



Stéganographie et stéganalyse: tendances actuelles et perspectives.

Jean-François Couchot¹

¹Institut FEMTO-ST - Département DISC - Equipe AND.
Univ. Bourgogne Franche-Comté (UBFC), France

24 mars 2017 / Besançon

Journée recherche et développement

Outline



1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion




1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion

Stéganographie dans des images numériques spatiales

Intuition


L'art de dissimuler un message (souvent crypté) dans une image anodine et de manière imperceptible.

Un exemple dans le domaine spatial (Wikipédia)



RGB (218, 150, 149)

R = 11011010
G = 10010110
B = 10010101



Cas d'utilisation de la stéganographie



Message imperceptible (avant tout)

- 2010–'Illegals' : réseau d'espions russes envoyant des données dans des images stéganographiées
- 2011–Duqu (virus Windows) : clefs envoyées dans des images JPEG 54x54 pixels stéganographiées
- ...

Tatouage : difficile d'enlever le message (avant tout)

- DRM dans les images de photographes

Stéganalyse : dual de la stéganographie




Intuition

Méthodes permettant de décider si une image contient un message.


Une démarche de classification

1. Construction des caractéristiques statistiques des images
2. Comparaison avec celles de supports vierges connus
3. Verdict

Exemple : comparaison des histogrammes LSB



(a) Original image.



(b) After LSB substitution.

Le jeu : stéganographie contre stéganalyse

Objectifs contradictoires

- Un stéganographeur :
 - un choix intelligent des pixels à modifier ;
 - un algorithme de modification des pixels efficace.
- Un stéganalysteur :
 - un ensemble de caractéristiques statistiques discriminantes (d'images) ;
 - un algorithme de classification efficace.

Évaluation de la sécurité d'un stéganographeur

- Principe de Kerckhoffs : le stéganalysteur connaît
 - le stéganographeur
 - la taille des messages embarqués dans les images
- Stéganalyse difficile \leftrightarrow stéganographeur sécurisé



1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion

LSB : remplacement et correspondance




Remplacement des LSBs

- Remplacement des LSBs de l'image par les bits du message
- Très peu sécurisée : histogramme caractéristique

Correspondance de LSBs¹

- Pixel : inchangé si LSB égal au bit courant du message
- Pixel : ± 1 aléatoirement
- Attaquable par histogramme de longueurs de valeurs égales²



1. Sharp, T. (2001, April). An implementation of key-based digital signal steganography. In International Workshop on Information Hiding (pp. 13-26). Springer Berlin Heidelberg.

2. Yu, X.Y. and N. Babaguchi, 2008. Run length based steganalysis for LSB matching steganography. Proceedings of the IEEE International Conference on Multimedia and Expo, June 23-April 26, Hannover, Germany, pp : 353-356.

Stéganographie adaptative⁴




Problématique

A partir d'un support X à n éléments : trouver le moyen de transmettre le message m dans l'image stéganographiée Y en minimisant la distorsion.

Étape 1 : carte de distorsion

- Modéliser le *coût de modification* par une fonction de distorsion D additive :
$$D(X, Y) = \sum_{i=1}^n \rho(i) |X_i - Y_i|$$
- Trouver l'image Y qui minimise D :
 $Y = \arg \min D(X, Y)$.
- Intuitivement : valeur de la distorsion
 - zone facilement modélisable, uniforme → élevée ;
 - zone de texture ou chaotique → faible.



Étape 2 : modification efficaces des bits par STC³

- Généralisation des codes de Hamming à n'importe quelle taille.

3. Filler, T., Judas, J., & Fridrich, J. (2011). Minimizing additive distortion in steganography using syndrome-trellis codes. *IEEE Transactions on Information Forensics and Security*, 6(3), 920-935.


4. Fridrich, J., & Filler, T. (2007, February). Practical methods for minimizing embedding impact in steganography. In *Electronic Imaging 2007* (pp. 650502-650502). International Society for Optics and Photonics.

Exemples de stéganographie adaptive



Basée sur les modifications de caractéristiques : HUGO⁵

- Distorsion $\rho_i = |f(y_i) - f(x_i)|$ où
- f : valeur des caractéristiques SPAM autour de i



Basée sur les filtres de convolution

- S-UNIWARD⁶ : $\rho_U(X) = \sum_{i=1}^3 \frac{1}{|X \star K^i| + \sigma} \star |K^i| \curvearrowright$, où K est un filtre d'ondelettes de Daubechies-8
- HILL⁷ : $\rho_H(X) = \frac{1}{|X \star H_1| \star L_1} \star L_2$, où $H_1, L_1, L_2 \dots$

5. Pevný, T., Filler, T., & Bas, P. (2010, June). Using high-dimensional image models to perform highly undetectable steganography. In International Workshop on Information Hiding (pp. 161-177). Springer Berlin Heidelberg.


6. V. Holub, J. Fridrich, T. Denemark, *Universal Distortion Function for Steganography in an Arbitrary Domain*, EURASIP J. on Inf. Se., 2014(1)

7. B. Li, M. Wang, J. Huang, X. Li, *A New Cost Function for Spatial Image Steganography*, 2014 IEEE International Conference on Image Processing (ICIP). pp. 4206-4210, 2014.

Exemples de stéganographie adaptative (suite)

Basée sur un a priori : STABYLO⁸

- Bords dans une image : concentrent les fortes variations
- Modifications des pixels de bords : a priori peu détectables




Basée sur des distributions probabilistes : MIPOD⁹

Estimation des paramètres de la distribution statistique d'une fenêtre de pixels avant/après.

Basée sur l'analyse vectorielle : Ky¹⁰

- Trouver les pixels sur des lignes de niveau les plus irrégulières grâce à des dérivées secondes.



8. Couchot, J. F., Couturier, R., & Guyeux, C. (2015). STABYLO : steganography with adaptive, bbs, and binary embedding at low cost. *annals of telecommunications-Annales des télécommunications*, 70(9-10), 441-449.

9. V. Sedighi, R. Cogranne and J. Fridrich, *Content-Adaptive Steganography by Minimizing Statistical Detectability*. IEEE Transactions on Information Forensics and Security. 11(2) : 221-234 (2016)

10. Couchot, J. F., Couturier, R., Fadil, Y. A., & Guyeux, C. (2016). A Second Order Derivatives based Approach for Steganography. *SECURITY 2016* : 424-431.




1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion


Des histogrammes discriminants



Remplacement des LSBs




(a) Original image.



(b) After LSB substitution.

Correspondance de LSBs



Une approche en deux étapes




Étape 1 : construction des caractéristiques (modèle d'images)

Caractéristiques statistique des images et de leur composante de bruit :

- révélant les dépendances entre les pixels des images ;
- sensibles aux modifications, mais indépendantes du contenu de l'image.

Étape 2 : outil de classification

- N'importe quel outil par apprentissage : FLD, SVM, NN
- Compatible avec les caractéristiques statistiques
- Pratiquement : FLD Ensemble classifieur¹¹ (EC)



11. J. Kodovský, J. Fridrich, & V. Holub, Ensemble Classifiers for Steganalysis of Digital Media. IEEE Transactions on Information Forensics and Security, Vol. 7, No. 2, pp. 432-444, April 2012.


Des modèles d'images de plus en plus riches

Modèle SPAM¹² : 686 dimensions

- Calcul des variations D dans les huit directions ($\rightarrow, \swarrow, \downarrow, \dots$)
- Pour chacune d'elle, calcul de la matrice de probabilités de modification $p(D = u | D = v)$ pour certains u, v

Modèles riches¹³ : ≈ 34000 dimensions

- Calcul des variations du bruit : $z_{ij} = x_{ij} - \text{Pred}(\text{Vois}(x_{ij}))$
- Quantifications et troncatures variées
- Co-occurrences entre pixels voisins :



12. Pevny, T., Bas, P., & Fridrich, J. (2010). Steganalysis by subtractive pixel adjacency matrix. IEEE Transactions on information Forensics and Security, 5(2), 215-224.


13. V. Holub and J. Fridrich, Phase-Aware Projection Model for Steganalysis of JPEG Images, Proc. SPIE, Electronic Imaging, Media Watermarking, Security, and Forensics XVII, vol. 9409, 2015.

Deep learning : une seule étape



Réseaux de neurones par convolution¹⁴

- Caractéristiques discriminantes inférées par le réseau
- Architecture :



14. G. Xu, H.-Z. Wu, Y.-Q. Shi, Structural Design of Convolutional Neural Networks for Steganalysis, IEEE Signal Processing Letters, vol. 23, num. 5, pp. 708–712.

Stéganographie contre stéganalyse : bilan

Règles du jeu

- Base BOSS¹⁵ de 10,000 images en niveaux de gris 512 × 512
- Connu : stéganographeur et taille du message embarqué

Résultats : erreur moyenne de classification

| | S-UNIWARD | | MiPOD | | HILL | |
|---------------------------|-----------|-------|-------|-------|-------|-------|
| | 0.1 | 0.4 | 0.1 | 0.4 | 0.1 | 0.4 |
| Caffe ¹⁴ (CNN) | 42.67 | 19.76 | X | X | 41.56 | 20.76 |
| SRM + EC ⁹ | 39.84 | 18.06 | 41.18 | 21.42 | 42.96 | 23.31 |

- Approches fournissant des résultats globalement équivalents

15. Bas, P., Filler, T., & Pevný, T. (2011, May). "Break Our Steganographic System": The Ins and Outs of Organizing BOSS. In International Workshop on Information Hiding (pp. 59-70). Springer Berlin Heidelberg.



1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion

Réduire l'erreur de détection



Réseaux de neurones par convolution ?

- D'autres filtres, d'autres tailles, ...
- Sans résultats

Exploiter le meilleur des deux approches ?

- Pour une image donnée : quel stéganalyseur est le plus efficace ?
- Critères pour orienter vers un des outils

Classification de SRM+EC / du CNN



Notre implantation en plus et en aveugle

| | S-UNIWARD | | MIPOD | | HILL | |
|-----------------------|-----------|-------|-------|-------|-------|-------|
| | 0.1 | 0.4 | 0.1 | 0.4 | 0.1 | 0.4 |
| Caffe ¹⁴ | 42.67 | 19.76 | X | X | 41.56 | 20.76 |
| TensorFlow (aveugle) | 47.38 | 20.52 | 43.72 | 19.36 | 46.79 | 20.25 |
| SRM + EC ⁹ | 39.84 | 18.06 | 41.18 | 21.42 | 42.96 | 23.31 |
| SRM + EC (aveugle) | 40.57 | 20.85 | 41.18 | 21.42 | 43.35 | 23.99 |

Exemples de classification par CNN




Stéganographie effectuée avec MiPOD avec un ratio de 0.4 bpp

- Situations de succès pour le CNN TensorFlow :

1388 .pgm




8873 .pgm




- Situations d'échec pour le CNN TensorFlow :

1911 .pgm




3394 .pgm



Erreur de classification avec CNN-Tensor Flow

p.r. $\overline{\rho_U}$

$\overline{\rho_U}$: distorsion moyenne selon S-UNIWARD



Quiz



Devinez le \overline{PU} pour chaque image.



$\overline{PU}_{1388} = ?$



$\overline{PU}_{8873} = ?$



$\overline{PU}_{1911} = ?$



$\overline{PU}_{3394} = ?$


Quiz




Devinez le $\overline{\rho U}$ pour chaque image.



$$\overline{\rho U}_{1388} = 7.05$$



$$\overline{\rho U}_{8873} = 7.39$$



$$\overline{\rho U}_{1911} = 2.1$$




$$\overline{\rho U}_{3394} = 3.06$$

Erreur de détection selon SRM+EC p.r. $\overline{\rho U}$




200 évaluations



Comment choisir le meilleur stéganalysateur ?

Proposition de méthode

- Calcul préalable : abscisse $\overline{\rho_U}$ de l'intersection entre les courbes.



- Pour chaque image I :
 - calcul de la distorsion moyenne $\overline{\rho_U}(I)$ selon S-UNIWARD
 - si $\overline{\rho_U}(I) < \overline{\rho_U}$, utiliser le verdict de SRM+EC
 - sinon, utiliser le verdict du CNN

Résultats d'erreur moyenne de classification

Taux d'embarquement : 0.4

| | SRM+EC | $\overline{\rho_U}$ | CNN | Notre approche | SRM+EC | CNN |
|----------------------|--------|---------------------|------|----------------|--------|-------|
| S-UNIWARD | 20.01 | 7.1 | 8.25 | 14.82 | 18.06 | 19.76 |
| S-UNIWARD aveugle | 22.05 | 6.9 | 9.50 | 15.87 | 20.85 | X |
| MiPOD | 23.89 | 6.6 | 9.26 | 15.65 | 21.42 | 19.36 |
| HILL | 24.51 | 6.6 | 9.78 | 16.22 | 23.31 | 20.76 |
| HILL aveugle | 25.41 | 6.6 | 9.78 | 16.61 | 23.99 | 20.25 |

Taux d'embarquement : 0.1

| | SRM+EC | $\overline{\rho_U}$ | CNN | Notre approche | SRM+EC | CNN |
|----------------------|--------|---------------------|-------|----------------|--------|-------|
| S-UNIWARD | 40.08 | 9.2 | 23.36 | 38.06 | 39.84 | 42.67 |
| S-UNIWARD aveugle | 41.00 | 9.2 | 23.36 | 38.88 | 40.57 | X |
| MiPOD | 42.13 | 8.0 | 25.84 | 37.82 | 41.18 | 43.72 |
| HILL | 43.48 | 8.9 | 21.88 | 40.24 | 42.96 | 41.56 |
| HILL aveugle | 44.30 | 8.3 | 27.72 | 40.64 | 43.35 | 46.79 |



Résumé de cette proposition

- Choix guidé du stéganalysesur le plus efficace
- Meilleurs résultats connus en termes de stéganalyse

Développement sur GPU

- Matériel
 - Développement du réseau → 1 NVIDIA GPU Titan X
 - Exécution du réseau au Mesocentre → 4 NVIDIA GPU Tesla K40
- Durée d'entraînement sur la NVIDIA GPU Titan X
 - ratio d'embarquement de 0.4 bpp → ≈ 3 jours pour des résultats "très bons "
 - ratio d'embarquement de 0.1 bpp → ≈ 7 jours pour des résultats "bons "

Environ 15,000 heures de calcul en utilisant le Mesocentre

Publié en mai 2017

Couchot, J.-F., Couturier, R., & Salomon, M. *Improving Blind Steganalysis in Spatial Domain using a Criterion to Choose the Appropriate Steganalyzer between CNN and SRM+EC*. 32nd International Conference on ICT Systems Security and Privacy Protection - IFIP SEC 2017, May 29 - 31, 2017, Rome, Italy.

Plan



1. Introduction
2. Stéganographie : de LSBR à l'analyse vectorielle
3. Stéganalyse : des histogrammes au deep learning
4. Un travail récent de recherche en stéganalyse
5. Conclusion

Conclusion



Résumé de la présentation

- Jeu « stéganographie contre stéganalyse » : ne fait que commencer
- Distorsion en stéganographie : ondelettes, analyse vectorielle, probabilités
- Stéganalyse : caractéristiques, deep learning

Et après ?

- Pratique : stéganographie par CNN, + de puissance de calcul
- Théorique : pourquoi les CNN font aussi bien sans connaissance ?

Compétences pour cette thématique

- Extraction d'info dans des données de grande taille (SVD, PCA)
- Des mathématiques discrètes, des probabilités, développement Tensor-Flow
- Outils de classification
- Au cœur des thématiques de AND-DISC-FEMTO-ST

Equipe AND-DISC-FEMTO-ST



AND - Mozilla Firefox

AND

www.femto-st.fr/fr/Departements-de-rech

free wifi desact

femto-st
SCIENCES & TECHNOLOGIES

Automatique AS2M Informatique
SIST Energie Mécanique appliquée Micro
nano MN2S Optique Temps fréquence


INFORMATIQUE DISC

L'INSTITUT LA RECHERCHE LA TECHNOLOGIE PARTENARIAT / VALORISATION EMPLOI FORMATION

Accueil > La recherche > DISC > Equipes de recherche > AND > ...

Équipe Algorithmique Numérique Distribuée (AND)

Responsable
Raphaël COUTURIER



Contexte

L'équipe AND (Algorithmique Numérique Distribuée) a démarré ses activités dans le domaine de l'algorithmique numérique distribuée et du calcul haute performance, en focalisant ses travaux sur les itérations asynchrones. Ces dernières sont utilisées pour accélérer la convergence vers la solution d'un problème formulé sous forme d'un point fixe.