

11 Septembrie, 2013

Marius Leordeanu
Email: leordeanu@gmail.com
Telefon: +40746 033 711

Memoriu de Activitate Stiintifica

Domeniul nostru de cercetare este **Computer Vision**, o ramura din Inteligenta Artificiala de o importanta crescanda in stiinta, tehnologie si industrie. Computer Vision isi propune *sa inteleaga problema vederii (a interpretarii lumii vizuale)* si sa faca computerele sa *vada* si sa inteleaga lumea din imagini si secvente video, intr-un mod intelligent similar cu cel uman.

Metodele dezvoltate in computer vision fac posibila interpretarea automata a imaginilor si secventelor video: computerele de azi “vad”, de exemplu, daca intr-o imagine exista o fata umana, si sunt capabile sa o gaseasca si sa o recunoasca. Ele pot sa alinieze automat scene tri-dimensionale urbane pentru a crea automat harti 3D fotorealiste de tip Google Streetview. Metode recente din vision fac posibila lumea jocurilor pe calculator interactive (Microsoft Kinect) si a masinilor cu pilot automat (Google Driverless Car). Computer Vision leaga rezultate si cunostinte stiintifice din mai multe domenii precum Matematica, Statistica, Informatica, Invatarea Automata (Machine Learning), Inteligenta Artificiala, Robotica, dar si Stiente Neuro-cognitive. Aceasta stiinta va contribui esential si profund la dezvoltarea viitoare a lumii in care traim.

2010-2013: Detectarea Generalizata a Marginilor (Generalized Boundary Detection)

Problema de *Boundary detection* este fundamentala in computer vision si e esentiala pentru o varietate de sarcini cum ar fi gasirea automata a marginilor si contururilor de obiecte, segmentarea de regiuni semantice, detectarea simetriei, si recunoasterea de obiecte si categorii de obiecte. In [1,2] am introdus o formulare generalizata de boundary detection, cu solutie *closed-form*, aplicabila la localizarea diverselor tipuri de margini (boundaries), cum ar fi: margini in imagini naturale, si margini cauzate de ocluzie in secvente video. Metoda noastra de *Generalized Boundary Detection (Gb)* combina simultan interpretari ale imaginilor la mai diferite nivele de interpretare intr-o singura problema de optimizare (gasirea vectorului si a valorii proprii a unei matrici special construite) care

gaseste in mod optimal atat orientarea (vectorul propriu) cat si puterea raspunsului de margine (radicalul valorii propriei). Aceasta solutie complet noua face ca metoda noastra sa obtina rezultate state-of-the-art la un cost computational si de memorie mult mai scuzut (40x mai rapid) decat metodele competitioare curente. De asemenea, propunem doua componente care se combina natural cu Gb: mai intai, introducem o procedura foarte rapida de soft-segmentare care creeaza noi straturi de input (nivele de interpretare) pentru o imbunatarire semnificativa a performantei, si doi, propunem o metoda eficienta de grupare si clasificare pe contururi care, la un cost computational foarte scuzut, imbunataste si mai mult calitatea marginilor produse.

Rezultatele noastre, in forma lor initiala, au fost acceptate si publicate [1] mai intai la European Conference on Computer Vision (ECCV), Florenta, Italia, 2012 – una din primele trei conferinte din domeniu la nivel mondial. O extensie a acestei lucrari [2], care include metoda de interpretare inteligenta a contururilor a fost submisa la IEEE-Transactions on Pattern Analysis and Machine Intelligence (impact factor 6.68) si a trecut de prima faza de reviewing (o revizie a fost deja submisa si ne asteptam ca va fi acceptata). Cercetarea pe problema de boundary detection face parte dintr-o colaborare stransa si continua cu Google Research (Dr. Rahul Sukthankar).

La nici un an de la publicare, Gb a fost folosit deja [3] pentru imbunatarirea descriptorilor care folosesc informatii de segmentare semantica a obiectelor si regiunilor. Noii descriptori au fost publicati in IEEE-Computer Vision and Pattern Recognition, USA, 2013 [3].

References:

- [1] M. Leordeanu, R. Sukthankar and C. Sminchisescu, „Efficient Closed-Form Solution to Generalized Boundary Detection”, Florence, Italy, ECCV, 2012
- [2] M. Leordeanu, R. Sukthankar and C. Sminchisescu, „Generalized Boundaries from Multiple Image Interpretations”, (revision submitted), PAMI 2013
- [3] E. Trulls, I. Kokkinos, A. Sanfeliu and F. Moreno-Noguer, „Dense Segmentation-aware Descriptors”, CVPR, Ohio, USA, 2013

2010-2013: Sparse-to-dense Matching pentru estimarea automata de ocluzii si optical flow

Estimarea unui camp dens de corespondente intre frame succesive in video (optical flow estimation) e o problema esentiala in computer vision, cu aplicatii in multe probleme de invatare automata si recunoastere. Noi am dezvoltat o metoda noua de Sparse-to-Dense Matching pentru estimarea de optical flow si a zonelor de ocluzie. Aceast algoritm a fost acceptat pentru publicare la International Conference on Computer Vision (ICCV), Sydney, Australia, 2013 [4], (prima conferinta in lume din domeniu, , <http://www.iccv2013.org/>).

Ca o alternativa la abordarile piramidale curente de tip coarse-to-fine din literatura de optical flow, algoritmul nostru porneste cautarea de la nivelul mai inalt de interpretare folosind *Sparse Matching* cu descriptori de aparenta sofisticati si relatii geometrice complexe, folosind un model nou local afin care ia in considerare si zonele de ocluzie. Apoi, la pasii ulteriori, cautarea se rafineaza si se indreapta catre un model de flow mai clasic, folosind o metoda noua de interpolare sparse-to-dense, care ofera o tranzitie naturala intre campurile sparse si dense. De asemenea, demonstram experimental ca aspectele noastre de aparenta bogate, impreuna cu modelul de constrangeri geometrice complexe permit estimarea corecta a miscarii chiar si in cazurile de deplasari mari si schimbari de aparenta vizuala semnificativa. De asemenea, introducem si o metoda noua de clasificare pentru detectarea de ocluzii, care functioneaza in conjunctie cu metoda noastra de sparse-to-dense matching. Algoritmul introdus a fost validat experimental pe cea mai recenta, mai mare si mai dificila baza de date (Sintel) publica, pe care am obtinut rezultate state-of-the-art [5].

References

- [4] M. Leordeanu, A. Zanfir and C. Sminchisescu, „Locally Afine Sparse-to-Dense Matching for Motion and Occlusion Estimation”, Sydney, Australia, 2013
- [5] **Rezultatele noastre State-of-the-Art** officiale (metoda noastra apare S2D-Matching in tabelul oficial): <http://sintel.is.tue.mpg.de/results>

Important: metoda noastra (S2D-Matching) depaseste in performanta toate celelalte metode publicate pana acum, de la grupuri de cercetare de top din lume (Berkeley, Japan, Microsoft Research printre altele) pe baza de date Sintel – cel mai nou, mai extins si mai dificil set de testare

existent. In medie, metoda nepublicata inca Deep-Matching-Flow ne-a intrecut (dar nu pe toate tipurile de eroare) – aceasta metoda va apărea (va fi publicată) împreună cu a noastră la ICCV, Sydney, Australia, 2013. De notat e și faptul că metoda Complex-Flow (care apare în tabel) nu a fost acceptată pentru publicare.

2012-2013: Metode eficiente pentru recunoaștere în real-time de acțiuni în RGB-D video

Recunoașterea de acțiuni umane cu latenta observatională scăzută se bucură de un interes crescând în computer vision datorită dezvoltării rapide de tehnologii de interacțiune om-computer, jocuri interactive pe calculator și aplicații de supraveghere. Noi am dezvoltat o metoda rapidă, simplă și eficace (numita **Moving Pose Framework**) pentru recunoaștere cu latenta scăzută (Real-Time) de activități și acțiuni, care a fost acceptată pentru publicare la International Conference on Computer Vision [6] (ICCV), Sydney, Australia 2013 (prima conferință în lume din domeniu: <http://www.iccv2013.org/>).

Central metodologiei noastre este descriptorul **Moving Pose** care consideră atât informații despre pose (poziția corpului, ale membrilor și încheieturilor) cât și cantități diferențiale (viteză și accelerată) ale încheieturilor corpului în diferite momente în timp. Descriptorul propus, centrat temporal în jurul unei anumite frame de referință, este folosind în conjuncție cu un clasificator modificat de tip kNN - care consideră atât localizarea globală a framei în cadrul secvenței de acțiune, cât și puterea de discriminativitate a descrierii Moving Pose relativ la alte frame din setul de antrenare. Metoda rezultată este simplă, non-parametrică și face posibilă recunoașterea eficientă și cu latenta scăzută, învățarea *one-shot*, și detectia de acțiuni în secvențe nesegmentate dificile. De asemenea, framework-ul nostru este real-time, scalabil și depășeste ca performanță abordările competitoare pe baze de date precum Microsoft Research - Action3D și Microsoft Research - DailyActivities3D.

References

- [6] M. Zanfir, M. Leordeanu and C. Sminchisescu, „The *Moving Pose*: An Efficient 3D Kinematics Descriptor for Low-Latency Action Recognition and Detection”, ICCV, Sydney, Australia 2013.

2003:2013: Graph Matching, Invatare Automata si Optimizare, Modele Grafice Probabilistice

O parte importantă din cercetarea mea în computer vision include dezvoltarea de metode computationale eficiente pentru recunoașterea automată de obiecte și categorii de obiecte din imagini și secvențe video. Algoritmii pe care i-am dezvoltat iau în considerare atât caracteristici vizuale locale dar și relații geometrice de ordinul doi sau superior. Ele sunt legate de problema cunoscută sub numele de *graph matching*: obiectele sunt reprezentate ca și grafuri cu caracteristici vizuale continue în nodurile grafului și cu relațiile geometrice modelate de legaturile dintre noduri. Folosind graph matching obiectele pot fi găsite și recunoscute automat în imagini prin potrivirea automată dintre un graf-model (invatat automat în prealabil) și graful extras automat din imagine sau secvența video.

Metodele de graph matching pe care le-am publicat sunt considerate state-of-the-art în domeniu și, datorită eficienței lor, au fost preluate, utilizate și extinse mai departe în universități și centre de cercetare de prestigiu ale lumii. Acum, după zece ani de munca de cercetare pe aceasta tema, aş putea spune că rezultatele noastre în graph matching (majoritatea incluse în teza mea de doctorat [27]) au deschis poarta pentru graph matching-ul modern în computer vision, bazat pe formularea QAP (Quadratic Assignment Problem) și au contribuit fundamental la formarea unui drum nou pe problema de recunoaștere automată de obiecte în vision.

Problemele teoretice pe care le-am abordat pana acum sunt: 1) Graph și hiper-graph matching [7,16]; 2) Inferenta Maximum A Posteriori (MAP) în modele grafice probabilistice Markov Random Fields (MRFs) [14]; 3) Invățare automată supervizată, semi-supervizată și complet nesupervizată pentru graph și hypergraph matching și modele grafice probabilistice Markov Random Fields [11,16]. 4) Metode eficiente de hypergraph clustering [26] și alte metode de optimizare, cum ar fi optimizarea generală a funcțiilor non-negative [15].

Pe lângă contribuțiile mele pentru problema de Graph Matching, am dezvoltat, de asemenea, metode noi pentru alte probleme din computer vision cum ar fi: object tracking în secvențe de rezoluție scazuta [35], recunoșterea de categorii de obiecte[8], alinierea / gasirea de corespondente între scene urbane scanate 3D [36]. Mai în detaliu, rezultatele mele științifice includ:

1. Recunoașterea automata a obiectelor si categoriilor de obiecte

- Am combinat detectarea de obiecte cu graph matching folosind fragmente de contururi, astfel depășind cele mai bune rezultate oficiale din 2007 Pascal pentru patru clase de obiecte (în teza de doctorat). Am combinat, de asemenea, recunoașterea de categorii de obiecte bazata pe forma cu detectie de contururi specifice clasei de obiecte si am demonstrat o imbunatatire semnificativa fata de stat-of-the-art (ECCV 2008 [9]).
- Am proiectat si implementat un sistem care foloseste fragmente de conturui si metoda noastra de Spectral Graph Matching, rezultand intr-o metoda noua de invatare semi-supervizata de modele de clase de obiecte (publicate in CVPR 2007 [8] – prezentare orala). Această metodă a fost folosită ulterior pentru recunoașterea de acțiuni din video, la Universitatea din Florida (Yan et al., CVPR 2008 [25]). Ea a devenit subiectul unui capitol de carte (Dickinson et al., 2009 [21]) și a influențat mai multe abordări recente pentru descoperirea automata de obiecte din sevante video.
- Am dezvoltat o metodă de învățare nesupervizata de obiecte din sevante video, cu rezolutie redusa si in presenta ocluziilor (publicata in CVPR 2005 [13]).

2. Invatare automata si inferenta in modele grafice probabilistice

- Am dezvoltat un algoritm de învățare semi-supervizata pentru hypergraph matching si i-am demonstrat eficacitatea pe seturi dificile de date, cu performanta state-of-the-art (publicat in ICCV 2011 [16]). Acesta este primul algoritm publicat pentru invatare in Hypergraph Matching.
- Am propus metoda Inger Projected Fixed Point (IPFP) (NIPS 2009 [12]) pentru graph matching si inferenta MAP in Markov Random Fields. Aceasta a depasit semnificativ metodele state-of-the-art existente. Algoritmul este acum considerat a fi state of the art și a fost deja folosit si extins de catre alti cercetatori din strainatate pentru diferite probleme din computer vision: de exemplu, metoda IPFP a fost folosită pentru segmentarea imaginilor la Universitatea de Stat din Oregon - USA (Brendel et al, NIPS 2010 [17].) și Universitatea din Maryland - SUA (Chen și colab, CVPR 2011 [20]). Aceasta a fost, de asemenea, extinsa la Universitatea din New South Wales - Australia pentru inferență in MRFs de ordin superior (Semenovich et al, ICPR 2010 [28]).
- Am propus un algoritm eficient de învățare nesupervizata pentru graph matching (IJCV 2012 [11]). Este primul algoritm de invatare nesupervizata pentru graph matching. Am propus de asemenea o metodă similară de învățare pentru probleme de inferenta in modele grafice probabilistice (IJCV 2012 [11]).

- Am creat o metoda de inferenta pentru MRF's inspirata din metoda noastra de Spectral Graph Matching (publicat in ICML 2006 [14]). Metoda noastra a fost extinsa ulterior la Universitatea din Pennsylvania - SUA (Cour et al, AISTATS 2007 [18]). Aceasta a fost, de asemenea, folosita recent si de cercetatorii de la Universitatea Stanford și Google pentru segmentarea si clasificare de imagini (Huang et al., CVPR 2011 [29]).
- Am creat algoritmul Spectral Graph Matching (ICCV 2005 [7]) – o metoda eficientea de gasire de corespondente intre doua imagini (sau intre o imagine si un model) care foloseste atat caracteristici visuale locale cat si relatii geometrice. Această metodă a fost modificata ulterior și extinsa de mai multe grupuri de cercetare, cum ar fi printre altele: Universitatea din Pennsylvania - SUA si INRIA-Paris (Cour et al, NIPS 2007 [19]; Duchenne et al, CVPR 2009 [22]). Acest algoritm este utilizat de diverse grupuri de cercetare pentru: descoperire de obiecte (University of Central Florida [24], Intel Research Labs [33]), captarea miscarilor umane (Max Plank Institutul de Informatică [30]), potrivire de aspecte articulate pentru obiecte in imagini (Institutul Tehnologic Toyota din Chicago [32]) si modelare de scene 3D (Universitatea Tubingen [31]). O discutie mai ampla despre alte abordari care au folosit Spectral Graph Matching [7] se gaseste in teza mea de doctorat [27], in capitolul introductiv.

3. Optimizare

- Am proiectat o nouă metodă de Hypergraph Clustering, folosind relații de ordin doi si superior, care surclasaza alti algoritmi publicati recent (publicata in AISTATS 2012 [26]).
- Am dezvoltat un algoritm de optimizare globala, care surclasează pe experimentele noastre metode bine-cunoscute, cum ar fi Markov Chain Monte Carlo și Simulated Annealing (publicat in CVPR 2008 [15]). Un nou rezultat teoretic care leagă metoda noastră de metoda de inferenta Belief Propagation a fost publicat la Penn State University (M. Park, teza de doctorat, 2010 [34]).

References

- [7] M. Leordeanu and M. Hebert, A Spectral Technique for Correspondence Problems Using Pairwise Constraints, International Conference on Computer Vision (ICCV), 2005. **Citations: 331.**
- [8]. M Leordeanu, M. Hebert, R. Sukthankar, Beyond Local Appearance: Category Recognition from Pairwise Interactions of Simple Features CVPR 2007. **Citations: 102.**

- [9] J. Mairal, M. Leordeanu, F. Bach, M. Hebert and J. Ponce, Discriminative Sparse Image Models for Class-Specific Edge Detection and Image Interpretation, ECCV, 2008. **Citations: 84.**
- [10] J. Hays, M. Leordeanu, A. Efros and Y. Liu, Discovering Texture Regularity as a Higher-order Correspondence Problem, ECCV, 2006. **Citations: 83.**
- [11] M. Leordeanu, R. Sukthankar and M. Hebert, Unsupervised Learning for Graph Matching, International Journal of Computer Vision (IJCV), 2012. Impact factor: 5.76. **Citations: 32.**
- [12] M. Leordeanu, M. Hebert and R. Sukthankar, An Integer Projected Fixed Point Method for Graph Matching and MAP Inference, Neural Information Processing Systems, 2009. **Citations : 33.**
- [13]. M. Leordeanu and R. Collins, Unsupervised Learning of Object Features from Video Sequences, IEEE Computer Vision and Pattern Recognition (CVPR), 2005. **Citations: 28.**
- [14] M. Leordeanu and M. Hebert, Efficient MAP Approximation for Dense Energy Functions, International Conference on Machine Learning, USA, 2006. **Citations: 13.**
- [15] M. Leordeanu and M. Hebert, Smoothing-based Optimization, Computer Vision and Pattern Recognition, USA, 2008. **Citations: 6.**
- [16] M. Leordeanu, A. Zanfir and C. Sminchisescu, Semi-supervised Learning and Optimization for Hypergraph Matching, International Conference on Computer Vision, Barcelona, 2011. **Citations 6**
- [17] Brendel W, Todorovic S, “Segmentation as maximum weight independent set”, Advances in Neural Information Processing (NIPS), Canada, 2010. **Citations: 12.**
- [18] Cour et al., Solving markov random fields with spectral relaxation, Artificial Intelligence and Statistics (AISTATS), USA, 2007. **Citations: 27.**
- [19] Cour T, Srinivasan P, Shi J, Balanced Graph Matching, Advances in Neural Information Processing Systems (NIPS), Canada, 2007. **Citations: 120.**
- [20] Chen, Xi, et al. "Piecing together the segmentation jigsaw using context." Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on. IEEE, 2011. **Citations: 4.**
- [21]. Dickinson et al, “Object Categorization: Computer and Human Vision Perspectives”, Cambridge University Press, 2009
- [22] Duchenne O, Bach F, Kweon I, Ponce J, “A tensor-based algorithm for high-order graph matching”, Prize paper, CVPR 2009. **Citations: 115.**
- [23] Gaur, Utkarsh, et al. "A “string of feature graphs” model for recognition of complex activities in natural videos.", ICCV, 2011. **Citations 22.**

- [24] Liu, Jingen, Jiebo Luo, and Mubarak Shah. "Recognizing realistic actions from videos "in the wild"." IEEE Computer Vision and Pattern Recognition, USA, 2009. **Citations: 331.**
- [25] Yan, Pingkun, Saad M. Khan, and Mubarak Shah. "Learning 4d action feature models for arbitrary view action recognition." Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on. IEEE, 2008. **Citations 74.**
- [26] M. Leordeanu and C. Sminchisescu, Efficient Hypergraph Clustering, International Conference on Artificial Intelligence and Statistics (AISTATS), La Palma, 2012.
- [27] M. Leordeanu, Spectral Graph Matching, Learing and Inference for Computer Vision, PhD Thesis, Carnegie Mellon University, 2009.
- [28] Semenivich and Sowmya, Tensor power method for efficient MAP inference in higher-order MRF's, International Conference on Pattern Recognition (ICPR), 2010.
- [29] Huan et al., A hierarchical conditional random field model for labeling and segmenting images of street scenes, IEEE-Computer Vision and Pattern Recognition, 2011. **Citations: 8.**
- [30] E De Aguitar et al. Performance capture from sparse multi-view video, ACM Transactions on Computer Graphics SIGGRAPH, 2008, **Citations: 242.**
- [31]. B. Huhle et al., On-the-fly scene acquisition with a handy multi-sensor system, Int. Journal of Intelligent Systems Technologies and Applications, 2008. **Citations: 43**
- [32]. X. Ren, Learning and Matching Line Aspects for Articulated Objects, IEEE-Computer Vision and Pattern Recognition, 2007. **Citations: 14.**
- [33]. D. Parikh and T. Chen, Hierarchical semantics of objects (hSOs), International Conference on Computer Vision, 2007. **Citations: 29.**
- [34]. Minwoo Park, Efficient Mean-Shift Belief Propagation and Its Applications in Computer Vision, Doctoral Dissertation, USA, 2010.
- [35]. R. Collins, Y. Liu and M. Leordeanu, Online Selection of Discriminative Tracking Features, IEEE-TPAMI, 2005. **Citations: 927.**
- [36]. I. Stamos and M. Leordeanu, Automated Feature-based Range Registration of Urban Scence of Large Scale, IEEE-Computer Vision and Pattern Recogniton (CVPR), 2003. **Citations: 118.**