
Teme

[L]icenta [C]ercetare-[D]isertatie

Conf. Dr. Ing. Costin-Anton Boiangiu (costin.boiangiu@cs.pub.ro)

Ing. Mihai Zaharescu (mihzaha@yahoo.com)

Observatii:

- Pentru orice fel de detalii suplimentare va rog sa ne contactati prin e-mail (costin.boiangiu@cs.pub.ro, mihzaha@yahoo.com) sau sa ne vizitati in sala EG405b!
- Unele teme pot fi alese de catre mai multi studenti impreuna, cu o crestere corespunzatoare a dificultatii/cerintelor.
- Activitatea de cercetare se poate desfasura pe parcursul celor 2 ani de master si se poate finaliza cu lucrare de disertatie
- Apreciem in mod deosebit inventivitatea studentilor in cazul tratarii temelor alese, incurajam cercetarea unor noi abordari si suntem interesati de a gasi solutii impreuna la problemele ivite!

LCD An Image Binarization Algorithm Using Watershed-Based Local Thresholding

Algoritmii care sunt aplicați asupra localităților (vecinătăților unui pixel) consideră o fereastră rectangulară în jurul pixelului de prelucrat. În această fereastră pot intra și alte obiecte decât cele care se vor să influențeze rezultatul. În prezent, singura soluție este să se micșoreze fereastra astfel încât să excludă obiectele străine și să le includă doar pe cele utile.

Metoda de față vrea să definească un alt tip de localitate, care poate avea orice formă, folosindu-se de doi algoritmi fundamentali: Watershed, pentru o segmentare localizată, și Otsu, global. Petecele rezultate din segmentare sunt localitățile care vor fi procesate cu algoritmul dorit.

Separat cei doi algoritmi nu produc o segmentare de calitate foarte bună, Watershed având tendința de a supra-segmenta iar Otsu de a pierde detalii locale.

Metoda dezvoltată vrea să se folosească de puterea de clasificare a lui Otsu, dar să includă detaliile locale din watershed. Pentru aceasta, se aplică întâi segmentarea Watershed cu parametri setați astfel încât să se obțină zone relativ mari ce conțin doar două tipuri de informație. Asupra rezultatului, pentru fiecare cluster se aplică binarizarea Otsu care separă cele două clase astfel încât diferența dintre ele să fie maximă.

Avantajul acestei metode este că se calculează un prag local pentru fiecare segment similar din imagine. În rezultate se observă detalii greu deductibile altfel, dar există tendința de a clasifica zone neimportante ca și importante. Ca și continuare ne propunem să includem un pas de filtrare a zonelor neimportante.

Documente externe explicative / Bibliografie

- An Image Binarization Algorithm Using Watershed-Based Local Thresholding.PDF

LCD Elemental Dust: Another Signal Perspective

În prezent, singurele metode pentru stocarea imaginilor sunt în format raster (pixeli) sau în format vectorial (curbe). Niciunul din formate nu este total satisfăcător: formatul raster nu se comportă bine la transformări geometrice, iar formatul vectorial simplifică foarte mult imaginea inițială.

Formatul propus se folosește de puncte de informație. Fiecare pixel conține mai multe puncte luminoase sau întunecoase aranjate în așa fel încât trecerile de la o zonă întunecoasă la una luminoasă să fie lină, dar marginile să rămână clare. De asemenea, ele se comportă ca particule care se resping, fiind împrăștiate uniform în zone uniforme.

Rezultatele obținute în urma transformărilor geometrice aplicate (deformare perspectivă și deformare perspectivă cu valuri) arată că nu a intervenit niciun artificiu, care ar fi intervenit în mod normal în imaginile raster. De asemenea, nu este nicio diferență de calitate între imaginea raster nemodificată și cea reținută ca și puncte de informație.

Pentru continuarea temei, trebuie să găsiți o metodă de stocare eficientă a punctelor de informație, întrucât stocarea a două variabile float (poziția x , y) pentru fiecare punct generează un fișier de dimensiune foarte mare. Generarea unor puncte distribuite uniform, similar pentru fiecare pixel pierde din generalitate.

Documente externe explicative / Bibliografie

- Elemental Dust - Another Signal Perspective.pdf

LCD Refacerea Detaliilor din Imagini după o Succesiune de 2-1 Downsampling - Upsampling

Compresia video actuală nu permite o metodă prin care calitatea să se poată adapta la viteza conexiunii, aceasta fiind setată la început. Scăderi în viteza rețelei pot duce la întreruperea filmului, iar creșteri în viteză nu adaugă calitate.

Metoda de downsampling și upsampling permite sistemului să se adapteze în funcție de viteza instantanee a rețelei. Un frame este spart într-o piramidă de imagini reziduale și o imagine de bază, prin redimensionarea imaginii la jumătate și înapoi și scăderea ei din imaginea inițială. Nivelul de reziduu rezultat este mult mai uniform decât imaginea inițială și poate fi codat cu Huffman. Când conexiunea este bună se pot trimite toate straturile din piramidă, iar când viteza scade, se trimit doar primele straturi.

S-au observat reduceri cu 75% în dimensiunea frame-urilor, iar sistemul este adaptiv la fluctuațiile de viteză.

Pentru a păstra cât mai mult din calitatea inițială, această metodă poate fi îmbunătățită cu un algoritm de Super Resolution folosind cadrele anterioare (metodă prezentată la super resolution cu mai multe imagini), sau cu trimiterea a câtorva informații în plus cu ajutorul cărora să se genereze detalii în plus la interpolare, sau chiar cu metode bazate pe super resolution cu fractali sau vectorizare (super resolution cu Generalised Edge), care să adauge detaliu artificial.

Documente externe explicative / Bibliografie

- [Work in progress] Upsampling_Downsampling.PDF

CD Simulator Univers

Viteza de observare a fenomenelor cosmologice, dar și de descoperire de noi teorii matematice pentru explicarea mediului înconjurător a crescut enorm odată cu dezvoltarea tehnologiei și aplicarea ei pe piața de larg consum. Ultimele descoperiri au nevoie de testare și analizare rapidă și într-un mediu virtual.

Proiectul de față analizează modele cunoscute de fizică în simularea interacțiunii între particule cosmologice (de la gaze la obiecte solide care generează câmp gravitațional puternic) și metode propuse pentru transformarea lor în modele informatice viabile (evitarea depășirilor numerice), de exemplu prin modelarea singularităților gravitaționale sau a obiectelor cu viteze foarte mari. De

asemenea, mai analizează și metode de optimizare de memorie și calcul, atât prin modelări matematice (analizarea obiectelor care nu pot interacționa între ele sau obiecte care nu își mai modifică starea și care pot fi caracterizate împreună printr-o altă ecuație) cât și prin modelări de Geometrie Computațională (simularea gravitației prin mesh încadrator) dar și prin modelarea datelor folosind tehnici de structuri de date și paternuri de programare paralela.

Documente externe explicative / Bibliografie

- 3DUnivers.PDF

LCD Analiza de layout prin votare

Analiza de layout presupune etichetarea diverselor blocuri ca fiind zone de text, ilustrații, simboluri matematice.

Au fost dezvoltate metode atât top-down (pagina e împărțită repetat în bucăți tot mai mici), bottom-up (se grupează componentele de bază în funcție de similaritatea dintre ele) dar și hibride. Acestea pot folosi cunoștințe semantice, metode geometrice, operații morfologice dar și euristici, ceea ce poate să le specializeze pe un anumit tip de document.

Lucrarea de față își propune să dezvolte un sistem de votare prin care să se aleagă algoritmul care se comportă cel mai bine pe fragmentul respectiv de pagină. Rezultatele sunt comparabile cu cele furnizate de o abordare unilaterală specializată deși au fost folosite metode simple de segmentare.

Pentru continuarea temei va trebui să dezvoltați noi metode de analiză sau segmentare a paginilor sau o metodă mai bună de votare.

Documente externe explicative / Bibliografie

- Voting-Based Layout Analysis.PDF

LCD OCR prin votare

În ultimii ani digitizarea documentelor a devenit prioritate întrucât volumul de informație crește exponențial dar și pentru că documentele digitale sunt ferite de deteriorare și se pot înmulți ușor. OCR urile sunt acele metode care pot citi textul dintr-o poză și să îl transforme în text digital.

Toate OCR-urile, pe lângă rezultatele furnizate, întorc și o valoare care reprezintă cât de sigur este că a citit corect fiecare cuvânt. Deși se întâmplă ca multe motoare OCR să citească același cuvânt greșit, probabil din cauză că era deteriorat pe hârtie, se poate observa că fiecare se comportă bine pe un anumit tip de document, pentru că au fost gândiți algoritmi altfel. Folosind mai multe astfel de

rezultate și combinându-le cu ajutorul valorii de acuratețe pentru fiecare cuvânt dat de fiecare OCR ar trebui să obținem un rezultat superior celor individuale.

Documente externe explicative / Bibliografie

- Aceeasi idee ca la: Voting-Based Image Segmentation.PDF

LCD Segmentarea prin Votare a Imaginilor

Segmentarea se referă la procesul partiționării unei imagini în seturi de pixeli cu caracteristici asemănătoare. Acest proces este folosit în separarea zonelor cu informație utilă de zone de background, făcând imaginea mai ușor de analizat.

Până în prezent, nu s-a găsit un singur algoritm care să facă o segmentare bună a imaginilor. În principal, rezultatele lor se pot caracteriza ca fiind supra-segmentate (prea multe zone mici) sau sub-segmentate (prea mare varianță în cadrul clusterului mare). Algoritmii de față ia în considerare această tendință a fiecărui algoritm în parte, dându-i posibilitatea să spună cât de sigur este în privința unui rezultat. Dacă un algoritm care supra segmentează spune că doi pixeli se află în același grup, probabil este adevărat, iar dacă un algoritm care sub segmentează spune că doi pixeli se află în grupuri diferite, ar trebui separați.

Rezultatul folosirii mai multor algoritmi de segmentare împreună se dovedește a fi mai bun din punct de vedere vizual decât cel al folosirii unui singur algoritm. În general au putut fi deduse zonele clar delimitate bine. Ca îmbunătățiri, trebuie adăugat un pas de post procesare care să includă grupurile foarte mici, care pot fi zgomot, în grupuri mai mari și să folosească parametrii adaptivi pentru binarizarea folosită în unirea/spargerea segmentelor. Va mai trebui să adaugați noi algoritmi de segmentare și să alegeți o euristică prin care obțineți cel mai bun rezultate în urma votării (dezvoltarea de noi metode de votare).

Documente externe explicative / Bibliografie

- Voting-Based Image Segmentation.PDF

LCD Binarizare prin votare

Binarizarea împarte o imagine în zone de prim plan, sau informație utilă și de background, sau informație neimportantă pentru aplicația curentă. Acest proces este util în multe interpretări de imagini, cum ar fi OCR-urile.

Algoritmii de binarizare vin în multe forme: globali și locali, adaptivi și neadaptivi fiecare cu tehnici diferite de selectare a pragului sau a vecinătății. Acești parametrii și algoritmii diferiți îi fac să genereze rezultate foarte diferite pentru aceeași imagine: unii pierd zone utile alții adaugă informații inutile, unii se comportă foarte bine pe unele zone din imagine iar pe altele foarte prost. Se știe dinainte cum se comportă fiecare algoritm și în funcție de aceasta, se pot alocă ponderi pentru fiecare regiune dedusă de fiecare algoritm.

Rezultatul obținut prin combinarea ponderată, sau prin votare, a tuturor algoritmilor de binarizare ar trebui să fie mai bun decât cel generat de unul singur dintre algoritmi.

Documente externe explicative / Bibliografie

- Aceeasi idee ca la: Voting-Based Image Segmentation.PDF

C Beta-Smart Shape

O problemă care apare des în domeniul Graficii este reconstrucția cât mai precisă a conturului poligonal ce încadrează un set de puncte.

Există multe abordări pentru deducerea unui contur poligonal concav, cea mai folosită fiind Alpha-Shapes. Această metodă are dezavantajul că rupe conturul în zonele în care punctele sunt mai depărtate decât o rază dată, limitând precizia conturului generat la distanța cea mai mică dintre puncte.

Algoritmii propus pornește de la înfășurătoarea convexă a setului de puncte și folosește o abordare iterativă de rafinare a rezultatului, prin introducerea în soluție a punctelor candidat potrivite. Au fost efectuate teste pe pagini de ziar cu imagini, conturul încadrând foarte bine ilustrațiile și nefiind întrerupt de zonele albe.

Pentru a putea alege această temă, trebuie să îmbunătățiți algoritmul de bază, de exemplu pentru a genera rezultate mai bune, sau pentru a rula mai rapid. De asemenea poate fi extins la spații N-dimensionale.

Documente externe explicative / Bibliografie

- beta-shape.PDF

C Sistem de clasificare a monedelor

Un sistem pentru clasificarea automată a monedelor îi poate ajuta pe istoricii care lucrează cu monede antice sau pe colecționarii care pot folosi servicii online în acest sens.

Metodele din literatură de recunoaștere a monedelor se folosesc de transformări invariante la rotație și translație, pentru a transforma imaginile într-un sistem comun, și de rețele neurale.

Metoda de față se folosește de datele reale ale imaginii: imaginea monedei (stema), textura monedei și textul; textul doar ca poziționare. Pentru aflarea similaritatea între steme, folosește un algoritm de detecție a marginilor invariant la orientarea sursei de lumină și care completează segmentele rupte cu cele mai probabile segmente. Pentru clasificarea texturii folosește descompunerea în frecvențe din Transformata Cosinus Discretă. Pentru aflarea poziției elementelor distinctive se folosește o segmentare bazată pe distanța față de centrul monedei și una bazată pe unghi (ca feliile de pizza). Invarianța rotațională se obține cu ajutorul calculării unghiului de rotație din transformata Fourier.

Metoda s-a dovedit a fi foarte eficientă pentru monedele actuale, clasificările greșite fiind datorate calității foarte slabe a fotografiilor monedelor. Testele pentru monede vechi nu sunt la fel de promițătoare din motive că acestea nu au fost construite cu precizie de fabrică și au suferit și deteriorări datorate utilizării, timpului și condițiilor de depozitare.

Pentru alegerea acestei teme trebuie să continuați/îmbunătățiți algoritmul prezentat.

Documente externe explicative / Bibliografie

- A Method for Automatic Coin Classification.PDF

LCD Clasificarea zonelor ca text, ilustrație, tabel, separator, spațiu alb

Fie că se dorește compresia hibridă specifică pe text sau pe imagini, corecția înclinației sau digitizarea textului, este nevoie să fie separate zonele de text și de imagini.

Metode care pot clasifica zonele de text pot să se bazeze pe mânăjirea imaginii, presupunând că textul este orizontal, și alegerea elementelor rezultate care seamănă cu rânduri de text. Pe operații morfologice pentru a unii literele din cuvinte, a separa posibile cuvinte de imagini și a elimina elemente mici rezultate din fragmente de imagini. După aplicarea operațiilor, se aleg doar acele zone care au înălțimi apropiate, cel mai probabil reprezentând linii de text. Pe găsirea spațiilor albe sau a liniilor de text prin metode ca Projection Profiling, transformate Hough și Radon și Cross Correlation și eliminarea obiectelor care nu respectă paternul găsit.

Algoritmii întorc rezultate foarte diferite, unii fiind robuști la înclinare și zgomet, alții fiind robuști la analizarea documentelor cu multe grafice, alții putând să observe layout-uri complicate.

Documente externe explicative / Bibliografie

- Voting-Based Layout Analysis.PDF

- Efficient Solutions for OCR Text Remote Correction in Content Conversion Systems.PDF

LCD Super Resolution cu mai multe imagini

De multe ori dispozitivele de achiziționare (aparate de fotografiat, ecografe, tomografe, radare) nu au rezoluția necesară prelucrării corecte a datelor, dar au posibilitatea de a lua mai multe imagini, prelungind timpul de expunere.

Două imagini fotografiate din poziții ușor diferite au informații ușor diferite. Presupunem ca aparatul de fotografiat s-a mișcat cu 7,3 pixeli spre dreapta, asta înseamnă că între pixelul 7 și 8 din imaginea inițială putem intercala pixelul 1 din a doua imagine. Dar pixelul 7 și pixelul 8 conțin amândoi un pic de informație din pixelul 1 din imaginea a doua. Iar pixelul 1 conține un pic din ceilalți doi. Aplicându-se o metodă de unire și una de deconvoluție, se poate afla valoarea sub pixelilor, măbind efectiv rezolutoria imaginii.

Metodele dezvoltate până acum, pot genera imagini de doua ori mai mari, fără să pară acestea că ar fi fost rezultate din imagini mai mici.

Documente externe explicative / Bibliografie

- MultiresolutionSequenceOfTransformedImages.pdf

LCD Localitate și Globalitate în procesarea semnalelor

Cele mai multe operații care se efectuează asupra imaginilor au nevoie de mai mult de un singur pixel la intrarea algoritmului. Fie că e vorba de binarizare, detecție de margini, convoluție, deblur, segmentare, etc. , au nevoie de o fereastră în jurul pixelului de procesat curent. În prezent, această fereastră este aleasă manual de utilizator, astfel încât să genereze rezultate cât mai bune.

Această temă își propune testarea unor euristici cu ajutorul cărora să se aleagă automat dimensiunea de fereastră pentru fiecare pixel. Cât de locală trebuie să fie vecinătatea sau cât de globală. O primă euristică arată că e bine să creștem dimensiunea ferestrei până când variația pixelilor din cadrul ei începe să scadă pentru prima dată, deci un prim maxim local al variației.

Metoda a fost testată pe o binarizare de documente. Rezultatele obținute, în care nu s-a dat nicio indicație algoritmului despre cât de mare trebuie aleasă fereastra, sunt aproape identice cu cele în care utilizatorul a trebuit să aleagă dimensiunea ferestrei.

Documente externe explicative / Bibliografie

- Local Thresholding with Variable Window Size Approach.pdf

LCD Asemănarea Imaginilor

În prezent, marea parte a testărilor pentru asemănarea imaginilor se fac la nivel de pixel și culoare. Metodele bazate pe mean squared error și peak signal to noise ratio pot fi folosite bine în domenii unde se dorește o asemănare a rezultatelor din punctul de vedere al valorilor (măsurători fizice, etc), dar se dovedesc a fi neadecvate pentru a măsura similaritatea perceptuală. De exemplu, pentru o metodă de compresie prin scenă 3D, pot apărea mici diferențe de proiecție, translație și scalare, insesizabile omului. Totuși, algoritmi bazați pe PSNR ar selecta o imagine mult distorsionată de compresie în favoarea acesteia.

Găsirea unei măsurători pentru evaluarea gradului de asemănare dintre imagini poate fi utilă în foarte multe domenii: clasificarea celulelor și identificarea aberațiilor, identificarea unei imagini într-o bază de date de timbre, monede, tablouri, edificii, rezultatele oferite de motoarele de căutare, înlocuirea evaluării standard MSE/PSNR care nu reflectă bine diferența perceptuală, clasificarea mai bună a blocurilor pentru compresie bazată pe fractali.

Odată cu lucrarea lui Peters din 2007 bazată pe near sets pentru similaritatea vizuală dintre imagini, au început să se dezvolte algoritmi care să poată clasifica imagini nu doar la nivel de pixel sau histogramă.

Documente externe explicative / Bibliografie

- perceptual1.pdf

LCD Codificarea Imaginilor folosind Fractali și informația de Localitate / Globalitate

Continuând tema prezentată anterior: Localitate și Globalitate în procesarea semnalelor, sau Localitate în imagini utilizând zone Watershed, se pot alege vecinătăți locale pixelilor și zone globale imaginii. Localitățile pot fi comparate cu globalitățile pentru a încerca codificarea lor cu fractali.

Codificarea unui petec local cu un fractal atrage după șine compresia imaginii, dar și posibilitatea de scalare fără pierdere de informație.

Documente externe explicative / Bibliografie

- refine.pdf
- FractalSatellite.pdf

LCD Spectral Image Matting

Algoritmii de segmentare a imaginilor produc o împărțire abruptă a pixelilor pe regiuni. De cele mai multe ori aceasta nu este folositor. De exemplu, dacă se dorește segmentarea unei imagini în care este fotografiată o persoană, părul nu se poate separa clar, nu se poate spune: acest pixel este un fir de păr iar acesta este peretele din spate, ci fiecare pixel este o combinație de culori din fiecare element fotografiat (părul este puțin transparent).

Această metodă se bazează pe procesări spectrale aplicate peste algoritmii de segmentare obișnuiți, pentru a obține elemente ce conțin și transparență pe margini. Rezultatele sunt foarte bune din punct de vedere vizual, după plasarea unei persoane dintr-o fotografie în alta și ajustarea căldurii luminii, această modificare nefiind vizibilă.

Documente externe explicative / Bibliografie

- spectral-matting-levin-et-al-cvpr07.pdf

LCD Aplicații ale Wavelet-urilor în prelucrarea imaginilor

Wavelet-urile sau undinele sunt funcții matematice simple care sunt aplicate peste funcții mai complicate (de exemplu imagini) ca și rezonatori. Zonele intense din rezultat arată că în acel punct se găsește acea undină, iar zonele întunecoase arată că nu apare acolo.

Aplicând diferite tipuri de undine peste imagini (formă și dimensiune sau frecvență), putem vedea ce forme de unde și ce lungimi de unde (frecvențe) apar în fiecare regiune a imaginii, analizând imaginea nu numai din punctul de vedere al frecvențelor existente în ea, dar și a pozițiilor lor.

Datorită informațiilor evidențiate de undine, se pot face numeroase procesări pe imagini: denoise (ex: se analizează tipul zgomotului din zone uniforme și se elimină din restul imaginii), binarizare (ex: se păstrează elementele de frecvență mare, care reprezintă marginile, făcându-se un filtru pe orientări, pentru a elimina zgomotul, iar elementele din interiorul și exteriorul bordurilor se colorează cu culori diferite), compresie (ex: se sparge imaginea în blocuri de frecvențe iar elementele redundante sau cu influență foarte mică sunt eliminate. În acest fel marginile pot rămâne

neafectate, iar zgomotul poate fi eliminat, ducând la scăderea dimensiunii), combinare de focalizări (alegerea frecvențelor mari (clare) din mai multe imagini și combinarea lor în una), etc.

Puteți să folosiți și noua tehnică de spargere în 32 de waveleturi pe frecvență (complexe wavelet packets) pentru o analiză mai rafinată.

Documente externe explicative / Bibliografie

- satellite wavelets.pdf
- singleSideEdge.pdf
- WaveletsForKids.pdf

LCD Compresie hibridă folosind MRC, Smart Resampling Filters și Super Resolution

O singură metodă de compresie a imaginilor nu este suficient de bună pentru a fi aplicată asupra unei fotografii de document, care poate conține text colorat diferit, imagini, grafice... deoarece metodele bazate pe frecvențe (jpg) nu se comportă bine la compresia marginilor; cele bazate pe culori și biți nu pot reda bine zone cu treceri line de la o culoare la alta, cele vectoriale nu pot comprima texturi fine, etc.

Această metodă vrea să spargă o fotografie a unui document în mai multe straturi de culoare și de informație. După aplicare unei metode de clasificare a zonelor dintr-un document (vezi tema de dinainte: Clasificarea zonelor ca text, ilustrație, tabel, separator, spațiu alb), fiecărei zone clasificate i se asociază un strat de colorare care va fi comprimat cu o metodă potrivită pentru conținutul lui. Apoi fiecare zonă va fi trecută la valori binare alb și negru, care arată unde are influență și unde nu stratul de culoare asociat zonei. De exemplu, stratul de culoare pentru un text negru va fi o imagine neagră iar stratul de informație va conține pixeli albi unde este text și negri unde nu este.

Prin aplicarea a diferite metode de compresie pentru fiecare strat se poate obține și un rezultat mult mai bun și o dimensiune mai mică a fișierului.

Documente externe explicative / Bibliografie

- http://en.wikipedia.org/wiki/Mixed_raster_content
- <http://image.unb.br/queiroz/papers/ei99mrc.pdf>

LCD Debluringul unei imagini

Restaurarea semnalelor deteriorate este o problema cercetată îndelung, atât de cercetătorii care caută modele matematice cât și de oameni care încearcă să vadă cât de bine pot ascunde o informație sau să vadă cât pot scoate din niște date corupte. Blurring-ul unui semnal reprezintă un gen de deteriorare, care îl face neclar prin convoluția cu o funcție în care predomină frecvențele mici (defocalizare) sau frecvențele mari (blur de mișcare).

Prin debluring sau deconvoluție se dorește aplicarea procesului invers, deci va trebui să rezolvăm un sistem de multe ecuații cu multe necunoscute (întrucât fiecare pixel este o medie ponderată a pixelilor din jur). Pentru fiecare pixel va trebui construită o ecuație, ce va avea ca rezultat culoarea pixelului respectiv, iar ca necunoscute, pixelii din jur. Ei sunt necunoscuți, întrucât și eu au fost afectați de operația convoluției.

Totuși această metodă s-a dovedit că nu poate fi aplicată banal deoarece amplifică prea mult zgomotul. De aceea s-au introdus artificii de deconvoluție în domeniul frecvenței (inverse filtering, wiener), care estompează frecvențele care pot fi exagerate de zgomot.

Documente externe explicative / Bibliografie

- Image Deblurring – Challenges and Solutions.PDF

LCD Super Resolution cu Generalised Edge

Una din problemele scalării imaginilor este că acestea încețoșează marginile. O idee pentru rezolvarea acestei probleme este detectarea marginilor cu Generalised Edge (vezi tema: Algoritmii Difference-Gatherer Min-Max Variance și Generalized Edge), transformarea imaginii în imagine vectorială, scalarea ambelor imagini și compunerea lor în funcție de cât de importante sunt marginile.

Documente externe explicative / Bibliografie

- vectorised-edges.pdf

LC Determinarea unui Layout Poligonal fără coliziuni al unui document

Vezi: Analiza de layout prin votare pentru detalii despre clasificarea zonelor dintr-un document.

Această metodă folosește generarea unor poligoane disjuncte de încadrare optimală (compromis: număr de puncte, naturalețea formei, arie) care împart elementele constitutive ale unei pagini document.

Aceste zone delimitate de poligoane pot apoi fi clasificate și trimise spre compresie cu MRC (vezi: Compresie hibridă folosind MRC, Smart Resampling Filters și Super Resolution).

LCD Image Inpainting

Aceasta este o metodă de a umple anumite zone dintr-o imagine cu informații generate artificial, astfel încât marginile să fie continue iar textura interioară să nu se observe că a fost generată artificial.

Poate fi folosită la reconstrucția din punct de vedere vizual a picturilor cojite, fotografiilor vechi, imaginilor din satelit afectate de nori, etc.

Documente externe explicative / Bibliografie

- Inpainting.pdf

LCD Focalizarea automată a unei imagini folosind un set de imagini

Se dorește realizarea unei aplicații care să genereze o imagine care poate fi focalizată în planul oricărui pixel, selectat de utilizator, pornind de la un set de imagini (focalizate diferit, stereo, etc)

Documente externe explicative / Bibliografie

- http://en.wikipedia.org/wiki/Focus_stacking

CD Recolorarea Imaginilor

Pornind de la o imagine color se dorește generarea unei imagini în nuanțe de gri astfel încât diferențele relative între culori să se păstreze pe cât posibil.

Spre exemplu putem avea o imagine cu un text scris cu roșu pe un perete verde. Conversia grayscale a celor două nuanțe de roșu și respectiv verde e identică, deci pentru a face textul citibil e nevoie ca maparea culorilor să fie făcută într-un spațiu al diferențelor perceptuale de culoare și nu prin conversie grayscale directă.

Această tehnică are aplicații în multe domenii de procesări de imagini, întrucât prelucrările, de regulă, se aplică pe imagini în nuanțe de gri (de obicei pe fiecare culoare în parte) și e nevoie să primească și un strat care să facă legăturile între culori.

LCD Prelucrări de imagini sau video folosind Epitom-uri

Epitom-urile sunt rezumate sau descrieri ale obiectelor din imagini/filme. O imagine sau o secvență video poate fi codificată folosind epitom-uri. Rezultatul creării rezumatului unei imagini este o imagine mai mică care conține o colecție de obiecte rezumat. Fiecare rezumat este o generalizare a obiectelor similare din imaginea respectivă iar prin modificarea epitomului caracteristic obiectelor de tip „floare” toate florile din imagine se vor modifica. Același lucru este valabil și pentru obiectele din filmări sau chiar din fotografii diferite ale obiectelor similare.

Această generalizare bazată pe obiecte atrage după sine posibilități numeroase de prelucrare a imaginilor sau filmelor: segmentare, eliminare de zgomot, super resolution, recolorări, transformări de obiecte, inpainting, etc...

Rezultatele în toate din domeniile menționate sunt foarte bune.

Documente externe explicative / Bibliografie

- EpitomeAnalysis.pdf
- VideoEpitome-IJCV.pdf

LCD Algoritmi Difference-Gatherer, Min-Max Variance și Generalized Edge

Majoritatea motoarelor OCR (Optical Character Recognition) au nevoie de o imagine binară la intrare, care să conțină litere clare. Calitatea imaginii binare influențează foarte puternic rezultatul final.

Toți algoritmi cunoscuți de binarizare fac doar o clasificare a pixelilor, bazată, în cel mai bun caz, pe caracteristicile pixelilor vecini.

Algoritmul nou conceput și numit Difference Gatherer își propune să genereze o imagine îmbunătățită, care să ajute procesul de binarizare prin accentuarea contrastului obiectelor din imagine. În acest sens, pentru fiecare pixel calculează o nouă valoare, care este suma ponderată cu distanța, cu parametrii aleși optim pentru distanță pe orizontală și verticală și diferență de culoare, a diferenței dintre pixelul curent și vecinii lui, într-o fereastră de o anumită dimensiune.

Generalised Edge este o metodă care își propune să detecteze toate tipurile de margini din imagine și să le filtreze pe cele nefolositoare. Pentru fiecare pixel, calculează o forță între el și toți ceilalți pixeli având amplitudinea egală cu diferența de culoare dintre pixeli iar orientarea de la pixelul curent la cel verificat. Forța rezultantă este o caracteristică a pixelului respectiv. În funcție de forțele din fiecare pixel, se generează marginile care ajută algoritmul Difference Gatherer în construirea unui contrast mai bun.

Metoda a fost testată pe motoarele Tesseract și ABBI, cu imagini de calitate medie, slabă și foarte slabă (diferențe de luminozitate, zone cu contrast puternic și foarte slab). S-au obținut îmbunătățiri cu până la 48% pe Tesseract și 42% pe ABBI.

Pentru a automatiza procesul de digitizare am introdus o metodă de selectare adaptivă automată a dimensiunii ferestrei pentru fiecare pixel, folosind cea mai mică și cea mai mare varianță din jurul pixelului (Min Max Variance). Rezultatele sunt similare cu cele prezentate mai sus, tinzând să ofere calitate sporită pentru imaginile foarte neclare.

Documente externe explicative / Bibliografie

- DiffGatherer – A Preprocessing Enhancement Algorithm for OCR Systems.PDF