

Clustering Urdu News Using Headlines

Samia Khaliq, **Waheed Iqbal**, Faisal Bukhari, Kamran Malik
PUCIT, University of the Punjab,
Lahore, Pakistan

Motivation

www.newslink.pk



نیوز لنک

صفحة اول	پاکستان	انٹرنیشنل	کھیل	انٹرنیشنل	پرنس	سائنس / صحت	اشتتارات
----------	---------	-----------	------	-----------	------	-------------	----------

ذرائع

مقبول خبریں

1۔ بھٹو کی پھانسی اور بے نظیر کا قتل، ادیب باودانی کی تحقیق پر مبنی

تازہ ترین خبریں



پاکستان میں انٹرنیٹ کے استعمال کی آزادی غیر سلسلی بخش: رپورٹ

رپورٹ میں بتایا گیا ہے کہ پاکستان میں یوٹیوب پر پابندی اٹھانے جانے اور ملک میں انٹرنیٹ پر صارفین کی تعداد میں اضافے کے باوجود صورت حال میں کوئی قابل ذکر تبدیلی نہیں آئی ہے۔



پانامہ لیکس: عدالت کی لندن فلینس پر نوچہ مرکوز رخصت کی ہدایت

عدالت نے تحریک انصاف کے وکیل سے کہا کہ محض سیاسی بیانات کی بنا پر کسی کے خلاف کارروائی نہیں کی جا سکتی۔



نیبر آرمینسی: افغانستان سفر کے لیے ویزہ ضروری ہوگا

قباہل علاقوں میں انسانی حقوق کے لیے کام کرنے والی تنظیموں کے سربراہ زمر علی خان آفریدی نے وائس آف امریکہ سے گفتگو میں کہا کہ اس فیصلے سے قباہل عوام کی مشکلات میں اضافہ ہوگا

Introduction

- We are actively scraping Urdu news from news agencies including Jang, Geo, Express, Nawa-e-Waqat etc.
- Currently we have around 0.5 million news scrapped from different news websites.
- Our aim is to develop a portal that can provide Urdu news analytics.
- In this work, we presented our algorithm to automatically cluster similar Urdu news.

News Scrapping

- We use Selenium to scrap the news websites.
- We configured a cron job to run the scrapper after every 4 hours.
- We scrap around 700 to 1200 news every day.

Pre-Processing

News headlines are cleaned in this step by removing stop words and identifying tokens.

News	Stop Words	Tokens
حکومت، جوڈیشل کمیشن کے قیام پر رضامند ہے، عارف علوی	پر، کے، ہے	حکومت، جوڈیشل، کمیشن، قیام، رضامند، عارف، علوی
وزیر اعلیٰ پنجاب سے وزیر داخلہ چوہدری نثار علی خان کی ملاقات خان کی ملاقات	سے، کی	وزیر، اعلیٰ، پنجاب، وزیر، داخلہ، چوہدری، نثار، علی، خان، ملاقات
سعید اجمل کا ورلڈ کپ میں حصہ نہ لینے کا فیصلہ	کا، میں، نہ، لینے	سعید، اجمل، ورلڈ، کپ، حصہ، فیصلہ
مہمند آجینسی، بینظیر بھٹو شہید کی ساتویں برسی عقیدت و احترام سے منائی گئی	کی، و، سے، گئی	مہمند، آجینسی،، بینظیر، بھٹو، شہید، ساتویں، برسی، عقیدت، احترام، منائی، گئی
ایم کیو ایم نے نیشنل کاؤنٹر ٹیررزم پالیسی پر سفارشات کو حتمی شکل دیدی	نے، پر، کو، دیدی	ایم، کیو، ایم، نے، نیشنل، کاؤنٹر، ٹیررزم، پالیسی، سفارشات، حتمی، شکل
ملیشیا کی نجی ہوائی کمپنی کا طیارہ لاپتہ ہو گیا	کی، کا، ہو گیا	ملیشیا، نجی، ہوائی، کمپنی، طیارہ، لاپتہ
میلبرن ٹیسٹ: کوہلی اور ہارنے ڈٹ گئے	اور، گئے	میلبرن، ٹیسٹ،، کوہلی، ہارنے، ڈٹ

New Similarity

Given two news i and j we need to identify similarity between them:

$$st_{avg} = \frac{st_i + st_j}{2}$$

$$S_{i,j} = \frac{m_{i,j}}{st_{avg}}$$

st_i - size of tokens list of news i

st_j - size of tokens list of news j

st_{avg} - average size of token lists of news i and j

$m_{i,j}$ - count of similar tokens of news i and news j

Algorithm 1: getRelatedNewsList

Input: n_i , news headline which is a source headline and we need to identify list of similar news to this news from our dataset

Result: Algorithm return a list of news similar to given news n_i

```
1 begin
2   relatedNewsList  $\leftarrow$  null
3    $t \leftarrow 0.5$ 
4   datasetList  $\leftarrow$  getDatasetList()
5   for  $j = 0$  to datasetList.size do
6      $n_j \leftarrow$  datasetList[j]
7      $S_{i,j} \leftarrow$  getSimilarityScore( $n_i, n_j$ )
8     if  $S_{i,j} \geq t$  then
9       | relatedNewsList.add( $n_j$ )
10    end
11  end
12  return relatedNewsList
13 end
14 getSimilarityScore ( $n_i, n_j$ )
15 begin
16    $tl_i =$  _getTokensList( $n_i$ )
17    $tl_j =$  _getTokensList( $n_j$ )
18    $st_i = tl_i.size$ 
19    $st_j = tl_j.size$ 
20    $S_{i,j} \leftarrow 0$ 
21    $m_{i,j} \leftarrow 0$ 
22   for  $x = 0$  to  $st_i$  do
23     for  $y = 0$  to  $st_j$  do
24       | if  $tl_i[x]$  matches  $tl_j[y]$  then
25         | |  $m_{i,j} \leftarrow m_{i,j} + 1$ 
26       | end
27     end
28   end
29   if  $m_{i,j} > 0$  then
30     |  $avg = (st_i + st_j)/2$ 
31     |  $S_{i,j} = m_{i,j}/avg$ 
32   end
33   return  $S_{i,j}$ 
34 end
```

Ground Truth

- We randomly selected 100 news from each of the following categories:
 - International
 - National
 - Health
 - Business
 - Entertainment
- Each news category is given to three different persons who marked related news manually. Then we identified the common clusters as ground truth in each of the category.

Evaluation Criteria

- We use the same 500 news to run our news similarity algorithm.
- The algorithm gives us cluster of news. Then we computer Confusion Matrix by comparing it with our Ground Truth.
- Now system generated clusters are compared with ground truth clusters and for each category Confusion Matrix is created. Confusion Matrix for category National is given below:

		Predicted	
		UNC	CN
Actual	UNC	TN = 91	FP = 1
	CN	FN = 3	TP = 5

Evaluation Measures

- F-measure
- Precision
- Recall

Evaluation Results

Category	Precision	Recall	F-Measure
International	0.62	0.5	0.55
National	0.83	0.63	0.71
Health	0.43	0.5	0.46
Business	0.26	0.35	0.3
Entertainment	0.29	0.33	0.31
Micro Average	0.45	0.46	0.46
Macro Average	0.48	0.46	0.47

Results

Sr#	Related News	Source
Cluster1	بنگلہ دیش: جماعت اسلامی کے ایک اور رہنما کے لیے سزائے موت	VOA
	بنگلہ دیش: جماعت اسلامی کے رہنما انظر الاسلام کو سزائے موت	BBC
	بنگلہ دیش میں ٹریبونل نے جماعت اسلامی کے ایک اور رہنما کو سزائے موت سنائی	Express
Cluster2	ذکی الرحمن لکھنوی کی نظر بندی کا حکم معطل	BBC
	ذکی الرحمن لکھنوی کو ایک مقدمے میں گرفتار کر لیا گیا	BBC
	ذکی الرحمن کی نظر بندی کا حکم معطل	VOA
	ذکی الرحمن لکھنوی ایک اور مقدمے میں گرفتار	VOA
Cluster3	موڑے پولیس کی تنخواہوں میں 20 فیصد اضافے کا اعلان	Jang
	وزیر اعظم کا موڑے پولیس کی تنخواہوں میں 20 فیصد اضافے کا اعلان	Express
	وزیر اعظم کا موڑے پولیس کی تنخواہوں میں 20 فی صد اضافے کا اعلان	UrduPoint
Cluster4	4 ارب سال قبل مریخ زمین جیسا تھا	BBC
	4 ارب سال قبل سارہ مریخ کا ماحول زمین جیسا تھا: ناسا کا دعویٰ	NawaeWaqt
	4 ارب سال قبل مریخ کا ماحول زمین جیسا تھا	BBC
Cluster5	سینٹ لوشیا، پاکستان کا ہدف 243 رنز	BBC
	سینٹ لوشیا، پاکستان کی پہلے بیننگ	BBC
	سینٹ لوشیا، ویسٹ انڈیز کا ہدف 230 رنز	BBC
	سینٹ لوشیا، پاکستان کا ہدف 262 رنز	BBC
	سینٹ وئسٹ: ویسٹ انڈیز کا پاکستان کو ہیت کیلئے 153 رنز کا ہدف	Jang
Cluster6	انسداد دہشت گردی کے قومی ادارے نیکیا کو بحال کرنے کا فیصلہ	UrduPoint
	انسداد دہشت گردی کے قومی ادارے "نیکیا" کو بحال کرنے کا فیصلہ	Jang
	انسداد دہشت گردی کے قومی ادارے کی فوری بحالی کی ہدایت	VOA
	انسداد دہشت گردی کے قومی ادارے نیکیا کو بحال کرنے کا فیصلہ	GEO

Results (Cont.)

صفحة اول	پاکستان	انٹرنیشنل	کھیل	انٹرنیشنل	بزنس	سائنس / صحت	اشتہارات
----------	---------	-----------	------	-----------	------	-------------	----------

اس جیسی خبریں

- 1- مشرقی یوکرین لڑائی میں 'درجنوں ہلاک'
- 2- یوکرین کا مشرقی علاقوں میں کارروائیاں جاری رکھنے کا حزم
- 3- یوکرین بحران: مشرقی علاقوں میں باغیوں کا ریفرنڈم
- 4- یوکرین کے مشرقی علاقوں کو روس میں ضم کرنے کا مطالبہ
- 5- رواں ماہ مشرقی یوکرین میں لڑائی سب سے ہلاکت خیز رہی: رپورٹ
- 6- یوکرین کا مشرقی علاقوں میں روسی فوج کے حملوں کا الزام
- 7- مشرقی یوکرین کے نو عمر سپاہی
- 8- مشرقی علاقوں میں ریفرنڈم ایک 'ڈھونگ': یوکرین
- 9- مشرقی علاقوں میں ریفرنڈم ایک 'ٹانگ': یوکرین

خبر کی تفصیل

یوکرین کے مشرقی علاقوں میں لڑائی میں شدت، عام لوگوں کی پریشانی



Results (Cont.)

صفیہ اول	پاکستان	انٹرنیشنل	کھیل	انٹرنیشنل	بزنس	سائنس / صحت	اشتہارات
----------	---------	-----------	------	-----------	------	-------------	----------

اس پلیسی خبریں

- 1- پنجاب میں سموگ کاراج برقرار
- 2- پنجاب میں دس افراد کو چھانسی دے دی گئی
- 3- پنجاب میں مزید 24 افراد میں ڈینگی وائرس کی تصدیق
- 4- پنجاب میں ڈینگی وائرس سے متاثرہ افراد کی تعداد 54 ہو گئی
- 5- پنجاب میں مزید 69 افراد میں ڈینگی وائرس کی تصدیق
- 6- سندھ پنجاب انتخابات میں 50 افراد زخمی
- 7- انسانی اسمگلنگ میں ملوث مزید چھ افراد پنجاب سے گرفتار
- 8- ناہینا افراد پنجاب حکومت کی خلاف ورزیوں پر
- 9- پنجاب میں فورسز کا آپریشن، مزید 250 افراد گرفتار
- 10- پنجاب میں سرچ آپریشن، 200 افراد زیر حراست

خبر کی تفصیل

پنجاب میں 1200 سے زائد افراد سموگ سے متاثر ہو گئے



لاہور (اُردو پوائنٹ اخبار تازہ ترین۔ 05 نومبر 2016ء) لاہور میں سموگ مکمل طور پر ختم نہ ہو سکی، صبح کے اوقات میں سموگ میں کمی اور شام میں اس کی شدت بڑھ جاتی ہے، سموگ سے بارہ سو سے زائد افراد متاثر ہو کر ہسپتال پہنچ گئے۔ دوسری طرف پنجاب کے مختلف علاقے دھند کی لپیٹ میں رہے، موٹروے کئی مقامات پر بند رہی۔ اس صورتحال کے پیش نظر ماہرین نے شہریوں کو احتیاط برتنے کی اپیل ہے۔ ماہرین کا کہنا ہے کہ شہری ماسک

Conclusion and Future Work

- We have an algorithm in place to integrate with newslink.pk to identify similar news automatically.
- Experimental evaluation shows an average micro average for Precision measure is 0.45 and the macro average for Precision is 0.48.
- In future, we intend to use LDA to identify similar news and compare it with our work.

THANKS!