

Bootstrapping Asian Language Treebank using Indonesian language resource




Badan Pengkajian dan Penerapan Teknologi

Hamman Riza


Deputy Chairman

Agency for the Assessment and Application of Technology
(BPPT)


Treebank



Treebanks have become valuable resources in natural language processing (NLP) in recent years (Abeillé, 2003) such as training corpus, repository for linguistic research or as evaluation corpus.




A treebank is a collection of syntactically annotated sentences in which the annotation has been manually checked. The name derives from the fact that syntactic descriptions of sentences often come in the form of tree structures, in particular constituent trees.



But treebank annotation has also been done in the framework of dependency grammar and recent annotation has also exceeded syntax towards semantic features such as predicate-argument structures or word senses.

Introduction

- ❖ **READY:** This is ASEAN's time. In the geographic heart of the world's premier growth corridor, ASEAN is poised to "seize the moment."
- ❖ **SET:** With a market of **over 600 million consumers** and combined **GDP of nearly US\$3 trillion**, ASEAN is offering a future of prosperity and stability. The AEC is one of the foundations of that future.
- ❖ **GO:** Agreements on trade, services and investment are changing the economic landscape and allowing the freer flow of goods, services and people across the region.



1



ASEAN Economic Community ประเทศ ประชาคมเศรษฐกิจอาเซียน



THAILAND
ราชอาณาจักรไทย

ธงชาติประเทศไทย
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ประชาธิปไตยอันมีพระมหากษัตริย์ทรงเป็นประมุข
นายกรัฐมนตรี
คุณเศรษฐา ทวีสิน
812,118 ตารางกิโลเมตร
68 ล้านคน (พ.ศ. 2555)
ไทย
บาท

INDONESIA
สาธารณรัฐอินโดนีเซีย

ธงชาติอินโดนีเซีย
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ประชาธิปไตยที่มีประธานาธิบดีเป็นประมุข
ประธานาธิบดี
โจโก วิโดโด
1,904,443 ตารางกิโลเมตร
242 ล้านคน (พ.ศ. 2555)
อินโดนีเซีย
รูปี

VIET NAM
สาธารณรัฐสังคมนิยมเวียดนาม

ธงชาติเวียดนาม
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ลัทธิคอมมิวนิสต์
เป็นระบอบการปกครอง
นายกรัฐมนตรี
ฟานวันถิ
331,890 ตารางกิโลเมตร
89.57 ล้านคน (พ.ศ. 2553)
เวียดนาม
ดอง

CAMBODIA
ราชอาณาจักรกัมพูชา

ธงชาติกัมพูชา
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ประชาธิปไตยแบบราชาธิปไตยที่มีกษัตริย์เป็นประมุข
นายกรัฐมนตรี
พนมเปญ
181,038 ตารางกิโลเมตร
14.14 ล้านคน (พ.ศ. 2553)
เขมร
เรียล/กัมพูชา

LAO PDR
สาธารณรัฐประชาธิปไตยประชาชนลาว

ธงชาติลาว
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ลัทธิคอมมิวนิสต์ (ระบอบการปกครอง)
โดยมีพรรคประชาชนปฏิวัติลาว
นายกรัฐมนตรี
เวียงจันทน์
236,800 ตารางกิโลเมตร
6.0 ล้านคน (พ.ศ. 2553)
ลาว
กีบ

SINGAPORE
สาธารณรัฐสิงคโปร์

ธงชาติสิงคโปร์
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

สาธารณรัฐแบบรัฐสภา (มีกษัตริย์)
นายกรัฐมนตรี
สิงคโปร์
710 ตารางกิโลเมตร
5.08 ล้านคน (พ.ศ. 2555)
อังกฤษ, มาเลย์, จีนกลาง
ดอลลาร์สิงคโปร์

MALAYSIA
มาเลเซีย

ธงชาติมาเลเซีย
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

สหพันธรัฐ โดยมีกษัตริย์ทรงเป็นประมุข
นายกรัฐมนตรี
กัวลาลัมเปอร์
329,758 ตารางกิโลเมตร
28.9 ล้านคน (พ.ศ. 2555)
มาเลย์
ริงกิตมาเลย์

Brunei Darussalam
รัฐบรูไนดารุสซาลาม

ธงชาติบรูไน
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

สมบูรณาญาสิทธิราชย์
โดยมีสมเด็จพระราชาธิบดีเป็นองค์ประมุข
นายกรัฐมนตรี
บันดาร์เซาะบายวัน
5,765 ตารางกิโลเมตร
414,000 คน (พ.ศ. 2553)
มาเลย์
ดอลลาร์บรูไน

MYANMAR
สาธารณรัฐแห่งสหภาพพม่า

ธงชาติพม่า
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

ระบอบรัฐสภา
ประธานาธิบดี
เนปีดอ
657,140 ตารางกิโลเมตร
58.38 ล้านคน (พ.ศ. 2555)
พม่า
จัต

PHILIPPINES
สาธารณรัฐฟิลิปปินส์

ธงชาติฟิลิปปินส์
ผู้ปกครอง
เมืองหลวง
พื้นที่
ประชากร
ภาษา
สกุลเงิน

สาธารณรัฐ โดยมีประธานาธิบดีเป็นประมุข
ประธานาธิบดี
ฟลอยด์
344,740 ตารางกิโลเมตร
101.8 ล้านคน (พ.ศ. 2555)
อังกฤษ, สเปน, ฟิลิปปิน
เปโซ

The ASEAN Economic Community (AEC) shall be the goal of regional economic integration by 31 Dec 2015. AEC envisages the following key characteristics:

- (a) a single market and production base,
- (b) a highly competitive economic region,
- (c) a region of equitable economic development,
- (d) a region fully integrated into the global economy.

Total Population: 600 million+
GDP: USD \$3 trillion



Extending ASEAN+ICJK = Asian Languages



Why we need Asian Language Treebank (ALT)?



- **Accelerates research of NLP** for Asian languages
 - **Indonesian, Vietnamese, Japanese**, Khmer, Laos, Malay, Myanmar, Philippine, Thai,
- **No** publicly available POS-tagged and constituency **tree corpora** for most of Asian languages. (Though, some corpora are available for some languages)
- **No parallel corpora** among all Asian languages
- Expected members
 - **NICT, BPPT, IOIT**, NECTEC, UCSY, and other research bodies
 - NICT and UCSY have already started making parts of ALT
 - NICT and IOIT agreed to propose the ALT project to ASEAN IVO

Schedule for ALT

- Current progress in FY 2015
 - NICT translates English Wikinews (460,000 words, 20,000 sentences) into **Indonesian, Vietnamese**, Japanese, Thai, Khmer, Laos, Malay, Myammar, Philippine,
 - NICT makes the Japanese and English treebanks
 - UCSY makes the Myammar treebank
- Proposal for project in FY 2016
 - NICT provides **Indonesian**-English Wikinews parallel corpus to **BPPT**
 - NICT provides **Vietnamese**-English Wikinews parallel corpus to **IOIT**
 - **BPPT** makes the Indonesian language treebank
 - **IOIT** makes the Vietnamese language treebank
 - Word segmentaion, POS tagging, Parsing, Word alignment (NICT has annotation tools)
 - NICT develops Japanese and English NLP tools using Japanese and English treebanks
 - **ALT and tools are shared** with NICT, BPPT, IOIT and other participants

Speech Technology R&D Roadmap



- **Mobile Perisalah (Cellular Operator Based) Transcription And Summarization System**

- **Multi Language Transcription and Translation System**

2014


- **Indonesian Speech Portal for Speech to Speech Translation System**

- **Commercialization of Speech Product (Perisalah, Notula)**

2015-2017

Universal Speech Translation Advance Research (U-STAR)

Speech Corpora, Parallel Text Corpora ,TTS, ASR



University of Indonesia

Speech Recognition and NLP (continuing activities)

- **Speech recognition.**

Leveraging our years of experience with Indonesian language models, we are currently developing acoustic models trained on a large multi-speaker speech corpus, and investigating the suitability of applying these models to existing open-source speech recognition systems such as JULIUS3 and SPHINX4

- **Corpus-based NLP tools for Information Retrieval.**

In a joint collaboration with NUS and USM, various resources and algorithms are being researched for large-scale Malay and Indonesian information retrieval using corpus-based methods. Interim results include the development of a statistical part-of-speech tagger.

- **Construction of an Indonesian WordNet.**

An ongoing project is concerned with the development of an Indonesian WordNet. Using the expand model approach], map Princeton WordNet to existing word sense definitions in the Indonesian Master Dictionary (KBBI), which defines semantic equivalence classes between KBBI senses.

- **Finite state morphological analysis.**

Reduplication is an example of non-concatenative morphology, which formally cannot be modelled by finite state techniques, the prevalent paradigm for modern morphological analysis.

- **Language Processing Tools**

- Indonesian Stemmer
- Indonesian POS Tagger
- Indonesian Named Entity Tagger for text article
- Indonesian Phrase Chunker
- Indonesian Statistical Constituent Parser
- Indonesian Dependency Parser
- Indonesian Reference Resolution
- Indonesian Semantic Analysis (Constituent based)
- Indonesian NE Tagger for social media
- Indonesian Term Normalization for social media
- Indonesian Spelling Checker

- **Text Mining**

- Indonesian Question Answering System (open domain & closed domain of dialogue system)
- Indonesian Information Extraction (Social Media): Citizen Complaint, Strike Event
- Indonesian Text Classification (Social Media)

- **Speech**

- Indonesian Automatic Speech Recognizer using Deep Neural Network
- Indonesian ASR for spontaneous speech
- Indonesian Speech Synthesizer using Hidden Markov Model
- Improvement of Indonesian Prosody using Decision Tree Learning
- Al-Quran Automatic Speech Recognizer: corpus and system development
- Indonesian emotional recognition: corpus and system development

ITB Indonesian TreeBank

- Consists of Lemma, POS Tag and Dependency Relation Information
- 2098 sentences, annotated by 5 native speakers which are Indonesia linguists

Sentence Type		Number of Sentences (& Percentage)
Sentence type	Single	1067 (50,86%)
	Compound – equivalent	349 (16,63%)
	Compound – gradual	527 (25.12%)
	Compound – complex	155 (7,39%)
Type of Sentence Root	Transitive Verb	1017 (48,47%)
	Intransitive Verb	989 (47,14%)
	Adjektive	69 (3,29%)
	Others	23 (1,10%)

Information of Data Tuple

- ID: token position in sentence
- FORM: token lexical
- LEMMA: base form of token
- CPOSTAG: coarse-grained POS tag (universal POS tag universal)
- POSTAG: fine-grained POS tag
- FEATS: syntactic information (still empty)
- HEAD: head ID of current token
- DEPREL: dependency relation type (still empty)
- PHEAD: head ID if it is projective
- PDEPREL: dependency relation type of PHDEAD

Example of Data Tuple

- 1 Adik Adik NOUN NNP _ 2 _ _ _
- 2 membeli beli VERB VBT _ 0 _ _ _
- 3 susu susu NOUN NN _ 2 _ _ _
- 4 kemarin kemarin NOUN NN _ 2 _ _ _

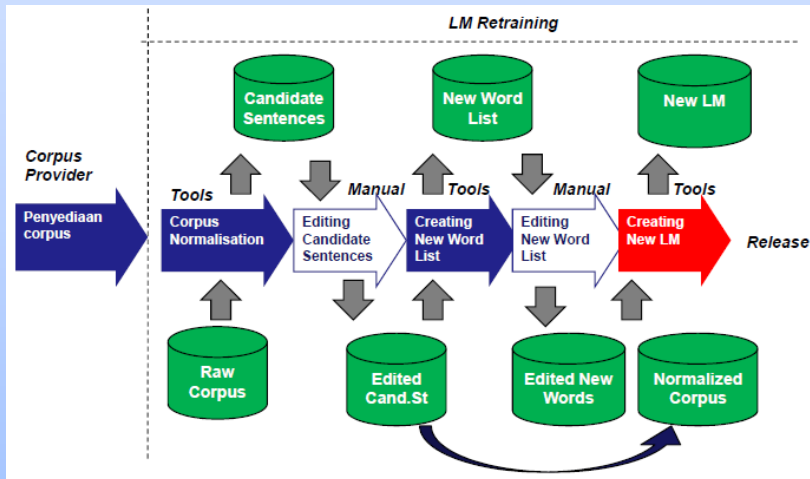
- 1 Jangan Jangan ADV NEG _ 2 _ _ _
- 2 bermain-main main VERB VBI _ 0 _ _ _
- 3 saja saja ADV RB _ 2 _ _ _
- 4 kamu kamu PRON PRP _ 2 _ _ _

- 1 Ketika Ketika ADP SC _ 3 _ _ _
- 2 saya saya PRON PRP _ 3 _ _ _
- 3 pulang pulang VERB VBI _ 7 _ _ _
- 4 ke ke PRT IN _ 3 _ _ _
- 5 rumah rumah NOUN NN _ 4 _ _ _
- 6 hari hari NOUN NN _ 7 _ _ _
- 7 hujan hujan NOUN NN _ 0 _ _ _

Corpus Development 2013-2015



- Perisalah Speech Corpora
- Perisalah POS Tagged Corpus
- Corpus Management System



- Indonesian POS Tagged Corpus
- Indonesian Named Entity Tagged Corpus
- Indonesian Syntactical Tree Tagged Corpus
- Indonesian Dependency Tree Tagged Corpus
- Indonesian Question Answering
- Using of Indonesian TTS for blind operator who work in Call Center
- Sunda Lexical Database
- Indonesian-Japanese Parallel Corpus
- Indonesian-English Parallel Corpus

INACL – Community Setup

- Background:
 - Importance on research collaboration among Indonesian CL researchers, government and industry
- Activities:
 - Initiated (first meeting) at PACLING 2015 (Bali, organized by BPPT & ITB)
 - Communication group: social media & mailing list
 - National workshop meeting (plan: December 2015 or January 2016)
 - Indonesian Data Resource & CL Tools Sharing
 - Support international conference (such as Cocosda 2016)
- Website:
 - <http://www.inacl.id>
- Member:
 - 91 members (from 32 universities + 1 government inst. + 5 industries)

Portal for Language Resource Service Support System



BPPT Portal Sistem Pendukung Layanan Language Resources

Welcome Stemmer Concordance Download

Welcome

Layanan Stemmer untuk Pengguna

Email Address: Stem Kata
@liferay.com

Ini adalah contoh layanan yang dapat digunakan pengguna untuk menemukan kata dasar dari contoh kata berimbuhan yang ada. Disini ada beberapa contoh inputan yang dapat dimasukan ke dalam layanan ini :

Password: membeli
mempermalukan
berlari

Remember Me

Sign In

Layanan Stemmer untuk Pengguna

Ini adalah contoh layanan yang dapat digunakan untuk menemukan kata dasar dari kalimat yang diinputkan.

Silahkan masukan kata y

OpenID Create Forgot Password

mempersilakan

Masukkan Teks

This is the Concordance Corpus portlet in View mode.

Word : ini

ok

Words : ini

Result :

001. Bapak-bapak dan Ibu sekalian yang hadir pada hari ini ; Dirut, PLN dan seluruh jajaran direksi yang
002. BRI , BCA dan BNI . Saya rasa ini adalah suatu moment yang sangat penting , mungkin
003. membutuhkan suatu effort dari semua pihak supaya proyek ini bisa dijalankan dan bisa dilaksanakan sesuai dengan desain
004. . Oleh karena itu , memang melaksanakan proyek ini secara tepat waktu dan tepat kualitas menjadi salah
005. salah satu kunci yang sangat penting . Proyek ini akan menggunakan bahan batu yatu bahan bakarnya adalah
006. dengan tingkat harga yang lebih murah kalaupun sekarang ini sudah sangat murah karena disubsidi , berarti tingkat
007. rupiah 5,7 triliun yang ditandatangani pada pagi hari ini dan ini masih merupakan tahap awal karena dari
008. triliun yang ditandatangani pada pagi hari ini dan ini masih merupakan tahap awal karena dari 10.000 MegaWatt
009. sangat senang bahwa menurut PLN mendapatkan tender pembiayaan ini sesuai yang digariskan oleh pemerintah harus melakukannya secara
010. seluruh perbankan terhadap PLN akan bisa melaksanakan proyek ini secara baik dan profesional dan yang kedua juga
011. para tamu yang saya hormati , Untuk saya ini adalah suatu perjalanan napak tilas sebetulnya karena hari
012. situasi yang seperti yang dialami kalau melihat gedung ini . Masih saya ingat betul suasana tanggal 27
013. itu , begitu saya tiba dan melihat gedung ini perasaan saya sangat berkecamuk banyak sekali antara tidak
014. itu . Tentunya kita bersyukur bahwa pada hari ini kita telah berhasil membangun suatu gedung . Saya
015. Saya tentu merasa bersyukur bahwa di dalam proses ini semua mungkin peranan dari Departemen Keuangan dianggap sebagai
016. . Tentu kita harap bahwa hampir semua institusi ini bisa melakukan dengan semangat yang sama . Saya
017. sama . Saya juga senang bahwa pada hari ini adalah hari ulang tahun yang ketiga yang disebut
018. tahun yang ketiga yang disebut BRR dan berarti ini menggambarkan tahun ketiga walaupun dari sisi waktu terjadinya
019. lalu . Sudah mulai dengan adanya peresmian gedung ini barangkali semangat yang tidak tertulis adalah adanya suasana
020. Bapak-bapak dan Ibu sekalian yang hadir pada hari ini

Kata : mempersilakan
Kata Dasar : sila

Stem

Teks : Ini adalah cont
Hasil Stemming : Ini a

Jumlah : 20

Features :

• Download Corpus

• Speech Corpus (Male-Female)

• Monolingual

• Bilingual

• Stemmer

• Concordance

Asean Economic Community (AEC)



<http://www.aec2008.aecsecret.com>

asean@seamit.com

Harigato Gozaimasu

THANK YOU