UNCLASSIFIED







TECHNOLOGY DRIVEN. WARFIGHTER FOCUSED.

Luis Hernandez Army Research Laboratory

11 December 2008



UNCLASSIFIED TECHNOLOGY DRIVEN. WARFIGHTER FOCUSED.




- Background
- Goals
- Objectives
- Project Accomplishments
 - Datasets
 - Tools
 - Evaluations
- Future Plans



The Challenge







Hand-Written or Degraded Document Images into machine readable documents







Military Applications

Workflow and associated process


Document Image Processing, Analysis and Optical Character/Handwriting Recognition

Research and Experimentation

 Image Noise Removal and Enhancement


RIJEH

- Document Image Analysis
- Machine printed and hand-written character recognition
- Image to text services for Machine Translation and retrieval processes



Ultimate Goal of Systems

HIEH



Pursue intelligent digital capture, segmentation, recognition and processing of documents to enable fused, timely information from all relevant document sources to the Warfighter.




- How to evaluate such systems in various phases, in order to:
 - Evaluate the state of the art (comparison of systems)
 - Measure progress during development of new algorithms
 - Measure progress against operational needs
- Each is important
 - Technological progress in the field
 - Technology insertion for initial capabilities

Bobcat-DI: Project Goals

- Provide for a Web Enabled Government environment for:
 - evaluating COTS and GOTS OCR, Hand Writing Recognition systems and associated digital image processing technologies.
 - investigating the effects of character recognition accuracy on end-to-end accuracy of embedded MT systems
 - examination of downstream effects of image categorization and routing on MT output and analyst's extraction of metadata
- Use proven metric techniques
 - Character Error Rate
 - Character Accuracy Rates
 - Word Error Rate
 - Precision and Recall
 - Others

RIJEH



ARL collaborates heavily w/many agencies in IC and across services



- Layout the framework for a document image testing environment
- Provide tools ... to extend ground-truth data collections to include Arabic Anfal images
- Develop and transition the test methods, metrics, and procedures ... as part of an assessment infrastructure
- Provide test designs, data analysis procedures, and interpretation guidelines for evaluating COTS and GOTS OCR systems and other DIP tools

BOBCAT - DI: Tasks

R

- Data Sets
 - Zone Classification and Segmentation GT
 - Character/Word level GT
- Tools

BUER

- Modify UMD's Groundtruthing Editor Document Interface (GEDI) to allow handwritten data representation
- Develop DocLib Extensions/add-on routines
- Extend ARL Image and OCR Toolkit (IOTK) UI
- Evaluation
 - Conduct Pilot Segmentation evaluations
 - Conduct Pilot Zone Classification evaluations

BOBCAT – DI: Datasets

Overview

HIJEH

- Many datasets exist as simple collections of images
- Most to not accurately reflect the challenges faced by government organizations
- There is a significant need for datasets that can easily be evaluated across application – OCR, Page Segmentation, Classification, Indexing and Retrieval, etc.
- UMD/ARL is establishing a common format usable in GEDI and IOTK for many tools and for exchange between algorithms.

BOBCAT – DI: Data Sets

RDECO



Name	Number of Images	Level of GT	Applications	Comments
AMA-Arabic 1.2	5000	GEDI - Word + PAWs	OCR	Arabic Handwritten
UMD/AMA-Zones	> 25,000	Zones + Type	Segmentation - Classification	Subset of Tobacco
Tobacco Clutter	7.9million	None	Segmentation - Enhancement	English, Some Foreign Language
MADCAT – Dev, Train, Eval Set	~10000 Total	MADCAT - Word/Line	OCR	Arabic Handwritten
Anfal Box 50-53 Subset	> 7000	None	Segmentation- Enhancement	Arabic Handwritten and Machine Printed
LAMP - Syn Lines	50	Implicit in base images	Line Removal Line Detection	Arabic Handwritten and Machine Printed
UWASH	1600	Zones + Type	Segmentation - Classification	English Only

Sample GT from Data Sets

- Segmentation/Classification
 - 26,007 pages of Tobacco Litigation Corpus
 - 320,000 + zones

BUEH

- Useful for Large Evaluations

the 3 ? forthel alal	
Dana Conce Cutte - Erroge	
thermality set - specially in Presents and stopy; ped encountry & methics; weal infin	inguy dreams.
14 Har Frants Tot Proje at 27 tot Sty 15 open part	Kinsten Had
3 South & Such matine	

Anfal	GT	set	of
_	Han	dwrit	ten

- Machine Printed
- Graphics

4	من و جاری می این است معام می به دور معام مان ما نام می مازد این از این این از این این از این این از این این این این می می می می می می این این این این این این این این این ای	
للوري ستر الر	الم مستعمل المسلمات ا المسلمات المسلمات الم مسلمات المسلمات المسلم	
ίω	ان مدینه مان مواند است ترجیله است. معین می از می مواند از معالی می مواند است از معالی از معالی می از معالی می مواند از معالی معالی از معالی معالی می از معالی از معال	
	ا در ماره مراسط می اعلامه در ۱۰ مرابع مرابع می اعلام در ۱۰ مسئل برسه ماهمی ا ۱۰ مسئل می از می اعلام در مراسط می این این این این این این این این این ای	
1		





GEDI – Ground Truth Annotation

11121

IOTK – UI, Workflow and Evaluation process management

DOD Scoring Software – Accuracy evaluation of OCR text


PETS – Performance Evaluation of Layout based Algorithms (Page Segmentation, Zone Classification)



- Generic Tool for representing regions and attributes on images
- Bobcat -DI Project Extensions
 - Polygons for complex layouts
 - Reading order
 - Representation of run length encoded data for line segmentation
 - Direct integration of evaluation capabilities via scripts
 - Results visualization

UMD GEDI Tool Interface

BDEED



Example XML Format Output

```
<?xml version="1.0" encoding="UTF-8"?>
<!--GEDI was developed at Language and Media Processing
Laboratory, University of Maryland .-->
<GEDI xmIns="http://lamp.cfar.umd.edu/GEDI" version="1.0">
  <USER name="Elena" date="5/23/2008 17:24"
dateFormat="mm/dd/yyyy hh:mm"> </USER>
  <USER name="Orri" date="6/11/2008 12:52"
dateFormat="mm/dd/yyyy hh:mm"> </USER>
  <DL DOCUMENT src="sample.tif" docTag="xml"
NrOfPages="3">
    <DL PAGE gedi type="DL PAGE" src="sample.tif"
pageID="1" width="1728" height="2292">
      <DL_ZONE gedi_type="DL_TEXTLINEGT" id="2"
col="1285" row="269" width="166" height="335"
                      orientationD="16.169" contents=""
offsets="" segmentation="word">
      </DL ZONE>
   </DL PAGE>
    <DL_PAGE gedi_type="DL_PAGE" src="sample.tif"
pageID="2" width="2592" height="3300">
   </DL PAGE>
    <DL PAGE gedi type="DL PAGE" src="sample.tif"
pageID="3" width="2592" height="3300">
   </DL PAGE>
  </DL DOCUMENT>
</GEDI>
```

(1) E H


Statistics


Distribution of Zone Categories in AMA-Zones Dataset

Category	Documents	Zone Type	Count
advertisement	451	FORM	3,679
bibliography	158	GRAPHICS	3,430
calendar	44	HANDPRINT	50,138
drawings	597	Image	1,484
email	962	LOGO	4,070
fax	815	MACHINEPRINT	210,696
foreign	761	MARKUP	27,533
form	1,407	SIGNATURE	5,552
graphic	518	STAMP	5,074
handwritten	2,766	TABLE	5,559
etter	2,561	TITLE	5,800
list	395		
marginalia	888	Total	323,015
memo	1,893		
newspaper	615		
periodical	22		
photograph	227		
questionnaire	188		
report	985		
tables	690		
Total Documents	16,943		
Page Count	26.007		

Image and OCR Tool Kit (IOTK)


RDEEL






IOTK OCR Module


BUEHI





IOTK Segmentation Module

BDEED





BDEEL



🛃 PETS View _ 8 × File Name: 00010028.xml Segmenter: ((مماورة الكتاب)) ((محدورة الكتحاب) استعاد القرار البيئة الذائع الموضعة) تسخط عبر المراق للمراط ٢٢٠، ميلة ماه ١٢٩ (في ١٢٢ - (٦/ ٢٢ والقدائع) لم المحقق عمر المراق للمن ي قوي (٢ من الدوائملي العيس الر من طريع الدعقة من الفيخة والمنابي عن المالير والمراح الاجازات الا مقالية علمائية علمائة ٢٨ مـ ٢ من طريع الديرة والالانة القري العالي المالير والمراح المالية الجازات المالية المعارفة موارود المالية علم على طريع الذير معرفين المكار الي في (٢/ ٢٨ ٢) والمعدة الجازات المالية المعارفة المحارفة المالية المحارفة ال المالية على معرفين المكار المالي على مراحين (٢٢ مالية العالية المعارفة المعارفة موارود المالية المالية المحارفة المحارفة المحارفة المحارفة المحارفة المحارفة المحارفة موارود المالية مالية مراحية المحارفة مالية معدمات (٢٢ محارفة مالية معارفة محارفة المحارفة موارود المالية المحارفة موارود المال استعادا لقرار تلهيئة الذائم (المونسة) لمنكمة عمر المراق المرقم (٢٢٠ميئة مامة ١٢٧ في ٢٢ - ١/٢ ٢٢ والقتيفي مع الحقوق التقامية لمتقامين في الامراق م ٢٢٠ميئة مامة ١٢٧ من عالين الامتكان من الذي قرابيني عالية امته الجاوات الامتيان يتعايية للمادة ٢٤ ... ٢ من عالين عالية الامتيان على المالي رقم المنة ٢٢ (١ مالي رقم 1 منة ٢٢ مار عالم عالين عالية القرارية في ١/١/٨٢ والمعد تامياً قوام الامتيان على التقام... د عالم عالي مع معلون بالكام والبين أبين (١/٢٨٢ والمعد تامياً قالم الامتيان على التقام... د مارية عالم القرارية مع منافر المالي رقم 1 منه 1/٢/٨٢ والمعد تامياً قوام الا معاد معادي المعام... د مارية عالم من المرية مع مارية من مارية (١/٢٨٢ والمعد تامياً قوام الاميان على التقام... د مارية دولم مارية المالي مع مارية مارية (منه 1/٢٨٢) والمعد تامياً قوام المالي رقم 1 مع مارين المالية (١/٢٠ مارية استوديد ماصرة، السرم بخلاف ماتقد م يعمد ل ٢٧ من راتيهم التقاعدي مع التقدير • واسترديد ماصرة، اليهم بخلاة، ماتقدم بمدرل ٢٥٪ من راتيهم التقاهدي معالتقدير • فائق مد ملم بان فافق مد ملم مدير التقاءد المام مسمسه مدير التقاءد المام مسمسة اسم الله الرءين الرءيم سم الله الرءدن الرحيم الامن المامة ألامن الدامة يرية امن مطفظ^ة اربيه. ال ديرية امن محافظة (ربيه. ال -Unce/ Keles Nr YX الله أشبة بد د اليوم ا لمدذ / الادارة/ ٨ ٧٧ [(المية برد اليوم)] لتاريخ / ١٩٢ / ١٩٢ / ١٩٢ لتاريخ / ١٩ / ١٢ / ١٩ / ١٩٧ الى/ كافة المداونيات وشعب الطر/ الى/ كافة المحاونيات وشحب الطر/ م/ المحالين على التقاعد من توى الا من الداخلي وتاريخ مدميم م/ المسالين على التظاهد من توى الا من الداخلي وتاريخ هدمهم المقون التقاهدية . الحقوق المتاعدية الصلام صورة كتاب مديرية التقاف الحامة ٩٦٤٥ ٥ في ٥/ ٢/١٢ ٢٢ الجلغ الينا بكترساب ﴿ الصافه صورة كتاب دديرية التقاط العامة ١٢٦٥ ٥ في ١/١٢ لم الجلخ اليلا بكترساب ف مريدة الا من المامة / أدارة والمقاعد المرتم A ١٤٤٣ في ١١ (١٢ ٩/ ١٢ ، راجين طرحناة علورد فيه ديرية الامن المامة /أدارة والتقاعد المرتم ١٤٤٣٨ في ١٢/١٣/١٢ والجدن علامالة ملودة لفيه M. . . ج رافد الأ ×11 - 5 - 5 - 16 مدير أمن مماداة الإيساسل مدير أمن ممافتاة ان يستسل 2200 ~~~ В. Zones (Ground Truth) Image Properties Zones (Results) Zone Match Breakdown Zone Classification Breakdown Coordinate Pixels Coordinate Pixels View © Results -• Save Image Zone Class Filter All -C Results + Ground Truth Zone ID Zone Cla Zone 0 text_sm Zone Class Zone ID Zone Cla Zone Class Width Height 🔺 Upper Left Lower Right Width Height 🔺 Upper Left Lower Right (740, 148) (754, 167) 14 19 (835, 2205) (848, 2225) Zone 1 text_sm (816, 185) (1143, 231) 327 Zone 1 text_sm 46 Image: Constraint of the constr Zone 2 text_sm (216, 252) (1606, 670) 1390 418 (988, 2055 . (993, 2059 Zone 3 text_sm (270, 702) (1616, 908) 1346 206 (130, 2044) (135, 2049) Zone 4 text_sm (807, 958) (1146, 1011 339 53 (967, 2011) (982, 2018) Zone 5 text_sm (1252, 1098) (1586, 1195) 334 97 (1181, 1963) (1215, 2004) 34 41 Zone 6 text_sm Zone 6 text_sm (260, 1022) (688, 1219) 428 197 (1045, 1763) (1268, 1947) 223 184 Zone 7 text sm (247 1280) (261 1284) 14 4 (267, 1306) (1630, 1814) 1363 508 (261, 1248) (1630, 1838) (1649, 1370) (1692, 1412) Zone 8 text sm 1369 590 🗹 🚍 Zone 8 🛛 text_sm • 43 42 -🏄 Start 🥶 🚱 🖓 Voronoi | 🍕 IOTK (Running) - Microso... | 🚭 Jasc Paint Shop Pro Image & OCR Tool Kit (I... 🛐 🖉 😰 🕄 🗘 « 🔍 🕵 🕵 3:42 PM



General Concept:

- Given two zones to be compared, calculate the matching score if there is at least one shared ON pixel
- Four types of result
 - MATCHED: location and zone type
 - DETECTED: location but not zone type
 - FALSE: Extra zone in Results
 - MISSED: Zone not matched from GT
- Threshold is set to determine which zones are matched for "detection"
- Full match matrix is built to store the score of each pair of zones.
- Software follows DocLib design paradigm.
- Will be provided to DocLib as an Add-On component

Matching Score and Result Types

- I = set of all ON pixel in Image
- **R**_i = set of all ON pixel in the result zone
- G_j = set of all ON pixel in the ground truth zone
- T(s) = function that count the
 elements of set s

MATCHED

RDEEDM

 $\begin{aligned} \text{MatchScore}(i,j) &\geq \text{threshold} \\ L(i) &= L(j) \end{aligned}$

DETECTED

 $\begin{aligned} & \text{MatchScore}(i,j) \geq \text{threshold} \\ & L(i) \neq L(j) \end{aligned}$


FALSE


MatchScore(i,all) < threshold

MISSED

MatchScore(all,j) < threshold

$$MatchScore(i, j) = \frac{T(G_j \cap R_i \cap I)}{T((G_j \cap R_i) \cap I)} \times 100$$





Segmentation and Classification

RDEED

Summary of Results

- Total Number of Sample : 21786
- Overall Accuracy : 95.78%
- Average of Each Class Accuracy : 55.31%

01. Information on Classes

Label	Name of Class	Number of Sample	Accuracy
00	text_sm	20617	97.34%
01	ruling	201	61.69%
02	drawing	299	88.29%
03	table	76	46.05%
04	text_lg	51	64.71%
05	math	301	60.47%
06	halftone	144	83.33%
07	logo	13	0.00%
08	chm_drawing	80	51.25%
09	map	4	0.00%

Segmentation and Classification

02. Confusion Matrix

RDECOM

Out∖GT	00	01	02	03	04
00	20068(97.3%)*	70(34.8%)	11(3.7%)	14(18.4%)	12(23.5%)
01	69(0.3%)	124(61.7%)*	0(0.0%)	1(1.3%)	1(2.0%)
02	93(0.5%)	1(0.5%)	264(88.3%)*	23(30.3%)	4(7.8%)
03	46(0.2%)	0(0.0%)	5(1.7%)	35(46.1%)*	0(0.0%)
04	19(0.1%)	1(0.5%)	0(0.0%)	0(0.0%)	33(64.7%)*
05	284(1.4%)	2(1.0%)	8(2.7%)	2(2.6%)	1(2.0%)
06	38(0.2%)	3(1.5%)	6(2.0%)	0(0.0%)	0(0.0%)
07	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)
08	0(0.0%)	0(0.0%)	5(1.7%)	1(1.3%)	0(0.0%)
09	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)
	05	06	07	08	09
	106(35.2%)	5(3.5%)	7(53.8%)	0(0.0%)	0(0.0%)
	0(0.0%)	0(0.0%)	1(7.7%)	0(0.0%)	0(0.0%)
	9(3.0%)	18(12.5%)	0(0.0%)	9(11.3%)	4(100%)
	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)	0(0.0%)
	0(0.0%)	0(0.0%)	4(30.8%)	0(0.0%)	0(0.0%)
	182(60.5%)*	0(0.0%)	0(0.0%)	30(37.5%)	0(0.0%)
	0(0.0%) 0(0.0%)	120(83.3%)* 0(0.0%)	0(0.0%)	0(0.0%) 0(0.0%)	0(0.0%)
	0(0.0%) 4(1.3%)		0(0.0%)* 1(7.7%)		0(0.0%) 0(0.0%)
	4(1.3%) 0(0.0%)	1(0.7%) 0(0.0%)	1(7.7%) 0(0.0%)	41(51.2%)* 0(0.0%)	0(0.0%) 0(0.0%)*
	$\cup(\cup \cup \neg)$	0(0.03)	0(0.03)	0(0.03)	$0(0.03)^{\circ}$

03. Precision and Recall


RDECO

Class\Eval	precision	recall	detected	correct	total
00	98.89%	97.34%	20293	20068	20617
01	63.27%	61.69%	196	124	201
02	62.12%	88.29%	425	264	299
03	40.70%	46.05%	86	35	76
04	57.89%	64.71%	57	33	51
05	35.76%	60.47%	509	182	301
06	71.86%	83.33%	167	120	144
07	0.00%	0.00%	0	0	13
08	77.36%	51.25%	53	41	80
09	0.00%	0.00%	0	0	4



State of the Art:

- Stable tools are available for OCR evaluation
- Few tools are general enough to handle complex layouts and the layout of noisy handwritting







Survey: Page Segmentation Algorithms


Geometric

RDECOM

Dividing document into homogenous zones


Layout

Providing Zone content labeling Assigning logical relations based on location



Page Segmentation and Analysis

Goal: Decomposition of the page into constituent parts



Problems

Page Layout Analysis Page Segmentation Handwritten Line Detection Text Enhancement

Localization for the purpose of "internal routing" of content

State of the Art:

Whitespace or texture based segmentation Assumes objects are physically segmentable

Handwriting Challenges:

- Curvilinear text lines and small or missing linear inter-line gaps
- Stray marks which make rectangular white space analysis difficult
- Local skew
- No well-defined baselines, no Manhattan layout
- Regions not rectangular in nature bounding box may not be the best representation

Geometric Page Segmentation

Options for Arabic?

• X-Y cuts

BUEEL

- Layout to complex
- Smearing
 - Layout to Complex
- Whitespace Analysis
 - Noisy
- Constrained Text-Line Detection
 - More types of zones
- Docstrum
 - Zone Overlap
- Voronoi based
 - Maybe

Sample Results



Collaborations: Efforts Leveraged

✓ Doclib

11121

- An integrated Development Framework
- Core algorithms so we don't have to reinvent
- Unified representations
- Industry level testing and maintenance
- ✓ ARL IOTK and Information Exploitation Laboratory (IEL) Efforts
- ✓ UMD LAMP developmental technologies
- Multilingual Automated Document Classification and Translation Program (MATCAT)
 - Cutting Edge Research
 - Arabic Handwritten Expertise

Supporting MADCAT

لسان العالم الترجمة واللغة العالمية الموحدة

ميالعام 1991 كا علنت الغيد والية الدولية للمنزجسين المنبئة. عن حد فاسة الدونيد كرديرم 30 أيلول/سبتمبر يوما عالميا للنزجمة استناد بأحد فعا بذة الترجية في تاريخ البشرية وهر سانت مبيروم لذي قام على ترجمة الكتاب المتدس إلى اللغة اللاتينية بتكليف حد البابا ما صوس سنة 382 .

1 ما منالب ب العربي فقد عامت مصوفة من المترجمين الحريصية، على المهنة وعلى أسلم المترجم عامر محمد الدفام في شهر يناير من العام محمد بتأسيم المععية الدولية للمترجمين العرب على شبكة الدنترنت وهو عمل رسيادي في مقدمته أهدانه تعزير حوار الحفارات عن طريق النزحمة .

د الحركة المشيئة للتعارب النغامن بعامة ، والمعلومان على وجد الحمومي، كانت الععب، الدافعة لارد هار مراحة التوجعة سن اللغات الحية كلغة و بل الا نتراهات بوغات هذه الحركة الاظاهرة الأكثر دينا المكية في دفع العالم الرقمة على شبكة الا نترنت اليوم والقريب المساعات بين شرق وخرب ، مشمار وجنوب، ما يتمار على إقتصاء " التغريب " بين المجتمعات الم تحددة الله فشكل بنية القريب العالمة الواحدة .

> بعرّف كويتشيرو ما تسورا، مسير هيمّة اليه نيسكر. المقرّجم لما فه ذلك الوسيط (لمحا يدانني ليعي حاهمًا لي إيجاد (لررابط بي حوالم اتصعت الهوة بين بعد ماليه في بعد

عدم الاستنجاب ومود الذهم ما بجعومن الترجمة أداة

Set of Word Boxes Mapped to Lines

HIEH

- Run Length Encoded Data in each zone
- Algorithms return Polygons which are matched at the line level.
- All Annotation done with GEDI



Bobcat – DI: Reports

- Evaluation and Technology Survey
 - Algorithms, Datasets and Evaluation Metrics
 - Page Segmentation, OCR, Zone classification and Image processing
- PETS Software Specification and Manual
 - Evaluation Algorithms
 - Software Usage

1115

- Experimental Laboratory Environments: Image and OCR Tool Kit (IOTK) Utility Exploration, ARL Technical Memorandum 2 -2008
- PETS based Pilot Evaluations
 - Identification and evaluation of five technologies
 - Page Segmentation
 - □ Zone Classification
 - Rule Line Detection and Removal
 - Text Line Detection
 - Clutter Detection and Removal

Evaluations Preliminary Results


- Evaluations were performed on UMD-LAMP Software Developed for the DOD/MADCAT
 - Page Segmentation : Voronoi++
 - Zone Classification
 - Rule Line Detection and Removal
 - Text Line Detection
 - Clutter Detection and Removal
- All software being integrated into DocLib
- Pixels Accurate Evaluations used evolving "ImgDIFF" enhancements to PETS
 - Line Removal

BIJEHI

- Line Detection
- Publications in progress!




 Extension of State of the Art Approach to Deal with Handwriting – Variable tolerance for partitions, Adaptive Parameter Tuning



	Precision	Recall
voronoi	35.36%	58.49%
voronoi++	68.78%	78.30%






AFTER

Need Object Measures

BDEEL



Original Vorinoi Versus UMD Vorinoi++

Zone Classification



Approach:

31) EI

•Construct C(C-1)/2 two-against-all classifiers -- indicator classifiers; $f_{a-b,all}$

•Construct C(C-1)/2 one-against-one classifiers; $f_{a,b}$

•Use indicator classifiers to determine which binary classifier to use

Results

Test on UW dataset - 1690 documents - 24531 zones

10 zone classes

Chemical drawings, small text and symbols, drawing, halftone, logo or seal, map, math, ruling, table and large text

	1-vs-1	Wang et al.	Hybrid
Unbalanced	93.1%	98.45%	97.3%
Balanced	88.2%	N/A	96.6%

Rule Line Detection and Removal


Results

HIJEH

- Trained 12 one-class SVMs
- Test on synthetic dataset
- Compute average and median F1

درتیس در منابع با در بنی			
المجمع وملما ساشعة القر			
حرذا يلبق غرمي العر			
ر اعلي ملكهري			
مع معدا مر المعام له قسم رجداني نام			
مراجع بشكاره للكرار			
معدم المراس عبر م <u>ندن</u> معدم محمد بند علی الوجو -			
اننام تزریا حکسمة ٤ <u>٠/٥</u> سم <u>اء منفیة</u>			
معنا با قوس من التا تجين في عند الأرحا الجليلية			

REFORE



TECHNOLOGY DRIVEN. WARFIGHTER FOCUSED.

AFTER

فاريا ارمن الحروف

الارمى الحسفة

العم له قصو رجدانی نار شکاه الکرات

مما ليس إكاء

Text Line Detection

Affinity Propagation – Unsupervised Cluster Technique Operates in similarity space, rather than the feature space Number of clusters need not be *a priori* specified

Can cluster models on non-Euclidean manifolds

Results

HATEH

- Algorithm evaluated on the LDC dataset
- 1250 document images
- 21145 text lines

Precision	Recall	F1 score
78.2%	84.15%	81.06%


من فرزند وفا دار مردم افغانستان با شمولیتم در صفوف م مرز مروف دا رصد افغانسان ماسم در محص قواى ممىلح دولت افغانستان بنام خداوند متعال سوگند ياد ^و ای *مصبح د و کمت ا*فغانسهال ^ب اخدا د کم متعال سوک باد بيكنم كه يك افسر "سرباز" با دسيلين وفادار به همه على تريق العسر سركار ماديساس وفا دارا هم اصول، قوانين و مقررات دولت اسلامي افغانستان عزيز لول قي من دومقدان دول رمدامی افعال مال عرام بوده، تمام اوامر و هدایات امرین و قوماندانان را تحت وروبها م ادامر وجداما _ إمر روق ومار مالالتحت هر گونه شرایط زمان و مکان به مقصد دفاع از تمامیت ارضى، استقلال ملى و ارزش انقلاب اسلامى نسبت به ارمن اسقلال بیلی و ارزخوس دنعدا به اسل می ست ج هر نوع منافع دیگر ترجیح داده حتی از ریختاندن خون محصام مرتبه تر در در منه ار المعنا در العنا در الع خویش در این راه دریغ نمی نمایم. اگر بر خلاف این ومنس دراس د د در هم سی مد سی مدین مراف س تحليف ياد شده عمل نمايم، در انصورت جزاى سخت



Clutter Removal

• Pixel Level Enhancement Method

RDEED




Dataset	100 images Handwritten, printed English, Arabic 50 each for noisy n clean
Train vs Test	30:20 from each class
# of Features Linear SVM	7
Accuracy	97.5% Pixel Accuracy









Future Plans

Additional Work:

- Creation of Additional Datasets
- Extensions to GEDI
 - Semi-automated Annotation
- Extensions to IOTK
- Extensions of PETS for Image Based Evaluation
- · Collaborations to Extend capabilities as web services

Value Added

Community would benefit significantly from a common environment

DocLib


Structured Access to tools – IOTK/GEDI/PETS

Datasets and results of comparable research

Data and Evaluation

Resource where researchers could share data

- Data would be partitioned into test and training sets
- Individuals could run their data on state of the art algorithms
- Evaluation results could be tracked across time



Proposed Framework

Claims:

Community would benefit significantly from a common environment DocLib Structured Access to tools – IOTK/GEDI/PETS Datasets and results of comparable research

Data and Evaluation

Resource where Researchers could Share data

- Data would be partitioned into test and training sets
- Individuals could run their data on state of the art algorithms
- Evaluation results could be tracked across time

Summary: Project Contributions



- Development of Standard Practices framework
- Ability to generate and provide organized access to datasets
- Access to enhanced Annotation and interface tools (GEDI, IOTK)
- Collaborative Annotation of Existing sets
- New datasets

RDEHD

- Embedded Development (DocLib) and Evaluation (PETS) Tools
- Technical Documents
- Support collaborations with ongoing efforts



- Background
- BOBCAT DI Goals
- BOBCAT DI Objectives
- Project Accomplishments
 - Datasets
 - Tools
 - Evaluations
- Future Plans Environment Layout and Framework

UNCLASSIFIED







TECHNOLOGY DRIVEN. WARFIGHTER FOCUSED.

Luis Hernandez Army Research Laboratory <u>Ihernandez@arl.army.mil</u> 301-394-4301

11 December 2008



UNCLASSIFIED TECHNOLOGY DRIVEN. WARFIGHTER FOCUSED.