

Spoken Turkish Corpus Project

Yuji KAWAGUCHI

Tokyo University of Foreign Studies

Bosphorus University, Istanbul Oct. 4 2012

Presentation flow

1. Corpus Linguistics
 2. Turkish Corpus
 3. Constructing spoken corpus
 4. Spoken Turkish Corpus
 5. Corpus-based analysis
- Concluding remark

I. Corpus Linguistics

- 1967 Brown Corpus
 Computational Analysis of
 Present-Day American English
- 1987 Collins' COBUILD dictionary
- 1991 British National Corpus
 American National Corpus

- 1985 A Comprehensive Grammar of the
 English Language
- 1999 Longman Grammar of Spoken and
 Written English

2.1. Turkish Corpus

- Written Turkish Corpus:
METU Turkish Corpus

[http://fodor.ii.metu.edu.tr/content/
metu-turkish-corpus](http://fodor.ii.metu.edu.tr/content/metu-turkish-corpus)

Turkish National Corpus

<http://www.tnc.org.tr/index.php>



- Spoken Turkish Corpus:
Spoken Turkish Corpus (STC)
<http://std.metu.edu.tr/en>



2.2. COE Projects at TUFs

21 Century COE Program, Usage-Based Linguistic Informatics (UBLI)

2002-2006

Global COE Program, Corpus-based Linguistics and Language Education (CbLLE) 2007-2011

Construction of Spoken Language Corpora

- French, with Aix-Marseille University
- Spanish, Autonomous University of Madrid
- Malay, Kebangsaan University
- Chinese, Tamkang University
- Russian, Russian State University for Humanities



<http://www.coelang.tufs.ac.jp/english/index.html>

2.3. Spoken Turkish Corpus Project

21st Century COE Program

Selim Yilmaz (Marmara University),

Arsun-Uras Yilmaz

(University of Istanbul)

2005: 29 free conversations 98,100 tokens

Global COE Program

2007: 14 free conversations 56,300 tokens


2008: 10 free conversations 38,900 tokens

2009: 23 free conversations 75,900 tokens

2010: 30 free conversations 60,500 tokens

2011: 59 free conversations 184,700 tokens

Total: 514,400 tokens



http://cblle.tufts.ac.jp/multilingual_corpus/tr/index.html?contents_xml=top&menulang=en

3. Constructing spoken corpus

Objectives

- Written language vs Spoken language
→ Syntactic/morphological/phonological structures
- Description of real use of language
→ Sociolinguistic/pragmatic variations
- Usage norm for language teaching
→ Frequent/infrequent use

3.1. Nature of spoken language

- Does “spoken” mean “broken”?
→ Claire Blanche-Benveniste
- What is the unit of speech?
→ Sentence, discours, turn
- Enormous variations
→ Who speaks to whom and where?
- Representativeness
→ Is there a representative spoken speech?

3.2. Informant's profile

*No		*Date	
Name / Family Name		Sex	☐ Man ☐ Woman
Address			
Telephon		e-Mail	
Profession	(Institution)	Birth Place (City/Country)	
Birth Date	Education	☐ Primary School ☐ Middle School ☐ High School ☐ University ☐ Others (.....)	
1st Language	☐ Turkish ☐ Other languages (.....)		
If you have another language in everyday life:			
Parents' Birth Place			
Father: (City / Country) Mother: (City / Country)			
*No and subject of conversation :			
*Particular information:			

3.3. Transcription of spoken language

Symbol	Meaning
Initials of Name	Ex: SY = Selim Yılmaz. SY ₁ , SY ₂ , SY ₃
(?), (!)	Interrogation and Exclamation
-	Beginning of discours. Ex: -SY ₁
#, ##, ###...	Pause. Symbol represents its length.
ooo, aaa,...	Long and emotional vowel Ex: yook, haayır, eveet, yaaa.
(.)	Incompletion Ex: çek(.) çekilmez gibi geliyo(r)

3.3. Transcription of spoken language

(x) (xy)	Dropping Ex: bur(a)da, bi(r) gün, geliyo(r)
_____	Accentuation Ex:## <u>ancak</u> Kastamonu'nun çevresi ilçeleri çok güzel
e, ee, eee,...	Hesitation or filler. Ex: yoksa ee yani çek(.) çekilmez gibi geliyo(r)
m, mm,...	Murmuring
{.....}	Dislocated element. Ex: hava güzel {bugün}, yarın gideceğim {okula}.
[.....]	Paralinguistic element or gesture Ex: [gülüşmeler], [öksürme], [gürültü]

3.3. Transcription of spoken language

<.....>	Overlap. EX: -ben de yani <ya öyle> biraz yüzeysel düşünmüşüz ama içine girince <tabi çok> çok derin olduğunu fark ettik(.)
* *	Accelerated element EX: *hakikaten de güzel birşeyler yaptık*
(...)	Incomprehensive element EX: doktora yapıyordu internetten indiriyor (...) yapıyor
%.....%	Special intonation EX: çünkü el yazmaları var ## %bunun dışında% doğa güzelliği mükemmel {Kastamonu'da}

4. Spoken Turkish Corpus

Example 1 : Lecture on Turkish Literature

ND₁ – “geç kaldım # bütün bunlar için geç kaldım” # “yoo böyle deme gençsin # öğrenmenin yaşı yoktur # bittiği durduğu yer yoktur” # bir gün konuşma içerisinde geçti (.) arasında *böyle ilmi yetersizliğini görürüz* bur(a)da bir bozkırın ötesi diyor # yani öyle bi(r) (...)

OS₁ - evet biraz önce konuştüğümüz gibi # yani ufkunu biraz daha ötelere götürmeye çalışıyor # yani ama demek ki onun ilmide o kadar yeterli değil # yani kendiside bunun farkında #

ND₂ - bozkırın ötesinde (.) yerleşik hayat şimdi Nizam Bey bozkırda yetişmiş çadırda yaşadım falan diyor (.) daha yerleşik hayat istiyor {yani}

.....

The screenshot displays the 'Global COE Multilingual Spoken Corpus' interface. On the left, a navigation menu lists links: Top, Outline2005, Outline2007, Research Team, References, Corpus2005, Corpus2007, Related Sites, and Pictures. Below this menu is the 'Global COE Program' logo and a link to 'The 21st Century COE Program'. The main content area features a title bar 'Global COE Multilingual Spoken Corpus' and a subtitle 'Lecture on Turkish Literature'. Below the subtitle, there are two text boxes. The first box contains the text: 'Turkish, "geç kaldım # bütün bunlar için geç kaldım" # "yoo böyle deme gençsin # öğrenmenin yaşı yoktur # bittiği durduğu yer yoktur" #'. The second box contains the text: 'Turkish, bir gün konuşma içerisinde geçti (.) arasında *böyle ilmi yetersizliğini görürüz* bur(a)da bir bozkırın ötesi diyor # yani öyle bi(r) (...)'. On the right side of the interface, there are three green circular buttons with play, pause, and stop icons, and a vertical volume slider. Below these buttons are two checkboxes: 'Turkish' (checked), 'Japanese', and 'English', and a 'Scroll On/Off' button.

4. Spoken Turkish Corpus Example 2 : About the subway

FS19 - yani mimar olarak ben şöyle düşünebiliyorum e tamam şimdi metrobüsler gayet güzel yer altına yapılan bu sistem çok pahalı bunu onaylamıyorum yer altına gerek yok bunun yerine artık tüm dünyada kabul edilmiş artık hep yer üstünde ee asma olarak yapılması lazım hem pratik hem ekonomik ama bunun yerine bizde nedense hep altlardan kazmayı düşünüyorlar daha zorunu yapmaya çalışıyorlar bu heralde siyasetin bi(r) parçası veya başka bi(r) insanlara imtiyaz tanımanın bi(r) parçası gibi geliyor {bana}

.....

Global COE Multilingual Spoken Corpus

Top
Outline2006
Outline2007
Research Team
References
Corpus2006
Corpus2007
Related Sites
Pictures

Global COE Program
The 21st Century COE Program
Image-Based Linguistic Information

Turkish
Japanese
English

Scroll On/Off

About the Subway

Turkish: yani mimar olarak ben şöyle düşünebiliyorum e tamam şimdi metrobüsler gayet güzel yer altına yapılan sistem çok pahalı bunu onaylamıyorum yer altına gerek yok

Turkish: bunun yerine artık tüm dünyada kabul edilmiş artık hep yer üstünde ee asma olarak yapılması lazım hem pratik hem ekonomik ama bunun yerine bizde nedense hep altlardan kazmayı düşünüyorlar daha zorunu yapmaya çalışıyorlar

5. Corpus-based analysis

5.1. Dropping of /r/ Kawaguchi (2009)

Corpus 2005-2006


10h26m, word types 17,417, word tokens 93,837

Different parameters

- Conversation topic : $r = .11$
- Conversation speed : $r = .25$
- Gender difference : $r = .16$
- Age difference : $r = - .19$

(r = Pearson correlation coefficient)

Individual variation of -r dropping in *-lyor* and *bi(r)*



|-----| average of -r dropping: -lyor = 69.0 %; bir = 61.8 %
less -r dropped

5.2. Postpredicative element

Kawaguchi (2011)

Oya bir köpek gördü bahçede.

Utterance Head	Immediately before Predicate	Predicate	Postpredicate
Theme	Focus		Background

Syntax and Information Structure

5.2. Postpredicative element

	token
1. adverb	149
2. conjunctive	68
3. locative	61
4. dative	47
5. definite direct object	45
6. subject pronoun	40
7. noun phrase	37

	token
8. postposition	34
9. appellative	22
10. instrumental	19
11. genitive	17
12. interjection	14
13. verbal noun	7
14. others	6
total	566

5.2. Postpredicative element

	token	type
1.truth	41	açıkçası (11), aslında (17), esasında (3), gerçekten (5), hakikaten (2), etc.
2.time	25	birbirinden (1), -ken (2), sonra (2), şimdi (2), zaman (6), zamanda (2), etc.
3. opinion	14	bence (12), kanımca (1), sence (1)
4. example	14	mesela (14)
5. quantity	12	biraz (7)
6. place	1	aşağı (1)
7. sentential	42	artık (5), belki (5), herhalde (5), sanki (3), zaten (8)
Total	149	() occurrences

- 1) HS142- (...) # ben o yüzden buraya indim # {**açıkçası**}
AA20- (...) # kolay değil {**aslında**}
- 3) ES27- (...) ## bunları anlamak gerçekten hani ee ## bizim boynumuzun borcu {**bence**}
BY1 – (...) ee bunlara bunlara bi(r) düzen getirilmesi gerekiyo(r) {**kanımca**} #

Concluding remark

Corpus-based analysis of Spoken Turkish Corpus

- Structural analysis
Phonological, morphological, syntactic variations
- Pragmatics & conversation analysis
Fillers, discourse analysis, politeness
- Sociolinguistics & stylistics
Diastratic & diaphasic variations
- Applied linguistics
Norm of usage & authentic material for learners

References

- Blanche-Benveniste, Claire. 1997. *Approches de la langue parlée en français*, Gap: Ophrys.
- Erguvanlı, T. Eser. (ed.) 2001. *The Verb in Turkish*, Amsterdam/Philadelphia: John Benjamins.
- Gibbon, Dafydd, Roger Moore and Richard Winski (eds.) (1998) *Handbook of Standards and Resources for Spoken Language Systems*, Vol.1-4, Berlin/New York: Mouton de Gruyter.
- Göksel Aslı and Celia Kerslake . 2005. *Turkish A Comprehensive Grammar*, London: Routledge.
- Göksel, Aslı and Özsoy Sumru A. (2000) "Is there a focus position in Turkish?", In *Studies on Turkish and Turkic Languages*, Aslı Göksel and Celia Kerslake (eds.) Wiesbaden: Harrasotiwz Verlag. 219-228.
- Kawaguchi, Yuji. 2004. "Two Turkish Clause Linkages: -DIK- and -mE- -A pilot analysis based on the METU Turkish Corpus-" In: Toshihiro Takagaki. Susumu Zaima. Yoichiro Tsuruga. Francisco Moreno-Fernández and Yuji Kawaguchi (eds.) 2005. *Corpus-Based Approaches to Sentence Structures*. Amsterdam: John Benjamins, 151-177.
- Kawaguchi, Yuji. 2009. "A Corpus-Driven Analysis of -r Dropping in Spoken Turkish", Y. Kawaguchi, M. Minegishi, J. Durand, (eds.) *Corpus Analysis and Variation in Linguistics*, Amsterdam/Philadelphia: John Benjamins, 281-297.
- Kawaguchi, Yuji. 2011. "Postpredicate Elements in Spoken Turkish: A Copus-based Analysis" (in Japanese), *Working Papers in Corpus-based Linguistics and Language Education* 7, 171-197.
- Morel, M.-A. et L. Danon-Boileau, 1998. *Grammaire de l'intonation. L'exemple du français*, Paris: Ophrys.
- Özsoy, A. Sumru. 1999: *Türkçe Turkish*, İstanbul: Boğaziçi Üniversitesi Yayınları.
- Özsoy, A. Sumru. 2004. *Türkçenin yapısı – I, Sesbilim*, İstanbul: Boğaziçi Üniversitesi Yayınları.
- Yılmaz, Selim (2012) "Türkçede Sözlü Derlem Oluşturma Çalışmaları Üzerine Değerlendirmeler (Uluslararası Global COE Program Projesi Çerçevesinde)", *Working Papers in Corpus-based Linguistics and Language Education*, 9, Graduate School of Global Studies, Tokyo University of Foreign Studies, pp.165-184.
- (http://cblle.tufs.ac.jp/assets/files/publications/working_papers_09/section/165-184.pdf)

Thank you for your attention!

You can use our corpus exclusively for the academic purpose.

Please contact the COE office by e-mail :

cblle-faq@tufs.ac.jp

Acknowledgement

This work was supported by JSPS KAKENHI Grant Numbers 24320102
Grant-in-Aid for Scientific Research(B) Person in charge:Yuji KAWAGUCHI.