

# **Thai Text Processing and Its Applications**


**Virach Sornlertlamvanich**

Sirindhorn International Institute of Technology (SIIT),  
Thammasat University, Thailand  
[virach@siit.tu.ac.th](mailto:virach@siit.tu.ac.th)

# NLP Challenges

- **Natural Language Processing** is no more for the language study only.

**Turing Test** as a tool to understand whether "**machines can think**".




**Searle's Chinese Room argument** 1980 in "Minds, Brains, and Programs"

**Accurate NLP:** machine translation, summarization, machine reading, question answering, information retrieval, social text understanding, opinion mining, etc.

# NLP Challenges

- **Internet, Big Data, Machine Learning, Deep Learning** have brought along the possibilities.



## Facebook:-

Adds 0.5 petabyte ( $10^{15}$ ) of data every 24 hours

## Twitter:-

Adds 340 million tweets per day

## Youtube:-

Adds 100 hours of new videos every minute

Germin8, Social Intelligence

# NLP Challenges

## NLP NEEDS BIG DATA

Using Hadoop with NLTK

- Computational Linguistics methodologies are stochastic
- Examples are easier to create than rules
- Rules and Logic miss frequency and language dynamics
- Humans use lots of data for the same task- It's All!
- More data is better - relevance is in the long tail
- If you don't have enough data - hire a knowledge engineer

## BIG DATA WILL NEED NLP

Using NLTK with Hadoop

- Hadoop is great at massive amounts of text data
- However, current methods aren't really NLP
- Indexing, Co-Occurrence, even N-Gram Modeling is search
- We haven't exhausted frequency analysis yet
- But when we do, we're going to want semantic analyses

Bird Steven, Edward Loper and Ewan Klein (2009), Natural Language Processing with Python. O'Reilly Media Inc.

Data Community DC (DC2)

## Three NLP Fundamental Problems

- Word Segmentation/Tokenization
- Named Entity Recognition/Keyword Extraction
- Semantic Relation Extraction

## Three NLP Constructive Applications

- Linked Data → Knowledge Map
- Keyword Tracking → Social Movement
- Hyper Local News → Urban-Rural Info Gap


# **WORD SEGMENTATION**

# Thai Language as a Non-Segmenting Language

- No explicit word boundary marker e.g. capital letter, space character, punctuation mark, etc.
- No inflection
- No grammatical marker

How to determine word and sentence boundary?!?!

# Simulating a Non-Segmenting Language



# Word-Based Approach

## Word segmentation (accuracy for Thai)

- Longest matching: 92%
- Maximal matching: 93%
- POS tri-gram: 96%
- Machine learning: 97%

## Sentence segmentation (accuracy for Thai)

- POS tri-gram: 84.57%
- Feature-based approach  
(Winnow): 89.13%

# Character-Based Approach

## Term Extraction

- Automatic Corpus-Based Thai Word Extraction with the **C4.5** Learning Algorithm
- C4.5-trained decision tree for determining potential word boundary from **MI**, **Entropy** and some **linguistic information**
- Capable of discovering new words in document without assistance from static dictionary

# Attributes(1) : Left and Right Mutual Information

$$MI_L(xyz) = \frac{p(xyz)}{p(x)p(yz)}$$

x

yz

$$MI_R(xyz) = \frac{p(xyz)}{p(xy)p(z)}$$

xy

z

where

x is the leftmost character of string xyz

y is the middle substring of xyz

z is the rightmost character of string xyz

p( ) is the probability function.

High mutual information implies that xyz co-occurs more than expected by chance. If xyz is a word, its  $MI_L$  and  $MI_R$  must be high.

...**efunction**... and ...**ffunction**...

## Attributes(2) : Left and Right Entropy

$$H_L(y) = - \sum_{\text{all } x \in A} p(xy | y) \cdot \log_2 p(xy | y)$$

$x$    $y$

$$H_R(y) = - \sum_{\text{all } z \in A} p(yz | y) \cdot \log_2 p(yz | y)$$

$y$    $z$

where

$x$  is the leftmost character of string  $xyz$

$y$  is the middle substring of  $xyz$

$z$  is the rightmost character of string  $xyz$

$p()$  is the probability function.

Entropy shows the variety of characters before and after a word.

If  $y$  is a word, its left and right entropy must be high.

...?function... and ...?unction...

# Attributes(3) : Frequency, Length Function Word

- **Frequency**

Words tend to be used more often than non-word string sequences.

- **Length**

Short strings are likely to happen by chance. The long and short strings should be treated differently.

- **Function Word**

Function words are used mostly in phrases. They are useful to disambiguate words and phrases.

$$Func(s) = \begin{cases} 1 & \text{if } s \text{ contains a function word} \\ 0 & \text{otherwise} \end{cases}$$

## Attributes(4): First Two and Last Two Characters

- **Frequency of the first-two characters** of the considered string which appears in the first-two characters of words in the dictionary  
high frequency -> the beginning of the considered string conforms to the Thai spelling system.

Ex.

function: how likely fu can be the beginning of word.

This idea can be also applied to **the last-two characters**.

# Experimental Results (1)

## The Precision of Word Extraction

	No. of strings extracted by the decision tree	No. of words extracted	No. of non-word strings extracted
Training Set	1882 (100%)	1643 (87.3%)	239 (12.7%)
Test Set	1815 (100%)	1526 (84.1%)	289 (15.9%)

## The Recall of Word Extraction

	No. of words that has more than 2 occurrences in corpus	No. of words extracted by the decision tree	No. of words in corpus that are found RID
Training Set	2933 (100%)	1643 (56.0%)	1833 (62.5%)
Test Set	2720 (100%)	1526 (56.1%)	1580 (58.1%)

Remark: These precision and recall are measured against 30,000 strings that occur more than 2 times in the corpus and conform to some simple Thai spelling rules.

# Experimental Results (2)

## Word Extraction VS. a Dictionary

	No. of words extracted by the decision tree	No. of words extracted by the decision tree which is in RID	No. of words extracted by the decision tree which is not in RID
Training Set	1643 (100.0%)	1082 (65.9%)	561 (34.1%)
Test Set	1526 (100.0%)	1046 (68.5%)	480 (31.5%)

Remark: RID is referred to the Thai-Thai dictionary published by The Royal Institute in 1982.

# **KEYWORD AND SEMANTIC RELATION EXTRACTION**

# Semantic Link Generation

- Semantic Representation of the description
  - **Keyword Extraction**
    - Extract keywords in text documents and link them to appropriate articles
  - **Semantic Relation Extraction**
    - Extract common syntactic patterns between two keywords and generalize them to a triple  $(e_i, r_{ij}, e_j)$
- Linked Data
  - Set of triple  $(e_i, r_{ij}, e_j)$

# Keyword Extraction

- Some keywords are readily available in the set **tags**, but many of them are still missing.
- Our task is to extract those missing keywords from the **description** and **title**.

## Focused NE in Cultural Domain Database

- Cultural attraction (Place)
- Cultural person (Person)
- Cultural artifact (Object)

# Training Data Preparation

- Generate a keyword list from **tags** and **titles** that are not shorter than 5 characters and not longer than 30 characters
- POS tagged **descriptions**
- Label the POS tagged descriptions with the keyword list

# Labeling

- Apply BIO tagging
  - B: beginning position of a keyword
  - I: intermediate (or end) position of a keyword
  - O: other words
- If several matches are possible, select the longest one

# Training Data

- Description

ผ้าชิ้นลายมัดหมีบ้านปทุมแก้ว เป็นงานฝีมือพื้นบ้าน .....

# Training Data

- Description

ผ้าซิ้นลายมัดหมีบ้านปทุมแก้ว เป็นงานฝีมือพื้นบ้าน ....

- Segmented/Tagged/Labeled Description

Word	POS tag	Label
ผ้าซิ้น	N	B-K
ลายมัดหมีบ้านปทุมแก้ว	N	I-K
<space>	P	O
เป็น	V	O
งานฝีมือพื้นบ้าน	N	O
.....	.....	.....

- Keyword List  
(extracted from tag and title)

.....  
ผ้า

.....  
ผ้าซิ้น


.....  
ผ้าซิ้นลายมัดหมีบ้านปทุมแก้ว

# Preliminary Experiment Result

- Based on Margin Infused Relaxed Algorithm (MIRA), Crammer et al., 2005

<b>(I): word 1, 2 grams + label bigrams</b> $\langle w_j \rangle, j \in [-2, 2] \times y_0$ $\langle w_j, w_{j+1} \rangle, j \in [-2, 1] \times y_0$ $\langle y_{-1}, y_0 \rangle$	<b>(III): (II) + POS 3 grams</b> $\langle p_j, p_{j+1}, p_{j+2} \rangle, j \in [-2, 0] \times y_0$
<b>(II): (I) + POS 1,2 grams</b> $\langle p_j \rangle, j \in [-2, 2] \times y_0$ $\langle p_j, p_{j+1} \rangle, j \in [-2, 1] \times y_0$	<b>(IV): (III) + k-char prefixes/suffixes</b> $\langle P_k(w_0) \rangle, k \in [2, 3] \times y_0$ $\langle S_k(w_0) \rangle, k \in [2, 3] \times y_0$ $\langle P_k(w_0), S_k(w_0) \rangle, k \in [2, 3] \times y_0$

# F-Measure



Average evaluation result on NE annotated online news  
Recall=0.8256, Precision=0.9061, F1=0.8640

# Semantic Relation Acquisition

- Extract commons syntactic patterns between two nouns
- Our task is to acquire triples  $(e_i, r_{ij}, e_j)$ , where
  - $e_i$  and  $e_j$  are entities (keywords)
  - $r_{ij}$  is a relationship between them

# Semantic Relation Template


<b>Domain</b>	<b>Relation</b>	<b>Surface</b>	<b>Argument</b>
Cultural attraction	ISLOCATEDAT	ตั้งอยู่ที่	LOC
	ISBUILTIN	สร้าง(ขึ้น)*ใน สร้าง(ขึ้น)*เมื่อ ตั้ง(ขึ้น)*เมื่อ	DATE
	ISBUILTBY	สร้าง(ขึ้น)*โดย ตั้ง(ขึ้น)*โดย	PER, ORG
	HASOLDNAME	เดิมชื่อ <sup>*</sup> ชื่อเดิม	LOC, ORG
Cultural person	MARRIEDWITH	สมรสกับ	PER
	HASFATHERNAME	บิดาชื่อ	PER
	HASMOTHERNAME	มารดาชื่อ	PER
	HASOLDNAME	เดิมชื่อ <sup>*</sup> ชื่อเดิม	PER
	HASBIRTHDATE	เกิด(เมื่อ)*	DATE
	BECOME MONKIN	อุปสมบทเมื่อ	DATE
Cultural artifact	ISMADEBY	ผลิต(ขึ้น)*โดย ทำ(ขึ้น)*โดย ผลงานโดย	PER, ORG
	ISSOLDAT	จำหน่ายที่	LOC, ORG

# Relation Instances Found in Word Distance

Relation	Argument	Distance					
		0	1	2	3	4	5
Cultural attraction							
ISLOCATEDAT	LOC	356	574	591	624	678	757
ISBUILDDIN	DATE	3825	11487	11538	11573	11633	11667
ISBUILDBY	PER, ORG	131	202	218	234	249	257
HASOLDNAME	LOC, ORG	0	9	21	26	27	29
Cultural person							
MARRIEDWITH	PER	132	177	177	177	177	177
HASFATHERNAME	PER	120	372	372	373	373	373
HASMOTHERNAME	PER	97	383	383	383	383	383
HASOLDNAME	PER	51	259	273	277	277	283
HASBIRTHDATE	DATE	4122	4745	4801	4947	4966	5075
BECOMEMONKIN	DATE	346	435	435	436	436	436
Cultural artifact							
ISMADEBY	PER, ORG	62	107	109	125	129	130
ISSOLDAT	LOC, ORG	31	31	56	59	62	64

# Extract Common Syntactic Pattern of a Predicate between Two Keywords

- Example



# Extract Common Syntactic Pattern of a Predicate between Two Keywords

- Example

(วัดทุ่ง, สร้างขึ้นในสมัย, กรุงสุโขทัย)

(วัดตราด, สร้างขึ้นในสมัย, กรุงศรีอยุธยาตอนต้น)

(หลวงพ่อขาว, สร้างขึ้นในสมัย, อุบลราช)

(พระพุทธรูปปางมารวิชัย, สร้างขึ้นในสมัย, รัตนโกสินทร์ตอนต้น)

(วิหารวัดโยธาโนมิต, สร้างขึ้นในสมัย, พระบาทสมเด็จพระเจ้าตากสินมหาราช)



( $e_i$ , BUILT\_IN,  $e_j$ )

# Extract Common Syntactic Pattern of a Predicate between Two Keywords

- Example

(กระโจมไฟบ้านโรงถ่าน, **สร้างโดย**, อพท.)

(ศาลาเจ้าตากสิน วัดบ้านค่าย, **สร้างโดย**, พระครูพิพัฒน์ชยาภรณ์)

(วัดทุ่งโหงไต้, **สร้างโดย**, กลุ่มชาวลាតาวน)

(ศาลาพระพรหม, **สร้างโดย**, เทศบาลนครเชียงราย)

(วงเวียนนิมิตร, **สร้างโดย**, เทศบาลนครภูเก็ต)



( $e_i$ , BUILT\_BY,  $e_j$ )

# Accuracy of Relation Extraction

<b>Relation</b>	<b>Argument</b>	<b>#Sample</b>	<b>#Correct</b>	<b>#Incorrect</b>	<b>Accuracy</b>
Cultural attraction					
ISLOCATEDAT	LOC	50	49	1	98%
ISBUILDDIN	DATE	50	48	2	96%
ISBUILDBY	PER, ORG	50	48	2	96%
HASOLDNAME	LOC, ORG	27	23	4	85%
Cultural person					
MARRIEDWITH	PER	50	49	1	98%
HASFATHERNAME	PER	50	48	2	96%
HASMOTHERNAME	PER	50	49	1	98%
HASOLDNAME	PER	50	47	3	94%
HASBIRTHDATE	DATE	50	48	2	96%
BECOMEMONKIN	DATE	50	50	0	100%
Cultural artifact					
ISMADEBY	PER, ORG	50	44	6	88%
ISSOLDAT	LOC, ORG	50	49	1	98%

NLP Applications


# **KNOWLEDGE MAP GENERATION**

I hope we will  
use the Net to  
cross barriers  
and connect  
cultures.

*Tim Berners Lee*

[meetville.com](http://meetville.com)

# Types of Semantic Relation



Domain	Relation	Surface	Argument
Cultural attraction	ISLOCATEDAT	พื้นที่ที่	LOC
	ISBUILTIN	สร้าง(ชื่น)*ใน สร้าง(ชื่น)*เมื่อ ตั้ง(ชื่น)*เมื่อ	DATE
	ISBUILTBY	สร้าง(ชื่น)*โดย ตั้ง(ชื่น)*โดย	PER, ORG
	HASOLDNAME	เดิมชื่อ <sup>*</sup> ชื่อเดิม	LOC, ORG
Cultural person	MARRIEDWITH	สมรสกับ	PER
	HASFATHERNAME	บิดาชื่อ	PER
	HASMOTHERNAME	มารดาชื่อ	PER
	HASOLDNAME	เดิมชื่อ <sup>*</sup> ชื่อเดิม	PER
	HASBIRTHDATE	เกิด(เมื่อ)*	DATE
	BECOME MONKIN	อุปสมบทเมื่อ	DATE
Cultural artifact	ISMADEBY	ผลิต(ชื่น)*โดย ทำ(ชื่น)*โดย ผลงานโดย	PER, ORG
	ISSOLDAT	จำหน่ายที่	LOC, ORG

# Knowledge Map

ISBUILTIN(พระเจดีย์กลางน้ำ, พ.ศ.2403)


ISLOCATEDAT(พระเจดีย์กลางน้ำ, ตำบลปากน้ำ)



A screenshot of a mobile application interface. At the top, there is a search bar with the text "พะยอม" and a magnifying glass icon. Below the search bar is a large image of a white pagoda against a blue sky. Underneath the image, the text "พะยอมพีಠกโลกานົມ" is displayed. At the bottom of the screen, there is a table with two rows of information:

ສໍາກັນ	ພ.ຮ.2403
ເທົ່ານີ້	ເຖິງບະຈາກນໍາ

## Knowledge map



# Knowledging

## Semantically Enhanced Cultural Database [Place, Person, Artifact]



# **SOCIAL MOVEMENT UNDERSTANDING**

ICICTES 2016, Pullman Hotel, March 20-22, 2016


# Data Data Data!!!

- Drastically increase number of users on social network
- Keywords in the contents express the concepts of the talk
- Social media texts are input in a time sequence
- But, social media texts are normally short, incomplete and diverse



# Word Article Matrix (WAM)

## Wikipedia Articles



## Creating WAM

Page  
Contents

Word seg. &  
Lemmatization  
Thinking -> Think

Word list

Page Title


Pages\Words	“Twitter”	“Tennis”	“Dollar”	“Google”	...
IT	2	0	1	4	
Sport	0	2	1	0	
Economics	0	0	2	0	
...					

Wikipedia WAM


ICICTES 2016, Pullman Hotel, March 20-22, 2016

# Text Similarity

SIM Function: Dot Product  $\sum_{t \in q \wedge t \in d} (w_{q,t} \cdot w_{d,t})$



# Modified WAM for Social Media Text Classification



# A Part of Modified WAM

i-WAM	อิเกล 'intel'	ศัลยกรรม 'surgery'	เมตตา 'mercy'	คลาวด์ 'cloud'	คลิป 'clip'	เน็ต 'network'
Life	0.052	0.205	0.160	0.168	0	0
Education	0	0.025	0.036	0	0	0
Technology	0.103	0	0	0.230	0	0

m-WAM	อิเกล 'intel'	ศัลยกรรม 'surgery'	เมตตา 'mercy'	คลาวด์ 'cloud'	คลิป 'clip'	เน็ต 'network'
Life	0.026	0.275	0.268	0.177	0.036	0.040
Education	0	0.013	0.018	0	0	0
Technology	0.164	0	0	0.281	0.009	0.187


  

m-WAM2	อิเกล 'intel'	ศัลยกรรม 'surgery'	เมตตา 'mercy'	คลาวด์ 'cloud'	คลิป 'clip'	เน็ต 'network'
Life	0.013	0.255	0.241	0.174	0.119	0.034
Education	0	0.009	0.011	0	0.009	0.019
Technology	0.107	0	0	0.238	0.019	0.143

# F-Measure

	Life	Education	Technology
i-WAM on text1	86.79%	36.09%	55.79%
m-WAM on text1	86.64%	34.57%	56.01%
m-WAM on text2	91.33%	29.91%	43.17%
m-WAM2 on text2	94.93%	29.47%	43.72%

# Tweeter Viewer



# Coup on May 22, 2014

- ทหาร, คสช., ประทetc, ประกาศ,  
ส่งบ, อำนาจ, รัฐบาล, รัฐประหาร,  
ชุมนุม, ตำรวจ, สถานการณ์, นายก,  
ควบคุม, ยึด, ประชุม, เศรษฐกิจ,  
กฎหมาย, ศึก, แก่นนำ, รัฐมนตรี,  
เลือกตั้ง, ประชาธิปไตย, ปฏิวัติ. ยึด  
อำนาจ. เดอร์ฟิว. กฎอัยการศึก
- military, NCPO, country,  
announce, peace, power,  
government, coup d'etat,  
gathering, police,  
situation, PM, control,  
seize, meeting, economy,  
law, war, leader, minister,  
election, democracy,  
revolution, seize the  
power, curfew, martial  
law


# Tweet Query

- Search Tweets by using Restful API
  - GET search/tweets. Set q = the keyword set
  - 100 tweets/search limited
  - Repeatedly fetch data until all tweets in the coup periods are discovered
- Be able to search back to 7 days


May 22, 2014 Coup-related tweet : 339,148 tweets

<http://sn.iisilab.org/>


# Timeline Word Cloud




May 22, 2014 1:00:00 PM - Total size: 19



May 22, 2014 2:00:00 PM - Total size: 22




May 22, 2014 3:00:00 PM - Total size: 37



May 22, 2014 4:00:00 PM - Total size: 118

**Coup D'etat**



May 22, 2014 5:00:00 PM - Total size: 57883



May 22, 2014 6:00:00 PM - Total size: 43123



May 22, 2014 7:00:00 PM - Total size: 33724



May 22, 2014 8:00:00 PM - Total size: 30870



May 22, 2014 9:00:00 PM - Total size: 26225

# **URBAN-RURAL INFORMATION GAP FILLER**

ICICTES 2016, Pullman Hotel, March 20-22, 2016


# Purpose

- To deliver local news to complement the deteriorating local newspaper
- To promote data usage in rural area



To improving rural livelihood through its reputation extraction!


# Collecting information



# Analyze

- **NEWS Classification**
  - Word segmentation
  - Named Entity Recognition
  - NEWS domain and province classification and ranking based on TF/IDF technique
- **Information Extraction**
  - Template based extraction
- **Infobox**
  - Celebrity i.e. politician, idol
  - Province
- **Social Media**
  - Trending topic
  - Leader and follower
  - Opinion polarity

# News Classification



ขาย - ห้องน้ำส่วนตัว	ขาย - บ้านเดี่ยว	ขาย - บ้านเดี่ยว	ขาย - บ้านเดี่ยว
 <p>ขาย - ห้องน้ำส่วนตัว คุณภาพพิเศษ โครงการ คงจำเนา รีสอร์ท เส้นสุข, วารีบันชาราน, อุบลราชธานี</p> <p>1,850,000 บาท</p>	 <p>ขาย - ห้องน้ำส่วนตัว ขยายบ้าน 99/79 ใน เมือง, เมือง อุบลราชธานี, อุบลราชธานี</p> <p>2,300,000 บาท</p>	 <p>ขาย - house for sale ubon บ้านให้เช่า, เมือง อุบลราชธานี, อุบลราชธานี</p> <p>1,800,000 บาท</p>	 <p>ขาย - บ้านเดี่ยว ใหม่ชั้นราคางานเก็บ ถูก สมเด็จ ( อุบล-ศากยสุน ) 8 ป่าบุ, เมือง อุบลราชธานี, อุบลราชธานี</p> <p>990,000 บาท</p>

คุณภาพชีวิต คุณภาพชีวิตรักษาสุขภาพ  
/ประสาทงานที่นำไปบริษัท เศรีครองแอลไ  
ลเกอร์ จำกัด (มหาชน) เป็นเดือนหมด  
ร่างเรียบร้อย 1/9/14

- เจ้าหน้าที่บัญชี ประจำสาขาอุบลฯ (STA-UB) ตำแหน่งบัญชี/การเงิน เป็นผู้ริบ  
ศธ์หรือผู้โกรธดีเด็กสห จำกัด (มหาชน) เป็นเดือน  
คาดปีงบประมาณเดือน 27/8/14
  - พนักงานภาระรายได้ ตำแหน่งบริการลูกค้า/C  
Center/พนักงานต้อนรับ/ตนไทยศิริพัทฯ LDS  
(Thailand) Co.,Ltd. เป็นเดือน 12,000-18,000  
27/8/14

## គ្មានអ៊ិបុត្រ នៃអង្គភាព

			
<p><b>ขาย - ปะตุาค่าย กາຍເນື້ອເສັ່ສ</b> ສູາພິພນາ ຂອຍໄຂຍ ສີຮັກ 1448/3 ຫຼູກ 18 ຕຳ ຫານໄຫຍງ, ເມືອງອຸປະຮາມໄຕ, ອຸປະຮາມໄຕ</p> <p><b>1,500,000 บาท</b></p>	<p><b>ขาย - ກາວນໍເຫົ່າສ ໄກລເຊັບຮອບອຸດຸກ</b> ສຸຄາ ເພີ້ງ 1.6 ອານ ບາກ</p> <p>ພົມຍື ໃນເມືອງ, ເມືອງ ອຸປະຮາມໄຕ, ອຸປະຮາມໄຕ</p> <p><b>1,600,000 บาท</b></p>	<p><b>ขาย - ກາວນໍເຫົ່າສ ທະນີໂຄດວັບ</b> ແສບສຸນ, ວາຮັນຫ່າງຮາບ, ອຸປະຮາມໄຕ</p> <p><b>900,000 บาท</b></p>	<p><b>ขาย - ບ້ານສ້າງ 10 ຕະກຣາມ 31 ໃນເມືອງ, ເມືອງອຸປະຮາມໄຕ, ອຸປະຮາມໄຕ</b></p> <p><b>3,500,000 บาท</b></p>

คู่มือการศึกษาฯ ใหม่



30/5/2015 03:12:06

# Summary

- **Word segmentation, Keyword extraction, NER, WSD, Semantic relation extraction etc.** are the basic issues of NLP in the current language environment.
- **Efficient computational scenario** is crucial under the drastic growth of data and coverage of the Internet.
- **User-generated contents** are the unlimited language resources.
- NLP technology helps in filling the **information gap** between the haves and the have-nots, filling the **technology gap** between the resource-rich and under-resourced languages.

# References

- Virach Sornlertlamvanich, Tanapong Potipiti and Thatsanee Charoenporn. **Automatic Corpus-based Thai Word Extraction with the C4.5 Learning Algorithm**. Proceedings of the 18th International Conference on Computational Linguistics (COLING2000), Saarbrucken, Germany, pp 802-807, July-August 2000.
- Virach Sornlertlamvanich, Thatsanee Charoenporn, Canasai Kruengkraii, and Hitoshi Isahara. **Statistical-based Approach to Non-segmented Language Processing**, IEICE Transactions on Information and Systems, Vol. E90-D, No.10, pp.1565-1573, October 2007.
- Canasai Kruengkrai, Virach Sornlertlamvanich, Watchira Buranasing, and Thatsanee Charoenporn. **Semantic Relation Extraction from a Cultural Database**, Proceedings of Workshop on South and Southeast Asian NLP, COLING2012, Mumbai, India, December 8-15, 2012.
- Virach Sornlertlamvanich and Kobkrit Viriyayudhakorn. **Social Movement Understanding by Keyword Tracking**, In Book: Information Modelling and Knowledge Bases XXVI, Volume 272, Eds. Thalheim, B. and et al., IOS Press, 2014.
- Virach Sornlertlamvanich and Canasai Kruengkrai. **Effectiveness of Keyword and Semantic Relation Extraction for Knowledge Map Generation**, Proceedings of The Second International Workshop on Worldwide Language Service Infrastructure (WLSI), Kyoto University, Kyoto, Japan, January 22-23, 2015.
- Virach Sornlertlamvanich. **Hyper Local NEWS Publishing. ---Collect, Analyze, Visualize---**, International Conference on Information Modelling and Knowledge Bases (EJC2015), Maribor, Slovenia, June 8-12, 2015.

# Acknowledgement

- Eakasit Pacharawongsakda
- Kobkrit Viriyayudhakorn
- Canasai Kruengkrai
- Thatsanee Charoenporn
- Tanapong Potipiti
- Situdhibhong Laokok
- Watchira Buranasing
- Thanasan Tanhermhong
- Wirat Chinnan
- Ministry of Culture
- Claudia Soria (hint of images)