

Research Report on Bangla Tagset

Altaf Mahmud and Mumit Khan

Center for Research on Bangla Language Processing, BRAC University, Dhaka, Bangladesh.

altaf.mahmud@gmail.com, mumit@bracuniversity.ac.bd

Abstract

This report describes the design of a POS tagset for Bangla, based on the Penn Treebank design. The resulting tagset contains 53 morpho-syntactic tags.

1. Introduction

This report describes the design of a tagset for Bangla, based on the Penn Treebank design. The design is heavily influenced by the work on Penn Treebank tagset, and follows the same methodology [1, 2, 3].

2. Bangla Tagset

Table 1: Bangla Tagset

#	Level 1	Level 2	Tag	Examples
1	Noun	<i>Proper</i>	NNP	মতিউর, অঞ্জেবর
2		<i>Common</i>	NNC	মানুষ, পানি
3		<i>Verbal</i>	NNV	করা, করানো, পরা, পরানো
4		<i>Temporal</i>	NNT	গতকাল, আগামীকাল, আজ, শনিবার, রবিবার
5	Pronoun	<i>First Person</i>	PR1	আমি, আমরা
6		<i>Second Person</i>	PR2	তুমি, তোমরা, ওগো
7		<i>Third Person</i>	PR3	সে, যে, তারা, যারা
8		<i>Non Person</i>	PRN	স্বয়ং, নিজে, সবাই, কে, কেউ
9		<i>Creditable</i>	PRC	আপনি, তিনি, যিনি, আপনারা, তাঁরা, যাঁরা
10		<i>Insignificant</i>	PRD	তুই, তোরা, ওরে
11		<i>Possessive</i>	PR\$	আমার, তোমার, তার, আমাদের, তোমাদের, ওর, আপনাদের, কার
12		<i>TO Pronoun</i>	PRTO	আমাকে, তোমাকে, তাকে, তারে, আপনাকে, কাকে

#	Level 1	Level 2	Tag	Examples
13	Adjective	<i>Simple</i>	AJ	সুন্দর, লাল, গরম, শ্রেষ্ঠ, শ্রেষ্ঠতর, শ্রেষ্ঠতম
14	Verb	<i>First Person</i>	VB1	করি, করছি, করেছি, করলাম, করছিলাম, করেছিলাম, করব, করাই
15		<i>Second Person</i>	VB2	কর, করছ, করেছ, করছিলো, করেছিলে, করাও
16		<i>Third Person</i>	VB3	করে, করছে, করেছে, করল, করছিল, করেছিল, করায়, করুক, হোক
17		<i>Non Person</i>	VBN	করলে, করালে
18		<i>Creditable</i>	VBC	করেন, করছেন, করেছেন, করলেন, করছিলেন, করেছিলেন, করবেন
19		<i>Insignificant</i>	VBD	কর, করছিস, করেছিস, করা
20		<i>Infinite</i>	VBIF	করে, করতে, করাতে
21	Adverb	<i>Adverb</i>	AV	আস্তে, দ্রুত, ধীরে, কেন, কিভাবে
22	Conjunction	<i>Co-ordinating</i>	CC	এবং, ও, কিংবা, অথবা, নতুবা
23		<i>Subordinating</i>	CS	তাই, যে
24	Inflectors	<i>AT</i>	ICAT	এ, য, তে
25		<i>BY</i>	ICBY	এ, তে (ইট-পাটকেলে/NNC+ICBY অনেক মানুষ হতাহত হয়েছে)
26		<i>Plural</i>	ICS	ৱা, এরা, গুলি, গণ
27		<i>TO</i>	ICTO	কে, রে, এরে, দিগকে, দিগেরে
28		<i>Possessive</i>	IC\$	এর, দের
29		<i>Determinative</i>	ICDT	টা, টি
30		<i>Adverbial</i>	ICAV	ও
31		<i>Definitive</i>	ICDF	ই
32	Postposition	<i>Common</i>	PP	দ্বারা, কর্তৃক, হতে, হইতে, থেকে
33		<i>Possessive</i>	PP\$	জন্য, চেমে, চাইতে
34	Interjection	<i>Interjection</i>	UH	বাহ!, ওহ! হায়!
35	Indeclinables	<i>Simple</i>	ID	আর, অবশ্য, তবে, হয়তো, সুতরাং, সর্বাপেক্ষা, সবচেয়ে

#	Level 1	Level 2	Tag	Examples
36		<i>Infinite</i>	IDIF	যদি
37	Particle	<i>Particle</i>	PT	কি, না, নাকি, যেন, বটে
38	Onomatopes	<i>Onomatopes</i>	ON	টনটন, কনকল, খাঁ খাঁ
39	Cardinal	<i>Cardinal</i>	CD	এক, দুই, ১, ২
40	Determiner	<i>Singular</i>	DT	এটি, ওটি, কি
41		<i>Plural</i>	DTS	সব, ওসব, সকল, তাৰৎ, কোন, যেকোন, এই, এই, কিছু
42		<i>Predeterminer</i>	DTP	এই/DTP সকল/DTI, যেকোন/DTP কিছু/DTI
43	Symbol	<i>Symbol</i>	SYM	বৈজ্ঞানিক বা অংকশাস্ত্রীয় যেকোন চিহ্ন
44	Taka	<i>Taka</i>	/=	৶ (টাকার চিহ্ন)
45	Sentence Final Punctuation	<i>Sentence Final Punctuation</i>		, ?, !
46	Comma	<i>Comma</i>	,	,
47	Colon, Colon, Semi-colon	<i>Colon, Semi-colon</i>	:	; ;
48	Bracket	<i>Left Bracket</i>	(([
49		<i>Right Bracket</i>))]
50	Quotation	<i>Opening Single Quote</i>	'	'
51		<i>Closing Single Quote</i>	'	'
52		<i>Opening Double Quote</i>	"	"
53		<i>Closing Double Quote</i>	"	"

3. Results

A sample text tagged with the tagset is shown below.

সব/AJ জল্লা-কল্পনাৱ/NJC+IC\$অবসন্ন/NJC
ঘটিৱে/VBIF আগবধায়ক/AJ সৱকাৱ/NJC ও/CC নিৰ্বাচন/NJC
কমিশন/NJC সংস্কাৱেৱ/NJC+IC\$বিষয়ে/NJC+ICAT
প্ৰধান/AJ দুই/CD দল/NJC বিএনপি/NNP ও/CC
আওয়াৰী/NNP লীগেৱ/NNP+IC\$ মহাসচিব-সাধাৱন/AJ
সম্পাদক/NJC পৰ্যায়ে/NJC+ICAT সংলাপ/NJC হচ্ছে/VB3
আজকাৱে/NJC+IC\$ মধ্যেই/PP\$+ICDF/I আওয়াৰী/NNP
লীগেৱ/NNP সাধাৱন/AJ সম্পাদক/NJC আদ্বুল/NNP
জলিল/NNP গতকাল/NNT শনিবাৱ/NNP দুবুৱে/NNC+ICAT
বিএনপিৱ/NNP+IC\$ মহাসচিব/NJC ও/CC শালীয়/AJ
সৱকাৱমষ্টী/NNC আদ্বুল/NNP মাজ্জাল/NNP ভুঁইয়াকে

/NNP+ICTO টেলিফোন/NJC কৱে /VBIFআজকাৱে
/NNT+IC\$মধ্যেই/PP\$+ICDFসংলাপে/NNC+ICAT
বসতে/VBIF আগহেৱ/NJC+IC\$ কথা /NNC জানান/VBC //
মাজ্জাল /NNP ভুঁইয়াও /NNP+ICAV জবাৰে
/NNC+ICATজানিয়েছেন/VBC/, সংলাপে/NNC+ICAT
বসতে/VBIF প্ৰস্তুত/AJ তিনিও/PRC+ICAV// দুজনে
/NNC+ICAT সুবিধাজনক/AJ সময়ে/NNC+ICAT
বৈঠকেৱ/NJC+IC\$ দিলক্ষণ/NJC ও/CC শান /NNC
ঠিক/AV কৱনেন/VBC// উভয় /DTIলতা/NNC প্ৰক /AJ
সংবাদ /NNC ড্রিকিংয়ে/NNC+ICATবিষয়টি /NNC+ICDT
জানান/VBC//
সংলাপে/NNC+ICATবসতে/VBIFদুই/CDদলেৱ/NJC+I
C\$প্ৰস্তুতি/NNCচূড়ান্ত/AJহওয়ায়/VB3
দেশেৱ/NNC+IC\$বিভিন্ন/AJছৱেৱ/NNC+IC\$মালুমেৱ/NNC+I
C\$মধ্যে/PP\$ঘৰিৱ/NNC+IC\$
ভাৱ/NNCদখা/VBIFযাছে/VB3//

বিভিন্ন/AJরাজনৈতিক/AJদল/NNC
বিষয়টিকে/NNC+ICDT+ICTO ইতিবাচক/AJ
বলে/VBIFসংগত/NNCজামিয়েছে/VB3।।

অবশ্য/ID এ/DTI অবশ্যর/NNC+IC\$ মধ্যেই/PP\$+ICDF
আজ/NNT রবিবার/NNP ।।/CD অক্টোবর/NNP বিএলপি/NNP
ও/CC তার/PR\$ শরিকেরা/NNC+ICS পালন/NNC
করছে/VB3 ।।/ ভোট/ AJবিপ্লব/AJ ।। দিবস/NNC ।।/

দিলটিকে/NNC+ICDT+ICTO বিবোধী/AJ দল/NNC
আওয়ামী/NNP লীগ/ NNPপালন/NNC করছে/VB3 ।।/
কালো/AJ দিবস/NNC ।। হিসেবে/PP ।।/ চলমান/AJ রাজনৈতিক/AJ
সংকট/NNC নিরসন/NNC+ICAT দ্রৃ/CD দলের/NNC+IC\$
মধ্যে/PP\$ সমরোতা/NNC ছেঁটার/NNC+IC\$ মধ্যে/PP\$
অনেকে/PRC আজকের/NNT+IC\$ এই/DTI
ষট্টনাকে/NNC+ICTO তৎপর্যপূর্ণ/NNC হিসেবে/PP+ICDF
দেখছেন/VBC ।।

4. Conclusion

This report presents a Bangla part-of-speech (POS) tagset that is based on the Penn Treebank tagset design. The tagset contains 53 2-level tags. A sample text tagged with this tagset is shown.

5. References

- [1] B. Santorini, *Part-of-speech tagging guidelines for the Penn Treebank Project*. Technical report MS-CIS-90-47, Department of Computer and Information Science, University of Pennsylvania, 1990.
 - [2] M.P. Marcus, M.A. Marcinkiewicz, and B. Santorini, “Building a large annotated corpus of English: the Penn Treebank”, *Comput. Linguist.* 19, 2, June, 1993, pp. 313-330.
 - [3] M. Marcus, G. Kim, M.A. Marcinkiewicz, R. MacIntyre, A. Bies, M. Ferguson, K. Katz, and B. Schasberger, “The Penn Treebank: annotating predicate argument structure”, *In Proceedings of the Workshop on Human Language Technology*, Human Language Technology Conference, Association for Computational Linguistics, Morristown, Plainsboro, NJ, March 08 - 11, 1994, pp. 114-119.