

RAPORT

ETAPA I: Îmbunătățirea predicției locale

Cercetarile s-au concentrat pe optimizarea parametrilor folosiți la predicția liniară locală, precum și pe dezvoltarea unor noi metode de marcarea reversibilă. Rezultatele obținute au fost publicate în patru articole prezentate la conferințe indexate ISI. Un articol de conferință se află în revizie pentru IEEE ICASSP, două articole de revistă sunt în faza avansată de redactare, iar un al treilea articol de revistă se află în faza inițială de redactare.

Activitatea 1.1. Management și diseminare.

Directorul de proiect, după discuții cu mentorul, a stabilit strategia de diseminare a rezultatelor care a vizat conferințe internaționale selectivă care se bucură de aprecierea specialiștilor din domeniul prelucrării imaginilor și anume *ICIP (IEEE International Conference on Image Processing)* cu două articole, și *EUSIPCO (IEEE European Signal Processing Conference)*. Mai exact, au fost publicate în 2018 următoarele articole:

- 1) I.C. Dragoi și D. Coltuc, "Reversible Data Hiding in Encrypted Color Images Based on Vacating Room After Encryption and Pixel Prediction," *25th IEEE International Conference on Image Processing (ICIP)*, Atena, Grecia, 2018.
- 2) I.C. Dragoi, Ion Caciula și D. Coltuc, "Improved Pairwise Pixel-Value-Ordering for High-Fidelity Reversible Data Hiding," *25th IEEE International Conference on Image Processing (ICIP)*, Atena, Grecia, 2018.
- 3) I.C. Dragoi și D. Coltuc, "Improved Pairwise Embedding for High-Fidelity Reversible Data Hiding", *26th IEEE European Signal Processing Conference (EUSIPCO)*, Roma, Italia, 2018.
- 4) A. Bobeica, I.C. Dragoi, I Caciula, D. Coltuc, F. Albu și F. Yang, "Capacity Control for Prediction Error Expansion Based Audio Reversible Data Hiding", *22nd International*

Conference on System Theory, Control and Computing (ICSTCC), Oct. 10-12, 2018, Sinaia, România.

Un articol se află în revizie:

- 5) I.C. Dragoi, D. Coltuc, "Prediction-Error-Ordering for High-Fidelity Reversible Data Hiding," in recenzie la *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019.

Două articole sunt în stare avansată de redactare și vor fi trimise spre evaluare și publicare la reviste clasificate în Q1 (reviste roșii): *IEEE Transactions on Information, Forensics and Security* (factor de impact 5.824) și/sau *IEEE Transactions on Image Processing* (factor de impact 5.071). Primul dintre aceste articole investighează marcarea reversibilă în imaginile color, folosind corelația dintre planele de culoare pentru a crește eficiența predictorului, care la rândul ei îmbunătățește rezultatele marcării reversibile. Ca metodă de marcarea folosim inserția în perechi de erori de predicție, propusă în [1] și optimizată în [2]. Această abordare necesită calculul simultan al erorilor ce aparțin aceleiași perechi, însă momentan predicția locală determină erorile individual [3] sau pe grupe de pixeli vecini [4] (grupe care nu sunt compatibile cu abordarea adaptivă din [2]). Articolul folosește un predictor bazat pe gradienti, urmând ca predictorul local să fie integrat în această tehnică de marcat într-un articol următor. Modificarea algoritmului de predicție locală pentru a permite marcarea pe bază de perechi de erori este discutată în secțiunea 2.2.

Al doilea articol aflat în stare avansată de redactare investighează optimizarea marcării reversibile pentru capacități de inserție mai mari de 1 bpp (bits-per-pixel). Acest articol a fost redactat inițial în jurul predictorului GAP (Gradient Adjusted Prediction [5]), însă rezultatele au fost îmbunătățite prin folosirea unui predictor liniar local cu context de predicție anti-cauzal. Se investighează și folosirea unei marcări în două etape care folosește un predictor local non-cauzal în prima etapă și apoi unul anti-cauzal în a doua. Acest aspect este discutat în secțiunea 2.3.

Menționăm și un al treilea articol aflat în stare inițială de redactare pe care intenționăm să-l trimitem la una din revistele menționate mai sus. Acesta introduce o formă generalizată a marcării reversibile cu perechi de erori din [2] și reprezintă un pas important pentru adaptarea

predictorului local la marcarea în perechi. Forma generalizată crește capacitatea maximă oferită de marcarea în perechi de la 0,2-0,26 bpp la 1 bpp.

Activitatea 2.2. Dezvoltarea algoritmilor de predicție locală cu selecție adaptivă a blocurilor de învățare

Performanțele predictorului local sunt determinate de doi parametri principali: dimensiunea blocului de învățare și forma contextului de predicție. Un pixel este estimat ca o medie ponderată a pixelilor din contextul său de predicție. Ponderile sunt calculate pe baza blocului de învățare, alegându-se valorile care minimizează eroarea pătrată medie (de predicție) pe blocul curent. Blocul de învățare este creat în jurul pixelului prezis, fără însă să-l conțină (regulă care se aplică și la contextul de predicție).

În această etapă a lucrării au fost întreprinse cercetări pentru determinarea unei metode de selecție adaptivă a blocului de învățare la nivel de pixel. În [3] și [4] se folosește o dimensiune fixă pentru acest bloc (12×12 pixeli), valoare care a obținut cele mai bune pe seturile de imagini testate. Astfel ponderile folosite de predictor sunt calculate pe baza erorii pătrate medii obținute pentru 99 de pixeli din jurul pixelului prezis (blocurile sunt considerate disjuncte, pixelii din prima și ultima linie/coloane nu au un context de predicție complet, iar pixelul curent este exclus din bloc: $(12 - 2)(12 - 2) - 1 = 99$ pixeli). Folosirea unei dimensiuni optime pentru imaginea curentă în loc de cea de 12×12 aduce în medie o creștere neglijabilă a PSNR-ului (de aproximativ 0.1 dB). Dacă s-ar folosi blocul optimal pentru fiecare pixel, creșterea în PSNR este de aproximativ 4 dB, însă această valoare nu poate fi determinată direct la decodare (este calculată pe bază valorii inițiale a pixelului curent). În continuare s-a evaluat folosirea unor valori locale disponibile la decodare care să estimeze dimensiunea ideală a blocului de învățare.




Figura 1. Contextul de predicție romb folosit de [1]-[4], [8].

Primul estimat testat a fost complexitatea locală. Pentru fiecare pixel x din imagine se calculează complexitatea locală l_c folosind contextul de predicție format din c_1, c_2, c_3 și c_4 (figura 1):

$$l_c = \frac{1}{4} \sum_{i=1}^4 \left(c_i - \frac{c_1 + c_2 + c_3 + c_4}{4} \right)^2$$

Pixelii sunt apoi sortați în funcție de l_c , iar șirul sortat este împărțit în 16 grupe cu un număr egal de pixeli. Se determină dimensiunea ideală a blocului de învățare pentru fiecare grupă. Cele 16 dimensiuni ideale sunt inserate în imaginea gazdă ca informație adițională (la fel cum se procedează cu pragul de marcare în [3]). S-a determinat experimental că dimensiunile calculate tind să fie similare cu dimensiunea ideală pentru întreaga imagine, clasificarea în funcție de complexitatea locală nu corespunde cu cea dată de dimensiunea ideală la nivel de pixel. S-a testat și posibilitatea de a corela direct dimensiunea blocului cu varianța (exemplu: $B = 7 + \left\lfloor \frac{l_c}{10} \right\rfloor$, unde B este dimensiunea blocului), însă nici această abordare nu a dat rezultate.

Al doilea estimat testat a fost blocul ideal pentru unul sau mulți pixeli vecini. Inițial s-a testat folosirea blocului ideal pentru c_3 . Este important de menționat că x face parte din blocul de învățare/contextul de predicție pentru c_3 . Valoarea lui x este înlocuită în toate blocurile testate pentru c_3 cu o valoare calculată cu un predictor simplu (în acest caz media vecinilor diagonali). Această abordare, precum și metodele derivate din ea (blocul ideal pe contextul romb/diagonal/complet), oferă un câștig limitat în PSNR care ajunge la 0,2 dB pe unele imagini de test, insuficient pentru a justifica creșterea substanțială în complexitate (de la determinarea unui predictor pentru fiecare x la 6 predictorii pentru fiecare c_3 și unul pentru x).

O a treia abordare a fost bazată pe valorile prezise pentru x date de fiecare bloc (media lor, medianul, valoarea cea mai reprezentată etc.). Nici această abordare nu a obținut rezultate satisfăcătoare.

Din testele efectuate reiese faptul că blocul de învățare ideal pentru fiecare pixel nu este direct corelat cu contextul local, iar acesta nu poate fi estimat corect pe baza lui. Nici valorile date de blocurile multiple pentru același pixel nu pot fi folosite pentru a determina valoarea optimală.

Articolele recente din domeniu sau concentrat pe optimizarea metodelor cu marcare bazată pe ordonarea pixelilor (Pixel-Value-Ordering, metodă introdusă în [6]) și cu marcări în perechi de erori ([1], [2]). Marcarea prin expandarea erorii de predicție (propusă în [7], îmbunătățită de [8])

și folosită în [3] pentru a descrie marcarea cu predicție locală) se află momentan într-un stadiu de stagnare. Pentru a menține relevanța predicției locale, aceasta trebuie adaptată pentru noile metode de marcarea reversibilă.

În forma sa actuală, metoda de marcarea reversibilă bazată pe ordonarea pixelilor nu folosește predictorii. Această metodă exploatează direct corelația dintre valorile pixelilor aflați într-un bloc de dimensiune mică (între 2×2 și 4×4 pixeli). S-a constatat că ecuațiile de marcarea folosite de [9] pot fi optimizate. [9] fiind cel mai performant algoritm bazat pe ordonarea pixelilor. Ecuațiile de optimizare pentru acest tip de marcarea au fost prezentate la *ICIP 2018* în "Improved Pairwise Pixel-Value-Ordering for High-Fidelity Reversible Data Hiding." Metodele derivate din [6] și [9] pot fi adaptate pentru a permite folosirea erorii de predicție. În "Prediction-Error-Ordering for High-Fidelity Reversible Data Hiding," articol în revizuire la *ICASSP 2019*, s-a arătat că ordonarea pixelilor dintr-un bloc pe baza erorii de predicție duce la o marcarea mai eficientă comparativ cu cea clasică bazată pe valoarea de gri a pixelilor.

Marcarea în perechi de erori se realizează în două etape. Pixelii gazdă sunt separați în două seturi disjuncte (figura 2.a), fiecare set este procesat în propria sa etapă de marcarea. În [2], pentru fiecare pixel x se caută un pixel pereche din același set pe baza erorii de predicție. Sunt evaluate pixelii p_1, p_2, \dots, p_8 ca posibile perechi pentru x (figura 2.b). În "Improved Pairwise Embedding for High-Fidelity Reversible Data Hiding," articol prezentat la *EUSIPCO 2018*, s-a simplificat procesul de marcarea, eliminându-se codarea parțială a mesajului secret folosită în [1] și [2]. Un aspect al marcării în perechi de erori care nu poate fi eliminat este calculul simultan al erorilor de predicție pentru x, p_1, p_2, \dots, p_8 . Blocul de învățare pentru predictorul local este creat în jurul pixelului curent. Pentru a menține reversibilitatea metodei, trebuie să eliminăm posibilele perechi din blocul de învățare. O altă problemă (întâlnită și la marcarea prin ordonarea pixelilor în funcție de eroarea de predicție) este faptul că predictorul local necesită ca pixelii să fie procesați la decodare în ordine inversă față de marcarea, însă algoritmul de realizare a perechilor are nevoie de aceeași ordine la marcarea și decodare. O posibilă soluție la această problemă este adaptarea algoritmului de realizare a perechilor pentru obținerea acelorași perechi când pixelii sunt procesați în ordine inversă.




Figura 2. Gruparea pixelilor în seturi (a) și perechile posibile pentru pixelul x (b).

S-a investigat și adaptarea metodelor actuale de marcare reversibilă la alte tipuri de semnale gazdă: imagini criptate ("Reversible Data Hiding in Encrypted Color Images Based on Vacating Room After Encryption and Pixel Prediction," *ICIP 2018*), imagini color (articol aflat în stare avansată de redactare) și fișiere audio ("Capacity Control for Prediction Error Expansion Based Audio Reversible Data Hiding," *ICSTCC 2018*). Marcarea cu predictorul local în ultimele două tipuri de semnale ar beneficia de o reducere a complexității de calcul a predicției, aceste semnale având un număr mult mai mare de valori/eșantioane față de imaginile cu tonuri de gri.

Activitate 2.3. Dezvoltarea algoritmilor de predicție locală cu selecție adaptivă a dimensiunii contextului de predicție

În aceasta etapă a lucrării au fost întreprinse cercetări pentru determinarea unei metode de selecție adaptivă a formei și dimensiunii contextului de predicție. S-a pornit de la un context de predicție de 8 pixeli în jurul lui x ($c_1, c_2, c_3, c_4, p_1, p_2, p_3$ și p_4 în figura 2.b). Pe baza acestui context s-au calculat ponderilor predictorului local. Vecinii care au primit o pondere mai mică decât $\frac{1}{4n}$ sunt eliminați din context, unde n este numărul de pixeli din contextul curent. Procesul este repetat pentru noul context de predicție până când acesta nu se mai schimbă de la o iterație la alta. Algoritmul a obținut un câștig limitat în PSNR (0.1 dB) și necesită mai multe etape de optimizare.

O altă abordare ce prezintă interes este marcarea în două (figura 2.a) sau multe etape folosind un context optimizat pentru etapa curentă. La capacități de marcare mai mari de 1 bpp distorsiunea introdusă de marcare este semnificativă, influențând negativ predicția pixelilor cu

un context parțial sau integral marcat. Soluția folosită curent în literatură este de a elimina complet din context pixelii marcați. Un astfel de context (cauzal sau anti-cauzal) oferă o predicție mai slabă decât unul centrat pe pixel (non-cauzal). Astfel investigăm folosirea în primele etape de marcarea a unor contexte non-cauzale, iar în ultima etapă folosirea unui context anti-cauzal mai slab decât cele clasice (sacrificând ultima etapă pentru o predicție mai bună în celelalte etape). În toate etapele se folosesc la predicție pixeli nemarcați.

Activitate 2.5. Achiziție echipamente si materiale

Achizițiile s-au desfășurat conform prevederilor contractului. S-a achiziționat: laptop, imprimantă, routere, plăci FPGA, plăci de dezvoltare, materiale (toner imprimantă, topuri de hârtie, marker tablă), audit.

Bibliografie

- [1] B. Ou, X. Li, Y. Zhao, R. Ni and Y.-Q. Shi, "Pairwise prediction-error expansion for efficient reversible data hiding," *IEEE Trans. on Image Processing*, vol. 22, no. 12, pp. 5010–5021, 2013.

- [2] I.-C. Dragoi and D. Coltuc, "Adaptive pairing reversible watermarking," *IEEE Trans. Image Process.*, vol. 25, no. 5, pp. 2420–2422, 2016.

- [3] I.-C. Dragoi, D. Coltuc, "Local Prediction Based Difference Expansion Reversible Watermarking," *IEEE Trans. on Image Processing*, vol. 23, no. 4, pp. 1779-1790, 2014.

- [4] I.-C. Dragoi, D. Coltuc, "On local prediction based reversible watermarking, *IEEE Trans. on Image Processing*," vol. 24, no. 4, pp. 1244-1246, 2015.

- [5] X. Wu, N. Memon. "Context-based, adaptive, lossless image coding," *IEEE Trans. on Commun.*, vol. 45, no. 4, pp. 437–444, 1997.

- [6] X. Li, J. Li, B. Li and B. Yang, "High-fidelity reversible data hiding scheme based on pixel-value-ordering and prediction-error expansion," *Signal Process.*, vol. 93, no. 1, pp. 198–205, 2013.
- [7] D. M. Thodi, J. J. Rodriguez, "Expansion Embedding Techniques for Reversible Watermarking," *IEEE Trans. on Image Processing*, vol. 15, pp. 721–729, 2007.
- [8] V. Sachnev, H. J. Kim, J. Nam, S. Suresh, Y. Q. Shi, "Reversible Watermarking Algorithm Using Sorting and Prediction," *IEEE Trans. on Circuits and Systems for Videotechnology*, vol. 19, no. 7, pp. 989-999, 2009.
- [9] B. Ou, X. Li and J. Wang, "High-fidelity reversible data hiding based on pixel-value-ordering and pairwise prediction-error expansion," *Journal of Visual Communication and Image Representation*, 39, pp. 12–23, 2016.