

IADLC 05

(International Advanced Digital Library Conference)

A UNIFIED FRAMEWORK FOR AUTOMATIC METADATA EXTRACTION FROM ELECTRONIC DOCUMENT

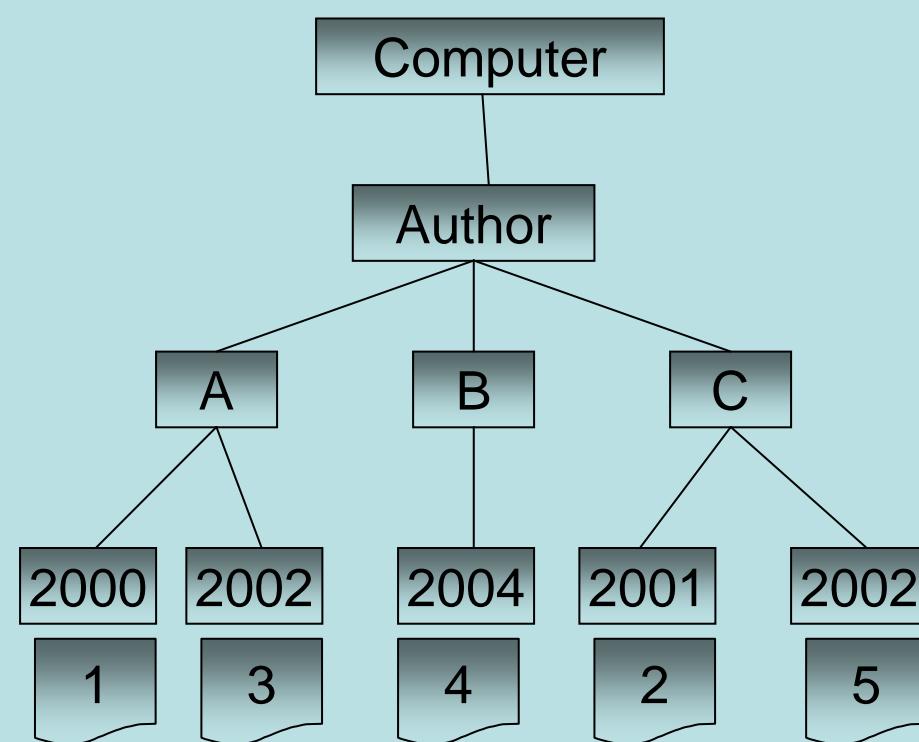
Asanee Kawtrakul, Chaiyakorn Yingsaeree and Team

NAiST Research Laboratory
Dept of Computer Engineering, Faculty of Engineering
Kasetsart University, THAILAND

26 August 2005, Nagoya

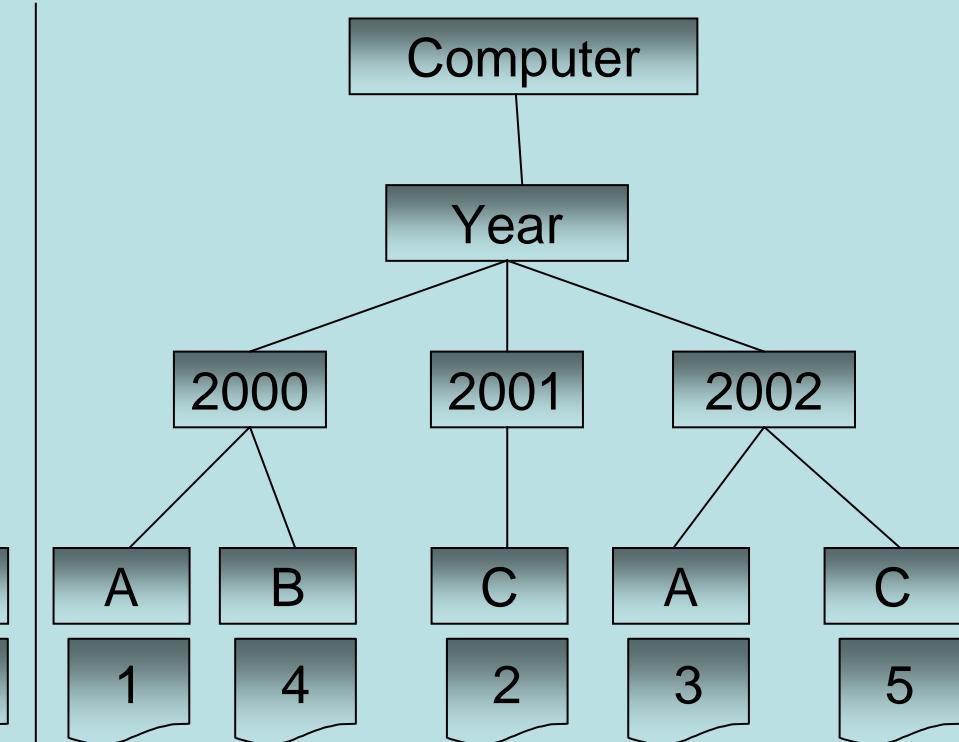
Goal

Knowledge Tracking : Different Tracking Paths (Same Documents)



Another Knowledge Gain :

- Author B is a new researcher.
- Author C publishes papers continuously
- Author A do not publish in year 2001
- And more...



Another Knowledge Gain :

- Author C is only one who published in year 2001
- Author A and B are pioneer researchers in domain.
- And more ...

Today's Outline

- Introduction
- Problems
- Architecture
- Current Status
- Conclusion
- Ongoing Projects

Introduction

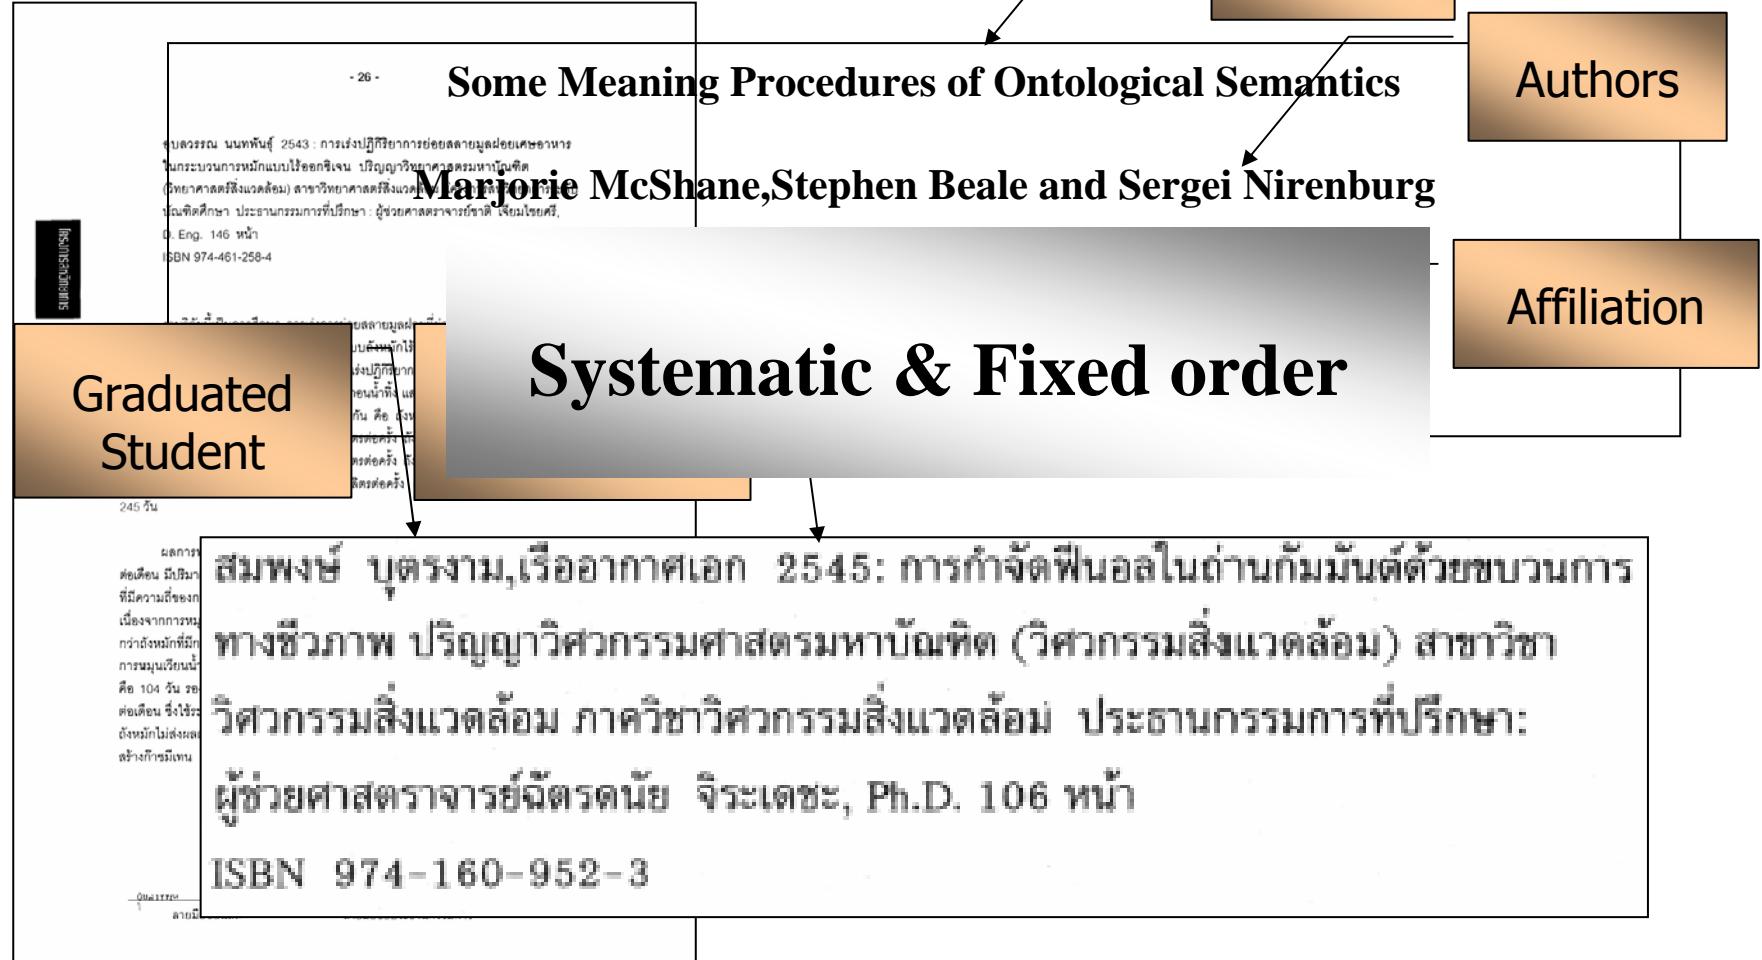
❑ What is metadata?

- ❑ Data about data
- ❑ Ex:
 - ❑ About document: Traditional library card catalogue,
 - ❑ About content: purpose, problem spaces, methodologies, and results.

❑ Why is it important?

- ❑ Help people distinguish relevant from non-relevant documents,
- ❑ Multi-view point of Knowledge Tracking

Examples of Metadata



Introduction (2)

- Where does it come from?
 - By Human
 - Annotating the document manually
 - By Computer
 - Metadata Harvesting
 - Metadata Extraction

Introduction (3)

Metadata Harvesting

- Collect metadata from previously defined metadata
- Usually performed by creating a parser to analyze source metadata and transform parsing results into an appropriated format
- Application includes interoperability between metadata of different systems and platforms

Introduction (4)

Metadata Extraction

- Extract metadata from document content
- Usually performed by machine learning, rule-based parser and Regular Expression
- Machine learning approaches are robust and adaptable, but require a large training example
- Rule-based parsers and Regular Expression are dependent on an application domain, and no training example is required

Introduction (5)

□ Objective

□ Create a framework for automatic metadata extraction from technical and thesis documents which have fixed format.

□ Solution

□ Use rule-based parser due to simplicity and cost

Problems

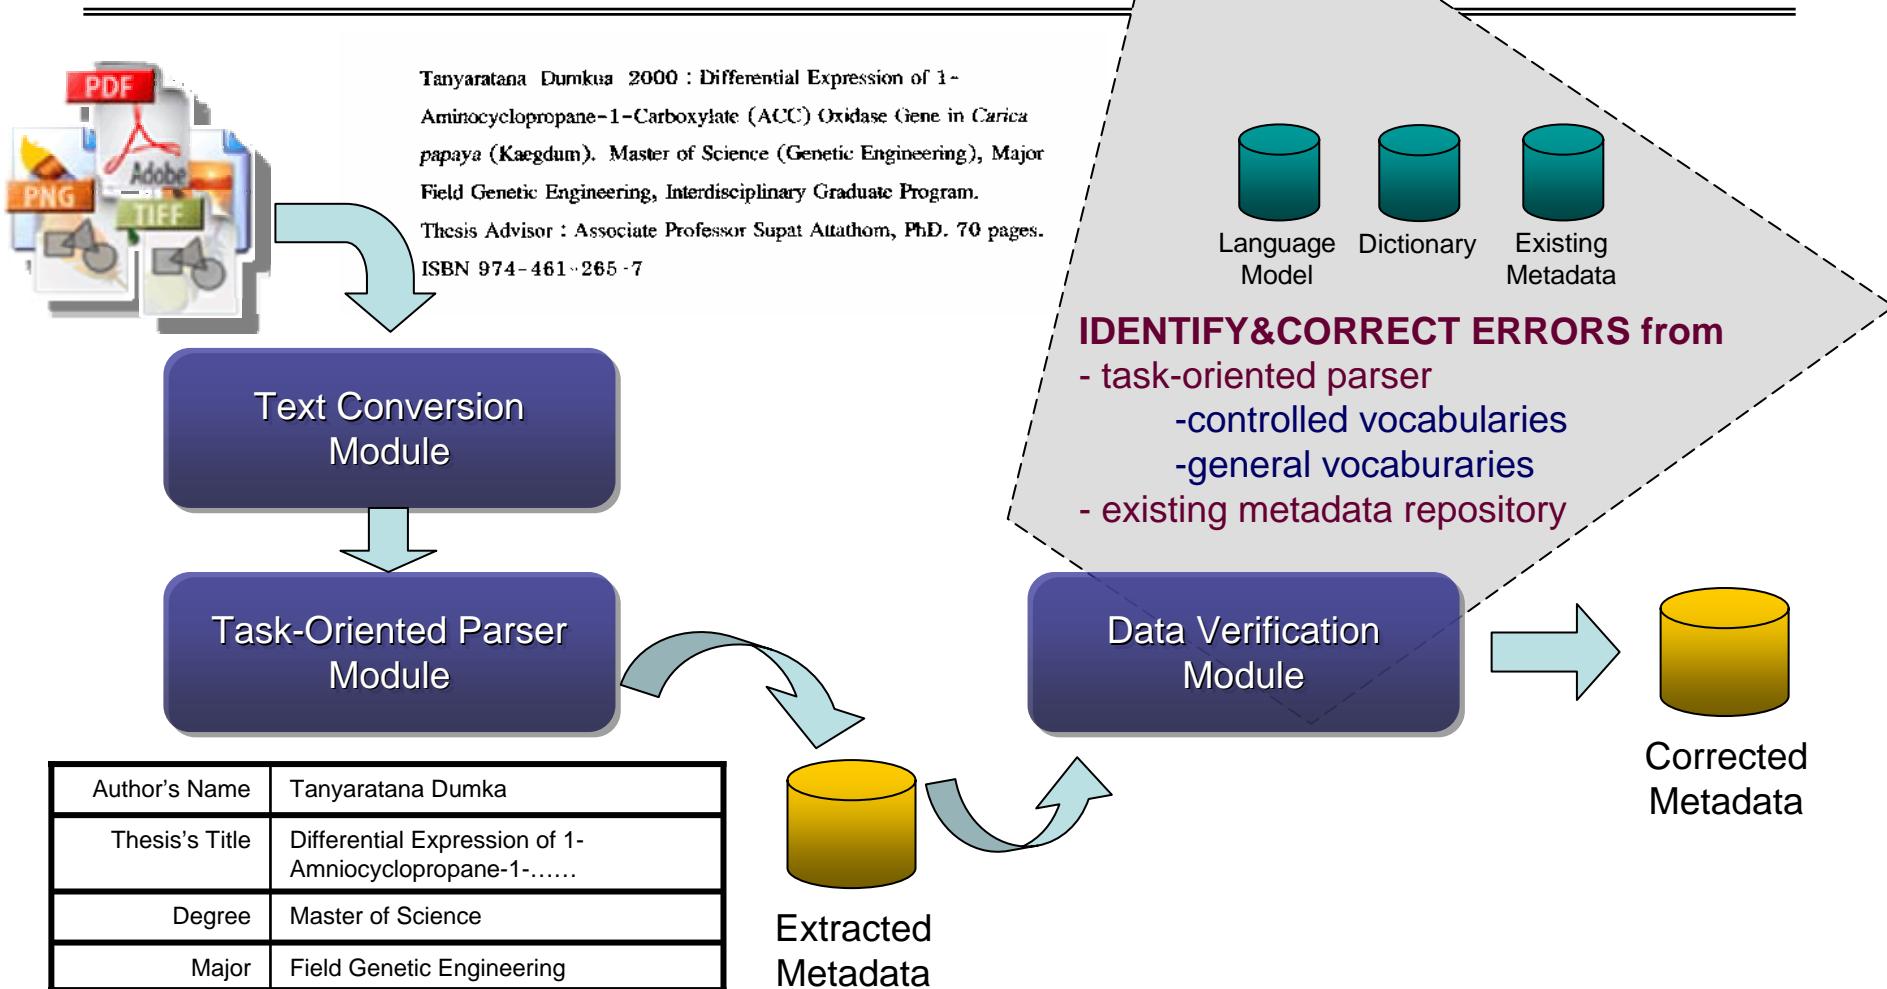
□ Variety of electronic document formats

- E-Document can be stored in a variety of formats
 - e.g. Microsoft Word, Adobe Acrobat, Image of document, etc.
- It is necessary to convert such document into text file in order to access document content

□ Quality of extracted metadata

- Extracted metadata may contain errors both from original documents and text conversion process,
- Some mechanisms are required to produce high-quality metadata

Architecture



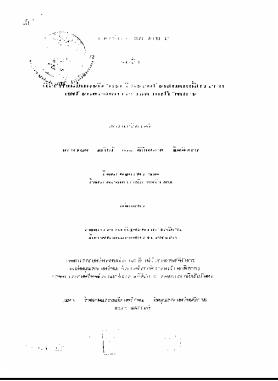
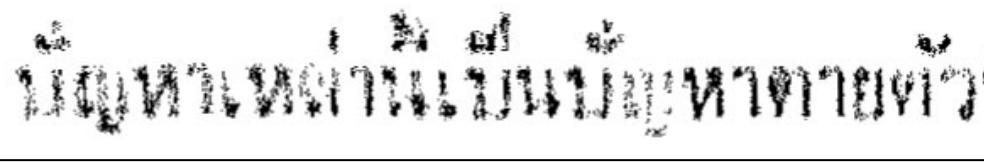
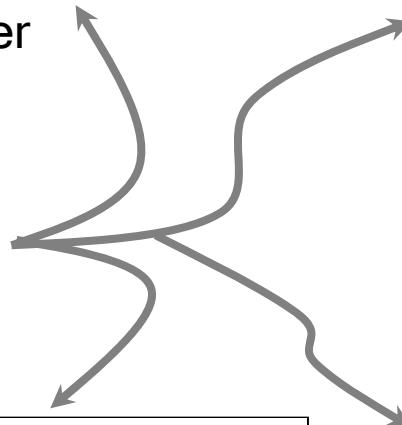
Text Conversion Module (1)

- ❑ AFPL Ghostscript (for PS & PDF)**
- ❑ CATDOC (for Microsoft Word & Excel)**
- ❑ OCR (for Image Document)**
 - ❑ Document Skew Correction**
 - ❑ Marginal Noise Removal**
 - ❑ Salt-and-Pepper Noise Removal**
 - ❑ Broken Character Management**

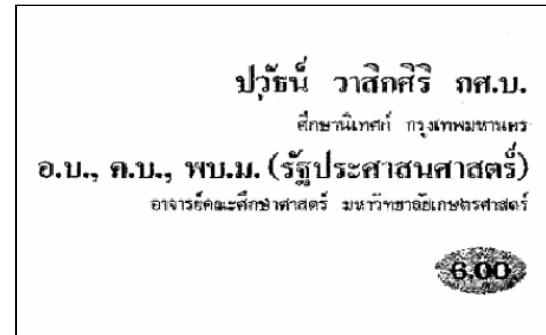
Text Conversion Module (2)



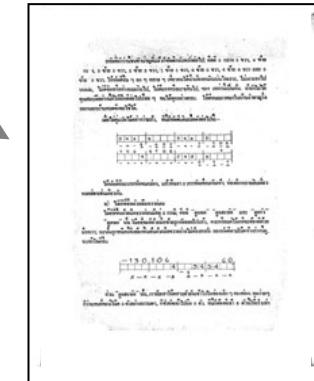
Broken Character



Skew



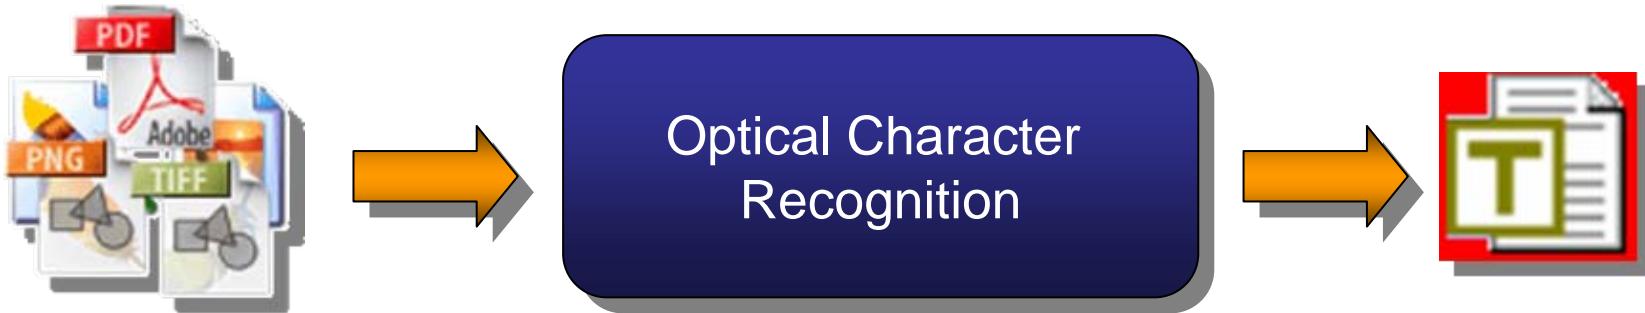
Salt-and-Pepper Noise



Marginal Noise

Optical Character Recognition

□ Conversion from Image to Text



หญ้าแฟกหอมหรือแฟกลุ่ม 4 พันธุ์

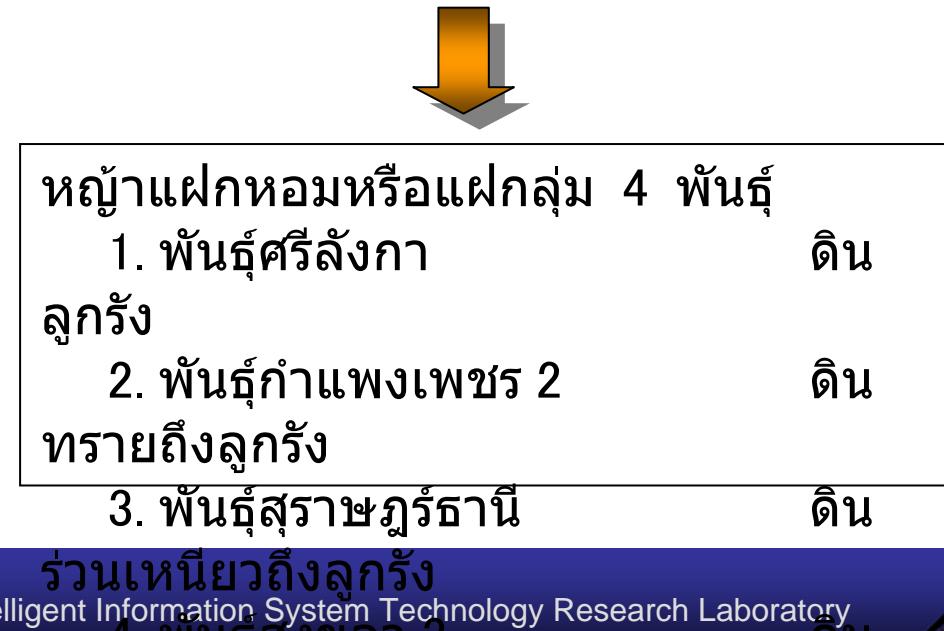
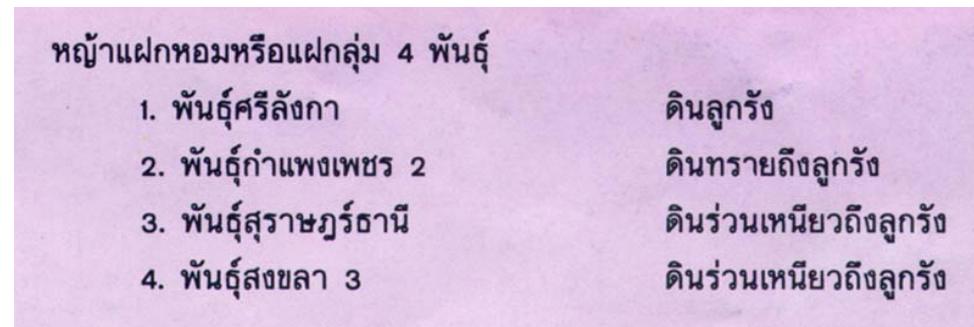
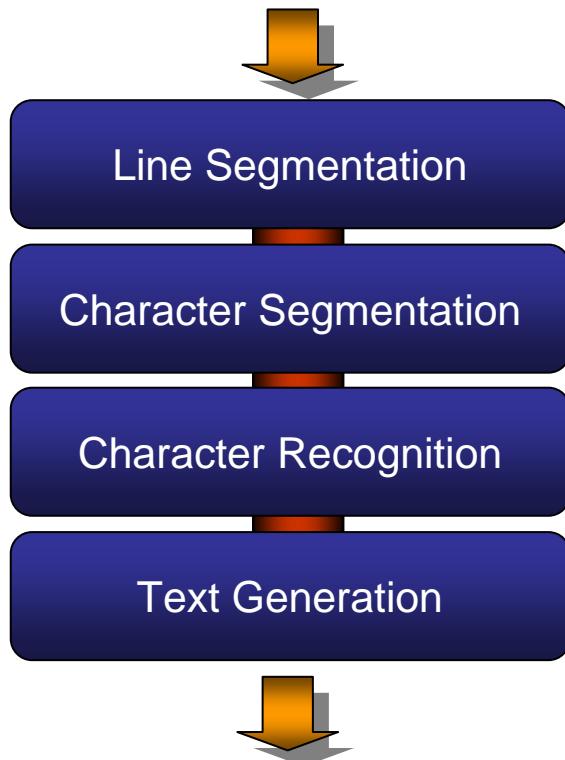
1. พันธุ์ศรีลังกา
2. พันธุ์กำแพงเพชร 2
3. พันธุ์สุราษฎร์ธานี
4. พันธุ์สงขลา 3

- ดินลูกรัง
ดินรายถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง

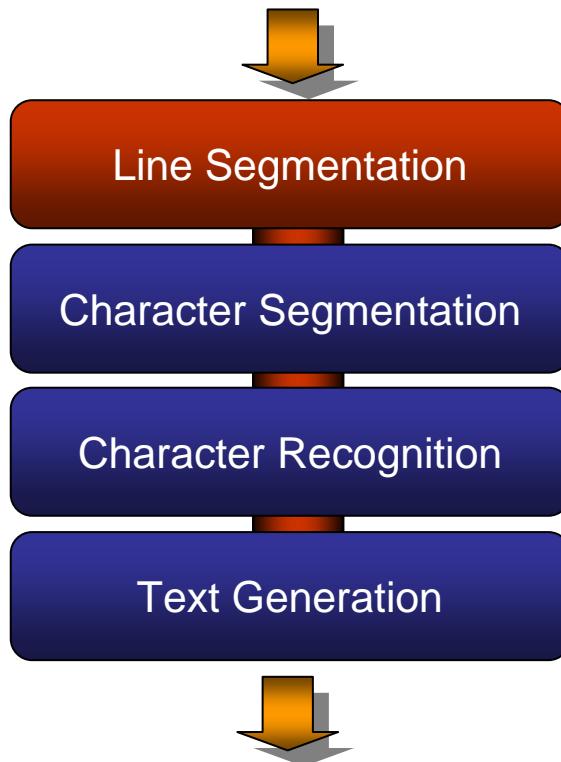
หญ้าแฟกหอมหรือแฟกลุ่ม 4 พันธุ์

- | | |
|-----------------------|------------------|
| 1. พันธุ์ศรีลังกา | ดินลูกรัง |
| 2. พันธุ์กำแพงเพชร 2 | ดิน |
| 3. พันธุ์สุราษฎร์ธานี | ดินร่วน |
| 4. พันธุ์สงขลา 3 | ดินร่วนเหนียวถึง |
| | ลูกรัง |

Optical Character Recognition



Optical Character Recognition



ัญญาแฟกหอมหรือแฟกลุ่ม 4 พันธุ์

1. พันธุ์ศรีลังกา
2. พันธุ์กำแพงเพชร 2
3. พันธุ์สุราษฎร์ธานี
4. พันธุ์สิงขลา 3

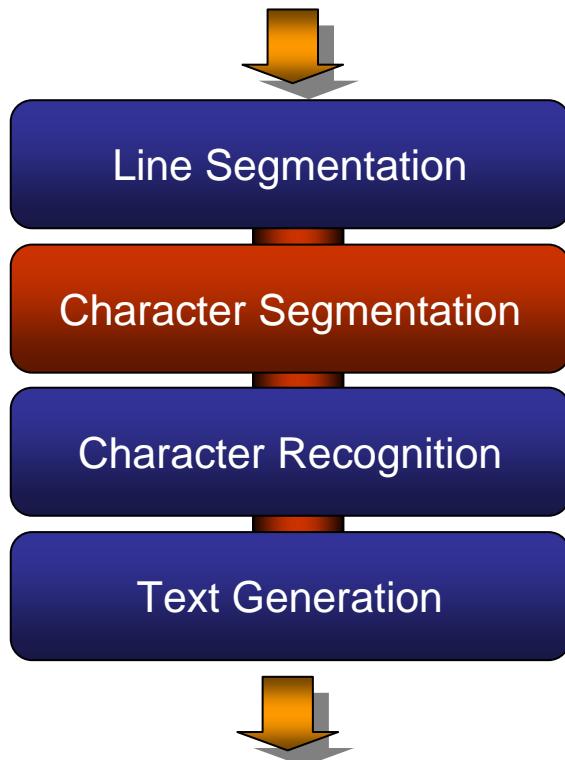
ดินลูกรัง
ดินกรายถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง

ัญญาแฟกหอมหรือแฟกลุ่ม 4 พันธุ์

1. พันธุ์ศรีลังกา
2. พันธุ์กำแพงเพชร 2
3. พันธุ์สุราษฎร์ธานี
4. พันธุ์สิงขลา 3

ดินลูกรัง
ดินกรายถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง
ดินร่วนเหนียวถึงลูกรัง

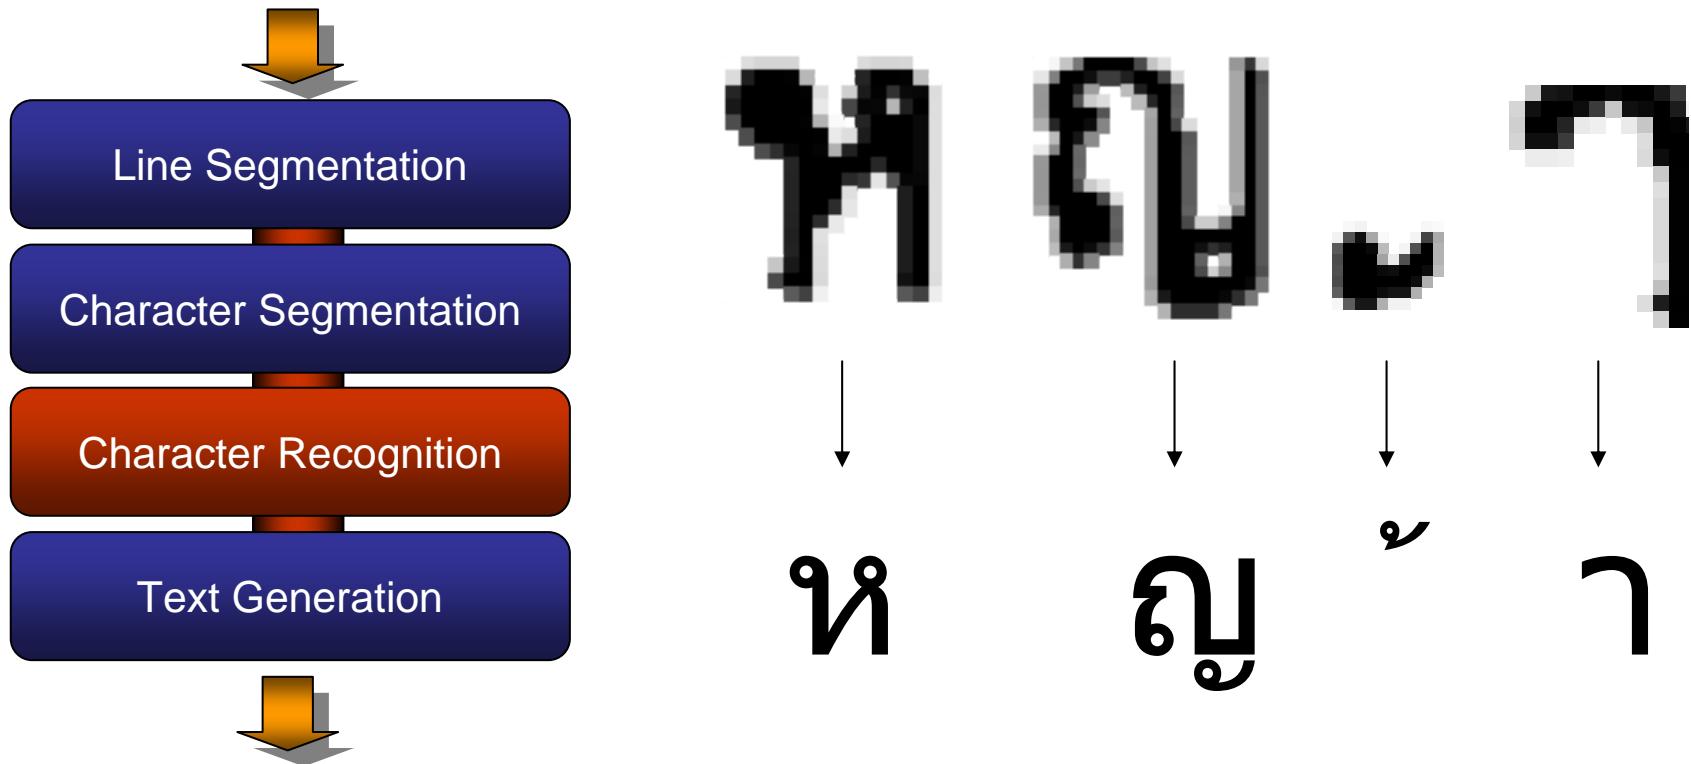
Optical Character Recognition



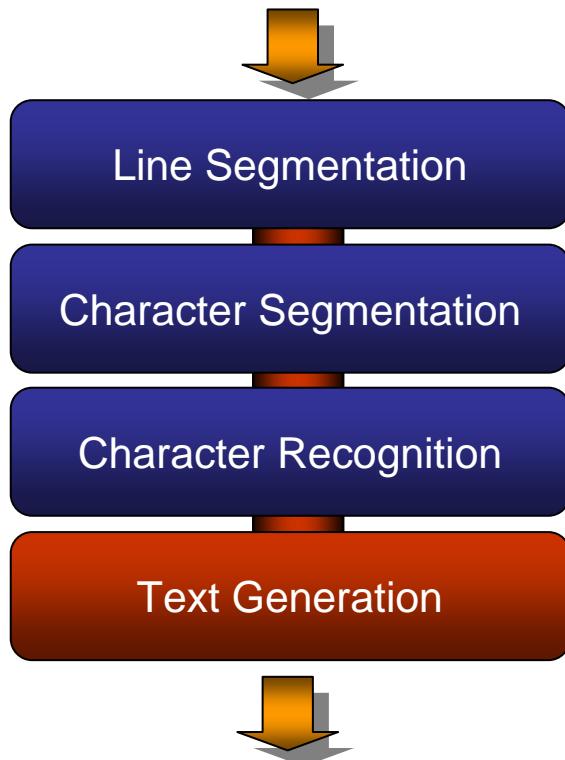
අභ්‍යායනකහොමහිටුවයි ප්‍රක්ලුම 4 ප්‍රති

අභ්‍යායනකහොමහරා මැයි 4 ප්‍රති

Optical Character Recognition

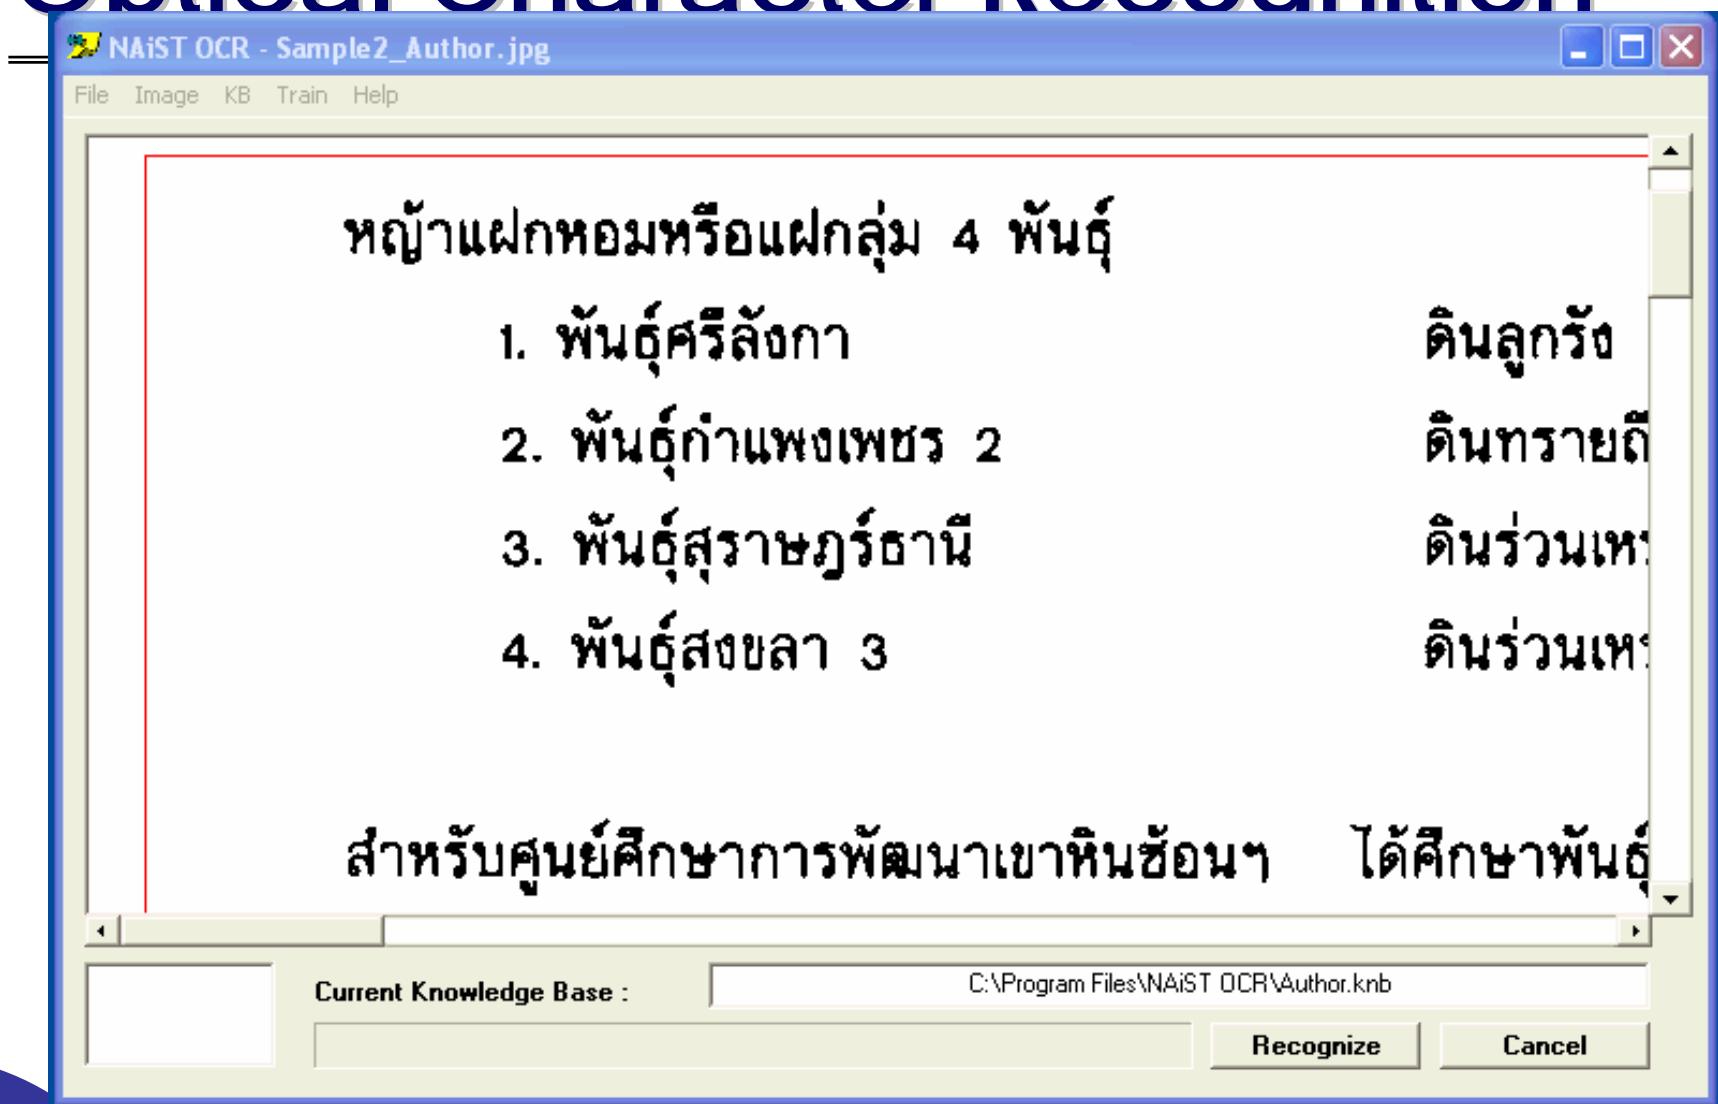


Optical Character Recognition

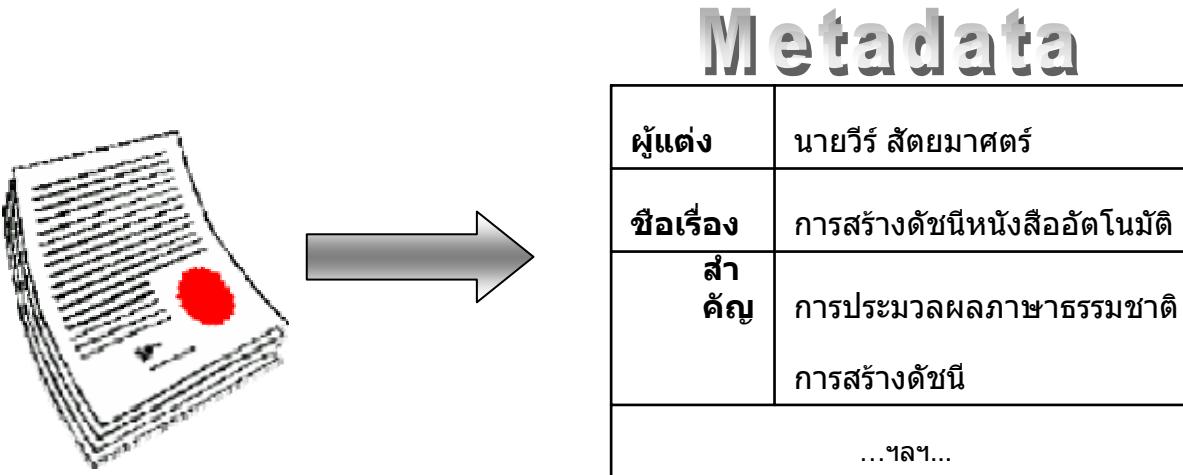


หลักการหออมหรือแยกกลุ่ม 4 พันธุ์
... ห อ ม ห ร อ ย อ แ ก ล ,
หลักการหออมหรือแยกกลุ่ม 4
พันธุ์

Optical Character Recoanition

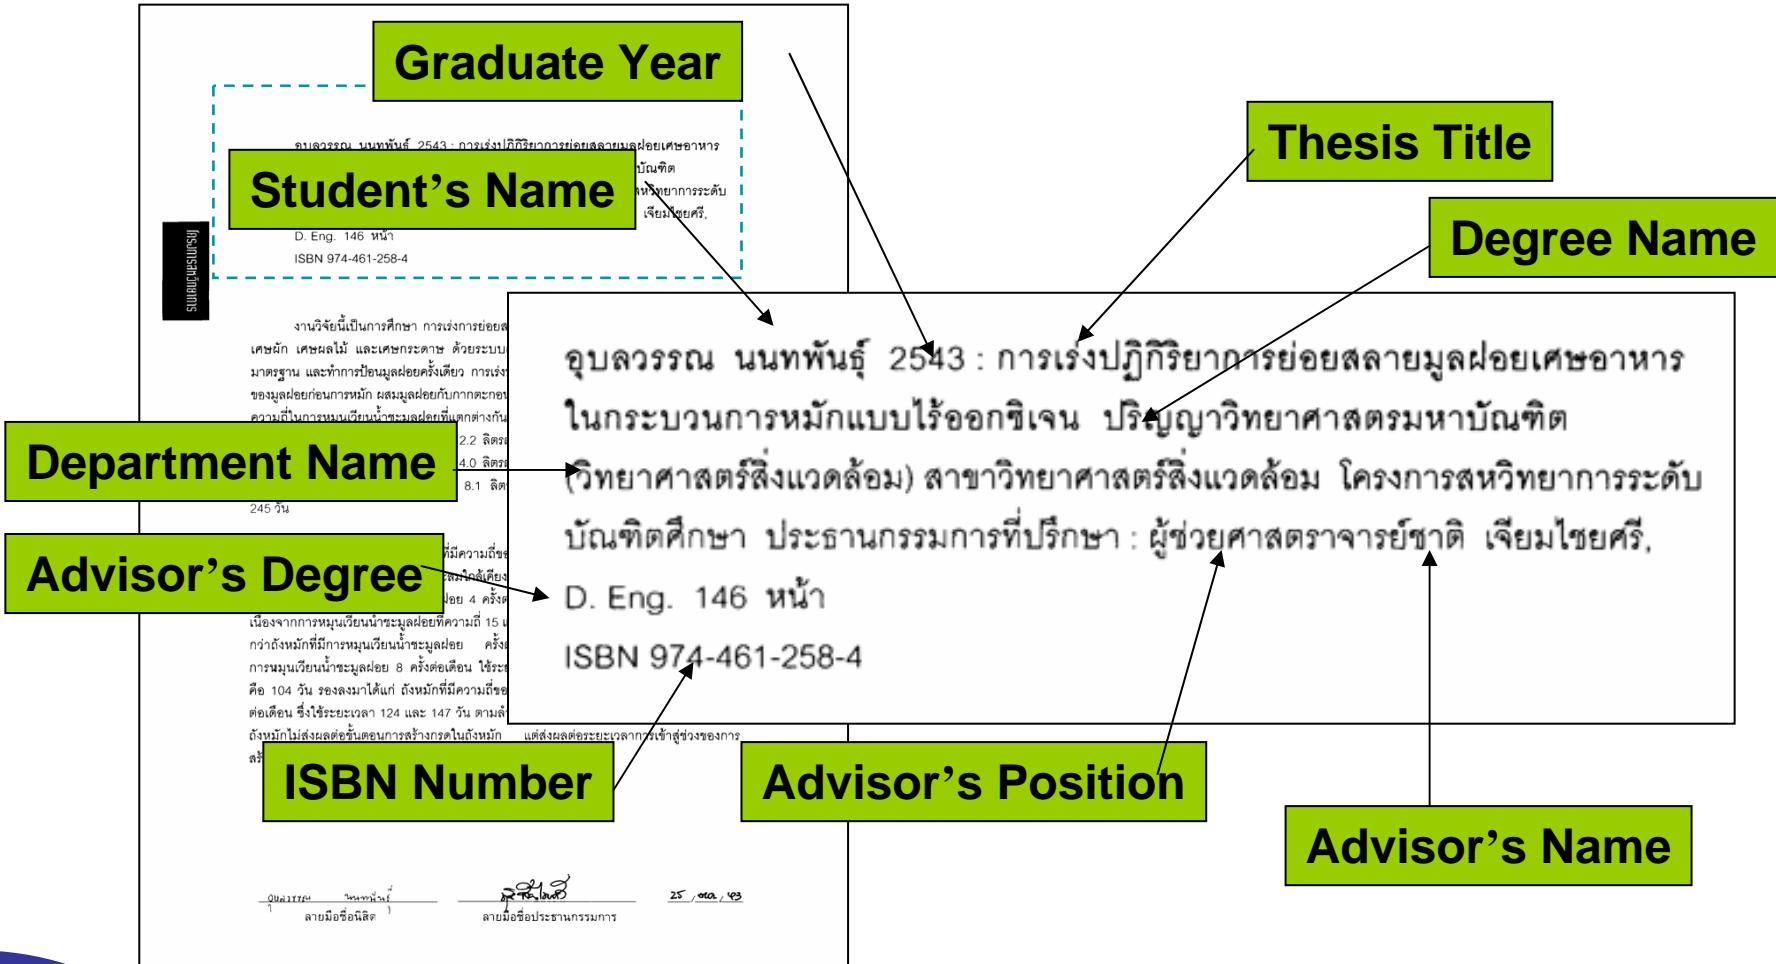


Automatic Metadata Extraction



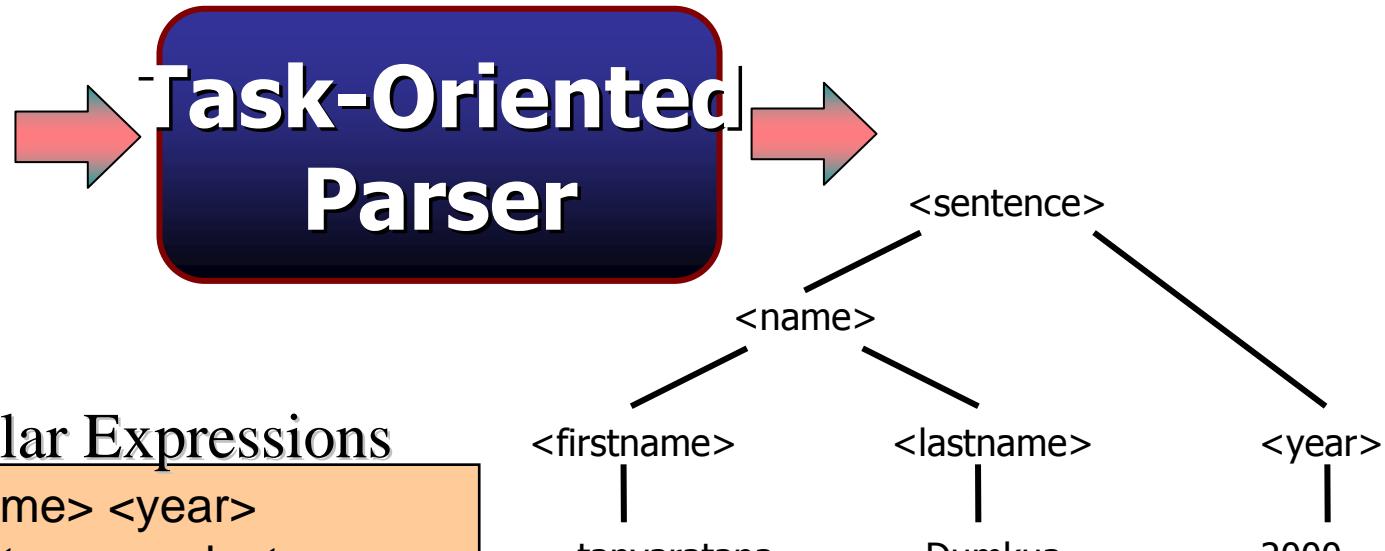
Needs Resources and Cost

Extraction Meta Data for e-thesis



Automatic Metadata Extraction

Tanyaratana Dumkua 2000



Regular Expressions

```
<sentence> :- <name> <year>
<name>      :- <firstname> <lastname>
<firstname>   :- [A-Z][a-z]+
<lastname>   :- [A-Z][a-z]+
<year>       :- [0-9]+
```

Extraction Result for e-thesis

ผลลัพธ์การค้นหา	อุบลวรรณ นนทพันธุ์ 2543 : การเร่งปฏิกิริยาการย่อยสลายมูลฝอยเศษอาหารในกระบวนการหมักแบบไร้ออกซิเจน บริษัทสาขาวิชาศาสตร์มหาบัณฑิต (วิทยาศาสตร์สิ่งแวดล้อม) สาขาวิชาศาสตร์สิ่งแวดล้อม โครงการสหวิทยาการระดับบัณฑิตศึกษา ประธานกรรมการที่ปรึกษา : ผู้ช่วยศาสตราจารย์ชาติ เจียมไชยศรี, D. Eng. 146 หน้า ISBN 974-461-258-4
คำอธิบายผลลัพธ์	ด้วยนิยามค่าน้ำหนักมูลฝอย 4.0 ลิตรต่อตัวชั้ง ตั้งแต่แก้วที่ 3 จนถึงแก้วที่ 4 คำอธิบายต่อไปนี้เป็นมาตรฐานของมูลฝอย 8.1 ลิตรต่อตัวชั้ง ดำเนินการทดลองในระยะเวลาทั้งสิ้น 245 วัน
ผลลัพธ์	Name: อุบลวรรณ
ต่อเดือน มีปีที่มีความตื้นเข้มจากภายนอก การหมุนเวียน คือ 104 วัน ต่อเดือน หรือ ตั้งแต่แก้วที่ 1 ไม่ถึงแก้วที่ 2	Surname: นนทพันธุ์
Topic:	การเร่งปฏิกิริยาการย่อยสลายมูลฝอยเศษอาหารในกระบวนการหมักแบบไร้ออกซิเจน
Major:	วิทยาศาสตร์สิ่งแวดล้อม
Department:	โครงการสหวิทยาการระดับบัณฑิตศึกษา
...

Data Verification Module (1)

- ❑ Error from Task-Oriented Parser Module
 - ❑ Controlled Vocabularies
 - ❑ General Vocabularies
- ❑ Error in Existing Metadata Repository

Data Verification Module (2)

- **Error from Task-Oriented Parser Module**
 - The parser might not be able to parse some documents due to incomplete grammar, error from text conversion, or defect in the document itself
 - To solve the problem, either creating new rules or fixing the defect is required

Data Verification Module (3)

❑ Error in Controlled Vocabularies

- ❑ Some metadata fields' value can be only a word(s) in controlled vocabularies
- ❑ Error identification can be achieved by comparing extracted data with a dictionary
- ❑ When error occurs, the correction process simply replace the error word with its closest word in the dictionary by means of Edit Distance

Data Verification Module (4)

❑ Error in General Vocaburaries

❑ Use spelling correction technique to detect and correct the errors

- ❑ OCR Error Correction
- ❑ Typing Error Correction

❑ This module is under development

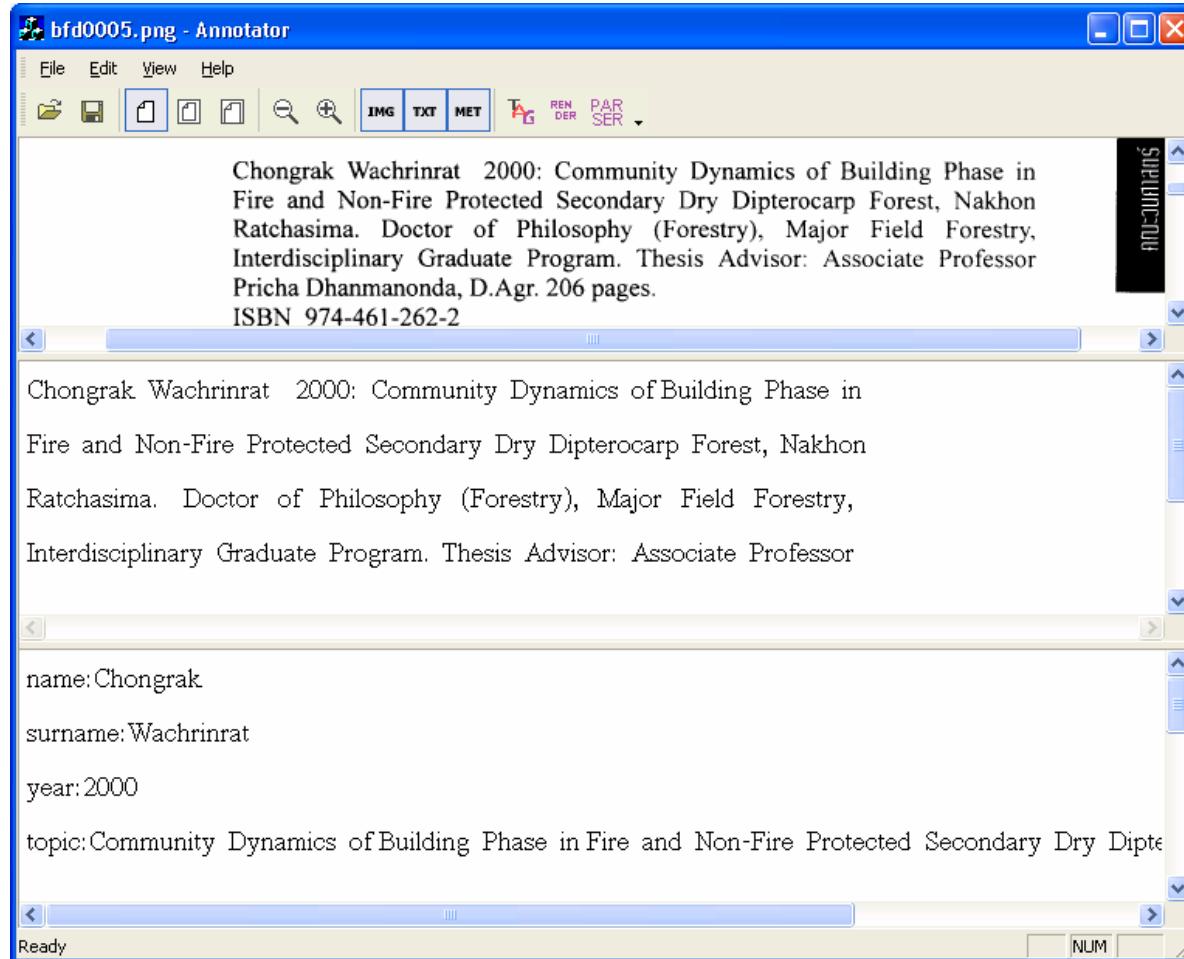
Data Verification Module (5)

❑ Error in Existing Metadata Repository

- ❑ Hand-made metadata usually contained many errors
- ❑ Instead of manually correcting the error, we can use automatic metadata extraction and alignment tool to ease data correction process

Current Status

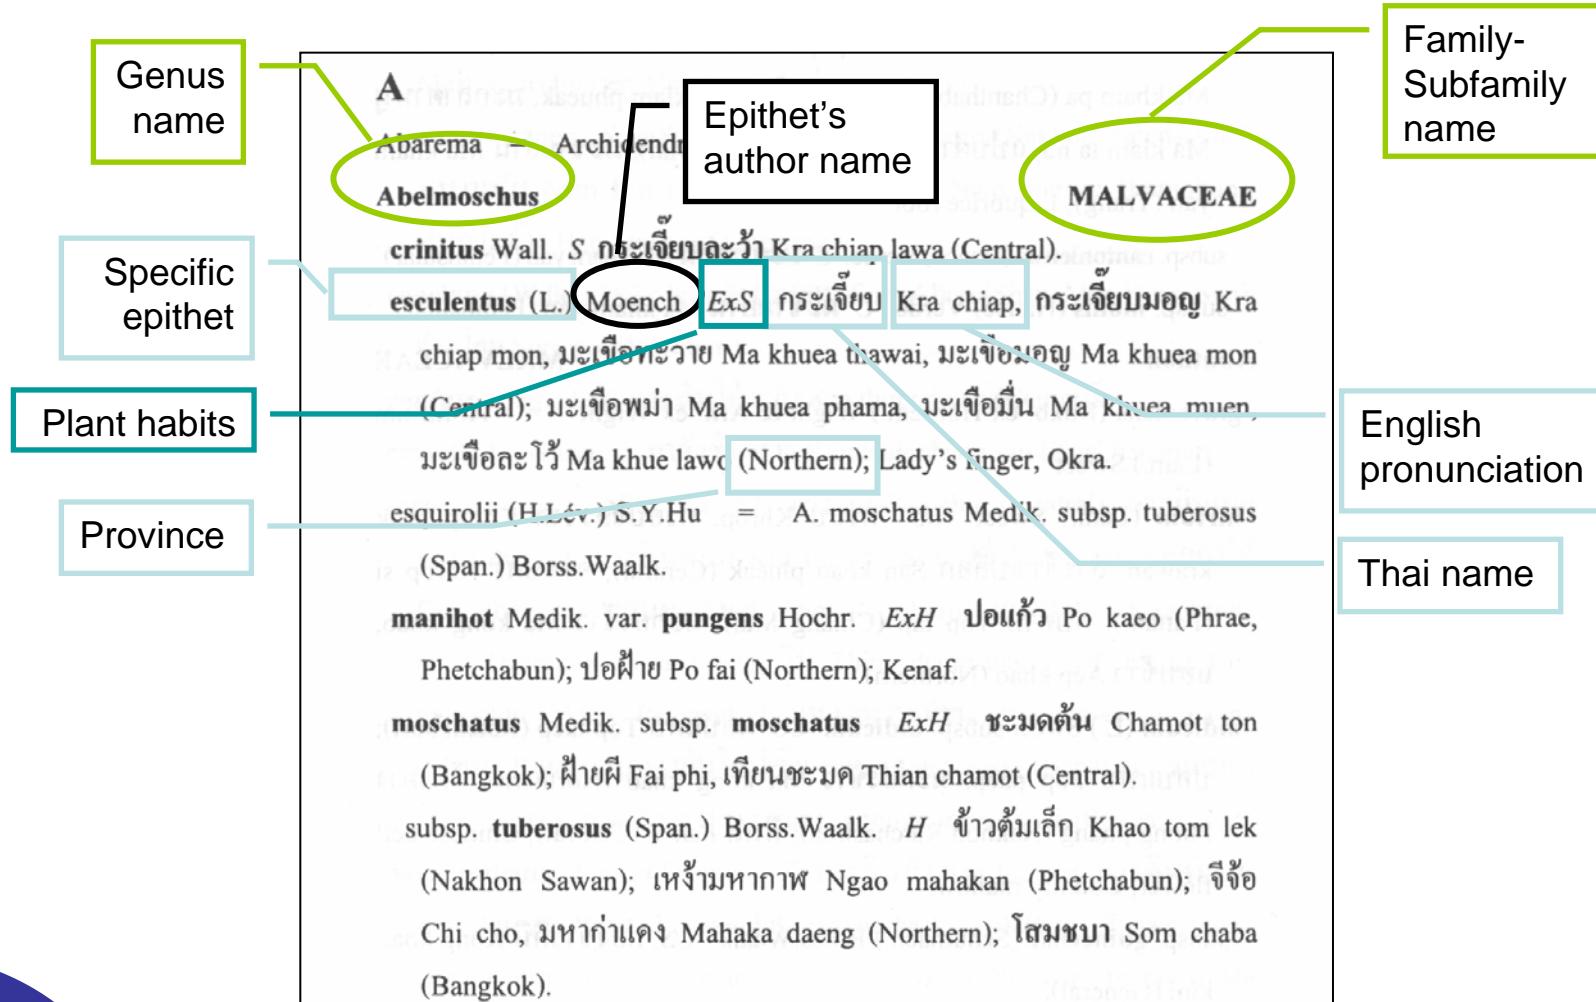
Extracting metadata from students' thesis abstract (1)



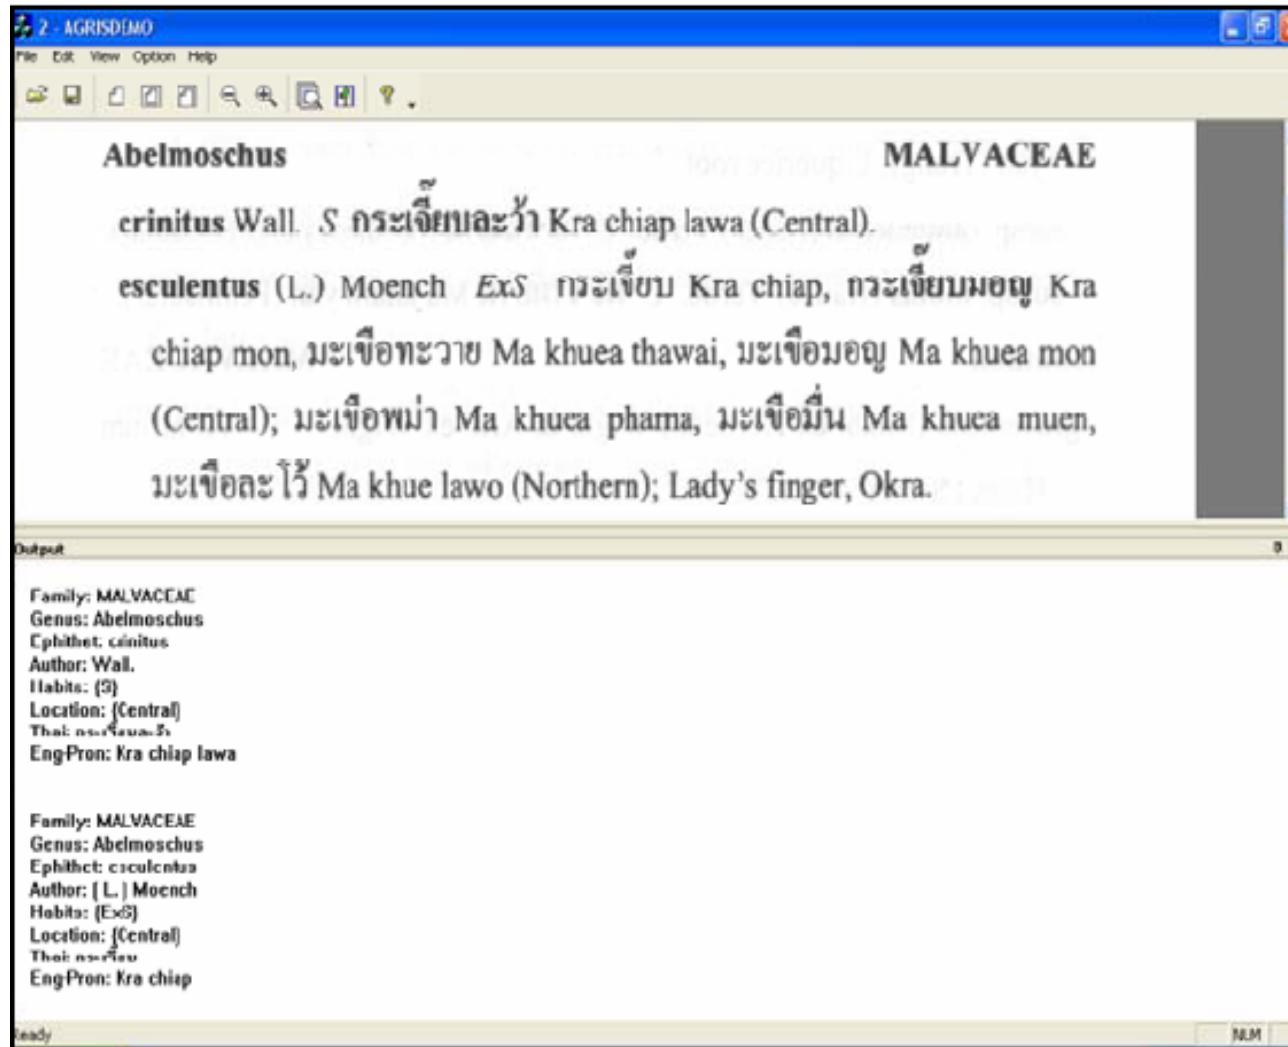
Extracting metadata from students' thesis abstract (2)

The preliminary results with 3,712 thesis show that using this system greatly reduce the labor work of metadata creation process by correctly extracting metadata 91.41% of the documents.

Extracting plant information from image of Thai plant name dictionary(1)



Extracting plant information from image of Thai plant name dictionary (2)



Conclusion

- A Unified Framework for Automatic Metadata Extraction from Electronic Document
- Consists of three main components
 - text conversion module
 - task-oriented parser module
 - data verification module
- The experimental result shown that using the framework greatly reduce the labor work of metadata creation process

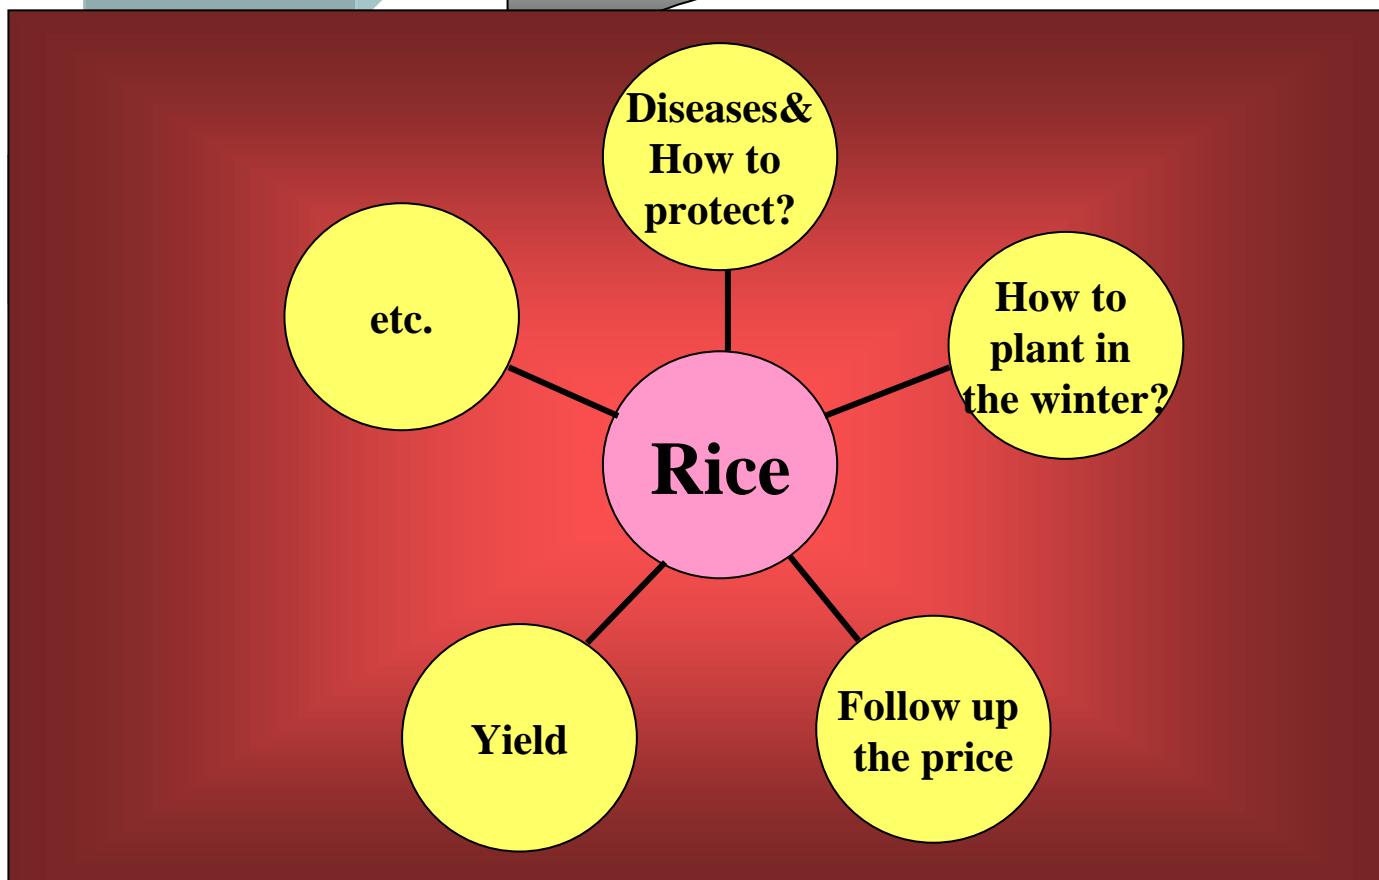
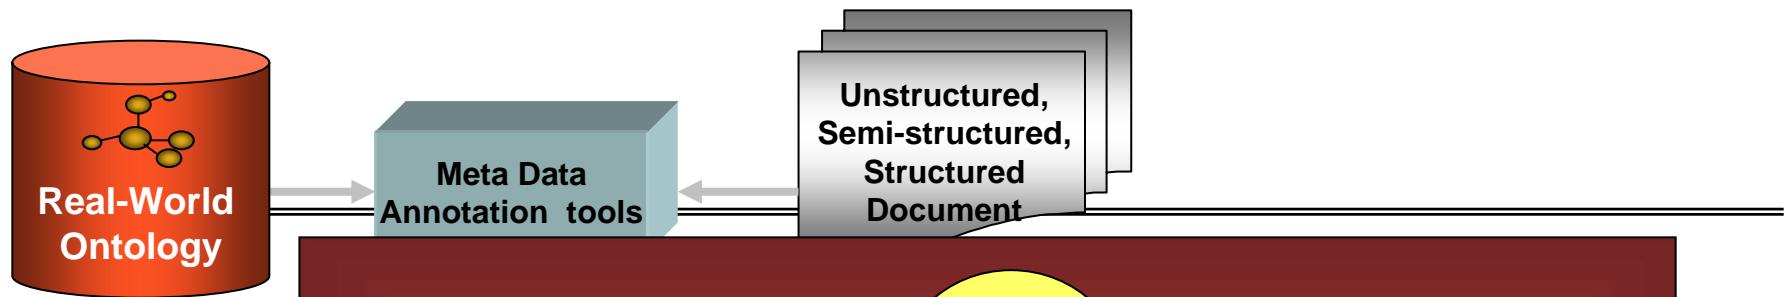
Ongoing Projects

□ Agricultural Knowledge Portal

- Ontology Maintenance
- Information extraction
- Knowledge Mining

□ Open source Digital Library

- Knowledge collecting, sharing and Accessing (DSpace)
- Library System Management (Koha)



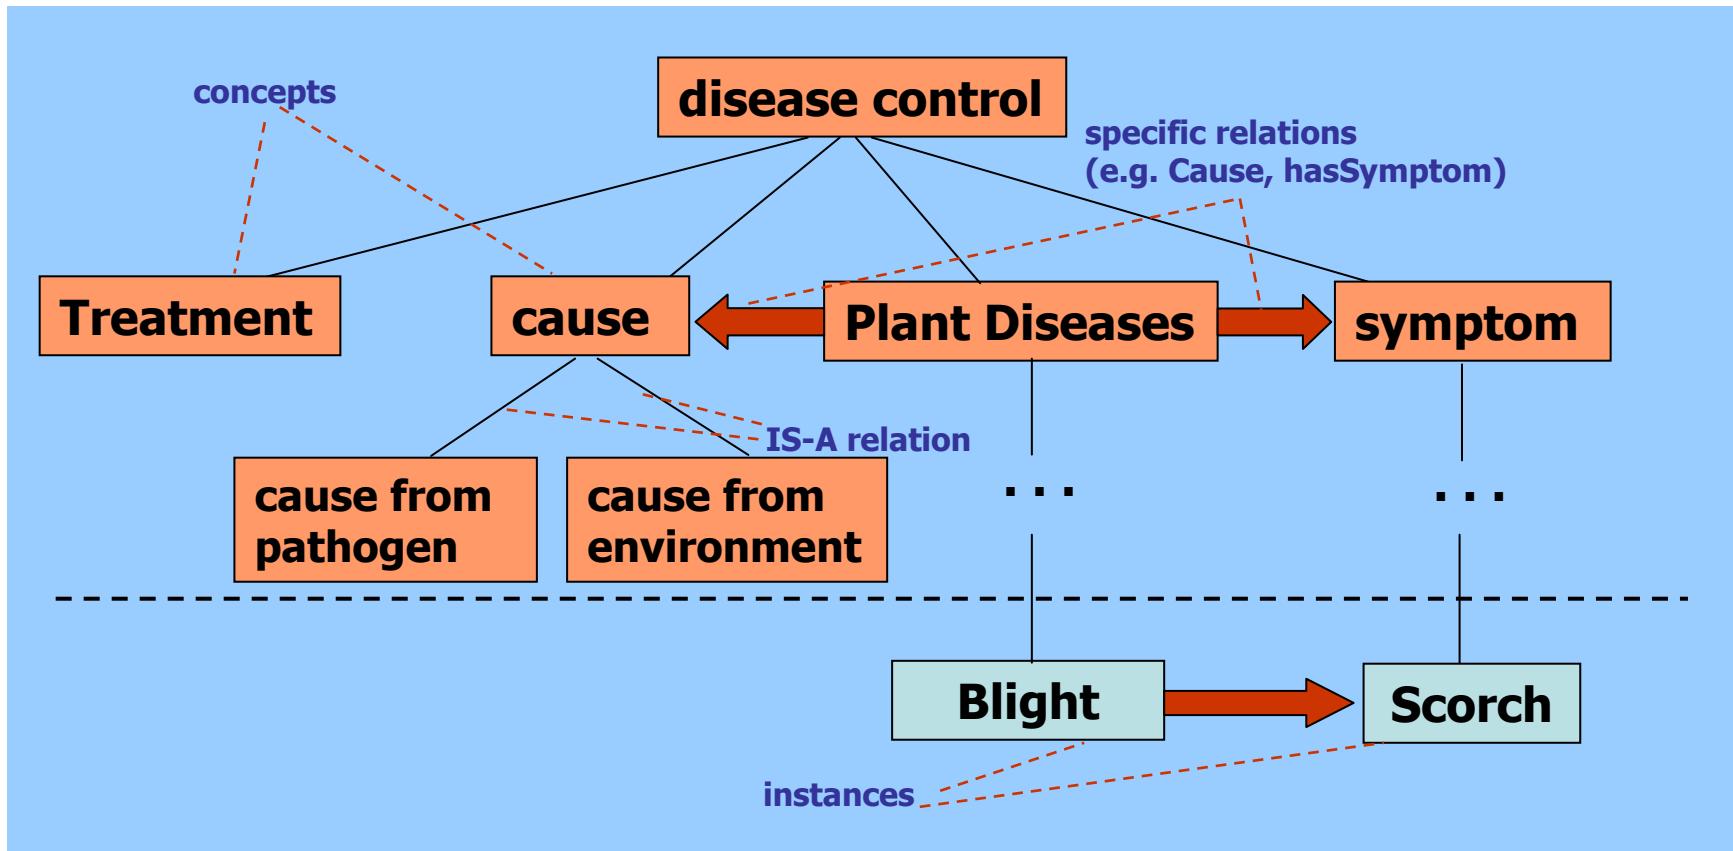
MT

KT



Ontology Development for Enhancing Service

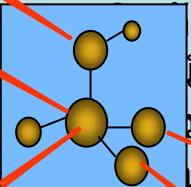
Task Oriented ontology



Automatic Ontology Construction

Raw Text Example

ผักกาดหอม

ผักกาดหอม เป็นผักที่ใช้บริโภคส่วนใน เป็นผักจำพวกผักสดที่มีคุณค่าทางอาหารสูง นิยมบริโภคกันแพร่หลายที่สุดในบรรดาผักสด ด้วยกัน โดยส่วนใหญ่นิยมรับประทานสดและนำมาประกอบอาหารหลายชนิด คนไทยนิยมใช้ผักกาด ข้าวเกรียบปากหม้อ เป็นต้น  อาหารจำพวกยำต่างๆ สาคูหมู หรือเป็นผักสดที่มีคุณค่าทางอาหารมาก เช่น กะหล่ำปลี กะหล่ำดอก ฯลฯ ยังจัดเป็นอาหารทางตาด้วยโดยการนำมาตกแต่งอาหารให้มีสีสัน น่ารับประทานมากขึ้น นอกจากนี้ผักกาดหอมยังมีคุณสมบัติในการเป็นยาอีกด้วย ความต้องการผักกาดหอม มีอยู่ตลอดทั้งปี โดยเฉพาะในช่วงเทศกาลต่างๆ จึงนับได้ว่าผักกาดหอมเป็นผักที่มีความสำคัญทางเศรษฐกิจชนิดหนึ่งที่นับวันจะทวีความต้องการเพิ่มขึ้นเรื่อยๆ

ผักกาดหอมมีชื่อเรียกอีก ได้แก่ ชื่อ เช่น ภาชนะหรือเรียกว่า ผักกาด ชื่อภาษาอังกฤษเรียกว่า ผักกาด เป็นต้น ผักกาดหอมเป็นพืชที่จัดอยู่ในตระกูล Compositae มีชื่อวิทยาศาสตร์ว่า *Lactuca sativa* มีถิ่นกำเนิดในทวีปเอเชียและยุโรป มีปลูกในประเทศไทยมาช้านานแล้ว

Corpus based Ontology Construction

□ Problems in this process:

□ Many Candidate Terms



Ex1. Many herbs can be used as medicine and some of them are manufactured in the industry such as garlic, soy, ginkgo biloba and green bean.

Candidate Terms \rightarrow herbs, medicine, industry

Ontological Term Selection

- Statistical Technique
 - Mutual Information, the measure of word association

$$MI(w_1, w_2) = \log_2 \frac{P(w_1, w_2)}{P(w_1) P(w_2)}$$

Where

w_1 is a candidate term

w_2 is a related term

$P(w_i)$ is probability of term w_i

$P(w_i, w_j)$ is probability of co-occurrence of term w_i and w_j

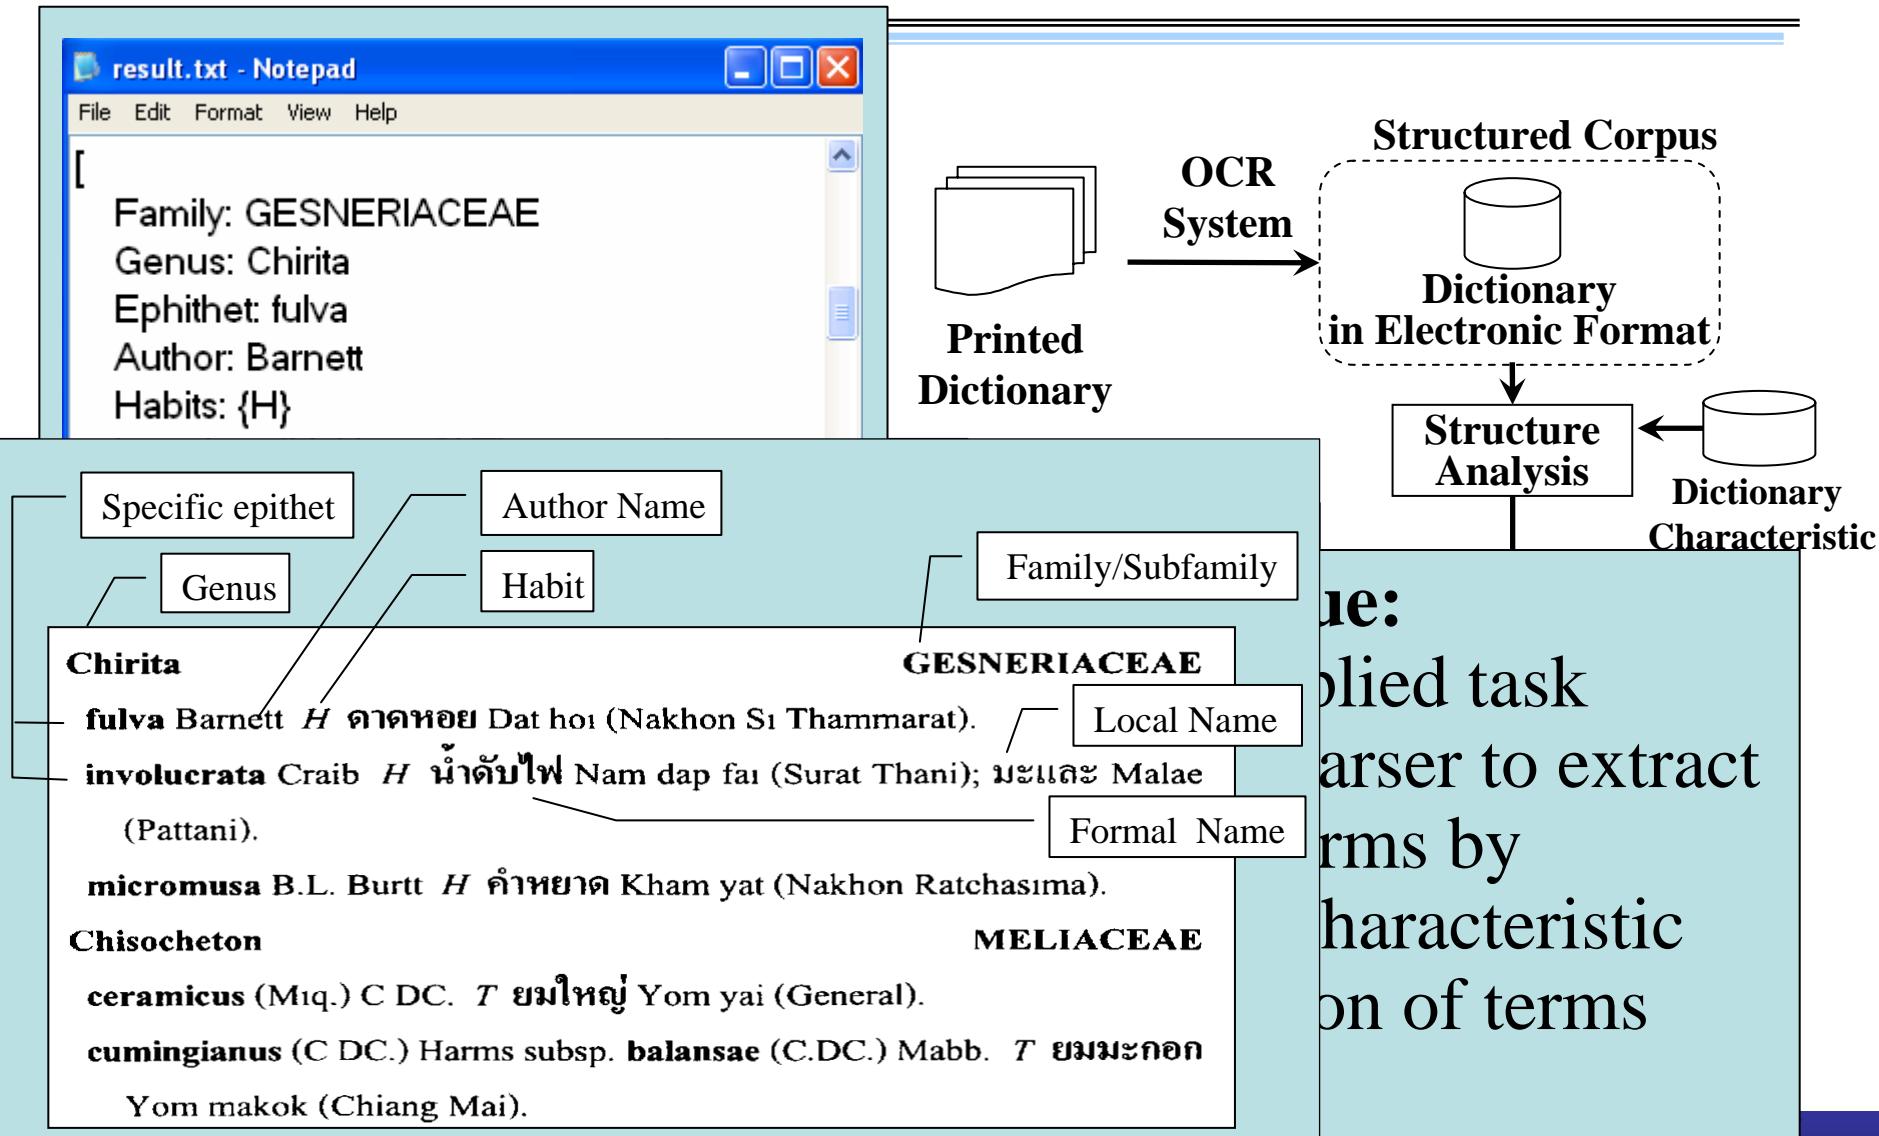
- Example

Many **herbs** can be used as **medicine** and some of them are manufactured in the **industry** level, **such as** garlic, ginkgo biloba

MI(herb, garlic) > MI(medicine, garlic), MI(industry, garlic)

Results : HYPO(garlic, herb)

Dictionary based Ontology Construction



Dictionary based Ontology Construction

□ Alphabet Characteristic of Dictionary.

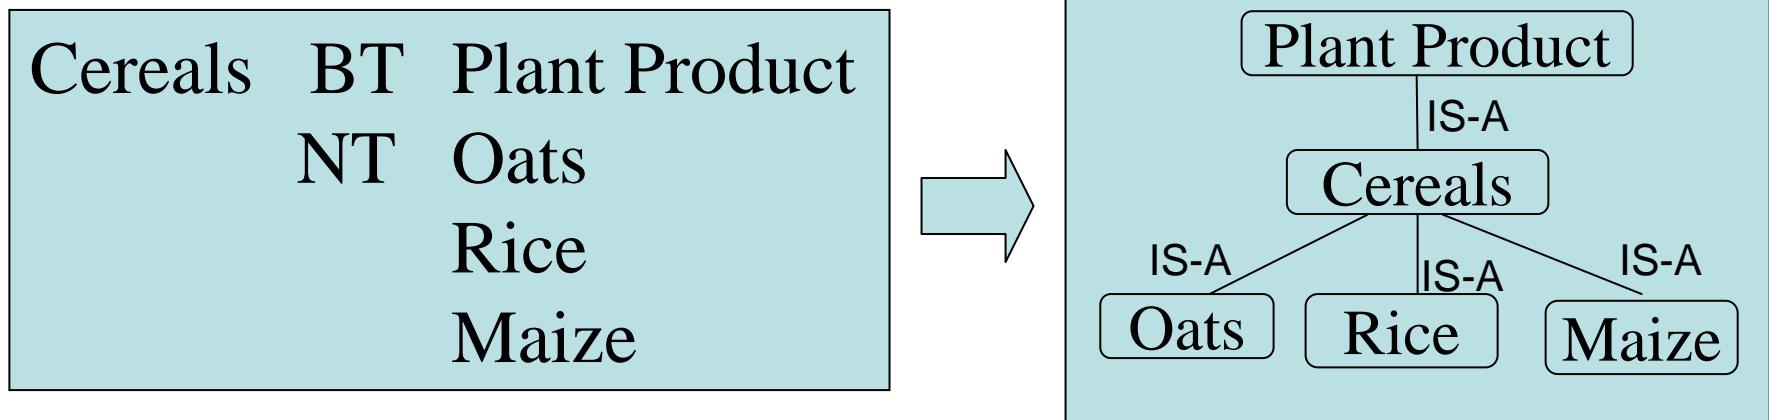
Feature	Database field	Example
All upper case	Family/Sub-Family	EUPHORBIACEAE
Start with upper case	Genus	Acalypha
All lower case	Specific epithet	brachystachya
Thai alphabet with bold font	Formal Name	ตำแหน้วยดอยในบาง
Thai alphabet	Local Name	เกี้ยวเกล้า

□ Limitation:

- Dictionary has only plant names

AGROVOC Thesaurus based Ontology Construction

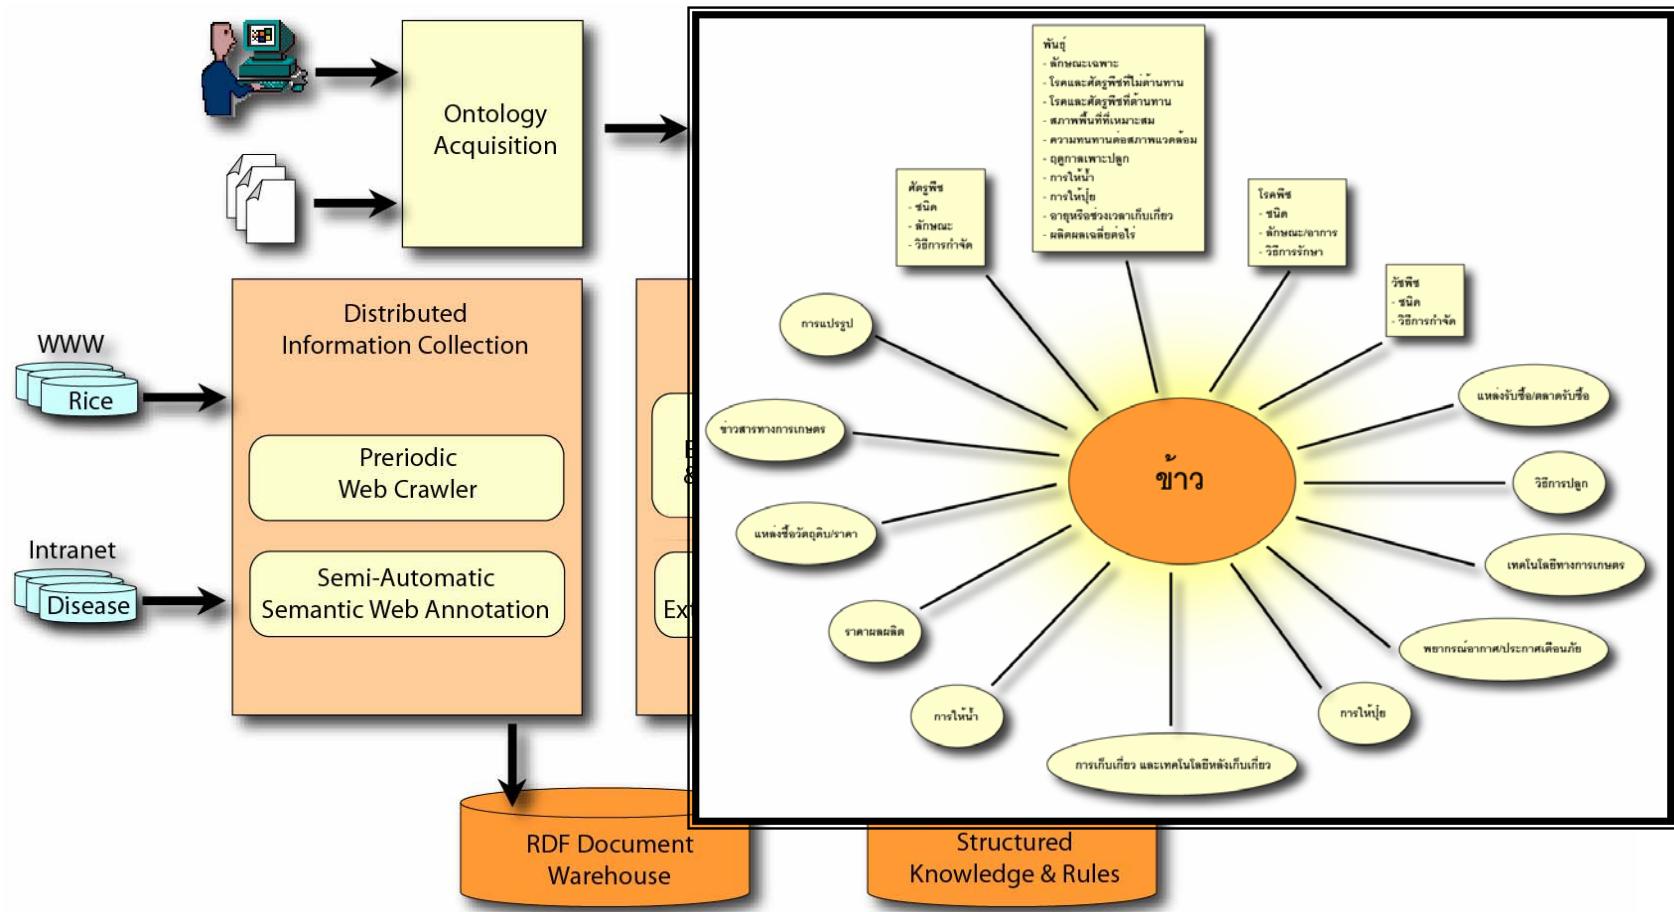
- Technique:
 - Convert BT/NT to IS-A Relation



Experimental Results

Source	Number of Terms	Number of Relations	Accuracy
Raw Text (150 doc.)	3,720	3,312	73 %.
Dictionary	37,110	21,620	100%.
Thesaurus	27,540	15,628	91%.
3 Sources	43,073	31,387	87 %.

- By random checking with 1,000 united terms, the accuracy of the system is 87 %.



Deployment

Knowledge portal as

One Stop Service



**Better living condition of
Agriculture**

Finally,

- We have just initiated an open source Digital Library since it will be the back bone of e-learning for both formal and informal education.

Knowledge based Society and Economy, Academic Knowledge Factory and Knowledge Park

so on.

Acknowledgement

- KURDI: Kasetsart University Research and Development Institute
- Graduate School of Kasetsart University
- IADLC2005 Chairs and Organizer