

NICTでは自動翻訳への活用などのため、アジア言語における文字・音声処理技術に関する研究開発を行っている。私はその中でもアズギダ系文字を効率的な入力を実現す

情報通信研究機構

NICT 先端研究

88

るため、計算言語学理論と言語処理技術を併用し、文字体系にある冗長性を低減して、使いやすい入力インターフェースを創出した。

一般的に文字は言語を記録する符号のことである。世界中の言語は数千種類もあり、それらを記録する文字体系

系も異なる。例えば和文に使われる仮名は「音節文字」を言い、子音・母音」と記号を設けるローマ字は「音素文字」を言う。音節・音素文字はともに「表音文字」である一方、漢字のようないくつかの体系もある。欧米諸言語に音素文字が採用されることは対し、アラビア系には複雑な文字体系が用いられる。日本では、進んだ和文入力技術がすでに日常生活に浸透している。

一方、人口が多く経済発展が目覚ましいアジアに広く使われる「アラビア系文字」の処理は、十分に発展しない。アラビア系文字は「音素音節文字」とも言う。仮名のように「独立文字」があり、母音の変換・子音の結合を表す「付加記号」もある。従来の入力方式では、文字・記号の順番を正しく組み合わせないと文字化が生じる。さらに文字

アブギダ系文字入力効率化

先進的音声翻訳研究開発推進センター・先進的翻訳技術研究室テニュアトラック研究員

丁度
塵辰



アブギダ系文字の簡素化および自動復元

実デニユ...

...

ノン ナーン ヌーン ニーン
 /noon/ /naen/ /nuen/ /nein/
 ノン ナーン ヌーン ニーン
 記号を省略
 文字を合併
 N N.

大幅に簡素化


自

復元精度

文字	98%	96%	94%	92%	90%	88%
タイ文字	98%	97%	96%	95%	94%	93%
クメール文字	96%	95%	94%	93%	92%	91%
ミャンマー文字	94%	93%	92%	91%	90%	89%
ラーオ文字	92%	91%	90%	89%	88%	87%

1,000,000

複元率：各の実験 (回数)



における復元精度を高めている。利用される実データ量の増加に従い、復元性能が向上する。現在、私たちは、実用化に向け、入力システム、ソフトウェアを開発し、アジア言語処理技術の向上を目指している。(火曜日に掲載)