제19회 한국정보처리학회 춘계학술발표대회 논문집 제10권 제1호 (2003.5)

불완전 입력문장의 인식과 완성

조용윤[O], 박용관, 박호병, 김상헌, 유재우
숭실대학교 컴퓨터학과
{yycho[O], psiver, r5me, shkim}@amin.ssu.ac.kr, cwyoo@comp.ssu.ac.kr

Recognition and Completion of Incomplete Inputs

Yong-Yoon Cho[O], Yong-Kwan Park, Ho-Byung Park, Sang-Heon Kim, Chae-Woo Yoo
SoongSil University School of Computer

요 약

에디터 환경에서 사용자가 문법적으로 불완전한 문장을 입력하면, 에디터는 오류를 발견하고 적절한 오류 처리 루틴을 실행하게 된다. 대부분의 에디터는 에러를 발견하면 에러 발생 여부를 사용자에게 알리고, 에러 위치를 하이라이트 시켜 사용자가 오류를 수정할 수 있도록 해준다. 에디터 환경에서의 사용자 입력은 입력 부분의 왼쪽, 오른쪽에서 완전하지 못한 형태로 입력될 수 있다. 그러나, 기존 오류 처리 방법은 불완전한 문장에 대해 에러 처리만을 통보할 뿐, 계속적인 파싱을 보장하지 못한다. 본 논문은 파서가 문법적으로 불완전한 입력 문장을 해당 문법에 따라 올바로 인식하고, 누락된 문법 심벌을 찾아 파스 트리의 부족한 부분을 완성함으로써 계속적인 파싱을 보장할 수 있는 파싱 방법을 제안한다. 제안된 방법을 통해 사용자는 입력의 문법 오류에 대한 부담을 줄일 수 있고, 불완전한 입력에 대한 계속적인 파싱을 보증받을 수 있어 파싱 효율을 높일 수 있다.

1. 서론

일반적으로, 파서는 입력 문장에 대해 파싱을 수행한 후, 결과로 파스 트리를 생성한다. 만약 파스 트리가 하향식으로 구성된다면, 파서는 불완전한 입력으로부터 생성된 파스 트리의 누락된 부분을 정확히 찾아 낼 수 있을 것이다. 그러나, LR 파싱 방법에 있어서 파스 트리가 상향식으로 생성되고 트리의 노드는 축약이 이루어 질 때 생성되어지기 때문에 정확하게 파스 트리의 누락된 부분을 찾는다는 것은 어렵다. LR파싱 과정에서 사용되는 LR 스택은 파스 트리의 각 부분 트리의 루트를 의미하는 비단말 기호를 포함한다. 그러나, 입력이 불완전할 경우, 파싱 스택은 완전히 축약되지 못하여 여러 개의 비단말기호를 가진 문장형을 이루게 되며, 더 이상의 표준 LR 파서 에서는 파싱 작업이 이루어 질 수 없다. 편집기의 입력은 프로그램의 편집 위치에 따라 문장의 왼쪽 혹은 오른쪽이 부분적으로만 존재할 수 있다. 예를 들어, [그림 1] 과 같은 불완전한 XML 입력에 대해 파서는 문법적으로 <firstname> 이 빠져 있기 때문에 오류를 알린다.

```
<name>
    <firstname> yong-yoon </firstname>
    cho </lastname>
</name>
```

[그림 1] 간단한 불완전한 XML 입력

. 따라서, 파스 트리는 완성되지 않고 파싱은 종료된다. 그러나, 파서는 불완전 입력에 대한 적절한 문법 정보를 이용해 빠진 부분을 인식하고 그 부분에 대한 부분 트리를 구성하는 것이 바람직하다. 파서는 부분 트리의 완성으로 인해 파싱을 계속 진행시킬 것이며, 결과 적으로 완전한 파스 트리를 얻어 낼 수 있을 것이다. 따라서, 불완전 입력 문장을 인식하고 완성하기 위한 파서는 입력된 불완전 문장이 정해진 문법에 대해 유효여부를 확인 할 수 있어야 하고, 불완전 입력 문장이 문법에 대해 유효한 경우에 한해 부족한 부분을 완성해야만 한다. 본 논문에서는 불완전 입력의 인식과 완성을 위한 알고리즘을 구성하였다. 알고리즘은 불완전한 입력에 대해 문법적으로 빠져있는 입력 심벌을 생성하기 위해 일반적인 LR 파싱 테이블을 확장 시켰고, 불완전한 XML 입력에 대해 알고리즘에 대한 실험을 수행했다.

2. 본 문

편집 환경에서 입력되는 구문은 완전한 문장으로 입력되기보다는 부분적으로 문장의 일부가 입력되면서 점차 프로그램의 문장을 완성하게 된다. 따라서 본 논문은 부분적인 입력 문장을 문법적으로 인식하고 이를 통해 부족한 문장을 완성할 수 있는 방법을 제시한다.

2.1 불완전 입력의 인식

LR 파싱표를 이용하여 서브스트링을 인식하는 방법은 기본적으로 모든 가능한 prefix에 대하여 파서의 동작 상태를 따라 인식 가능한 형태의 파스 트리를 구하는 것이다. 서브스트링의 인식을 위해서는 스택의 움직임을 따르지만 푸시다운 오토마타가 파스 경로에 따라 다양한 형태의 동작을 가지도록 하여야 한다. 따라서 스택의 여러 가지 동작 과정을

모두 표현할 수 있는 방법이 필요하다. 이것은 Graph Structured Stack을 이용하여 해결할 수 있다[5]. 불완전 입력을 인식하기 위한 알고리즘은 다음과 같다.

[알고리즘 1] 서브 스트링 인식

서브 스트링을 인식하기 위해 LR파서의 동작을 reduce 항목에 대해 다음과 같이 수정한다.

reduce A := $\alpha\beta$ 일 때

case $|\alpha\beta| + 1 > |stack|$: 정상적인 LR 방법으로 파싱

case $|\beta| = |stack|$: placeholder로서 α 에 대한 노드를 생성;
goto(A) 에 대한 다음 상태를 조사;
A로 축약;

case $|\alpha\beta| = |stack|$: goto(A) 에 대한 다음 상태를 조사;
A로 축약;

제안된 알고리즘을 이용하여 [그림 1] 과 같은 불완전 입력에 대해 제안된 알고리즘을 이용한 파싱이 성공적으로 끝나면 [그림 2]와 같이 불완전 노드를 포함하는 파스 트리가 구성된다.

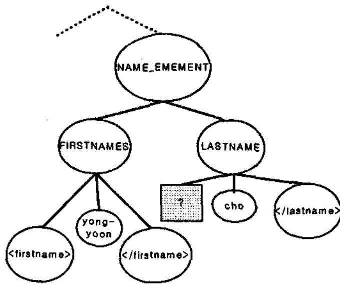

[그림 2] 불완전 입력 인식

알고리즘에 의해 빠져있는 노드의 인식불완전 노드를 포함하는 파스 트리의 각 트리의 노드는 LR 머신의 상태로 표시된다. 루트노드에서 단말노드까지의 모든 경로는 입력된 부분 문맥의 가능한 해석으로 LR 파서의 스택의 top 부분에 해당하며, 이 경우 경로의 *root*에 해당되는 노드의 상태는 스택의 top에 해당하게 된다.

2.2 불완전 입력에 대한 부분 트리 완성

불완전 입력에 대해 파서가 누락된 것으로 인식된 심벌을 적절한 위치에 생성시키고 파싱을 계속하기 위해서는 파서가 이용하는 LR 파싱 테이블의 정보를 확장해야 한다. 따라서, LR 파싱 테이블은 [알고리즘 1]에 따라 축약 부분에 대해 추가적인 정보를 제공할 수 있도록 확장되어야 한다.

확장된 LR 파싱 테이블을 얻기 위한 알고리즘은 다음과 같다.

[알고리즘 2] Nontermial/Goto 테이블의 구성

입력 : LR 파싱 테이블

출력 : Goto 테이블 N × { state }

방법 :

파싱 테이블의 모든 비단말 기호에 해당하는 열에서 상태 번호를 모두 구한다.

파싱 과정에서 여러 개의 경로가 나올 경우 각각의 트리는 별개로 구성한다. 트리가 구성될 수 있으면 유효한 서브스트링으로 간주된다. 트리가 구성될 수 없다면 해당 입력을 무시하고 트리의 단말에서 루트까지의 모든 경로를 삭제한다. 부분 문맥의 모든 입력이 이루어지고 유효한 파스 경로가 하나 이상 생성된다면 주어진 부분 문맥은 유효한 부분 문맥이다.

[알고리즘 3] 불완전 축약을 위한 파싱 테이블 확장

입력 : 문법 G와 canonical collection $C=\{I_1, I_2, \cdots, I_n\}$

출력 : n개의 state를 갖는 ACTION 함수로 구성된 확장형 파싱표

방법 :

(1) *[알고리즘 2]에 의해 파싱 테이블을 구성한다.*

(2) ACTION[S_i, \$] = "error" 항목을 다음과 같이 수정한다.

(2.1) 만일[$A\rightarrow\alpha\bullet\beta$]의 형태가 I_i에 있으면,

ACTION[S_i, \$]="reduce ˜$A\rightarrow\alpha\beta$"

(2.2) ACTION[S_0, \$] = "error"

3. 실험 및 평가

본 논문은 불완전한 XML 입력 문장에 대해 제안된 알고리즘을 이용해 인식하고 부분적인 파스 트리를 완성하는 과정을 보여준다. 파싱의 결과는 불완전 입력에 대해 문법적으로 완전한 파스 트리 이다.

3.1 XML DTD 에 대한 CFG 표현

불완전 입력에 대한 인식과 완성을 위해, 본 논문은 불완전 XML 입력을 LR 파서가 인식할 수 있는 CFG 형태로 표현한다. 따라서, XML DTD 의 일반적인 문법은 다음과 같은 변환 규칙에 따라 CFG 구성 요소로 바꾸어 표현 될 수 있다.

XML DTD 문법에 대한 CFG문법 G′ = {E, T, P, S}
1. E : set of elements
2. T : set of tags and PCDATA/CDATA
3. P : set of DTD rules
4. S : start symbol

일반적으로, 언어를 표현하기 위한 CFG G = {N, T, P, S}로 표현된다.[1] 본 논문은 XML DTD를 위한 CFG C′를 G′ = {E, T, P, S}로 표현한다. G′과 G의 각 튜플은 일대일 매핑 된다. 따라서, G′ 의 E 는 G 의 nonterminal 집합과 같으며, G′의 T, P와 S는 G의 T, P 그리고 S 와 대응되어 진다. 즉, G′ 의 E 는 non-terminal 역할을 하는 XML DTD 의 각 element 집합을 나타내며, 파싱 과정에 있어서 부분 트리의 루트에 해당한다. 또한 G′의 T는 terminal 들의 집합을 의미하며, XML DTD 의 각 tag와 PCDATA/CDATA 에 해당한다. G′ 의 P는 각 XML DTD element 에 적용되는 문법 규칙이다. G′ 의 S 는 문법 표현에 있어서 시작 심벌을 의미한다. [표 1]은 CFG 로 표현된 XML DTD 의 예제 이다.

```
1.<!ELEMENT name (firstname?, lastname)>
2.<!ELEMENT firstname (#PCDATA)>
3.<!ELEMENT lastname (#PCDATA)>

1. Start      -> NAME
2. NAME       -> <name> NAME_E </name>
3. NAME_E     -> LNAME
4. NAME_E     -> FNAME LTNAME
5. FTNAME     -> <firstname> PCDATA </firstname>
6. LNAME      -> <lastname> PCDATA </lastname>
7. PCDATA     -> id
```

[표 1] XML DTD 에 대해 변환된 CFG

파서는 문법 G′ 에 대해 [알고리즘 2]를 적용해 [표 2] 같은 nonterminal/goto테이블을 갖는다.

	NAME	FNAME	LNAME	NAME_E	PC
0	shift 2				
1		shift 5	shift 4	shift 3	
2					
3					
4					
5			shift 9		
6					shift 10
7					shift 12

[표 2] 문법 G′에 대한 non-terminal/goto table

각 Nonterminal 심벌의 파싱 동작에 대해 파서는 서로 다른 파싱 과정을 독립적으로 수행하게 된다. 따라서, 파서는 독립된 파싱 과정에서 생성된 부분 트리를 문법적으로 유효한지를 판단하여, 유효하지 않은 부분 트리를 유도한 파싱 동작은 삭제하고 유효한 부분 트리를 유도한 파싱 동작에 대해서만 계속적인 파싱을 수행한다.

이것은 불완전한 입력에 대해 문법적으로 모호한 파싱 동작을 해결할 수 있는 방법을 제공한다. 따라서, 제안된 파서는 문법적으로 유효한 파싱 동작에 대해서만 파싱을 수행할 수 있으며, 결과적으로 불완전한 입력에 대해 계속적인 파싱 과정을 수행할 수 있다. 파서가 문법적으로 유효한 상태에 대해서만 파싱을 할 수 있기 위해, 문법 G′에 대해 [알고리즘 3]을 적용해 [표 3]과 같은 확장된 파싱 테이블을 얻는다.

	<f>	</f>	<l>	</l>	id	<n>	</n>	$
0						s1		
1	s7		s6					
2								acc
3							s 8	
4							r3	
5			s6					
6					s11			
7					s11			
8								r2
9							r 4	
10				s13				
11		r7		r7				
12		s14						
13							r6	
14			r5					

[표 3] 문법 G′에 대한 확장된 파싱 테이블

3.2 불완전 XML 입력 문장에 대한 인식과 완성

문법 G′에 대해 [그림 1] 에 나타난 불완전 XML 입력 <name><firstname>yong-yoon</firstname>cho </lastname></name>의 파싱 과정은 [표 4]와 같다.

	STACK	INPUT	ACTION
1	0	<n> <f> yy </f> cho </l></n>$	s 1
2	0 <n> 1	<f> yy </f> <l> cho </l></n>$	s 7
3	0 <n> 1 <f> 7	yy </f> <l> cho </l></n>$	s 11
4	0 <n> 1 <f> 7 yy 11	</f> <l> cho </l></n>$	r 7
5	0 <n> 1 <f> 7 PC	</f> <l> cho </l></n>$	goto 12
6	0 <n> 1 <f> 7 PC 12	</f> <l> cho </l></n>$	s 14
7	0 <n> 1 <f> 7 PC </f> 14	cho </l></n>$	r 5
8	0 <n> 1 F	cho </l></n>$	goto 5
9	0 <n> 1 F 5	cho </l></n>$	s 6
10	0 <n> 1 F 5 <l> 6	cho </l></n>$	s 11
11	0 <n> 1 F 5 <l> 6 cho 11	</l></n>$	r 7
12	0 <n> 1 F 5 <l> 6 PC	</l></n>$	goto 10
13	0 <n> 1 F 5 <l> 6 PC 10	</l></n>$	s 13
14	0 <n> 1 F 5 <l> 6 PC 10 </l>13	</n>$	r 6
15	0 <n> 1 F 5 L	</n>$	goto 9
16	0 <n> 1 F 5 L 9	</n>$	r 4
17	0 <n> 1 NE	</n>$	goto 3
18	0 <n> 1 NE 3	</n>$	s 8
19	0 <n> 1 NE 3 </n> 8	$	r 2
20	0 N	$	goto 2
21	0 N 2	$	accept

[표 4] 불완전 XML 입력 에 대한 파싱 과정

파서는 초기 상태를 결정하기 위해서 [표 3]의 파싱 테이블을 참조한다. 파서는 파싱표 에서 첫 번째 입력인 '<firstname>'에 해당하는 열에서 모든 시프트 동작을 찾는다. 축약 동작은 이전의 입력에 적용되는 것이므로 여기서는 시프트 동작만을 선택하여 그 상태집합을 초기 상태로 한다.

문법 G'에 대한 [그림 1]의 불완전한 XML 입력은 문법적으로 빠져있는 심벌인 '<firstname>'에 대한 시프트 동작이 모두 상태7로 전이된다. 따라서 초기 상태는 7이 된다. 초기 상태에서부터 상태 10과 11에서 생성된 파스 포레스트는 [그림 3]과 같다.

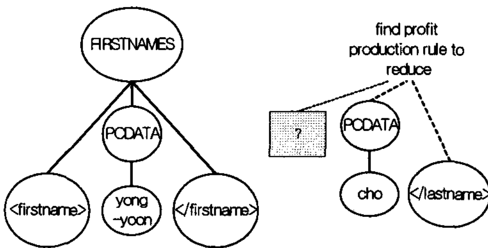

[그림 3] 불완전 입력에 대한 부분 트리 인식

이 때 축약에 적용된 생성 규칙인 "LASTNAME → <lastname> PCDATA </lastname>" 를 만족하기에는 스택의 내용이 부족하다. 따라서 부족한 기호인 '<lastname>'에 해당하는 기호노드를 생성하고 축약을 수행한다. [그림 4]에서 생성된 노드 <lastname>는 회색으로 표시되어 있다.

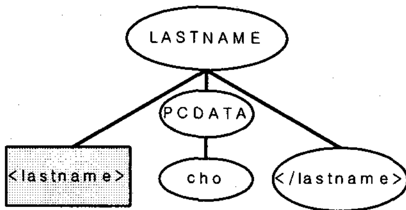

[그림 4] 부분 트리의 노드 생성

축약 후 상태는 goto 표를 참조하여 <lastname>에 대한 전이 상태를 결정한다. 이 예에서는 4와 9의 두 가지 shift 상태가 결정된다. 따라서, 이 상태들에 대해 각각 파싱을 수행하기 위해 스택을 두 가지 상태로 분리한 후 계속된 파싱 과정에서 유효하지 않은 파스 트리는 삭제하고 유효한 파스 트리를 선택한다. 파싱 결과는 [그림 5] 와 같다.

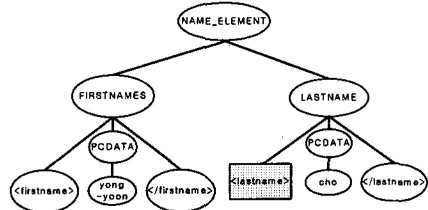

[그림 5] 파스 트리 인식과 완성

4. Conclusion

본 논문은 에디터에서 사용자가 입력하는 불완전 입력에 대해 인식하고 완성하는 방법을 제안하고 실험하였다. 일반적으로 에디팅 환경은 입력의 좌우에서 불완전하게 입력되는 경우가 많으므로 제안된 방법을 이용하는 파서는 불완전 입력으로부터 부족한 부분을 파악하고 완성시켜 파싱 작업을 계속 수행할 수 있다. 따라서, 사용자는 언어 편집에 있어서 불완전한 입력에 대해 문법적인 오류로 인한 파싱 작업의 중단에 대한 부담을 줄일 수 있고, 파싱 효율을 증대시킬 수 있다.

참고 문헌

[1] Aho, A.V., Sethi R., and Ullman J. D., *Compilers: Principles, Techniques and Tools*, Addison-Wesley, 1986.

[2] Bates, J. and Lavie A.,"Recognizing Substring of LR(K) Languages in Linear Time", *ACM TOPLAS*, Vol.16 ,No.3, pp.1051-1077, 1994.

[3] Grune D., Jacobs C., *Parsing Techniques: A Practical Guide*, Ellis Horwood Limited, 1998.

[4] Jalili F. and Gallier J., "Building Friendly Parsers", *Proceedings of 9th ACM POPL*, pp.196-206, 1982.

[5] Larchéveque J.M., "Optimal Incremental Parsing", *ACM TOPLAS*, Vol.17 ,No.1, pp.1-15, 1995.

[6] Nozohoor-Farshi R., "GLR parsing for ε-grammars.", *Generalized LR Parsing*, pp.61-75, Kluwer Academic Publishers, 1991.

[7] Reckers J. and Koorn W., Substring parsing for arbitrary context-free grammars. *ACM SIGPLAN Notices*,, 26(5), pp.59-66, 1991.

[8] Snelting G., "How to build LR parsers which accept incomplete input", *ACM SIGPLAN Notices*, vol. 25, no. 4, pp.83-89, 1990.

[9] Wagner A., and Graham S., "Incremental analysis of real programing languages.", *Proceedings of ACM PLDI '97*, 1997.