'un équilibre de Nash (Agent-Eve est dans le processus)