

# 確率的言語処理へのアプローチ

藤崎 哲之助

日本 アイ・ビー・エム(株) サイナス・インSTITUTE

## 1. はじめに

自然言語の解析を行うために文法を作る試みは数多く存在するが、対象とする文に作乐的な制限を行わない場合、自然言語のあいまいさが常に問題となる。Church, Ramesh [1]らの報告によれば、彼らの英文解析例でのあいまい度は最大958 ("Inasmuch as allocating cost is a tough job I would like to have the total costs related to each product.")に達し、約2%の文が300以上のあいまいな解釈を有しなと報告している。

これは特に驚くべき事ではない。すなわち、英語の場合を例にとれば、前置詞句の後端、接続詞句の両端などの名詞句の境界は常にあいまいさを生じさせる可能性がある。従って、文のあいまい度を、そのようなあいまいさを生じさせる構造の数の関数として推定することが出来る。

CATLAN 数[2]は、 $N$ 項式にカッパを挿入する組み合わせの数の指数的に増大するが、 $C(1)=1, C(2)=2, C(3)=5, 14, 42, 132, 469, 1430, 4892, \dots$ 。自然言語のあいまい度をよく近似する。例えば、次の例文:

*I saw a man in a park with a scope.*

は5つのあいまいな解釈を持つが、これは片側あいまいの3つの句構造、*saw NP, in NP, with NP*, を持つため、 $C(3)=5$ と一致する。

このような自然言語のあいまいさを統語的立場だけから完全に対処するのは不可能で、意味上、運用上での制約を導入するのが長い人工知能の歴史の教訓である。すなわち、意味ネット

ワーク、意味フレームなどにより、対象世界を記述し、それらの上での意味的、運用的、あるいは常識的制約により、その場面での正しい解釈を決定することが行われる。

このような立場は心理学・認知科学の立場から認められつつあり、終局的にはこのような方向で人間の言語理解活動がモデル化されると筆者は考えているが、現実的には、意味的・運用的知識を始めとして、常識・果ては話者の好み、性格に至るまで形式的なデータ・ベースにネットワークとして記述することの困難には、通り知れないものがある。そして、現在に至るまでも、ごく限られた実用的に至らない範囲で成功しているにすぎない。[3,4]

さらに、データ・ベースの照会の場面での次の例文を考える。

*print for me the sales of stair carpets.*

この文は一見あいまいでなく見えるが、データ・ベース中に米国の州別売り上げが情報として含まれるならば、"ME"としてMaine州の解釈をすることができ、文の真意はあいまいとなる。[5] この例の場合、真意は質問者のくせ、傾向を知った上で本質的に確率的にしか決定し得ないものと考えられる。

このような2つの立場 (a) 現段階の技術として、言語の解析に必要知識全てを詳細に至るまで記述し上げることは困難がある。(b) 言語の解析に本質的に確率的判断も必要とされる場面もある。) から、筆者は、確率的文法およびそれを用いた確率的構文解析[6]が有効であると考える。本稿では、



立て、各出力文字列  $D_{ij}$  を構文解析する。得られる解析木はマルコフモデル上での状態の遷移列であるが、それを  $D_{ij}$  (既定の解析木を識別する標識とする。) とする。

3. 各遷移列  $D_{ij}$  の出現確率は、その  $D_{ij}$  に含まれる遷移に対応づけられた  $f(s,t)$  の種として計算できるのでこれを計算し、 $Pr(i,j)$  とする。
4. この  $Pr(i,j)$  を用いて、 $D_{ij}$  を発生する際の状態  $S$  からの遷移  $\sigma$  をマルコフモデル上で通過した回数  $C(s,t,i)$  を推定することが出来る。

$$C(s,t,i) = \frac{\sum_j Pr(i,j) * m(s,t,D(i,j))}{\sum_j Pr(i,j)}$$

但し:  $m(s,t,D(i,j))$  は  $D_{ij}$  が  $\langle s,t \rangle$  の遷移を含む度数

5.  $C(s,t,i)$  を正規化し、 $i$  で平均することにより、 $f(s,t)$  の新しい推定値を得ることが出来る。

$$new f(s,t) = \frac{\sum_i C(s,t,i)}{\sum_{u,i} C(s,u,i)}$$

6.  $f(s,t)$  を  $new f(s,t)$  で置き換え、収束しているければ2へ戻る。

以上の手続は収束することが証明されており<sup>[4]</sup>、例文の集合から遷移確率を得ることが出来る。本稿では、この手続を直観的にわかりやすい形で紹介したが、より計算量の少なくてもお式が<sup>[8,9]</sup>に紹介されている。

#### 4. 文脈自由文法の確率化への拡張

前節で述べたマルコフモデルの遷移確率の推定手法を文脈自由文法の確率化に拡張することが出来る。

与えられた文脈自由文法  $G$  に対する可能な文型式 (Sentential Form) を状態とし、文脈自由の構文規則の適用を状態

の遷移とあるようなマルコフモデルを考える。(図2)




図2

このモデルでは、例えば状態  $S$  が規則 ' $S \rightarrow NP VP$ ' の適用により状態 ' $NP.VP$ ' に遷移し、状態 ' $NP.VP$ ' は規則 ' $NP \rightarrow DET NOUN$ ' の適用により状態 ' $DET.NOUN.VP$ ' に遷移する。

このようなマルコフモデルを想定すれば、文法  $G$  から生成された文を集めて、各節の手続により、各遷移確率の推定を行うことが出来る。たゞ、文脈自由文法では確率は各構文規則毎に与えられるので確率は規則毎に計算しなければならない。(図2での赤と青の遷移確率は同じにならない。) そのため前節の手続4で得られる  $\langle s,t \rangle$  の遷移の期待通過回数  $C(s,t,i)$  は各構文規則毎にまとめられ、また手続5の正規化も、構文規則上での左辺の等しいものの間で行われることになる。(この変更をほおせば文脈依存の文法にも適用の可能性はある。)

#### 5. 実験

実験のベースとなる文法として、1960年代にMIT大学の又野氏により作成された文法<sup>[10,11]</sup>を用いた。この文法は拡張された Graibach 標準形<sup>[12]</sup>の規則2118より構成されるが、後のバリエーション構文解析プログラムの都合より5241

のChomsky標準形の規則に変換した。  
特にこの文法をベースとして歴人なのは次の3つによる:

- a. 広範囲の英文を解析する能力があることが報告士している。
- b. 総辞形形の文脈自由文法に変換可能であり、我々の方式に好都合であった。
- c. 構文的、意味的差異により各範ちゅうが細分士しており、解釈の意味的差異が解析木の構造的差異に反映する。(形容詞7分類、副詞8分類、BE-動詞3分類、自動詞3分類、他動詞7分類など)

辞書としては、久野文法に付随した約2万5千語の辞書と、ウェスターオク版(約12万語)の辞書を用いた。

構文解析プログラムとしては、この実験のためにCocke-Kasami-Young型の11-パーサー<sup>[12]</sup>を作成した。あいまい度の高い文を多量に解析する必要から、効率の向上に考慮を払った。

最終的にこの構文解析プログラムは、DATAMATION, READER'S DIGEST 合わせて31の記事から選んだ文を表上の性能で解析することができた。

総文数	5528
平均語長	10.85
解析できた文の数	3582
1文当りの処理時間 (3033 Uni Processor, CPU時間)	0.89秒
平均あいまい度	48.5

特にこのプログラムで高速化を実現するため、ハッシングを多用し、また以下に述べる部分木の共有化を可能な限り実現する工夫を行った。(構造不共有型11-パーサー)

あるいは構文木の表現に從未用いら

るN本足のノード(親子関係を表現する。)に加えてOR-リンク(ある非末端記号の下記構造に異なる部分構文木がはいまい存在するとし、それらの部分構文木をリストとして表現する。)を導入した。例えば、図3(a)のNPの例で見られるように'ABC'の部分に2つの異なるNPが作られるとす、それらの下位部分木をOR-リンクでつないだ(図3-(b)の構造の表現が行われる。




図3

このOR-リンクの導入により、規則適用の対象とされる中間ノードの数が減少し、CKY型のアルゴリズムの11-パーサーでは $O(N^2)$ の高速化が期待できる。(但しNはOR-リンク上につなげられる部分木の平均個数) 従って、あいまい度の高い文の解析において特に有効である。

確率化。最初に与えられた5241の構文規則、また与えられた5528の文中に観測士れた辞書規則に対して、確率化を行った。その結果得られた確率的文脈自由文法の一部を図4に示す。図中の数字が反復により各規則に最終的に与えられた確率で、例えば図中(a), (b)の行は、範ちゅう'IT4'から語彙'HELP', 'SEE'が発生する辞書規則とその確率、(c), (d)は'SE → PRN VX PD', 'SE → AAA 4X VX PD'の構文規則の確率

** IT4	0.98788	HELP	---	(a)
	0.00931	SEE	---	(b)
	0.00141	HEAR		
	0.00139	WATCH		
	0.00000	HAVE		
	0.00000	FEEL		
	.			
** IT5	0.78550	GET		
	0.13246	HAVE		
	0.04307	WANT		
	0.03181	SEE		
	.			
** SE	0.28754	PRN VX PD	---	(c)
	0.25530	AAA 4X VX PD	---	(d)
	0.14856	NNN VX PD		
	0.13567	AV1 SE		
	0.04006	PRE NQ SE		
	0.02693	AV4 IX MX PD		
	0.01714	NUM 4X VX PD		
	0.01319	IT1 N2 PD		
	.			
** VX	0.16295	VT1 N2		
	0.14372	V11		
	0.11963	AUX BV		
	0.10174	PRE NQ VX		
	0.09460	BE3 PA		

図 4

がそれぞれ 28.8%, 25.5% であることを示している。但し:

- SE — sentence.
- PRN — pronoun.
- VX — predicate.
- PD — period preceded by optional post sentential modifier.
- AAA — article, adjective, etc.
- 4X — subject noun phrase

図 4 に示すような確率文法が得られれば、同じ構文解析プログラムを用いて、確率的構文解析を行うことができる。特に、あいまいな解析の起る際、最も発生確率の高いものだけに興味がある場合には、Viterbi<sup>[13]</sup> の手法を構文解析

に適用して、構文解析の終了と共に最大の発生確率を与える構文木を絶対確率、相対確率と共に  $O(L^3)$  の手間で得ることが出来る。(L は入力文の語長) それは図 5 の OR-リンク上に常に最大確率を与える部分木だけを残すことにより実現でき、その場合、才 2 位以降の部分解析木を捨て、そのための記憶域を開放できるため、作業域の減少が実現できる。

図 5 は、この確率文法を用いて確率的構文解析を行う、例である。入力文に対し、部分木 A, B, C の差異により示される 3 つのあいまいな解析が得られている。(A, B, C は OR-リンクにより結ばれている。) この内、C は通常の解析に対応し、A は 'OUTSIDE' と 'ART' の向の関係代名詞 which が省略された構造に対応する。B は、'ART SERVICE' が動詞 'UTILIZE' の目的語となり、'OUTSIDE' が前置詞として向に挿入された構造に対応する。

各 A, B, C につけられた数字、0.356, 0.003, 0.641 は最終的に得られた構文規則の確率より計算した各解析木の相対確率である。この例に示されるように、一番早くとらした解析の順(この場合 C, A, B)に高い値を与えられている。またカッコ内の数字は反復の途中で得られた規則の確率をまとって計算した解析木の相対確率で、この場合にも示されるように、正しい方向に収束していることがわかる。

表 2 に、結果をより系統的にまとめを示す。表 2 の場合 1, 場合 2 は、IBM 内部レター、Datamation, Reader's Digest の雑誌をそれぞれ対象域とした実験に対応している。それぞれの場合で文法規則は確率化され、その後、これに示される数の文を図 5 に示されるような確率付き構文解析木として出力した。その出力リストで、最も自然な解析に最高確率を与えられているものを手で

```

<WE DO NOT UTILIZE OUTSIDE ART SERVICES DIRECTLY . >
** total ambiguity is :      3

*:      SENTENCE
*:      PRNOUN      'WE      '
*:      PREDICATE
*:      AUXILIARY  'DO      '
*:      INFINITE VERB PHRASE
*:      ADVERB TYPE1 'NOT      '
A: 0.356(0.52) INFINITE VERB PHRASE
*:      VERB TYPE IT1 'UTILIZE
*:      OBJECT
*:      NOUN      'OUTSIDE
*:      ADJ CLAUSE
*:      NOUN      'ART
*:      PRED. WITH NO OBJECT
*:      VERB TYPE VT1 'SERVICES
B: 0.003(0.28) INFINITE VERB PHRASE
*:      VERB TYPE IT1 'UTILIZE
*:      OBJECT
*:      PREPOSITIN 'OUTSIDE
*:      NOUN OBJECT
*:      NOUN      'ART
*:      OBJECT
*:      NOUN      'SERVICES
C: 0.641(0.20) INFINITE VERB PHRASE
*:      VERB TYPE IT1 'UTILIZE
*:      OBJECT
*:      NOUN      'OUTSIDE
*:      OBJECT MASTER
*:      NOUN      'ART
*:      OBJECT MASTER
*:      NOUN      'SERVICES
*:      PERIOD
*:      ADVERB TYPE1 'DIRECTLY
*:      PRD

```

図5

確認した。(表2-g)

a.	テストケース	1	2
b.	対象分野	IBM 社内L9-	雑誌
c.	訓練用文数	624	3582
d.	1文当り平均語長	12.65	10.85
e.	検査した文数	21	63
f.	正しい解析木が含まれるか、在文の数	2	4
g.	最高確率が最も自然な文に与えられる	18	54
h.	他の自然な文の解析に最高確率が与えられる	1	5
i.	成功率 (g/(g+h))	0.947	0.915

表2

## 6. 考察

表2に示すように、本方式が、構文解析のあいまいさの除去に十分に有効であることが示せた。

これは主として辞書の誤りによるもので、あるが、やはりベースとした文法の次のような構造的問題による場合が半数以上を占めた。

あるわけ、英文における TO-不定詞句、前置詞句などのかかり受けは、多くの場合あいまいで、前述の CATLAN 数のあいまい度を発生する。又野文法では、それを回避するため、主動詞句以降に限定される副詞や、その前の句は、主文の最後に

文の後修飾句 (Post-modifying) として、文の結語記号から派生するという形式で処理している。従って、CATLAN 数のあいまいさはそれから生じるわけ、逆に、それらの被修飾-修飾の関係は木構造として現われず、それを解析する手段は失われている。例えば、図5の解析木において、副詞の 'DIRECTLY' が本来ある 'INFINITE VERB PHRASE' の部分木として派生すべきであるが、実際には、'PERIOD' から派生していることがわかる。

ケース1における唯一の誤りもここには由来している。あるわけ、その例では "... is going to work ..." が含まれ、'TO WORK' の部分の解釈として

- ① TO-不定詞句
- ② 前置詞句

の2つの解釈が図6の斜線部で競合している。




図6

しかし、図6のように 'TO WORK' の部分が直前の文脈から分離して最上位から直接派生しているの、実際に競合しているのは、図7の2つの構文規則である。

Post-Sentential Modifier → <TO-不定詞句>  
 Post-Sentential Modifier → <前置詞句>

図7

前後の文脈を忘れるなら、一般には前置詞句の方が、TO-不定詞句より高頻度で現われ、'TO'は前置詞として頻度が高く、'WORK'も名詞になり得るので図7では2番目の規則に高い確率が与えられるのは自然である。

### 7. 言語認識型問題への適用の展望

筆者は[14]において漢字仮名混り文の仮名ふりとかきかき書きが、Viterbi アルゴリズム<sup>[13]</sup>で形式化できることを示した。(その後京大の島崎助教も追試を行い、その効果を確率して下した。) これは、言語をマ

ルコフモデルを用いてモデル化し、局所的あいまいさをViterbi アルゴリズムで解消する枠組みであり、この漢字仮名変換の他にも、OCRの文字認識、音声認識、ステレオタイプライター出力の解析の後処理など数多くの応用が行われ、その効果が報告されている。[8,9,15] そして、今後さらに多くの問題への応用が期待される強力な枠組みである。

この枠組みで本質的に必要なのは、与えられた言語での文の発生確率を近似することであり、いままで Shannon により提案された N-gram 近似<sup>[16]</sup>が唯一の手法として用いられてきた。しかしこの N-gram 近似は、言語の文脈依存性が局所的である場合には非常に有効であるが、文脈依存の距離をのけるためには、距離に対し指数的増減のマルコフ・モデルの状態を用える必要がある。より長い文脈依存性の影響を考慮する問題、例えば、仮名漢字変換などにこのままで適用するには無理がある。一々自然言語の文脈依存性が長い距離にわたる事がよく知られている。(図7)

Is the letter written in English John's?

図7

そこで N-gram による近似に換わるものとして、本稿で紹介した文脈自由以上の確率文法による文の発生確率の近似が有効であると期待される。今後のこの方面の研究が期待される。

### 8. あとがき

本研究の主要部分は、筆者がIBMのワトソン研究所に滞在中のプロジェクトとして、John Cocke (IBM Fellow) の財政的支援を得て行ったものである。また、ハーバート大学の久野教授には多大の技術

的、精神的支援を得た。また、ワトソン研究所の連続音声認識グループ（E. Jelinek, 他）より多くの技術的コメント、助言を得た。F. Damerau, S. Patrick などのTQAグループよりも協力を得た。英文法上の問題に関しては、ニューヨーク州大のE. Black氏、実用化に関してはハーバード大のB. Green氏、J. Lutz氏の協力を得た。

以上の人々に対する感謝がある。

- [15] Raviv, J., "Decision Making in Markov Chains Applied to the Problem of Pattern Recognition, IEEE Trans. Information Theory, Vol IT-3, No. 4, 1967
- [16] Shannon, C.E., "Prediction and Entropy of printed English", Bell Sys. J, vol. 30, 1951

### 参考文献

- [11] Church, K., Ramesh, P., "Coping with Syntactic Ambiguity", MIT, Laboratory for Computer Science Memo, April, 1982
- [12] Knuth, D., Fundamental Algorithms, Vol 1. in The Art of Computer Programming, Addison Wesley, 1975
- [21] Martin, W., et. al., Preliminary Analysis of a Breadth-First Parsing Algorithm: Theoretical and Experimental Results, MIT LCS report TR-261, MIT 1981
- [31] Winograd, T., Understanding Natural Language, Academic Press, 1972
- [41] Woods, W., The Lunar Sciences Natural Language Information System, BBN Report No. 2378, Bolt, Beranek and Newman
- [51] Martin, W., et. al., Preliminary Analysis of a Breadth-First Parsing Algorithm: Theoretical and Experimental Results, MIT LCS report TR-261, MIT 1981
- [61] Fu, K.S., Syntactic Methods in Pattern Recognition, Vol 112, Mathematics in science and Engineering, Academic Press, 1974
- [71] Baum, L.E., A Maximization Technique occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains, Vol, 41, No. 1, The Annals of Mathematical Statistics, 1970
- [81] Bahl, L., Jelinek, F., and Mercer, R., A Maximum Likelihood Approach to Continuous Speech Recognition, Vol. PAMI-5, No. 2, IEEE Trans. Pattern Analysis and Machine Intelligence, 1983
- [91] Jelinek, F., "Continuous Speech Recognition by Statistical Method", Proc. of IEEE, Vol 64, No. 4, 1976
- [101] Kuno, S., The Augmented Predictive Analyzer for Context-free Languages-Its Relative Efficiency, Vol. 9, No. 11, CACM, 1966
- [121] Kuno, S., Oettinger, A.G., Syntactic Structure and Ambiguity of English, Proc. FJCC, AFIPS, 1963
- [131] Forney, G.D. Jr., "The Viterbi Algorithm", Proc. of IEEE, Vol. 61, 1973
- [14] 藤村, "動的計画法による漢字仮名混り文の単位切り仮名振り", 情報処理学会, 自然言語研究会 28-5, 1981