

Scurt rezumat al tezei de doctorat cu titlul (in limba engleza):

*Spectral Graph Matching, Learning, and
Inference for Computer Vision*

Marius Dan Leordeanu

Numar de Raport Tehnic: CMU-RI-TR-09-27

Conferita de catre:

*The Robotics Institute
Carnegie Mellon University
Pittsburgh, Pennsylvania 15213*

La data de: 16 iulie, 2009

Membrii comisiei de teza:

Prof. Dr. Martial Hebert (Presedintele comisiei),
Prof. Dr. Rahul Sukthankar,
Prof. Dr. Fernando De la Torre,
Prof. Dr. David Lowe (de la University of British Columbia).

Abstract

Un numar tot mai mare de aplicatii din *computer vision* (vedere artificiala) cum ar fi: recunoasterea de obiecte in 2D si 3D, recunoasterea categoriilor de obiecte, recunoasterea actiunilor in secvente video, descoperirea categoriilor de obiecte sau descoperirea si analiza texturii obiectelor, necesita abilitatea de a gasi eficient corespondente intre *interest points/local features* (puncte de interes sau trasaturi vizuale locale) extrase din imagini, secvente video sau apartinand unor modele (invatate automat sau construite manual).

Metoda de gasire a corespondentelor dintre *local features* (trasaturi locale) trebuie sa fie robusta, sa functioneze eficient si cat mai corect in prezenta altor obiecte din *background* (numite *distractors*), a ocluziei partiale, a deformatiilor elastice sau transformarilor rigide (rotatie, translatie, scalare sau o combinatie a acestora). Pentru a imbunatati robustetea dar si acuratetea de *matching* (gasirea corespondentelor) este important sa luam in considerare nu numai proprietatile locale (*local appearance*) ale punctelor de interes (*interest points/local features*), dar si relatiile de ordine superioara, geometrice, dintre ele (*higher-order geometric relationships*).

In aceasta teza formulam problema gasirii corespondentelor ca pe o problema de *graph matching* (potrivire de grafuri: gasirea corespondentelor dintre nodurile a doua grafuri) pentru care propunem mai multi algoritmi, bazati pe o formulare de *Integer Quadratic Programming* (IQP).

Mai intai prezentam algoritmul nostru *spectral matching*, o metoda eficienta pentru *feature matching*, care foloseste atat informatii de ordin local (*first-order*,

local appearance information) la nivelul trasaturilor vizuale locale, dar si relatiile geometrice dintre perechi de puncte de interes/trasaturi locale (*interest points/local features*). In aceasta teza analizam in detaliu proprietatile teoretice ale acestui algoritm si, de asemenea, prezentam modalitati eficiente de utilizare a acestor metode in aplicatii practice din *computer vision* (vedere artificiala).

De asemenea, propunem o metoda noua pentru “discretizarea” (obtinerea unei solutii cu elemente discrete de “0” sau “1”) din ultima faza de procesare, cand solutia finala “discreta” sau “binara” e gasita. Aceasta noua metoda (cunoscuta sub acronimul IPFP – *Integer Projected Fixed-Point Method*) are proprietati teoretice importante, dar si o performanta superioara metodelor *state-of-the-art* curente.

Teza cuprinde si alte metode originale (majoritatea publicate in conferinte de top internationale) precum cele pentru invatarea parametrilor optimi folositi in *graph matching* si *MAP (Maximum A Posteriori) inference* din domeniul modelelor grafice probabilistice (cunoscute in engleza sub denumirile: *Probabilistic Graphical Models, Markov Random Fields, Pairwise Markov Networks, Bayesian Networks, etc.*).

In aceasta teza exploram pentru prima data legatura dintre *graph matching* si *MAP inference* si propunem algoritmi eficienti si competitivi atat pentru *matching* (potrivire) si *inference* (inferenta) cat si pentru *learning* (invatare).

Toate metodele sunt prezentate in detaliu atat din punct de vedere teoretic cit si practic/experimental, folosind cele mai noi baze de date folosite in *computer vision*. In cele ce urmeaza vom prezenta pe scurt subiectul fiecarui capitol. Tinind cont de faptul ca teza originala cuprinde un material dens, elaborat pe parcursul a mai bine de 200 de pagini, in acest scurt rezumat nu abordam subiectul in

profunzime. Din acest motiv, ii incurajam pe cei interesati sa consulte teza in original pentru mai multe detalii si lamuriri.

Capitolul 1: Introducere

Incepem acest capitol prin a prezenta formularea *IQP (Integer Quadratic Programming)* a problemei de *graph matching* (gasirea de corespondente intre puncte de interes folosind relatiile geometrice dintre ele). Noi am fost printre primii care am introdus formularea *IQP* a problemei de *graph matching* in *computer vision*, intr-una din lucrarile noastre anterioare [1], alaturi de autorii lucrarii [10] - scrisa independent de a noastra si publicata in acelasi an (2005).

Tot aici prezentam pe scurt istoria problemei de *graph matching* din *computer vision*, precum si cele mai noi abordari. Metoda noastra numita *spectral matching* [1] si destul de binecunoscuta azi in domeniu, a pornit un val de noi metode si aplicatii legate de *graph matching*. Toate aceste metode au fost dezvoltate pentru a imbunatati atat viteza de *matching* (complexitatea) cat si calitatea performantei (*the matching rate*). O alta metoda pe care am publicat-o mai recent, numita *Integer Projected Fixed-Point Algorithm (IPFP)* [2], si prezentata pe larg in Capitolul 4 al acestei teze, a continuat si dezvoltat ideea din [1] si se numara in acest moment printre cele mai eficiente si mai performante din *computer vision*.

In acest prim capitol introducem, in mare, ideile cele mai importante pe care se bazeaza algoritmul *spectral matching*, metoda fiind prezentata mai pe larg in capitolul al doilea. Tot in primul capitol trecem in revista continutul capitolelor urmatoare din teza, fiecare adresand un subiect anume, introducand metode noi de

optimizare si de invatare automata, cu aplicatii practice (unde e cazul) si cu demonstratii experimentale.

De asemenea, tot aici prezentam o lista cu cele mai importante aplicatii din *computer vision*, care folosesc algoritmul nostru *spectral matching*. O parte dintre aceste aplicatii ne apartin, insa cea mai mare parte a lor sint dezvoltate de alte grupuri de cercetare, care au folosit metoda noastra. Aplicatiile variaza de la recunoastere de obiecte in imagini, reconstructii automate 3D, recunoastere de actiuni in video, precum si descoperirea automata de obiecte din imagini si secvente video. Aplicatiile sint destul de numeroase si variate, fapt care demonstreaza aplicabilitatea si importanta metodei *spectral matching*, ale carei proprietati esentiale sunt: performanta calitativa, viteza de executie, usurinta in implementare si motivatia intuitiva. Enumeram aici printre aplicatiile noastre in care am folosit acest algoritm: [3], [4] si [5]. Printre aplicatiile notabile care apartin altor grupuri de cercetare si care folosesc metoda noastra se numara: [6], [7], [8] si [9].

Pe scurt, cele mai importante contributii aduse in aceasta teza sunt:

1. **Algoritmul *spectral matching* (Capitolul 2):** publicat initial in 2005 [1], acest algoritm e cunoscut azi ca fiind unul din cei mai eficienti pentru *graph matching*. Lucrarea noastra [1] a acumulat pina in prezent mai mult de 130 de citatii (sursa: Google Scholar), si a constituit un punct de plecare in dezvoltarea altor algoritmi din domeniu, fiind folosita cu succes de cercetatori din intreaga lume.
2. **Algoritmul *spectral MAP inference* (Capitolul 3):** o metoda performanta, inspirata din algoritmul *spectral matching*, avind proprietati teoretice importante; este folosita pentru *MAP inference* in modele grafice

- probabilistice. In experimentele noastre algoritmul este superior unor metode populare precum *Loopy Belief Propagation* si *Iterated Conditional Modes*.
3. **Algoritmul *Integer Projected Fixed Point (IPFP)* (Capitolul 4):** o metoda de inferenta pentru *graph matching*; superioara algoritmului *spectral matching*. Publicata in 2009, IPFP este la ora actuala o metoda de top; s-a dovedit net superioara celor existente in numeroasele noastre experimente. Inspirata din *spectral matching*, pare a fi inrudita si cu alti algoritmi aplicati in alte domenii, precum *Iterated Conditional Modes* pentru modele grafice probabilistice si algoritmul *Frank-Wolfe* de optimizare a functiilor convexe.
 4. **Invatare automata nesupervizata pentru *graph matching* (Capitolul 5):** singura metoda publicata (CVPR 2009), dupa cunostintele noastre, care invata parametrii pentru *graph matching* in mod nesupervizat
 5. **O metoda originala de invatare pentru modele grafice probabilistice (Capitolul 6)**
 6. **Aplicatii ale metodelor prezentate in recunoasterea categoriilor de obiecte (Capitolul 7):** metode originale si eficiente, cu rezultate state-of-the-art.
 7. **Un nou algoritm de optimizare numit *Smoothing-based Optimization* (capitolul 8):** un algoritm cu proprietati practice si teoretice importante. In capitolul 8 prezentam si citeva aplicatii ale acestuia in *computer vision*.

Capitolul 2: *Spectral Matching*

In acest capitol prezentam in detaliu algoritmul *spectral matching* [1]. Aceasta metoda are la baza urmatoarea formulare: corespondentele posibile (*candidate*

assignments) formeaza un graf in care nodurile reprezinta posibile corespondente (i,a) unde i este indexul unui *feature/interest-point* din model iar a este indexul unui *feature* din imaginea de test. Setul de noduri poate cuprinde toate corespondentele posibile de tipul (i,a) sau doar un subset al acestora, obtinut in prealabil prin mentinerea acelor perechi care ar putea fi puse in corespondenta, considerand doar trasaturile vizuale locale (descriptori locali, care nu iau in considerare geometria).

Muchiile grafului au asociate scoruri pozitive $M_{ia:jb}$, care reflecta cat de bine se potriveste (atat la nivelul trasaturilor locale dar si la un nivel mai inalt, geometric), perechea de *features* (i, j) din model cu perechea de *features* (a,b) din imaginea de test.

In lucrarea mentionata [1] am facut o observatie importanta, care sta la baza algoritmului *spectral matching*: perechile de corespondente corecte formeaza un *cluster* (grup) cu muchii care au scoruri mari, pe cand cele incorecte formeaza intre ele muchii foarte slabe, si doar in mod sporadic, accidental (aceasta idee este inrudită de ideea de *accidental alignments*, care a fost introdusa pentru prima data in computer vision de Prof. David Lowe in anii '80, membru al comisiei mele de teza).

Observatia noastra sugereaza ca subsetul corespondentelor corecte poate fi gasit, in mod aproximativ, prin aflarea *cluster*-ului cel mai puternic (ca suma a valorilor asociate muchiilor corespunzatoare) al grafului de corespondente (graful mentionat mai sus, in care nodurile reprezinta posibile corespondente de tipul (i,a) iar muchiile au asociate scoruri $M_{ia:jb}$, care reflecta potrivirea dintre perechi de corespondente de forma $\{(i,a),(j,b)\}$).

Matricea de adiacenta M a acestui graf (simetrica si cu elemente pozitive) este construita iar clusterul respectiv este aflat, in mod aproximativ, prin calcularea vectorului propriu principal al acestei matrici M (acest vector are elemente pozitive, conform teoremei lui Perron-Frobenius si poate fi calculat eficient folosind metoda de *Power Iteration*).

Este binecunoscut faptul ca vectorii proprii ai unei matrici de adiacenta reflecta structura grafului corespunzator. Prin “discretizarea” adecvata a vectorului propriu principal al matricii de adiacenta M , gasim *cluster*-ul de corespondente corecte care respecta constrangerile de *one-to-one matching* (functia de punere in corespondenta este injectiva) si care maximizeaza scorul total (suma scorurilor tuturor perechilor de corespondente gasite este maximizat).

In lucrarea [1] am oferit pentru prima data in *computer vision*, alaturi de [10], intepratarea problemei de *graph matching* sub forma QAP (*Quadratic Assignment Problem*). QAP este o problema NP-hard si, prin urmare, nu exista solutii eficiente care sa ofere solutia exacta a optimului global. Solutia oferita de algoritmul nostru este aproximativa, insa calitativa si foarte eficienta, fapt care a dus la cresterea popularitatii acestei metode. Acest algoritm a stat la baza dezvoltarii altore metode de *graph matching* de catre alte grupuri de cercetare, cum ar fi, de exemplu, [16].

Mai multe detalii tehnice ale acestei metode sunt discutate pe larg in teza. Atat in acest capitol cat si pe parcursul intregii lucrari oferim experimentele necesare, in care comparam calitativ dar si din punctul de vedere al vitezei de executie algoritmi propusi de noi cu cei existenti, dovedind, nu de putine ori, superioritatea metodelor noastre.

Capitolul 3: Spectral MAP Inference

Lucrarea noastra [11] se numara printre primele care observa legatura stransa dintre problemele de *graph matching* si *MAP inference* din modelele grafice probabilistice (*Probabilistic Graphical Models*). In acest capitol prezentam pe larg materialul publicat initial in [11]. De asemenea, explicam legatura dintre *graph matching* si *MAP inference* si dezvoltam un algoritm inspirat din *spectral matching*, care poate fi folosit cu succes pentru MAP inference. In plus, oferim o evaluare experimentală solida, in care comparăm metoda noastră cu alte metode arhicunoscute, precum Loopy Belief Propagation (Loopy-BP) si Iterated Conditional Modes (ICM). Algoritmul prezentat in acest capitol, publicat de noi initial in [11], a constiuit punctul de plecare pentru varianta lui imbunatatita, dezvoltata de un alt grup de cercetare in lucrarea [17].

Capitolul 4: Obținerea unei soluții “discrete”

Dupa cum am mentionat anterior, este binecunoscut faptul ca problema de *graph matching* este *NP-hard*. Prin urmare metodele eficiente gasesc doar solutii aproximative.

Majoritatea algoritmilor moderni ofera solutii optime globale ale unor formulari modificate ale problemei, pentru care optimul global poate fi aflat in mod eficient: aceste formulari relaxeaza domeniul solutiilor astfel incat o solutie optima poate fi gasita in mod eficient.

Algoritmul *spectral matching* se numara printre astfel de metode, care ofera o solutie globala a problemei modificate, cu un domeniu relaxat: cu alte cuvinte, in

loc sa se rezolve problema originala care este NP-hard, rezolva o problema similara, dar mult mai simpla, in care solutia optima este vectorul propriu al matricei de adiacenta M a grafului de corespondente (avand ca noduri corespondentele posibile).

Asemenea metode (*relaxation methods*) se bazeaza pe intuitia ca aceste solutii globale ale problemelor modificate/relaxate (*relaxed problems*) sunt apropiate de solutia globala a problemei initiale. Totusi, aceasta idee e doar o intuitie si nu e nicidecum demonstrata teoretic. In acest capitol noi aratam de fapt contrariul: solutiile optime ale problemei relaxate pot fi adesea departe de solutia optima a problemei oringiale. Daca pana acum aflarea solutiei discrete (in domeniul initial discret/binar de constringeri *one-to-one*) a fost un pas aparent nesemnificativ, noi demonstram experimental contrariul: discretizarea este un pas esential si trebuie facuta cu grija. Aceasta obeservatie a dus la nasterea unui alt algoritim, IPFP [2], insiprat din *spectral matching*, pe care il prezentam pe larg in acest capitol (si pe care l-am mentionat anterior). IPFP, in loc sa ofere o solutie globala, ofera una locala dar situata in domeniul original al problemei. Aceasta metoda, pe care am numit-o *Integer Projected Fixed-Point*, se dovedeste a fi superioara din punct de vedere calitativ metodelor state-of-the-art publicate anterior. Chiar daca IPFP, din punct de vedere al timpului de executie, este sensibil mai incet decit *spectral matching* (care este probabil cel mai rapid algoritim de *spectral matching* la ora actuala) din punct de vedere al performantei de *matching*, in schimb, IPFP este net superior.

Prezentat in linii mari, IPFP pare a fi versiunea discreta a metodei *spectral matching*. Este inrudit si cu alte metode din optimizare si *machine learning*, care, in schimb, nu par a fi inrudite intre ele. De exemplu, IPFP este o versiune paralela, mai complexa, mai generala si mai performanta a popularului algoritim Iterated

Conditional Modes [14], publicat initial pe la sfirsitul anilor '80. De asemenea, este inrudit si cu un algoritim clasic folosit in *operation research*, cunoscut sub numele de *Frank-Wolfe algorithm* [15] (cunoscut si sub numele de: *reduced gradient method* sau *convex combination algorithm*). De la publicarea lui IPFP in 2009, au mai aparut cel putin doua metode ([12] si [13]) care il citeaza si par a-l folosi ca sursa de inspiratie.

Capitolul 5: Invatare Automata pentru Graph Matching

Ca si in cazul altor probleme din *computer vision*, problema invatarii automate este esentiala pentru graph matching, contribuind substantial la imbunatatirea performantei in practica. Cu toate acestea, nu sint multe lucrari publicate pe aceasta tema. Noi oferim o metoda eficienta de invatare automata [3] si, pentru prima (si, pina acum, singura) data in literatura de specialitate, oferim o metoda de invatare intr-un mod nesupervizat, spre deosebire de metodele existente care necesita cunosterea corespondentelor corecte (asa-numitul *ground truth*) in timpul invatarii. Tindind cont ca obtinerea manuala a *ground-truth*-ului pentru gasirea de corespondente necesita rabdare si un timp relativ indelungat din partea utilizatorului, oferta unei solutii nesupervizate sau semi-supervizate este foarte importanta si binevenita.

In linii mari, metoda consta in modificarea automata a elementelor matricii de adiacenta M a grafului de corespondente (aceeasi matrice folosita si pina acum de *spectral matching*, IPFP, precum si celelalte metode prezentate), in directia care apropie vectorul propriu principal al lui M , de un vector cu elemente discrete/binare. Aceasta "binarizare" sau "discretizare" a vectorului propriu se obtine prin calcularea eficienta a derivatelor pariale ale acestuia in functie de

parametrii care definesc scorurile $M_{ia;jb}$ (care sunt elementele matricii de adiacenta M).

In acest capitol oferim atat explicatiile si motivatiile de ordin teoretic, cit si o evaluare substantiala experimentală care arata ca metoda poate fi folosita cu success pentru a imbunatati semnificativ performantele algoritmilor state-of-the art de *graph matching*.

Capitolul 6: Invatare automata pentru *MAP inference*

In capitolul anterior am prezentat o metoda de invatare automata pentru *graph matching*. In capitolele anterioare am mentionat ca problema de *graph matching* este strans legata de problema de inferenta (cunoscuta sub numele de *MAP inference*) din modelele grafice probabilistice. Am facut aceasta paralela oferind algoritmi de inferenta similari pentru *graph matching* si *MAP Inference*. In acelasi mod, in acest capitol, prezentam un algoritm de invatare automata care imbunatateste rezultatele obtinute pentru *MAP inference*, inspirat de cel prezentat in capitolul anterior pentru *graph matching*.

Daca in cazul problemei de *graph matching* a fost posibila invatarea nesupervizata, in cazul de *MAP Inference*, care este un caz mai general, nu se poate efectua invatarea nesupervizata de fiecare data, ci doar in cazul anumitor probleme particulare. In acest capitol oferim explicatiile necesare precum si evaluarea experimentală care le justifica practic. De exemplu, invatarea nesupervizata este posibila pentru cazul de *de-noising images* cu un model de *noise* (zgomot) simplu, insa esueaza pentru modele de zgomot mai complicate. Din fericire, invatarea automata supervizata functioneaza cu succes in ambele cazuri.

Capitolul 7: Aplicatii pentru Recunoastere de Obiecte

Problema recunoasterii de obiecte este una dintre cele mai grele si mai importante in *computer vision*. Algoritmii prezentati anterior au ca ultim scop imbunatatirea performantelor in recunoasterea de obiecte. Nu este evident insa modul in care pot fi folositi eficient pentru recunoasterea de obiecte sau a categoriilor de obiecte. Urmind metoda pe care am publicat-o in 2007, in acest capitol oferim mai pe larg solutii eficiente pentru aplicarea metodelor de *graph matching* prezentate in capitolele anterioare in problemele de recunoastere automata. Demonstram ca metoda noastra poate imbunatati semnificativ rezultatele state-of-the-art curente, prin combinarea metodelor noastre care se bazeaza in special pe geometrie (forma obiectelor: de exemplu, forma unei masini) cu metode dezvoltate de alte grupuri de cercetare care se axeaza in principal pe recunoasterea contextului (locul in care se afla obiectele: de exemplu, strada pe care circula masini). Ca si in cazul altor metode de-ale noastre si algoritmul prezentat in acest capitol a folosit, in forma modificata, altor grupuri de cercetare, cum ar fi lucrearea [18].

Ca sa demonstram puterea ideilor din *graph matching* care folosesc *second-order geometric constraints* (constringeri geometrice de ordinul 2) ne axam pe cazul unor descriptori locali foarte simpli (puncte alese pe contururi si vectorii normali conturilor conrespunzatori), si aratam ca folosirea de informatii geometrice, de ordin secundar, e suficient de puternica pentru a imbunatati rezultatele metodelor state-of-the-art care nu folosesc deloc relatiile geometrice dintre trasaturile locale.

Majoritatea cercetatorilor sunt de acord, in principiu, ca geometria conteaza, dar sunt putine lucrari publicate care sa demonstreze acest lucru in competitiiile dificile curente. In majoritatea lucrarilor se folosesc descriptori locali folosind metoda

bag-of-words, pentru ca modul optim de folosire a geometriei nu este inca stiut, iar geometria e, in general, foarte costisitoare, fara a aduce, aparent, imbunatari evidente. Pe parcursul acestei teze oferim solutii eficiente de folosire a geometriei. Prezentam atat justificari teoretice solide, cat si evaluari extensive pe baze de date dificile, folosite in acest moment in competitiiile si lucrarile de la cel mai inalt nivel international din *computer vision*.

Capitolul 8: Grouping based on color

In Capitolul 8 oferim o metoda simpla, dar eficienta, de extragere a mastii obiectelor recunoscute folosind metodele prezentate anterior. Chiar daca aceasta metoda care se bazeaza pe idei de *grouping* (inrudite cu idei dezvoltate inca din anii '80) nu se ridica la nivelul materialelor din capitolele anterioare din punct de vedere teoretic, in mod practic in schimb, poate fi extrem de folositoare si de aceea am inclus-o in aceasta teza.

Apendix: Smoothing-based Optimization

In appendix prezentam metoda de optimizare pe care am publicat-o initial in CVPR 2008 si pe care am folosit-o pentru invatarea automata supervizata pentru *graph matching*, inainte de a dezvolta metoda din capitolul 5. Chiar daca noi am aplicat aceasata metoda pe un caz foarte particular, ea este mult mai generala si se aplica optimizarii de functii cu valori pozitive continue sau discontinue. Singura cerinta este ca functia sa aiba valori pozitive si sa poata fi evaluata in orice punct al domeniului de definitie, fara a fi nevoie forma *closed-form* (analitica) a functiei. Noi credem ca aceasta metoda nu a fost explorata suficient si ca merita o atentie mai aprofundata in domeniul optimizarii generale. Este in mod cert un algoritm

cu potential, care ar putea deveni o metoda cu impact mai mare daca ar fi analizata mai in detaliu si dezvoltata mai mult.

Bibliografie

- [1]. *A Spectral Technique for Correspondence Problems using Pairwise Constraints*, Marius Leordeanu and Martial Hebert, in International Conference on Computer Vision (ICCV), 2005.
- [2]. *Integer-Projected Fixed Point Method for Graph Matching and MAP Inference Problems*, Marius Leordeanu, Martial Hebert and Rahul Shukthankar, Neural Information and Processing Systems (NIPS), 2010.
- [3]. *Unsupervised Learning of Object Features from Video Sequences*, Marius Leordeanu and Robert Collins, in Computer Vision and Pattern Recognition COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2005
- [4]. *Discovering Texture Regularity as a Higher-Order Correspondence Problem*, J. Hays, M. Leordeanu, A. Efros and Yanxi Liu, in European Conference on Computer Vision (ECCV), 2006.
- [5]. *Beyond Local Appearance: Category Recognition from Pairwise Interactions of Simple Features*, Marius Leordeanu, Martial Hebert, Rahul Sukthankar, in COMPUTER VISION AND PATTERN RECOGNITION (CVPR) 2007.
- [6]. *Performance capture from sparse multi-view video*, E De Aguitar et al., SIGGRAPH 2008
- [7]. *Recognizing realistic actions from videos “in the wild”*, J. Liu et al, COMPUTER VISION AND PATTERN RECOGNITION (CVPR) 2009

- [8]. Unsupervised image categorization and object localization using topic models and correspondences between images, D. Liu et al, International Conference on Computer Vision (ICCV) 2007
- [9] On-the-fly scene acquisition with a handy multi-sensor system, *International Journal of Intelligent Systems Technologies and Applications*, Benjamin Huhle et al, 2008
- [10] Shape matching and object recognition using low distortion correspondences, A. Berg, T. Berg and J. Malik, COMPUTER VISION AND PATTERN RECOGNITION (CVPR) 2005
- [11] Efficient MAP approximation for dense energy functions, Marius Leordeanu and Martial Hebert, International Conference on Machine Learning (ICML) 2006
- [12] Segmentation as Maximum-Weight Independent Set, W. Brendel and S. Todorovic, Neural Information Processing Systems (NIPS) 2010
- [13] Tensor power method for efficient MAP inference in higher-order MRFs, D. Semenovich and A. Sowmya, International Conference on Pattern Recognition, (ICPR) 2010.
- [14]. Statistical analysis of dirty pictures, J. Besag, Journal of Applied Statistics, 1993
- [15] An algorithm for quadratic programming, M. Frank and P. Wolfe, Naval Research Logistics Quarterly, 1956
- [16] Balanced graph matching, T. Cour, P.Srinivasan and J. Shi, Neural Information Processing Systems (NIPS), 2006
- [17] Solving Random Markov Fields with Spectral Relaxation, T. Cour and J. Shi, International Conference on Artificial Intelligence and Statistics (AISTATS) , 2007
- [18] Recognizing Realistic Actions from Videos “in the Wild”, J. Liu, J. Luo, M. Shah, in COMPUTER VISION AND PATTERN RECOGNITION (CVPR) 2009