

Developing Standards and Linguistic Resources for Computational Research in Pakistani Languages



www.CLE.org.pk

Sarmad Hussain
Professor
Center for language Engineering (CLE)
Al-Khawarizmi Institute of Computer Sciences (KICS)
University of Engineering and Technology (UET) Lahore
sarmad.hussain@kics.edu.pk

1

Need

ICTs promise significant socio-economic impact
Impact dependent on size of population which can use ICTs

180 Million citizens need access
66+ languages
10% understand English
58% literate
11% have access to computers
70% have access to mobile phones
ITU IDI: Pakistan ranked 127 of 155 nations

Human Language Technology necessary to bridge the gap

www.cle.org.pk

2

Languages of Pakistan

	Urdu	Punjabi	Sindhi	Pushto	Balochi	Saraiki	Others (60)
Total	7.57	44.15	14.1	15.42	3.57	10.53	4.66
Rural	1.48	42.51	16.46	18.06	3.99	12.97	4.53
Urban	20.22	47.56	9.20	9.94	2.69	5.46	4.93

Percent Population of Pakistan by Mother Tongue

www.cle.org.pk

3

Languages of Pakistan

	Urdu	Punjabi	Sindhi	Pushto	Balochi	Saraiki	Others (60)
Total	7.57	44.15	14.1	15.42	3.57	10.53	4.66
Rural	1.48	42.51	16.46	18.06	3.99	12.97	4.53
Urban	20.22	47.56	9.20	9.94	2.69	5.46	4.93

Percent Population of Pakistan by Mother Tongue

www.cle.org.pk

4

Languages of Pakistan

	Urdu	Punjabi	Sindhi	Pushto	Balochi	Saraiki	Others (60)
Total	7.57	44.15	14.1	15.42	3.57	10.53	4.66
Rural	1.48	42.51	16.46	18.06	3.99	12.97	4.53
Urban	20.22	47.56	9.20	9.94	2.69	5.46	4.93

Percent Population of Pakistan by Mother Tongue

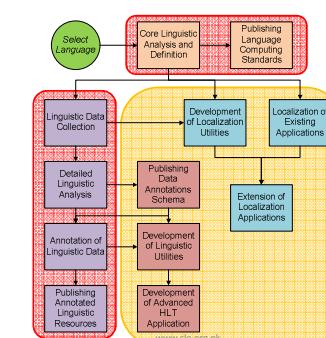
Languages of Pakistan in Danger (UNESCO) (23)

- Vulnerable
- definitely endangered
- severely endangered

www.cle.org.pk

5

Development Process of Human Language Technology



Standards & Linguistic Resources

- Core Linguistic Analysis and Definition
- Publishing Language Processing Standards
- Linguistic Data Collection
- Detailed Linguistic Analysis
- Annotation of Linguistic Data
- Publishing Annotated Linguistic Resources

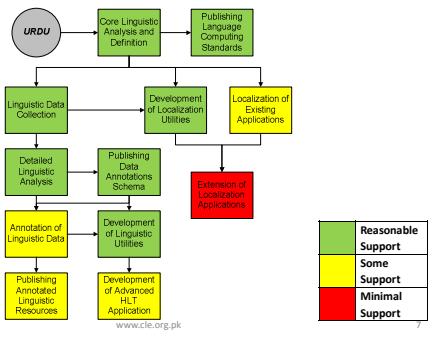
Human Language Technology

- Development of Localization Utilities
- Localization of Existing Applications
- Extension of Localization Applications
- Development of Linguistic Utilities
- Development of Advanced HLT Application

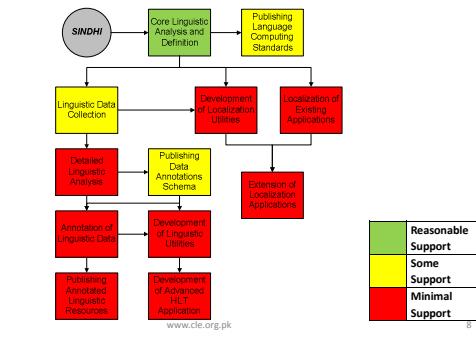
www.cle.org.pk

6

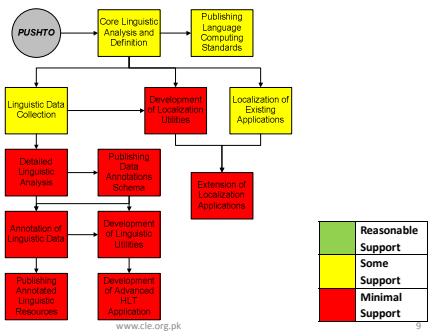
Status of Human Language Technology



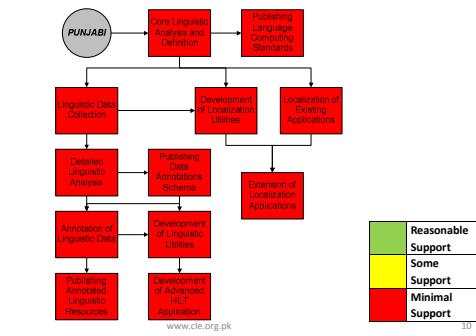
Status of Human Language Technology



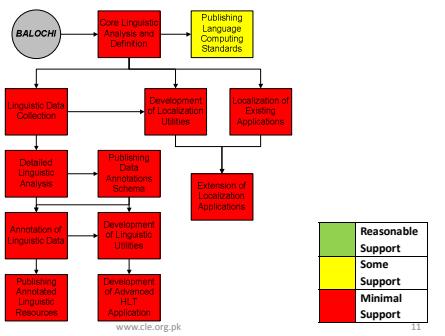
Status of Human Language Technology



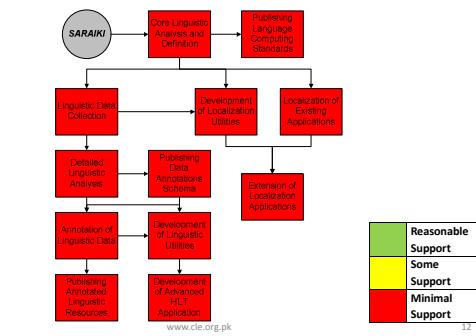
Status of Human Language Technology

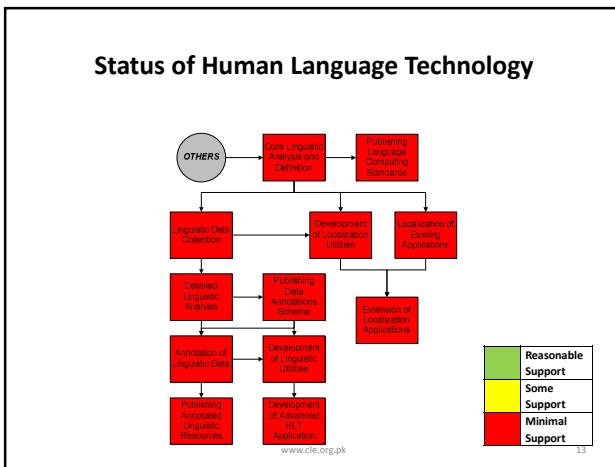


Status of Human Language Technology



Status of Human Language Technology





Core Linguistic Analysis and Definition

- Linguistic details incomplete or unavailable
- Relevant cultural conventions rarely documented
- Need analysis of language and cultural conventions
 - Should be driven by linguists and community
- Precise definitions of relevant aspects
 - Involvement of technologists to iron out ambiguities

www.cle.org.pk

14

Core Linguistic Analysis and Definition

- Character-set
 - Alphabet – letters & aerab
 - Punctuation marks
 - Special symbols, etc.
- Sorting or collation of characters
- Cultural conventions for representing
 - Numbers
 - Time
 - Calendar
 - Currency
- Translation of terms for software interface

www.cle.org.pk

15

Standards

- Character Encoding – ISO 10646 - Unicode
- Locale – ISO 639 – ISO 3166 – Unicode-CLDR
 - Keyboard
 - Collation Element
- Localization Terminology
- Develop national standards
- Follow up with international standards

www.cle.org.pk

16

Lexica

- Word lists
- Annotated Lexical
 - Pronunciation
 - Agreement information (num, gender, case, respect)
 - Part of Speech (POS)
 - Translation
 - Sub-categorization frame/argument structure
 - Root
 - Morphological information
- Wordnet

www.cle.org.pk

17

Word Lists

- Word list – surface forms
- Lexeme list
- Closed class words
- Proper Names
- Frequency based word lists

Ligature	Frequency	Word	Frequency
ا	2885748	ا	745649
ب	1716383	ب	382882
پ	915845	پ	515845
ج	1350586	ج	466800
ڻ	896166	ڻ	413798
ڻ	746801	ڻ	368155
ڻ	582882	ڻ	309355
ڻ	581999	ڻ	281802
ڻ	508375	ڻ	244917
ڻ	452167	ڻ	217940
ڻ	448244	ڻ	201031
ڻ	447729	ڻ	173467
ڻ	424334	ڻ	143888
ڻ	388097	ڻ	140317
ڻ	362535	ڻ	129851
ڻ	348302	ڻ	115041
ڻ	342672	ڻ	113461
ڻ		ڻ	108414
ڻ		ڻ	88237
ڻ		ڻ	83615
ڻ		ڻ	80788
ڻ		ڻ	84589

www.cle.org.pk

Phonetic Lexicon

Attock	A T T A K
Bahawalpur	B A H A A V A L P U R
Bhakkar	B_H A K A R
Chakwal	T_S H A K V A A L
Faisalabad	F A Y S L A B A A D_D
Gujranwala	G U D_Z Z R A A N V A A L A A N
Gujrat	G U D_Z Z R A A T T
Jhang	D_Z Z_H A N G
Jehlum	D_Z Z_A E H L A M
Kasur	K A S U U R
Khushab	X U U S H A A B
Lahore	L A A H O R
Mianwali	M I I A A N V A A L I
Multan	M U L T_D A A N
Rawalpindi	R A A V A L P I N D D II
Sahiwal	S A A H I I V A A L
Sargodha	S A R G O O D_D_H A A
Sheikhpura	S H A E X U U P U R A A
Sialkot	S I A L K O O T T

www.cle.org.pk

19

Urdu ID	English ID	English Word	Category	Concept	Example	Synset
100853	6854161	English	Noun	اے عربی اور فارسی کے سامنے ساتھ انگریزی کی بولی۔ انگلستان کی تباہی پر بھی جو درست مسائل تھا	انگریزی، انگلش	انگریزی، انگلش
103196	617535	reading	Verb	آن یہ کتاب پڑھنے کا موقع ہے	مطالعہ کرنا	پڑھنے، خدا، مطالعہ کرنا
101288	4977386	intensity	Noun	بُوش، نزدیکی، تندی	شیدی ہونے کی خصوصیت	بُوش، نزدیکی، تندی
103802	2179176	give	Verb	اس نے اپنے دوپے اس کو سونپے	فوجیہ پر لامس رکھنا	دینا، سونپنا
102950	145831	certainly	Adverb	بے شک کسی شہر کے نام	بیٹھنا، اس کا کام مکمل ہو گیا ہو گا	بالشہر، بالشہر، بے شک، ضرور، بیٹھنا
104727	9771320	child	Noun	اسنچن پر دھاکے کا زخمی سات	اس، جس کی عمر تصوری ہے	اسنچن، طفیل
				سالہ پر اپنے دم توڑ گیا	لڑکا، طفل، پچھر کرنا	سالہ، طفیل

www.cle.org.pk

20

Text Corpora

- Text corpus
 - Size
 - Time
 - Genre
- CLE Urdu Digest corpus
 - Size
 - 100k
 - 500k
 - 1M
 - Time
 - 2003-2012
 - Genres
 - Balanced

Category	Sub-category	Percentages
1. Informational (80%)		
a) Informal	Letters	10%
	Interviews	10%
a) Formal		
	Press	8%
	Religion	8%
	Sports	8%
	Culture (travel, history)	8%
	Entertainment	4%
	Health	8%
	Science (education, technology)	16%
1. Imaginative (20%)		
	Short Stories	8%
	Translation of foreign literature	4%
	Novels	4%
	Book reviews	4%

www.cle.org.pk

21

Text Corpora

State of the Art

- English: Web 1T 5-gram Version 1
- Published by Google
 - Number of tokens: **1,024,908,267,229**
 - Number of sentences: 95,119,665,584
 - Number of unigrams: 13,588,391
 - Number of bigrams: 314,843,401
 - Number of trigrams: 977,069,902
 - Number of fourgrams: 1,313,818,354
 - Number of fivegrams: 1,176,470,663

www.cle.org.pk

22

English: Web 1T 5-gram Version 1

- Sample Trigrams and Frequencies
 - ceramics community for 61
 - ceramics companies .53
 - ceramics companies consultants 173
 - ceramics company ! 4432
 - ceramics company , 133
 - ceramics company .92
 - ceramics company 41
 - ceramics company facing 145
 - ceramics company in 181
 - ceramics company started 137
 - ceramics company that 87
 - ceramics component (76
 - ceramics composed of 85
 - ceramics composition as 41
 - ceramics computer graphics 51
 - ceramics computer imaging 52
 - ceramics consist of 92

www.cle.org.pk

23

Annotated Corpora

- Text Corpus
 - POS tagged
 - Chunk tagged
 - Sense tagged
- Tree Bank
 - Syntax
 - Grammatical relations
 - Dependency relations

www.cle.org.pk

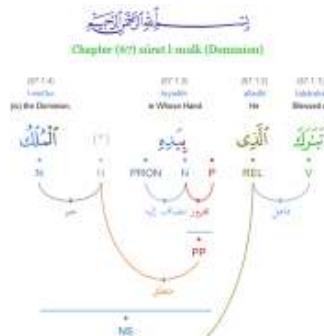
24

دنیا کا ہر فرد کامیابی کا آرزو مند ہے۔ ناکامی سے بے گھبڑتے ہیں۔ عزت، دولت، راحت اور عافیت کی ننگی کے سہی شیدائی میں۔ لیکن اصل کامیابی کیا چیز ہے؟ اور حقیقی عزت و راحت کس طرح نسبت ہوتی ہے؟ اس بھیجی سے ہست مگل واقف ہے۔ اگر آپ حقیقی کامیابی کے گار بانتا جائیتے تو ٹوکرائے ہمیں عامر کی تاریخ تینیں لکھ دیتا رہا۔ پیغمبیر صفحوں کی اس کتاب کا ایک ایک عزت بصیرت کے درمیان گھونٹے پر مامور ہے۔

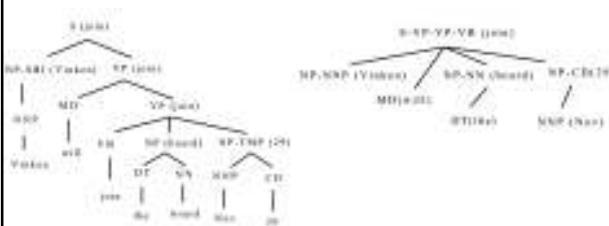
- ((S (NP Battle-tested industrial managers here) always (VP buck up (NP nervous newcomers) (PP with (NP the tale (PP of (NP (NP the (ADJP first (PP of (NP their countrymen)))) (S (NP *) to (VP visit (NP Mexico)))) , (NP (NP a boatload (PP of (NP (NP warriors) (VP-1 blown ashore (ADVP (NP 375 years) ago)))))) (VP-1 *pseudo-attach*)))))) .)



Arabic (Quran)



Phrase Structure vs. Dependency Treebanks



www.cle.org.pk

Sense Tagged Corpus

Text Corpora

- Parallel Text corpus
 - Language
 - Size
 - Genre
 - Time
 - Alignment
 - Spelling Error corpus

Parallel Corpus

- English
Pierre Vinken , 61 years old , will join the board as a nonexecutive director Nov. 29 .
 - Urdu
پیرے وینکن ، ۶۱ سالہ، ۶۱ سالہ، پیرے وینکن کی جانب سے ایک نامہ ایجاد کرنا۔
 - Nepali
६। <CD> वर्षीय<JJ>
पियरे<>NNP>
विनकेन<>NNP>
नोनेक्सिव<>NNP> २९<CD>
बाट<>POP>
सलाहकारकर<>NN><NP><>PKO>
> समुद्र<>NN> मा<>POP>
संचायकर<>NN>
समिति<>NN> मा<>POP>
आउनुनेथे<>VBX> |<YF>

Mr. Vinken is chairman of Elsevier N.V., the Dutch publishing group.

- | | |
|--------------------------------|---|
| NNP >> <u>کن</u> << NNP >> سرے | شی <> نہیں کن << NNP >> پر کا شان << NN |
| CM >> <u>پالندہ</u> << NP | سادھ <> NNP >> پر کا شان << NN |
| NN >> <u>اٹا</u> << JJ | پر کا شان <> NNP >> پر کا شان << NN |
| NNP >> <u>لش</u> << NP | پر کا شان <> NNP >> پر کا شان << NN |
| CM >> <u>لئی</u> << NNPC | بڑا بڑا <> NNP >> لے <> VNP >> لے <> V |

Corpora

- Speech Corpus
 - Duration
 - Speakers
 - Channels
 - Environments
 - Contents
 - Accent(s)
 - Gender
 - Style (read/spontaneous)
 - Vocabulary

Annotated Corpora

- Speech Corpus
 - Textual transcription
 - Segmental IPA transcription
 - Aligned transcription
 - Syllable boundaries
 - Stress
 - Intonation
 - POS

Speech Tagging Schema

```

p1^p2-p3+p4=p5@p6p7
/A:a1 a2 a3
/B/b1-b2-b3@b4-b5&b6-b7#b8-b9$b10-b11!b12-b13;b14-b15/b16
/C:c1+c2+c3
/D:d1+d2/E:e1+e2@e3+e4&e5+e6#e7+e8/F:f1f2
/G:g1 q2/H:h1=h2`h3-h4|h5/l1 l2

```

- | | |
|----|---|
| p1 | the phoneme identity before the previous phoneme |
| p2 | the previous phoneme identity |
| p3 | the current phoneme identity |
| p4 | the next phoneme identity |
| p5 | the phoneme after the next phoneme identity |
| p6 | position of the current phoneme identity in the current syllable (forward) |
| p7 | position of the current phoneme identity in the current syllable (backward) |

- | | |
|-----|---|
| i1 | whether the previous syllable stressed or not (0: not stressed, 1: stressed) |
| i2 | whether the previous syllable accented or not (0: not accented, 1: accented) |
| i3 | the number of phonemes in the previous syllable |
| o1 | whether the current syllable stressed or not (0: not stressed, 1: stressed) |
| o2 | whether the current syllable accented or not (0: not accented, 1: accented) |
| o3 | the number of phonemes in the current syllable |
| o4 | position of the current syllable in the current word (forward) |
| o5 | position of the current syllable in the current word (backward) |
| o6 | position of the current syllable in the current phrase (forward) |
| o7 | position of the current syllable in the current phrase (backward) |
| o8 | the number of stressed syllables before the current syllable in the current phrase |
| o9 | the number of stressed syllables after the current syllable in the current phrase |
| o10 | the number of accented syllables before the current syllable in the current phrase |
| o11 | the number of accented syllables after the current syllable in the current phrase |
| o12 | the number of syllables from the previous stressed syllable to the current syllable |
| o13 | the number of syllables from the current syllable to the next stressed syllable |
| o14 | the number of syllables from the previous accented syllable to the current syllable |
| o15 | the number of syllables from the current syllable to the next accented syllable |
| o16 | name of the vowel of the current syllable |
| c1 | whether the next syllable stressed or not (0: not stressed, 1: stressed) |
| c2 | whether the next syllable accented or not (0: not accented, 1: accented) |
| c3 | the number of phonemes in the next syllable |

a1	gpos (guess part-of-speech) of the previous word
a2	the number of syllables in the previous word
a3	gpos (guess part-of-speech) of the current word
a4	the number of syllables in the current word
a5	position of the current word in the current phrase (forward)
a6	position of the current word in the current phrase (backward)
a7	the number of content words before the current word in the current phrase
a8	the number of content words after the current word in the current phrase
a9	the number of words from the previous content word to the current word
a10	the number of words from the current word to the next content word
b1	gpos (guess part-of-speech) of the next word
b2	the number of syllables in the next word
c1	the number of syllables in the previous phrase
c2	the number of words in the previous phrase
d1	the number of syllables in the current phrase
d2	the number of words in the current phrase
d3	position of the current phrase in this utterance (forward)
d4	position of the current phrase in this utterance (backward)
d5	TOKI endone of the current phrase
e1	the number of syllables in the next phrase
e2	the number of words in the next phrase

www.cle.org.pk

37

Speech Annotated File Sample

```
p1^p2-p3+p4=p5@p6 p7
/A:a1 a2 a3
/B:b1-b2-b3@b4-b5&b6-b7#b8-b9$b10-b11/b12-b13;b14-b15/b16
/C:c1+c2+c3
/D:d1 d2/E:e1+e2@e3+e4&e5+e6#e7+e8/F:f1 f2
/G:g1 g2/H:h1=h2^h3=h4|h5/i1 i2
```

```
1807500 3432500 pau^pau-ao+th=er@1_2/A:0_0_0/B:1-1-2@1-2&1-7#1-4$1-3!0-2;0-
4|ao/C:0+0+1/D:0_0/E:content+2@1+5&1+2#0+3/F:in_1/G:0_0/H:7=5^1=2|L-
L%/:I:7=3/I:14+8-2
```

```
3432500 4557500 pau^ao-th+er=ah@2_1/A:0_0_0/B:1-1-2@1-2&1-7#1-4$1-3!0-2;0-
4|ao/C:0+0+1/D:0_0/E:content+2@1+5&1+2#0+3/F:in_1/G:0_0/H:7=5^1=2|L-
L%/:I:7=3/I:14+8-2
```

www.cle.org.pk

38

Corpora

- Document Image Corpus
 - Resolution (DPI)
 - Color/Grayscale/BW
 - Print quality
 - Paper quality
 - Paper transparency
 - Genre
 - Publisher

www.cle.org.pk

39

Annotated Corpora

- Document Image Corpus
 - Textual transcription
 - Line
 - Text Area
 - Figures and page frames
 - Heading
 - Header and Footer
 - Main bodies
 - Diacritics and their association

www.cle.org.pk

40

113

ایمان، امید اور محبت

جیکے عربی اور کسی حد تک اردو زبان بھی وہ بول لیتا تھا اگرچہ وہ ان زبانوں میں لکھا پڑھنیں سکتا تھا۔ اس کی اس خصوصیت کے اکشاف نے یکدم ہی اسے اپنی کلاس اور کسی حد تک اسکوں میں پاپولر کر دیا تھا۔ لیکن کوئی کی کلاس میں ایک دن اتفاقاً اس کے پیچے کو اس بات کا پتا چلا تھا کہ وہ جرمن زبان پر بھی درست رکھتا ہے۔

”تو ڈیپلی ٹم دوز بانوں کو استعمال کر سکتے ہو؟“ پیچرے اسے سراہت ہوئے کہا۔

”دونیں چار..... عربی اور اردو بھی۔ اگرچہ میں انھیں لکھ پڑھنیں سکتا گر اس میں گھنٹکو کر سکتا ہوں۔“ مدھم آواز میں کہنے گئے جملے نے یک دم ہی پوری کلاس کو سروڑ کر اس کی طرف متوجہ ہونے پر مجبور کر دیا۔ ان کی آنکھوں میں حیرت کے ساتھ ساتھ ستائش بھی تھی۔

”چار زبانیں..... زبردست۔ گرچار زبانیں کیسے؟ میرا مطلب ہے عربی اور اردو؟“

”میرے ذمیتی بہت عرصے سے مل ایسٹ اور ایشیا کے ممالک میں کام کرتے رہے ہیں، میری پیاس بھی مراد میں ہوئی اس لیے عربی بولنا آگئی اور پچھلے دو سال سے ہم لوگ انہیاں میں تھے۔ وہاں لوگوں سے بات چیت لکھا یا اردو میں ہی ہوتی تھی، اس لیے اس کو بھی استعمال کرنا آگئا۔“

113

ایمان، امید اور محبت

جیکے عربی اور کسی حد تک اردو زبان بھی وہ بول لیتا تھا اگرچہ وہ ان زبانوں میں لکھا پڑھنیں سکتا تھا۔ اس کی اس خصوصیت کے اکشاف نے یکدم ہی اسے اپنی کلاس اور کسی حد تک اسکوں میں پاپولر کر دیا تھا۔ لیکن کی کلاس میں ایک دن اتفاقاً اس کے پیچے کو اس بات کا پتا چلا تھا کہ وہ جرمن زبان پر بھی درست رکھتا ہے۔

”تو ڈیپلی ٹم دوز بانوں کو استعمال کر سکتے ہو؟“ پیچرے اسے سراہت ہوئے کہا۔

”دونیں چار..... عربی اور اردو بھی۔ اگرچہ میں انھیں لکھ پڑھنیں سکتا گر اس میں گھنٹکو کر سکتا ہوں۔“ مدھم آواز میں کہنے گئے جملے نے یک دم ہی پوری کلاس کو سروڑ کر اس کی طرف متوجہ ہونے پر مجبور کر دیا۔ ان کی آنکھوں میں حیرت کے ساتھ ساتھ ستائش بھی تھی۔

”چار زبانیں..... زبردست۔ گرچار زبانیں کیسے؟ میرا مطلب ہے عربی اور اردو؟“

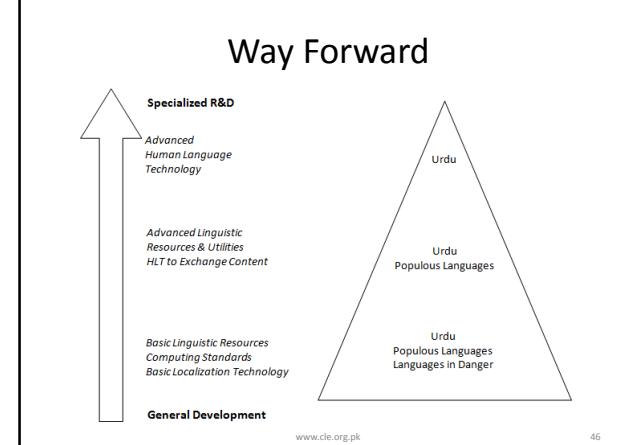
”میرے ذمیتی بہت عرصے سے مل ایسٹ اور ایشیا کے ممالک میں کام کرتے رہے ہیں، میری پیاس بھی مراد میں ہوئی اس لیے عربی بولنا آگئی اور پچھلے دو سال سے ہم لوگ انہیاں میں تھے۔ وہاں لوگوں سے بات چیت لکھا یا اردو میں ہی ہوتی تھی، اس لیے اس کو بھی استعمال کرنا آگئا۔“

113

امان، ایسا دوست
جک عربی اور کسی حد تک اردو ربان بھی وہ بول لمنا تھا اکچڑوہ ان ربانوں میں لکھ پڑھ سکتا تھا۔
ان کی اس خصوصیت کے اکشاف نے بکدم ہی اسے اپنی کلاس اور کسی حد تک اسکوں میں پاپر کر دیا تھا۔ لکھوچ کی کلاس میں ایک دن اتفاقاً اس کے تھپر کو اس بات کا باتا پڑا تھا کہ وہ جس ربان پر بھی درس رکھتا ہے۔
”لود ملٹم دور بانوں کو استعمال کر کے مو“ تھرے اسے سراۓ ہوئے کہا۔
”دوپسیں چار..... عربی اور اردو بھی۔ اگرچہ میں اپنی لکھ پڑھ سکتا کہ اس میں گھنکو کر سکتا ہوں۔“ دم آوار میں کہے گئے جملے نے یہ دم ہی پوری کلاس کو سر ہوا کر اس کی طرف منوجہ ہونے پر مجبور کر دیا۔ ان کی آنکھوں میں حیرت کے ساختہ ساختہ تھاں بھی تھی۔
”جاہر مانیں..... رو روت تک جا رہا میں کسے؟“ مرانٹل بے عربی اور اردو۔“
”بیرے ڈینی بہت عرصے سے مل ایسٹ اور ایشیا کے ممالک میں کام کرتے رہے ہیں، میری بیوائیں بھی مرکز میں ہوتی اس لیے عربی بولنا اسی کی اور بھلے دو سال سے ہم لوک انہماں سے۔ وہاں لوگوں سے ناتھ اٹکنے ارادو میں ہی ہوتی تھی، اس لیے ان کو بھی استعمال کرنا آگاہ“

113

امان، ایسا دوست
جک عربی اور کسی حد تک اردو ربان بھی وہ بول لمنا تھا اکچڑوہ ان ربانوں میں لکھ پڑھ سکتا تھا۔
ان کی اس خصوصیت کے اکشاف نے بکدم ہی اسے اپنی کلاس اور کسی حد تک اسکوں میں پاپر کر دیا تھا۔ لکھوچ کی کلاس میں ایک دن اتفاقاً اس کے تھپر کو اس بات کا باتا پڑا تھا کہ وہ جس ربان پر بھی درس رکھتا ہے۔
”لود ملٹم دور بانوں کو استعمال کر کے مو“ تھرے اسے سراۓ ہوئے کہا۔
”دوپسیں چار..... عربی اور اردو بھی۔ اگرچہ میں اپنی لکھ پڑھ سکتا کہ اس میں گھنکو کر سکتا ہوں۔“ دم آوار میں کہے گئے جملے نے یہ دم ہی پوری کلاس کو سر ہوا کر اس کی طرف منوجہ ہونے پر مجبور کر دیا۔ ان کی آنکھوں میں حیرت کے ساختہ ساختہ تھاں بھی تھی۔
”جاہر مانیں..... رو روت تک جا رہا میں کسے؟“ مرانٹل بے عربی اور اردو۔“
”بیرے ڈینی بہت عرصے سے مل ایسٹ اور ایشیا کے ممالک میں کام کرتے رہے ہیں، میری بیوائیں بھی مرکز میں ہوتی اس لیے عربی بولنا اسی کی اور بھلے دو سال سے ہم لوک انہماں سے۔ وہاں لوگوں سے ناتھ اٹکنے ارادو میں ہی ہوتی تھی، اس لیے ان کو بھی استعمال کرنا آگاہ“



Thank you

Questions?

sarmad.hussain@kics.edu.pk