

動的計画法による漢字仮名混り文の単位切りと仮名ふり

藤崎哲元助（日本アイ・ビー・エム(株) 東京サイエンティフィック・センター）

1. はじめに

日本語の言語処理が大学や会社の研究室の範囲を出て、様々な分野で実用的になりその技術が用いられるようになってしまったが、そこで依然として重要な基本的问题として日本文の入力の問題と漢字仮名変換の問題がある。

この漢字仮名変換とは通常の日本語の表記法に従いベタ書きから漢字仮名混り文を入力として、わざわざ書かれていた仮名文を出力するものであり、ベタ書き文を適切な単位でわざわざ書く単位切りの問題と、それからの漢字の読みみを文脈より決定する仮名ふりの問題の2つの問題を含んでいる。

この漢字仮名変換の重要性については特に言及するまでもないが、文書よりの索引 (KWIC / KWOC) の自動作成、文献検索のための自動キーワード切り出しなどを実現するためには不可欠の技術であり、また文書の点字化、将来の文書の自動朗読などにも結びつく技術である。

日本アイ・ビー・エム(株) 東京サイエンティフィック・センターでも、従来より将来的オフィス・オートメーション実現のための中核として日本語文書処理システム「ことなづ」の研究開発を行ってきているが、^[1, 2, 3, 4] そこでも、既存の漢テレ入力から文書に対して「ことなづ」の索引自動作成、キーワード文献検索などの文書処理サービスを利用可能とするためには漢字仮名変換の研究を行ってきている。

過去においても、この漢字仮名変換には、いくつかの試みが報告されている。^[5, 6, 7] たゞ、その目的により、特に単位切りにおいては、文節の単位

の単位切りと目指すもの、自立語/付属語の単位切りと目指すもの、これらは自立語が複合語である時に語基の単位切りまで目指すかのなどの差異があり、これらを一律に比較することはできない。

文節の単位までの単位切りにおいては、字種の変り目（ひらがなからひらがな以外への変り目）を文節の始まりとするという单纯な規則が有効であることがよく知られており、この单纯な規則だけにより 84% の分割精度を得たとの報告が行われている。^[8] 単位切りの単位が短くなるとさらに難しくなる。漢語が多く 2 文字単位で構成されることがや、複合語分解の分布を利用して規則と若干の接辞用漢字リストで分割を試みた例もあるが、^[9] 最終的には語基の辞書を整備し、分割の際に数万の辞書を参照しなければならぬ現状である。

一方、仮名ふりにおいても、単位切りと同様に、両隣の文字の字種が漢字以外なら訓読み、その他の場合は音読みとするというより单纯な音訓規則を利用すると、ある程度の漢字は読みが一通りしかないことなどを手伝って 85% 程度の精度を得ることはできる。^[10]

このように、文節切り、仮名ふり共に簡単な規則で 85% 程度は容易に達成できることだが、単位切りの単位をより細くする、精度を高め、などのためにはこれらの基本規則の例外を辞書もしくは例外コードとして蓄積することになる。自然言語は奥の深いものであるのでこのようなアプローチは最終的に避けられないと考えられるが、基本的規則の与える精度が低ければ低い程、辞書などの形で蓄積しなければならない

い情報の量は膨大となり、かつ分野への依存度が高まるのは避けられない。

筆者は、従来より文字認識・音声認識などのパターン認識の分野で用いられてきたマルコフ過程の推定アルゴリズムである Viterbi アルゴリズム^{[10][11]}がこの種の日本語の問題に有効であると考え、特に漢字仮名変換の問題への適用を試みた。もちろん、本稿で紹介する方程式が漢字仮名変換を完全に解決する訳ではなく、むしろ、この方程式が従来までの単純な基本規則を加えて構成され、例外辞書や、例外コードの直訳を大幅に軽減する可能性があると考える。実験もまだ小規模で、結果もこのアルゴリズムで得られた程度の極値に留まっている訳ではないが、この方程式の有効性を示す結果が出たこと、また、この方程式が漢字仮名変換以外の日本語関連の問題にも有効な手法になり得ると考え報告する。

2. Viterbi アルゴリズム

Viterbi アルゴリズムとは、離散時間の有限マルコフ過程における推定アルゴリズムであり、図1に示すようなマルコフ過程と記憶のない離散通信路の環境において通信路の出口に




図1 一般モデル

における観測値 Z (以後 Z と略す) からマルコフ過程からの出力 X (以後 X と略す) を推定するものである。問題を単純化するためマルコフ過程の内部状態と出力 X を同一視すれば、 $\{x_k \in (X_{k+1}, X_n)\}$ 通信路に記憶がないので次かぎえる。

$$P(Z|X) = P(Z|X_k) = \prod_k P(Z_k|X_k) \quad (i)$$

さて、これから X を推定するためには、内部状態と時間と共にそれを縦軸、横軸とする有向グラフ (trellis と呼ばれる) を作ることが有効である。(図2)




図2 trellis の例

この trellis は図1のマルコフ過程の内部状態の遷移を時間と共に表記したものであるが、重要なことは観測値 Z を発生させる可能性のある X がすべて trellis 上の別ルートとして表われられ、逆に Z を発生させる可能性のない X に対応するルートは含まれないようを作られていくことである。従って、これら X を推定することは、この trellis 上のルートを 1つ選ぶことである。

Z を観測して、それを発生した X の最もらしいものを $\{x^1, x^2, \dots, x^n\}$ (これが trellis 上のルートに対応) から選ぶのは $P(X^i|Z)$ を最大にする i を求めればよい。ベイズの定理により、

$$P(X^i|Z) = \frac{P(X^i, Z)}{P(Z)} = \frac{P(X^i) \cdot P(Z|X^i)}{P(Z)} \quad (ii)$$

であるので、結局 $P(X^i) \cdot P(Z|X^i)$ を最大とする i を求めることになる。一元、(ii)式と、trellis 上の各枝が、 X_k に対応しがつ (x_{k+1}, x_n) に対応して i は

ので、結局

$$P(\mathbf{x}) \cdot P(\mathbf{z} | \mathbf{x}) = \prod_k P(z_{k+1} | z_k) \prod_k P(z_k | x_k)$$

を最大ルートを trellis 上で求め
る。trellis の各枝 k

$$- \ln P(z_{k+1} | z_k) - \ln P(z_k | x_k) \quad (\text{iii})$$

を距離として与えれば、trellis 上の最短ルートを求めることに帰着である。
そしてこの最短ルートを求めることはよく知られているよう動的計画法(ダイケミック・プログラミング)の手法を用いて容易に理実的な計算時間で解くことができる。(図3)




図3 動的計画法による最短ルートの探索

3. 漢字仮名変換の形式化

漢字仮名変換の問題をこの Viterbi ルジズムに形式化するには、それがマルコフ過程よりの出力文字列 \mathbf{x} が雑音のある通信路を経て文字列 \mathbf{z} に変形される図1の構造で考えると専用がある。従って、タタキ果てはあるか、そもそも単位切り山を仮名書き文 \mathbf{x} が存在しており、その上に雜音のある通信路を経て漢字仮名混りのベタ書き文として観測されると考える。当然、ここでの雜音とは、 \mathbf{x} 内の仮名の部分文字列が漢字文字列 \mathbf{z} 確率的に互換

えられること、また、 \mathbf{x} 中の単位切りの空白が失われることである。特に単位切りに関しては、應用の目的から、文節単位切り、語基レベルまでの単位切りなど様々なものが考えられる訳だが、それらのいずれもは、通信路上の雜音の設定により形式化できる。




図4 漢字仮名変換のモデル

従って、この構造での漢字仮名変換とは、観測された \mathbf{z} を発生し得る全ての単位切り山を仮名書き文を全ルートとして含む前述の trellis を作り、各 trellis 上の枝の距離を (iii) 式により与え、その上で最短ルートを探索することである。最短ルートが得られれば、そのルートに對応する \mathbf{x} が、漢字仮名混りベタ書き文 \mathbf{z} の最も確からしい単位切りと仮名山リである。

3.1 雜音

図4の構造における雜音は \mathbf{x} 上の部分仮名列が漢字、ひらがな等において換えられるもの、また、 \mathbf{x} 上の空白が欠落するものの2種を考えねばならない。前者においては、より一般的には次のような確率的雜音 E を考えればよい。

$$E = \{ x^* \rightarrow z^*, P(z^* | x^*) \}$$

このEは任意長の假名列か。任意長の漢字列かおもねられるので、確率付の国語辞典を用意することとなる。但しここでの確率とは $P(\text{漢字正書} | \text{読み})$ である。このようすEが与えられれば観測文字列より、可能なXをすべてのルートとして持つ trellis を作ることは容易に行える。すちゅうEの逆変換E'を作れば、Z上の部分文字列にE'に含まれる変換を順次適用することですべてのXを含む有向グラフを作れる。(図5)

$$E = \left\{ \begin{array}{l} X_1, X_2 \rightarrow Z_1, Z_2, \quad 0.3 \\ X_1, X_2 \rightarrow Z_2, \quad 0.7 \\ X_1 \rightarrow Z_1, \quad 1.0 \\ X_2 \rightarrow Z_3, Z_4, \quad 1.0 \\ X_3 \rightarrow Z_4, \quad 0.9 \\ X_3 \rightarrow Z_2, Z_3, \quad 0.1 \end{array} \right\}$$

図5

$$Z = (Z_1, Z_2, Z_3, Z_4)$$

↓




図5 すべてのXを含む有向グラフ

図5 において各枝の下に付した数字は、
雑音Eの変換の起る確率で(iii)式の
2項に対応する。

空白が欠落する雑音は、図5に点線で示した位置に空白を発生するループを加えればよい。但しこのループは2度以上連続して回らなないので、展開して、ループを含まない有向グラフに展開できる。(図6)




図6 空白欠落を考慮した有向グラフ

従って、図6のグラフ上の全ルートはより可能な $\{X^i\}$ 及びそれに対応する $P(Z | X^i)$ を得ることができます。

3.2 n-gram

雑音Eより各 X^i に対する $P(Z | X^i)$ を得ることはできなかつたが、最適な X^i を選ぶためには、更に各単位切り假名書き文の生ずる確率 $P(X^i)$ を知らぬばならぬ。[(ii)式] しかし、これを自然言語で分野を限らず直接的に得ることは不可能に近い。

n-gram モデルとは、文字列上の文字の発生確率がその以前の $n-1$ 文字に依存するとするモデルで、自然言語のいろまじを近似するのに有効であることが知られています。^[12] 特に、このモデルを用いると、内部状態を過去 $n-1$ 文字の出力に対応させたマルコフ過程として、問題を Viterbi アルゴリズムに帰着することができます。従つて、動的計画法で現実的に解くことができるようになります。

もちろん、自然言語をマルコフ過程で近似することに抵抗はあるが、文献の外れに文字認識^[13]、暗号解読^[14]、音声認識^[15]などでの有効性が実証されていて、もちろん、 n を大きくすれば、それと共に近似はよくなり、遠距離の文脈依存性を持つことにはなるが、逆に内部状態の数が M^{n-1} (M はアルファベットの数) であるので計算は困難となる。また、 $P(X_n | X_1, X_2, \dots, X_{n-1})$ を計算するための n ケ組の数も M^n とあるので、確率の信頼性を保つのが困難となる。

特に、漢字假名変換などにおいては、漢字とその読みとの対応が遠く隔れた文脈に依存することは少ないと考えられるので小さい n で十分近似が可能と思える。

n -gram で近似を行うことにより、(ii)式におけるオーバーラップ $X^i = (X_0^i, X_1^i, X_2^i, \dots, X_n^i)$ に対して次のようになります。

但し X_0^i は文頭記号とする。

$$P(X^i) = P(X_0^i | X_0^i) \times \prod_{j=0}^{n-2} P(X_{j+1}^i | X_j^i, X_{j+1}^i) \quad (iv)$$

[n-gram の $n=3$ として]

これは図 6 の有向グラフ上の一のルート X^i に対応するので、図 6 の有効グラフより trellis を作成すれば各頂点 i 上の枝の距離 (iii) の第 1 値に対応する。従って 3.1 の雜音で並べて (iii) 式の第 2 値相当の $P(Z^* | X^*)$ と合わせて、trellis 上の各枝の距離が与えられることになり、Viterbi アルゴリズムに帰着できむ。

3.3 文脈に依存する雜音への配慮

3.1 で並べた雜音としては、假名文字列の漢字列へのおま換え、空白の欠落の 2 種がある。これらは文脈に依存しないとしてある。しかし、これらの発生確率が文脈に依存しないというのは、日本語の現実には合致しない。特に、文献 8 に見られるように単位切りのための空白と西隣の文字種の間に強い関係があるし、また、假名列から漢字列のおま換えは常に漢字列の長さが 1 であると (おま換えが漢和辞典型のとき) 西隣の文字種と強い関係がある。(例えば、訓型のおま換えを行つ雜音は西隣がひらがなにおま換えられる場合だけ起き易い等)

このように雜音のおま換えの発生確率がごく近い文脈に依存して變わり得ることを無視するのは適切でない。だが、この雜音の依存性を表現するのに、前述の E を文脈依存型のおま換え形式、例えば $\alpha X^* \beta \rightarrow \alpha Z^* \beta, P(Z^* | X^*)$ 、にあることはできない。従って、何らかの別の手段を找出し必要があるが、次のように解決することができる。

前述の E はおまかえ ($X^* \rightarrow Z^*; P(Z^* | X^*)$) の集合として定義されているが、それを次のようすに新しく定義する。

$$E = \{ (X^*, t \rightarrow Z^*; P(Z^* | X^*)) \} \quad (v)$$

新たに E にかける t は、おま換えの種類を表わす記号で、国語辞典型おまかえ (Z^* の長さ 2 以上)、漢和辞典型 (Z^* の長さ 1 で X^* が Z^* の音読みである時)、漢和辞典訓型 (Z^* の長さ 1 で、 X^* が Z^* の訓読みの時)、ひらがな型 ($X^* = 'ヒ', Z^* = 'ビ'$ 等の時)、カタカナ型、特殊記号型の便利を行う。(それぞれ以後、W, O, K, H, N, S と区別する。)

雜音 E を拡張すると同時に n-gram におけるアルファベットも次のように拡張する。おなじみ、これまでの議論では n-gram は X_i おなじみ假名文字の出現確率であるのだが、それを拡張して雜音 E のおま換え規則の左辺の和集合をアルファベットとして考えよ。従って従来 $X_i, X_{i+1}, \dots, X_{i+n-2}$ から X_{i+n-1} の出現確率を予想するものであるが、今度は n-gram は

$$P((X_0 X_1, t_1) | (X_1, t_1), (X_2 X_3 X_4, t_2)) \quad (vi)$$

[n-gram の $n=3$ のとき, $t \in \{W, O, K, H, N, S\}$]

のようす假名の並びの推定(上の例では $X_1 X_2 X_3 X_4 \rightarrow X_5 X_6$)を行ふとともに字種の並びの推定も行う能力を持つ。 $(t_1, t_2 \rightarrow t_3)$ 当然空白もアルファベットの 1 つとして含まれるので、文字種の文脈による空白の欠落と n-gram の配慮もねることになる。

この新たな雜音 E と n-gram のにおける形式化では、雜音は文脈に依存せずに発生するが、それに対する補償が n-gram より完全に行われるることとなる。これは図 1 の構造で

通常路における文脈依存性をマルコフ
過程に押しやるものがおり、Viterbi
アルゴリズムの特徴を用いた利点である。

4. 実験

本稿で紹介した漢字仮名変換の新しい方式の有効性を確めたために小規模の実験を行った。

4.1 確率付漢和辞典

3.1 及び 3.2 を述べたようにこの方式では一般に粗音として国語辞典型の変換を許すが、本実験では、(V) 式の区の長さを 1 に制限し、確率付の漢和辞典を用意した。(図 7)

$$\begin{aligned} E = & \text{ハツ, O} \rightarrow \text{發}, p_1 \\ & \text{ハツ, O} \rightarrow \text{発}, p_2 \\ & \text{ハツ, O} \rightarrow \text{菴}, p_3 \\ & \text{ハツ, K} \rightarrow \text{初}, p_4 \\ & \text{イ, O} \rightarrow \text{引}, p_5 \\ & \text{イ, O} \rightarrow \text{印}, p_6 \\ & \text{ヒ, K} \rightarrow \text{引}, p_7 \\ & \text{ヒ, K} \rightarrow \text{印}, p_8 \\ & \vdots \\ & \vdots \end{aligned}$$

図 7 確率付漢和辞典

これは国立国語研究所の調査^[16]を土台として若干の漢字を加え、現在約 2000 漢字を含んでいる。なお、音便形など(發→ハツ、ハツなど)に関する補正を行うと同時に、用言に用いられる漢字の送りがなく(引→ひ、ひく、取→と、とりなど特に連用形)に関する補正を行っているので、通常の漢和辞典より読みの種類が多くなっている。

4.2 n-gram

一元、(iii) 式のオーバーを得るために n-gram としては、理想的には n の大きい方がよいのが、本実験では n=3

と設定した。また実際 (vi) 式の形の 3-gram (tri-gram) を得るデータ準備の負担を軽減するため、(vi) 式の tri-gram を次式のように近似した。

$$\begin{aligned} P((x_5 x_6, t_3) | (x_1, t_1), (x_2 x_3 x_4, t_2)) \\ \Downarrow \\ P(x_5 x_6 | x_1, x_2 x_3 x_4) * P(t_3 | t_1, t_2) \\ \Downarrow \\ P(x_6 | x_4 x_5) * P(x_5 | x_3 x_4) * P(x_4 | x_2 x_3) * \\ P(x_3 | x_1 x_2) * P(t_3 | t_1, t_2) \quad (vii) \end{aligned}$$

従って、(vi) 式を得るために、字種の tri-gram と仮名文字の tri-gram が必要である。

字種の tri-gram は信頼のおけるデータが手に入らなかつたので、文献 8 の坂本氏の調査を基にして簡単なモデルによる推定値を加えて用いた。

一方、仮名文字の tri-gram は、仮名書きして 1200 ~ 1500 字程度の文章を 36 ケ集め、単位切り仮名書きし、仮名文字の 3 つ組を集計して作成した。文章の分野としては、新聞の社説約半分、コンピュータ関連のニュース、雑誌記事が約 1/4、残りが、社内規則である。ここでの単位切りは文節切りに加えて、4 文字以上の複合語内を 2 文字として 3 文字の語基に単位切りすることを行つた。(図 8) 従つて後述する結果の単位切りはその方針が反映している。

チホウ フンケンノ リネンヲ イカセ
タ" 117ジ" チホウ セイト" チョウガカイカ"、アタラシ
アリカニツイテ トウシソアンヲ マトメタ。9カ"リチュウニ
トウシソアンノ ナイヨウハ、ジニ、チホワヲ ツカシ"タ
オオキナ ハラダナツテイル ソノタメ トシ ケイカク ノラチ
キ" ヨウセイ クンケンノ チホウニ イシ"ヨウ、ココ"ホ
チホウ テ"サキ キカソラ ハイシ トウコ"ウスル サラニ チホ
キ" ヨウセイ ケイタイ キ" ヨウセイ イインカイ セイト" キ"
コンボンテキ モタ" イモ テイキサレテイル

図 8 訓練用データ

特に単位切り土山を訓練用データから仮名の3つ組を算計する際に、幼音、長音、濁音、半濁音などは先行する文字が限定されるので、独立して仮名文字とは認めなかつた。従つて、もし3. モーラ単位のtri-gramであるといえど。

4.3 解析

解析プログラムはPL/Iで約3000スレッソフで図9の構造である。入力列に對し、まず図7の確率付漢和辞典を引き、図6の形の{X}を含む有向グラフを作成する。次に有向グラフの図9のウインドウ部分をtrellisで部分的に展開する。(trellis全体を展開するのはメモリーを食うため) このウインドウを有向グラフの前から後ろへ移動する。同時に動的計画法により最短ルートを得られる。図10は、入力列「再上昇に転じた木金利」に対して得られる図6形式の有向グラフを例として示す。

入力列: X




図9 解析の流れ

再 上 昇 に 転 じ ..




図10 有向グラフの例
(○印を最終ルートが最終的)
(12層ばれ3。)

5 結果と考察

新聞の社説を適当12層んで本オオテの漢字仮名変換を試みを例の一節を図11に示す。

(図11)

引き続き高水準を続けている。一月の卸売物価指数は実成品・非鉄調整済
(.) (.) 引(ヒ)き(キ)続(ツツ)き(キ)高(コツ)水(スイ)卓(シ)ュン
)を(ヲ)続(ツツ)け(ケ)て(テ)い(イ)る(ル)。(.)一(イチ)月(カ
'ツ)の(ノ)卸(オロシ)亮(ウリ)物(フツ)售(カ)緒(シ)数(スツ)
は(ハ)充(カン)成(セイ)品(ヒン)。(.)卓(キ)算(セツ)調(チョツ)
整(セイ)第(サ)イ)。(.)

ベースで年率約二〇%も上昇した。新方式の採用後、しばらく

(.) (.) ベー(ヘ)一(ス)で(テ) 年(ネン)率(リツ)約(ヤク) D(D)
(D)・(.) も(モ) 上(ジ)ショウ界(ショウ)し(シ)た(タ)。(.)番(ジン)
方(ホツ)式(シキ)の(ノ)様(サイ)用(ヨク)後(コ)。(.)し(シ)
ば(ハ)ら(ラ)く(ク)。(.)

落ち着いていた通商供給量や銀行貸出しの増勢にも、昨年末から

(.) (.) 落(オ)ち(チ)着(ツ)い(イ)て(テ)い(イ)た(タ)過(ツツ)費(カ) 供(キョウ)総(キュウ)量(リョウ)や(ヤ)額(キ)行(コツ)費(カ)し(シ)出(タ)し(シ)の(ノ) 増(ゾ)ワ勢(セイ)に(ニ)も(モ)。
(.)昨(サ)ク 年(ネン)末(マツ)か(カ)ら(ラ)。(.)

伸び始める傾向がみられる。FRBとしては一月の卸売物価の動きが

(.) (.) 再(フタタ)び(ヒ)強(ツヨ)ま(マ)る(ル)傾(ケイ)向(コウ)
ガ(カ)み(ミ)ら(ラ)れ(レ)る(ル)。(.) A(A)と(ト)し(シ)て
(テ)は(ハ)一(イチ)月(カ)ツの(ノ)卸(オロシ)亮(ウリ)物(フツ)
售(カ)緒(シ)数(スツ)。(.)

確認した物価の躍勢持続、原油の値上がりがそれをさらに強めそうな

(.) (.) 墓(カク)躍(ニン)し(シ)た(タ)物(フツ)售(カ)の(ノ)量(トツ)費(セイ) 物(シ)総(ゾ)ク)。(.) 墓(ケン)油(ユ)の(ノ)量(ネ)上(ア)ガ(カ)リ(リ)ガ(カ)そ(ソ)れ(レ)を(ラ)さ(サ)ら
(ラ)に(ニ)物(ツヨ)の(メ)そ(ソ)う(ツ)な(ナ)。(.)

情勢を前に、改めてここで政策方針を明示する必要を感じたのである。

(.) (.) 情(シ)勢(セイ)を(ラ)前(マエ)に(ニ)。(.) 調(アラタ)
の(メ)て(テ)こ(コ)こ(コ)て(テ) 総(セイ)算(サ)方(ホツ)
計(ジン)を(ラ)明(メイ)示(シ)す(ス)る(ル) 志(ヒツ)望(ヨツ)を
(ラ) 調(カ)ン)じ(シ)た(タ)の(ノ)て(テ)あ(ア)る(ロ)う(ツ)。
(.)

アフガニスタン問題の発生に伴う米国の軍需生産の拡大、輸送拘束の

(.) (.) ア(ア)フ(フ)ガ(カ)ニ(ニ)ス(ス)タ(タ)ン(ン)調(モン)量(ダ)イ)の(ノ)亮(ハツ)生(セイ)に(ニ)售(トモナ)う(ツ)来(ベ)イ
国(コク)の(ノ)軍(グ)ン)賣(シ)賣(セイ)庫(カ)ン)の(ノ)大(カ)ク
(カ)大(タ)イ)。(.) 調(セン)算(リヤク)物(フツ)量(カ)ン)の(ノ)
(.)

表1にその社説全体における結果を示す。

a	総文字数	1072
b	総漢字数 (漢数字は一切含まない)	461
c	誤って読まれた漢字数	23
d	読みふり正答率(c/b)	95.01%
e	単位切り位置总数	273
f	余分に挿入された空白数	7
g	単位切り忘れた個数	16
h	単位切り正答率 $\frac{e-f-g}{e}$	91.58%

(注) ここで正しい単位切り位置とは文節句区切りと、複合語内語基句区切りである。

表1 結果

表1の結果は、訓練データの少なさ、(約45K假名文字)に対して十二分に満足できるものと考えられる。訓練データを蓄積することにより、また精度は向上すると認められる。

並れ、この実験もしくは形式化の境界を示す限り若干見られる。例えば「国家的計画、」が「コッカテキルケイガ、」のように変換される。これは(vii)のtri-gramを(vii)のように近似したことによる起因していると考えられる。すなはち(vii)式の近似によるとtri-gramで評価される假名列がすでにそれらの変換されるべき字種を忘れててしまう。従って、この例でも「計画」より得られる假名列「ケイカク」と「ケイガ」の比較で、後者が「系が」、「計が」、などと圧倒的に頻度の高い別の同音表現のため優先してしまっている。

別な例で興味深いのは「歩合」かいつでも「フコウ」と呼まってしまうことである。これも「歩合」から得られる「フコイ」、「フコウ」の比較において、「符号」、

「符合」、「直号」、「富豪」などのより頻度の高い同音語にひきかかれてしまふと思われる。

単位切りが91.58%とあまりよくなはないのは主として長い複合語分解の誤りによる。例えば、「連邦準備理事会」は「連山邦準備理年会」のようになくなれる。これは、現在のモデルの複合語分解が、漢語は2文字単位が多いためなどの複合語を適切に扱うための常識を用いて、洋に空白を仮名列間・字種間に含んだ場合のtri-gramによる評価だけで行っているからと考えられる。これは近い将来の課題である。

おわりに

本稿で紹介したViterbiアルゴリズムによる漢字假名変換は実用的観点からは精度が十分でないとの観点もある。しかし書き出しも並べるようだ。この上に例外辞書、例外コードなどを使って修正するための工夫として十分有効と考える。また、モデル自体にもまだ幾多の本質的改良の可能性がある。実験も小規模でこのモデルの性能を十二分に引き出している点もある。しかし、本稿で紹介したViterbiアルゴリズム及びそれでの漢字假名変換の形式化は全く新しい。他の実験問題でも十分に有効な手段であると考えるので報告を行いたい。

なお、最短ルートの探索パスのプログラム作成で、当センターの客員研究员瀧川清氏(早稲田大学)に協力いただいた事を感謝する。

参考文献

- [1] 藤崎他、日本語文書処理システム「ことだま」—概念と設計思想、東京サイエンティフィックセンター・レポート、N:9318-1512, 1980
- [2] 藤崎他、日本語文書処理システム「ことだま」の假名漢字変換、情報処理論文誌、vol 23, No.1, 1982 (予定)

- [3] 藤崎、諸橋、ことをさ文書処理システムの文書検索機能、IBM レビューピー 85, 1981(予定)
- [4] 大河内他、仮名漢字変換のための文法解析、情報処理計算言語学研究会資料 25-4, 1981
- [5] 田中、漢字かなモドリ文を全文カナ書き、ローマ字書きに変換するシステムについて、国立国語研究所報告 (34), 1969
- [6] 中野、言語研究のための日本語データ入力システム、日本語情報処理シンポジウム報告集、1978
- [7] 荒木、他、JICST の実用的全自动漢字一カナ変換システム、K-KACS 12について、情報処理、Vol 20. No. 10, 1979
- [8] 坂本、文節の設定、日本語情報処理シンポジウム報告集、1978
- [9] 長尾、他、国語辞書の記憶と日本語文の自動分割、情報処理、Vol 19, No. 6, 1978
- [10] G. D. FORNEY, JR., The Viterbi Algorithm, Proceedings of IEEE, Vol. 61, No. 3, 1973
- [11] A. J. Viterbi, Error bounds for convolutional codes and an asymptotically optimum decoding algorithm, IEEE Trans. Information Theory, vol. IT-13, 1967
- [12] C. E. Shannon, Prediction and Entropy of Printed English, Bell Sys. Tech. J., Vol. 30, 1951
- [13] J. Raviv, Decision Making in Markov Chains Applied to the Problem of Pattern Recognition, IEEE Trans. Information Theory, Vol IT-3, No. 4, 1967
- [14] L. R. Bahl, et. al., Disambiguation of Stenotype and Other forms of Ambiguous Text by Use of Contextual Statistics, personal memo, IBM T.J. Watson Res. Ctr, 1980
- [15] J. Jelinek, Continuous Speech Recognition by Statistical Methods, Proc. of the IEEE, Vol. 64, No. 4, 1976
- [16] 現代新聞の漢字、国立国語研究所、秀英出版、1976