

Vietnamese Text Retrieval : Test Collection and First Experimentations

Ho Bao Quoc

Vietnam National University

HoChiMinh City University of Sciences

Where are we ?



I am here !!!



- Faculty of Information Technology
HoChiMinh City University of Sciences
Vietnam National University
227 Nguyen Van Cu – 5 District – HoChiMinh
City – Vietnam
hbquoc@fit.hcmuns.edu.vn

Plan

- Vietnamese specialities
- Vietnamese Test Collection
- Experimentations

Vietnamese Specialities

Vietnamese Alphabet

- Monosyllabic language
- Latin based Alphabet with accents on vowels

Ex: ā, â, ê, ô, ù

- Usage six tons : (bẰng), ‘ (sẮc), ` (huyỀn), ? (hỎi) ~ (ngÃ), . (nẴng) : the word sense is changed with the different tons :

Tons example

Ex :	ma	=	phantom
	má	=	cheek
	mà	=	but
	mǎ	=	tomb
	mã	=	code
	mạ	=	rice seedling

=> There are many character-sets : ABC, TCVN, VNI, UFT-8.

Vietnamese word

- Linguistic unit : “tiếng” : string of characters separated with another by one white bank
- Word contain one or more “tiếng”

Ex. Sách = book

dữ liệu = data

xã hội chủ nghĩa = socialist

=> Word segmentation problem

Vietnamese word morphology

- Morphologic invariant
 - Some exceptions
 - Usage of some special characters in some case :
Ex. “Bác sĩ” and “Bác sỹ” are the same meaning
“Doctor”
 - Position of the tons
Ex. “Hòa bình” or “hoà bình” are acceptable !
 - Prefix, suffix : “sự” , ‘hóa’ : used infrequently
- => Word normalization is simpler

Vietnamese Word Category (POS : Part Of Speech)

- Dependent on context (can not recognize base on the word form like European Languages)
 1. “**thành công** (success) của dự án đã tạo tiếng vang lớn” (The success of the project created a big echo)
 2. “Anh ta đã **thành công** (succeed) trong nghiên cứu khoa học” (He have succeed in scientist research)
 3. “Buổi biểu diễn đã **thành công** (successful)” (The show was successful)

Vietnamese Text Retrieval

- What is better index terms for Vietnamese text ?
 - Linguistic unit “tiếng” : reuse of tokenization methods for European Languge (use white bank)
 - Word : need of word segmentation method
 - Noun phrase, concept : need of Vietnamese NLP tools as : Vietnamese POS tagger, Vietnamese Chunker
- Now : at the first steps
- How to evaluate Vietnamese IR ? Vietnamese test collection ?

Test collection

Document collections

- Monolingual Vietnamese Text Collection
 - New paper
 - Num of documents : 14.000
 - Size : 30Mb
 - Encoding : UTF-8
 - Format : TREC

Vietnamese Text Document sample

<TOP>
<NUM> 10</NUM>
<TITLE>
Thương mại Việt Mỹ
</TITLE>
<DESCRIPTION>
Các chính sách và hoạt động liên quan đến
thương mại giữa Việt nam và Mỹ
</DESCRIPTION>
<NARRATIVE>
Các chính sách mới trong quan hệ thương
mại hai nước, các cuộc tiếp xúc của các tổ
chức thương mại của hai bên, các báo cáo về
kết quả của sự hợp tác thương mại giữa hai
nước. Các bài báo nói về các vấn đề trên
được cho là liên quan.
</NARRATIVE>
</TOP>

<TOP>
<NUM> 10</NUM>
<TITLE>
Vietnam America Trading
</TITLE>
<DESCRIPTION>
The policies and activities relates to
trading of Vietnam and America
<NARRATIVE>
The new policies in trading of two
countries, the events are organized of
trading organizations of two countries,
the reports of trading cooperation
Vietnam – America, the documents
relate the subjects above are judged
relevance.
</NARRATIVE>
</TOP>

Bilingual English-Vietnamese text collection

- Automatic mining from web
- Number of pair documents : 1468
- Size : 20Mb

Collection	N. of pair documents	Size
Vietnamese Law	336	15Mb
VOA (Voice of America)	1074	4Mb
US. Embassy	58	1Mb
	1468	20Mb

Sample

- [P1] ISRAELI TROOPS KILL 5 MORE PALESTINIANS IN GAZA
- [P2] AN ISRAELI HELICOPTER STRIKE HAS KILLED TWO PALESTINIAN TEENAGERS IN THE NORTHERN GAZA STRIP, AS THE MILITARY CONTINUES A MAJOR OFFENSIVE TO TRY TO STOP MILITANTS FROM FIRING ROCKETS INTO NEARBY JEWISH SETTLEMENTS
- [P3] RESIDENTS OF THE JABALYA REFUGEE CAMP SAY ONE OF THE TEENS WAS A MILITANT.
- [P4] ISRAEL'S MILITARY SAYS IT FIRED ON A GROUP OF GUYS WHO WERE TRYING TO PLACE A BOMB
- [P5] MEAN WHILE, A PALESTINIAN BOY DIED FRIDAY FROM INJURIES SUSTAINED WHEN AN ISRAELI TROOPER FIRED ON THE REFUGEE CAMP LAST WEEK. A 10-YEAR-OLD GIRL WAS KILLED BY ISRAELI FIRE IN THE SAME AREA TODAY
- [P6] IN A SEPARATE INCIDENT, OFFICIALS SAY PALESTINIAN MILITARY SHOT AND KILLED A PALESTINIAN WORKER ON A FARM IN A JEWISH SETTLEMENT IN SOUTHERN GAZA
- [P7] MORE THAN 80 PALESTINIANS HAVE BEEN KILLED SINCE THE GAZA OFFENSIVE BEGAN LAST WEEK

- [P1] MÁY BAY TRỰC THẮNG ISRAEL BẮN CHẾT 2 THIỆU NIÊN PALESTINE TẠI DẢI GAZA
- [P2] MỘT MÁY BAY TRỰC THẮNG CỦA ISRAEL ĐÃ BẮN CHẾT 2 THIỆU NIÊN PALESTINE TẠI MIỀN BẮC DẢI GAZA KHI QUÂN ĐỘI TIẾP TỤC CUỘC HÀNH QUÂN LỚN ĐỂ NGĂN CHẶN CÁC PHẦN TỬ TRANH ĐẤU BẮN ROCKET VÀO CÁC KHU ĐỊA HÌNH CỦA DO THÁI
- [P3] CỨ DÀI TẠI TRẠI TỊ Ở JABALYA Ở RĂNG G MỘT TROOP 2 THIỆU Ở IỆT VÙA KỂ LÀ MỘT PHẦN TỬ TRẠI H ĐẤU.
- [P4] QUÂN ĐỘI ISRAEL Ở RĂNG HỌ BẮN VÀO MỘT Ở HÓM PHẦN TỬ VÔ TRẠI G ĐẠI G TÌM CÁCH GÀI BOM
- [P5] TROOP G KHI ĐÓ MỘT BÉ TRAI PALESTINIAN TỪ TRẠI Ở GÀY HÔM Ở ẤY VÌ VÉT THUỐC G DO MỘT XE TẢI G ISRAEL BẮN VÀO TRẠI TỊ Ở HỒI TUẬP TRƯỚC
- [P6] HÔM Ở ẤY, MỘT BÉ GÁI BỊ THIỆT MẠI G Ở GÀY VÌ TRÚNG G ĐẠI CỦA ISRAEL TROOP G CÙNG KHU VỰC Ở ÀY
- [P7] TROOP G MỘT DIỄN BIẾN KHÁC, CÁC GIỚI CHỨC Ở RĂNG G CÁC PHẦN TỬ TRẠI H ĐẤU PALESTINIAN ĐÃ BẮN CHẾT MỘT Ở GUỒI PALESTINIAN E LÀM VIỆC TẠI MỘT Ở G TRẠI TROOP G MỘT KHU ĐỊA HÌNH CỦA DO THÁI TẠI MIỀN Ở AM DẢI GAZA
- [P8] HƠI 80 Ở GUỒI PALESTINIAN E VÀ 3 Ở GUỒI ISRAEL ĐÃ THIỆT MẠI G KỂ TỪ KHI CUỘC HÀI H QUÂN CỦA ISRAEL BẮT ĐẦU HỒI TUẬP TRƯỚC

Search Topics

- 25 topics
- Choice from the themes of documents
- Criteria
 - Short topics
 - Long topics
 - Contain :
 - Simple word only
 - Simple word and compound word
 - Compound word only
- Format : TREC

Relevance Assessment

- Method : Pooling
- Used Systems :
 - SMART
 - Lemur
 - Terrier
- Pre-Works
 - We have modified these systems to work with Vietnamese character encoding UTF-8
 - Text collection pre-processing :
 - Vietnamese Word segmentation
 - connect the linguistic units of a word by _ (under score)
 - Modify tokenization module of Terrier

Relevance Assessment

- Use top 50 documents return by each system to make the pool

Experimentation

Experimentation purposes

- Test the different type of Vietnamese index term
- Test the indexing model for Vietnamese text

Experimentation scripts

- Test the types of Vietnamese index term
 - Linguistic unit : “uni-gram” : RUN_UNI
 - “Bi-gram” : two linguistic units adjunction : RUN_BI
 - Combination : uni-gram and lexicon : RUN_COM
- Test the indexing model (Use Lemur)
 - Okapi
 - Inquery
 - Language Model : KL-Divergence

Thanks you for your attention