

## Transliteration

- Languages are written in different Scripts
  - Russian, Bulgarian and Serbian – Cyrillic Script
  - Urdu, Farsi and Pashto – Arabic Script
  - Hindi, Marathi and Nepalese – Devanagiri Script
- Transliteration is conversion from one script to other
  - सीमा (sima) → Seema
  - مورغان (morghan) → Morgan
  - Талбот (tælbət) → Talbot

- Utility
  - Cross Lingual IR
  - Terminology Extraction
  - Machine Translation
    - OOVs, Disambiguation, Closely Related Language
- Transliteration System
  - Rule-based approach
  - Data-driven approach
    - Requires transliteration corpus

## Transliteration Mining

Магазин	Shop	<table border="1"> <tr> <td>Аналог</td> <td>Analog</td> </tr> <tr> <td>Пакистан</td> <td>Pakistan</td> </tr> <tr> <td>Энтони</td> <td>Anthony</td> </tr> </table> <p>Supervised and Semi-Supervised (Sherif and Kondrak, 2007; Kahki et. al., 2011; Noeman and Madkour, 2010)</p> <p>Fully Unsupervised (Sajjad et. al., 2012)</p>	Аналог	Analog	Пакистан	Pakistan	Энтони	Anthony
Аналог	Analog							
Пакистан	Pakistan							
Энтони	Anthony							
власть	Power							
Аналог	Analog							
Пакистан	Pakistan							
Нужда	Need							
...	...							
Энтони	Anthony							

## Unsupervised Transliteration Mining

<table border="1"> <tr> <td>а н а л о г</td> <td>0.83</td> <td>а   а</td> <td>0.78</td> <td>а н а л о г</td> <td>э н т о н и</td> </tr> <tr> <td>а н а л о г</td> <td></td> <td>э   а</td> <td>0.45</td> <td>а н а л о г</td> <td>а н т h o n y</td> </tr> <tr> <td>с и с т е м а</td> <td>0.05</td> <td>а   е</td> <td>0.07</td> <td>Н у ж д а</td> <td>В л а с т ь</td> </tr> <tr> <td>а н а л о г</td> <td></td> <td>г   г</td> <td>0.75</td> <td>Н e e d</td> <td>Р o w e r</td> </tr> <tr> <td>э н т о н и</td> <td>0.71</td> <td>и   у</td> <td>0.88</td> <td>М а г а з и н</td> <td>П а к и с т а н</td> </tr> <tr> <td>а н т h o n y</td> <td></td> <td>л   л</td> <td>0.82</td> <td>S h o p</td> <td>Р а к и с т а н</td> </tr> <tr> <td>я з ы к о в о</td> <td>0.001</td> <td>...</td> <td>...</td> <td>я з ы к о в о</td> <td>А м е р и к а</td> </tr> <tr> <td>l i n g u i s t</td> <td></td> <td>...</td> <td>...</td> <td>l i n g u i s t</td> <td>А м е р и с а</td> </tr> </table>	а н а л о г	0.83	а   а	0.78	а н а л о г	э н т о н и	а н а л о г		э   а	0.45	а н а л о г	а н т h o n y	с и с т е м а	0.05	а   е	0.07	Н у ж д а	В л а с т ь	а н а л о г		г   г	0.75	Н e e d	Р o w e r	э н т о н и	0.71	и   у	0.88	М а г а з и н	П а к и с т а н	а н т h o n y		л   л	0.82	S h o p	Р а к и с т а н	я з ы к о в о	0.001	...	...	я з ы к о в о	А м е р и к а	l i n g u i s t		...	...	l i n g u i s t	А м е р и с а	$p_1(e, f) = \sum_{a \in \text{Align}(e, f)} \prod_{j=1}^{ a } p(q_j)$ <p>Mining Model</p>
а н а л о г	0.83	а   а	0.78	а н а л о г	э н т о н и																																												
а н а л о г		э   а	0.45	а н а л о г	а н т h o n y																																												
с и с т е м а	0.05	а   е	0.07	Н у ж д а	В л а с т ь																																												
а н а л о г		г   г	0.75	Н e e d	Р o w e r																																												
э н т о н и	0.71	и   у	0.88	М а г а з и н	П а к и с т а н																																												
а н т h o n y		л   л	0.82	S h o p	Р а к и с т а н																																												
я з ы к о в о	0.001	...	...	я з ы к о в о	А м е р и к а																																												
l i n g u i s t		...	...	l i n g u i s t	А м е р и с а																																												
$p_2(e, f) = \prod_{i=1}^{ e } p_E(e_i) \prod_{i=1}^{ f } p_F(f_i)$ <p>Transliteration Model</p>	$p(e, f) = (1 - \lambda)p_1(e, f) + \lambda p_2(e, f)$ <p>Non-Transliteration Model</p>																																																

- EM-based Algorithm
- with transliteration model, we can score training and extract transliteration corpus
- if we knew which pairs in the training are transliteration we can build transliteration model from these

## Integration into SMT

- Method 1: Replace OOV words with 1-best
- Method 2: Select best transliteration from n-best in post decoding
- Method 3: Pass transliteration phrase-table into decoder
- Features
  - Transliteration Phrase Table
  - LM-OOV Feature

Lang	Test	B <sub>0</sub>	M <sub>1</sub>	M <sub>2</sub>	M <sub>3</sub>	OOV
AR	iwslt <sub>11</sub>	26.75	+0.12	+0.36	+0.25	587
	iwslt <sub>12</sub>	29.03	+0.10	+0.30	+0.27	682
BN	jhu	16.29	+0.12	+0.42	+0.46	1239
FA	iwslt <sub>11</sub>	20.85	+0.10	+0.40	+0.31	559
	iwslt <sub>12</sub>	16.26	+0.04	+0.20	+0.26	400
HI	jhu	15.64	+0.21	+0.35	+0.47	1629
RU	wmt <sub>12</sub>	33.95	+0.24	+0.55	+0.49	434
	wmt <sub>13</sub>	25.98	+0.25	+0.40	+0.23	799
TE	jhu	11.04	-0.09	+0.40	+0.75	2343
UR	jhu	23.25	+0.24	+0.54	+0.60	827
<b>Avg</b>		<b>21.9</b>	<b>+0.13</b>	<b>+0.39</b>	<b>+0.41</b>	<b>950</b>

Lang	Data	Train <sub>tm</sub>	Train <sub>tr</sub>
		Sent	Types
Arabic	IWSLT-13	152K	6795
Bengali	JHU	24K	1916
Farsi	IWSLT-13	79K	4039
Hindi	JHU	39K	4719
Russian	WMT-13	2M	302K
Telugu	JHU	45K	4924
Urdu	JHU	87K	9131

Can we improve results by improving Mining?

- Mined system (MTS) vs. gold-standard system (GST)
- MTS has better rule coverage
  - پ( پ b) → ( ب / al) → ε( ال
- Gigapixel vs Algegabixel

WMT-14 (HI-EN an RU-EN)

- Best systems in ¾ cases
- Gains from 0.24-1.07
- Integrated in Moses
- used in Syntax based systems

	AR		HI	RU	
Test	iwslt <sub>11</sub>	iwslt <sub>12</sub>	jhu	wmt <sub>12</sub>	wmt <sub>13</sub>
B <sub>0</sub>	26.75	29.03	15.64	33.95	25.98
MTS	27.11	29.33	16.11	34.50	26.38
GST	26.99	29.20	16.11	34.33	26.22
Δ	<b>-0.12</b>	<b>-0.13</b>	<b>0.0</b>	<b>-0.17</b>	<b>-0.16</b>
<b>Transliteration Pairs Used</b>					
MTS	6795		4719	302K	
GST	1799		2394	1859	