

Unsupervised Abstractive Summarization of Bengali Text Documents



Radia Rayan Chowdhury*, Mir Tafseer Nayeem*,
Tahsin Tasnim Mim, Md. Saifur Rahman Chowdhury, Taufiqul Jannat

Ahsanullah University of Science & Technology
radiarayan.rrc@gmail.com, mir.nayeem@alumni.uleth.ca,
tahsintasnimim@gmail.com, saif.chowdhury1997@gmail.com, taufiquljannat@gmail.com

*Equal contribution, listed by alphabetical order

EACL 2021

Text Summarizer

- Compression of large document
- Represents the most important or relevant information within the original content

Research Goal

- Unsupervised Text Summarizer for single document of low-resource language Bengali: 7th most spoken language in the world with 250 million native speakers

Our Contributions

- **BenSumm Model**: This model is the very **first unsupervised model** to generate **abstractive summary** from Bengali text documents
- **Dataset**: introduce a highly **abstractive dataset** with document-summary pairs which is written by professional summary writers of National Curriculum and Text-book Board (NCTB)
- Performs **hierarchical clustering** and calculate Cosine Similarity using **ULMFit pre-trained language model**
- Performs **Sentence fusion** on Bengali texts
- **Bengali Document Summarization Tool**

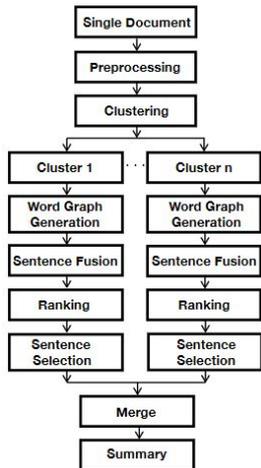
Why Unsupervised?

- Effective and Domain Independent
- No Need to Train Data
- Bengali: Low Resource Language

Why Document Clustering?

- Avoid incoherent summary and redundancy
- Ensure good coverage

Methodology (BenSumm Model)



Our BenSumm Unsupervised Model

Dataset

- **Abstractive Dataset**: Created a set of **139 samples** of human-written abstractive document-summary pairs written by professional summary writers of the National Curriculum and Textbook Board (NCTB)
- **Extractive Dataset**: Experiment with an Extractive Dataset Bangla Natural Language Processing Community (BNLPC)

Our Bengali Abstractive Summarizer Tool

Bengali Text Documents Summarizer

Bengali Text:

সমগ্র দেশে জুড়ে গবেষণা করা হয়েছে। কয়েকটি গুরুত্বপূর্ণ বিষয় নিয়ে গবেষণা করা হয়েছে। এই গবেষণার ফলে অনেক নতুন তথ্য পাওয়া গেছে। এই তথ্যগুলি আমাদের জ্ঞানকে আরও সমৃদ্ধ করেছে। আমরা এই গবেষণার মাধ্যমে অনেক নতুন জিনিস শিখতে পারি।

Extractive Summary:

সমগ্র দেশে জুড়ে গবেষণা করা হয়েছে। কয়েকটি গুরুত্বপূর্ণ বিষয় নিয়ে গবেষণা করা হয়েছে। এই গবেষণার ফলে অনেক নতুন তথ্য পাওয়া গেছে।

Abstractive Summary:

গবেষণার ফলে আমরা অনেক নতুন তথ্য শিখতে পারি। এই তথ্যগুলি আমাদের জ্ঞানকে আরও সমৃদ্ধ করেছে। আমরা এই গবেষণার মাধ্যমে অনেক নতুন জিনিস শিখতে পারি।

Apply

Text Preprocessing

- Tokenization
- Removing Punctuation
- Removing Stopwords
- POS Tagging

Results (Human Evaluation)

Average Score in Scale (1-5):

- Content : 4.41
- Readability : 3.95
- Overall quality : 4.2

Here, 1= Poor, 5=Good

	NCTB	BNLPC
Total #Sample	139	200
Source Length (Avg)	91.33	150.75
Human Reference Length (Avg)	36.23	67.06
Summary Copy Rate	27%	99%

Results (Automatic Evaluation)

NCTB (Abstractive)	R-1	R-2	R-L
Random Baseline	9.43	1.45	9.08
GreedyKL	10.01	1.84	9.46
LexRank	10.65	1.78	10.04
TextRank	10.69	1.62	9.98
SumBasic	10.57	1.85	10.09
BenSumm[Abs] (ours)	12.17	1.92	11.35

BNLPC(Extractive)	R-1	R-2	R-L
Random Baseline	35.57	28.56	35.04
GreedyKL	48.85	43.80	48.55
LexRank	45.73	39.37	45.17
TextRank	60.81	56.46	60.58
SumBasic	35.51	26.58	34.72
BenSumm[Abs] (ours)	61.62	55.97	61.09

Rough-1, Rough-2 and Rough-L Score on our NCTB Dataset and BNLPC Dataset

Future Work

Increasing document-summary pair dataset, Implementing multi-sentence compression and paraphrasing