

신경망을 이용한 대화체 문장의 담화 구조 분석¹⁾

° 김학수, 이해중, 서정연
서강대학교 전자계산학과 자연어처리 연구실

Analysis of Discourse Structure using Neural Network in Dialogue Sentences

Harksoo Kim, Haejoong Lee, Jungyun Seo
NLP Lab., Department of Computer Science, Sogang University
hskim@nlpzodiac.sogang.ac.kr

요 약

담화 구조를 파악하기 위한 대표적인 방법으로 Litman과 Allen의 계획 기법에 의한 것과 RDTN을 이용한 것을 들 수 있다. 그 중에서도 RDTN을 이용하여 대화의 흐름을 파악하려는 시도는 간단하며, 결정적이라는 장점이 있는 반면에 몇 가지 단점도 가지고 있다. RDTN을 이용한 대화 분석의 가장 큰 단점은 정확히 분석된 화행(speech act)을 입력으로 사용한다는 것이다. 즉, 현 상태에서 다음 상태로의 전이에 정의된 화행 이외의 화행이 입력으로 사용되면 분석을 실패하게 된다. 또 하나의 단점은 RDTN이 어느 정도 영역에 의존적인 특성을 보인다는 것이다. 본 논문에서는 이러한 확장성에 대한 문제점을 해결하고, 화행 분석의 어려움을 덜기 위해 신경망(neural network)을 이용한 새로운 대화 전이망을 제안한다. 제안된 대화 전이 신경망은 지역적 대화 전이 신경망과 전역적 대화 전이 신경망으로 구성된다. 지역적 대화 전이 신경망은 이전의 두 발화와 현재 발화와의 관계를 살펴서 현재 발화가 이전 대화의 연속인지, 새로운 대화의 시작인지, 아니면 부대화의 시작인지를 결정하는 역할을 한다. 전역적 대화 전이 신경망은 담화 스택과의 상호 작용을 통해 담화의 전체 구조를 살펴보고, 전체 담화 구조에서 현재 발화가 어떤 역할을 하는지를 결정한다.

1. 서론

자연언어 처리분야의 궁극적인 목적은 컴퓨터가 사람의 일상 언어를 이해하고, 생성하도록 하는 것이다.

1) 본 연구는 과학재단의 특정연구 과제인 "통계적 한국어 담화분석" 연구의 일부입니다.

특히, 자연언어 대화는 유연성(flexibility), 명료성(succinctness), 표현력(expressiveness)면에서 뛰어난 장점을 가지고 있기 때문에 컴퓨터와 인간의 통신 수단인 한 방법으로 사용될 수 있다. 그러나 대화를 이해하여 화자의 의도나 목적을 인식하는 문제는 일반적인 구문 해석과 의미해석만으로는 해결할 수 없다. 따라서 대화를 정확히 이해하기 위해서는 대화가 이루어지고 있는 상황에 대한 사전지식, 대화의 진행상에서 얻어지는 문맥정보, 담화구조에 대한 지식을 시스템 내에 유지하고 있어야 한다[1].

대화의 담화 구조를 파악하기 위한 대표적인 방법으로 Litman과 Allen의 계획(plan) 기법에 의한 것과 RDTN(Recursive Dialogue Transition Network)을 이용한 것을 들 수 있다. 그 중에서도 RDTN을 이용하여 대화의 흐름을 파악하려는 시도는 간단하며, 결정적이라는 장점이 있는 반면에 몇 가지 단점도 또한 가지고 있다. RDTN을 이용한 대화 분석의 가장 큰 단점은 정확히 분석된 화행(speech act)을 입력으로 사용한다는 것이다. 즉, 현 상태에서 다음 상태로의 전이에, 정의된 화행 이외의 화행이 입력으로 사용되면 분석을 실패하게 된다. 또 하나의 단점은 RDTN이 어느 정도 영역에 의존적인 특성을 보인다는 것이다. 즉, 분석하고자하는 대화의 영역이 바뀌면 RDTN도 해당 영역에 맞게 갱신되어야 한다. 본 논문에서는 이러한 확장성에 대한 문제점을 해결하고, 화행 분석의 어려움을 덜기 위해 신경망(neural network)을 이용한 새로운 대화 전이망을 제안한다.

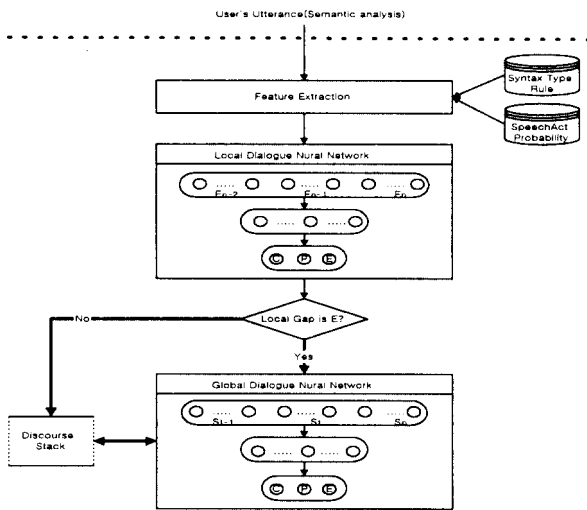
본 논문의 구성을 살펴보면 다음과 같다. 2장에서 대화 전이 신경망의 전체적인 구조도를 보이고, 3장에서는 신경망의 입력 패턴을 만들기 위한 특징 추출 방

신경망을 이용한 대화체 문장의 담화 구조 분석

법을 설명한다. 4장에서는 트라이그램(trigram)을 이용한 지역적 대화 전이 신경망을 제시하고, 5장에서는 담화 스택(discourse stack)을 이용한 전역적 대화 전이 신경망을 설명한다. 그리고, 6장에서 실험 및 평가를 하고, 7장에서 결론을 내린다.

2. 전체 시스템 구조도

본 논문에서 제안한 대화 분석기는 RDTN을 이용한 방법과 마찬가지로 하나의 담화 스택을 이용한다. 그러나, 대화 전이망에 RDTN 대신에 다량의 발음치로부터 학습된 대화 전이 신경망을 이용한다는 점이 다르다. [그림1]은 대화 전이 신경망의 전체 구조도이다.



< 그림 1 : 대화 전이 신경망 >

특징 추출(feature extraction) 모듈은 의미 분석 결과를 입력으로 하여 지역적 대화 전이 신경망의 입력 패턴을 생성한다. 지역적 대화 전이 신경망은 대화상 인접한 세 발화를 이용하여 1차적으로 담화 구조를 분석하고, 결과를 전역적 대화 전이 신경망에게 넘겨준다. 전역적 대화 전이 신경망은 담화 스택과 서로 상호 작용하면서 현재 발화의 최종적 담화 구조를 분석한다.

3. 특징 추출

대화는 여러 발화(utterance)들이 서로 유기적으로 관련되어 있으며, 그 발화들은 어떤 목적을 수행하기 위한 화자의 의도를 반영하게 된다. 즉, 발화 속에는 대화 목적을 수행하기 위해 화자에 의해 의도된 행위가

있게 된다. 발화 속에 포함된 이러한 행위를 화행(speech act)이라고 한다[1]. 대화를 처리한다는 것은 지금까지의 대화 상황들을 올바르게 분석하여 이에 대한 적절한 응답을 하는 것으로서, 대화 속에 포함된 해당 발화의 정확한 화행을 파악하는 것을 선결조건으로 하고 있다. 그러나, 정확히 화행을 분석한다는 것은 많은 지식을 필요로 하며, 매우 어려운 일이다. 본 논문에서는 [1]에서 정의한 12개의 화행을 좀 더 세분화한 17개의 화행을 이용한다.

화자가 전달하고자 하는 의도와 그러한 의도가 표면적인 발화로 나타날 때의 구문유형은 상호 밀접한 관계가 있다. 즉, 화자가 이번 의도를 상대방에게 전달하고자 할 때 화자는 원하는 의도를 가장 잘 표현할 수 있는 구문 형태로 발화하게 되고 청자는 주어진 형태의 발화와 대화 상황으로부터 화자의 의도를 추론하게 되는 것이다. 그러므로, 구문유형은 화행을 분석하기 위한 가장 기본적인 정보로 사용될 수 있다. 본 논문에서는 대화 전이 신경망의 입력으로 각 문장의 구문유형이 가질 수 있는 화행의 확률을 발음치로부터 추출한 것과 화행에 영향을 미치는 발화자에 대한 정보(발화자가 누구인지에 대한 정보: 직원 0, 고객 1)를 사용한다. 이는 화행 분석의 부담을 덜면서 화행이 가지는 특징을 대화 분석에 반영하고자 한 것이다. 다음 [식1]은 본 논문에서 정의한 화행 확률이다.

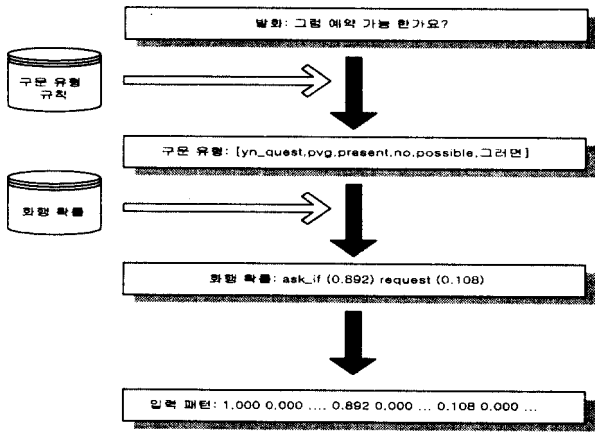
$$P(SA_i | ST) = F(SA_i | ST) / \sum_{all_i} F(SA_i | ST) \quad (1)$$

SA_i 는 17개의 화행 중에 i 번째 화행이며, ST 는 입력된 발화에 대한 구문유형이다. F 는 빈도수를 나타내며, \sum_{all_i} 는 본 논문에서 정의한 17개 화행의 빈도수의 총합이다. 그러므로, 구문유형 ST 에 대한 대화 전이 신경망의 입력 패턴은 해당 구문유형에서 나타난 17개 화행의 빈도수를 각각 계산하고 이것을 전체 빈도수로 나누어서 계산된 17개의 확률과 발화자에 대한 정보를 합쳐 18개로 구성된다. [표1]은 각 문장이 가질 수 있는 구문유형이며, [그림2]는 입력 패턴 추출 과정을 도식화한 것이다.

< 표 1 : 구문유형 >

문장 유형	본동사의 품사	시제	부정문	양상	단서 단어
Assert	PA	Present	Yes	희망	예
YN-Quest	PJ	Past	No	당위	아니오
WH-Quest	PV	Future		가능	그런데
...

제15회 음성통신 및 신호처리 워크샵(KSCSP '98 15권1호)



< 그림 2 : 입력 패턴의 추출 >

4. 지역적 대화 전이 신경망

일련의 발화 U_1, U_2, \dots, U_{n-1} 을 대화 D라고 하고, 현재 입력된 발화를 U_n 이라고 하자. 그러면, 발화 U_n 이 대화 D의 연속인지, 새로운 대화의 시작인지, 아니면 부대화(subdialogue)의 시작인지는 대화 D에 의존한다. 그러므로, 발화 U_n 의 이전 대화 D와의 관계는 [식]과 같이 정의될 수 있다. [식2]에서 F_n 는 3장에서 설명한 발화 U_n 에 대한 특징(feature)이다.

$$LR(F_n|D) = R(F_n|F_1, F_2, \dots, F_{n-1}) \quad (2)$$

그러나, [식2]와 같이 이전 발화 모두에 대해 현재 발화와의 관계를 살피는 것은 데이터의 희소성 문제로 현실상 불가능하다. 그러므로, 본 논문에서는 [식3]과 같이 이전의 두 발화만을 살펴 현재의 발화와의 관계를 결정한다.

$$LR(F_n|D) \approx R(F_n|F_{n-2}, F_{n-1}) \quad (3)$$

지역적 대화 전이 신경망에서 결정하는 것은 [표2]와 같은 세 가지의 GAP이다. C는 현재의 발화가 이전 대화의 연속이라는 것을 의미하며, E는 새로운 대화의 시작이라는 것을 의미한다. P는 이전 대화의 부대화가 시작되는 것을 의미한다.

< 표 2 : GAP의 의미 >

GAP	의미
C(ontinue)	이전 대화의 연속
E(end)	새로운 대화의 시작
P(art)	부대화의 시작

[그림3]을 살펴보면 고객의 첫 번째 발화 (1)과 직원의 대답 (2)는 하나의 주제인 수업료에 대한 대화의 연속이다. 그러므로, 둘 사이의 GAP은 C이다. 그러나, (2)와 (3) 그리고 (3)과 (4)의 경우는 다르다. (2)와 (3)의 경우에 고객의 두 번째 발화 (3)은 직원의 대답에 대해 확인을 요구하는 부대화의 시작이다. 그러므로, 둘 사이의 GAP은 P이다. (3)과 (4)의 경우에 고객은 수업료에 대한 대화를 끝마치고 개강일과 연수 기간이라는 새로운 주제에 대해서 질문을 하고 있으므로 둘 사이의 GAP은 E가 할당된다.

- (1) 고객: 그러면, 수업료는 얼마나 될까요?
 (2) 직원: 예, 20만원입니다.
 (3) 고객: 네, 20만원이라구요?
 (4) 고객: 그럼, 개강일 하고 연수 기간을 좀 알 수 있을까요?

< 그림 3 : 대화 예제 1 >

5. 전역적 대화 전이 신경망

지역적 대화 전이 신경망은 현재의 발화와 이전 대화와의 관계를 찾아 세 가지의 GAP을 할당한다. [그림4]와 같은 대화에서 (2)와 (4)는 (1)에 대한 부대화의 시작이다. 그러나, 지역적 신경망은 이전의 두 발화만을 고려하여 현재 발화의 GAP을 결정하므로 직원의 발화 (4)에 GAP E를 할당한다.

- (1) 고객: 단체 여행에 대해서 좀 여쭙보겠습니다.
 (2) 직원: 엑스포요?
 (3) 고객: 예.
 (4) 직원: 단체 여행 하신다구요?
 (5) 고객: 예.

< 그림 4 : 대화 예제 2 >


전역적 대화 전이 신경망은 이러한 현상을 보정해 주기 위한 신경망이다. 즉, 지역적 대화 전이 신경망의 결과가 GAP E인 것들 중에서 전체 대화 흐름 상 GAP P로 선정되어야 하는 것을 찾아내고 보정해 주기 위한 것이다. 전역적 대화 전이 신경망의 입력은 이전의 두 발화를 보고 현재 발화의 GAP을 결정한다는 것에서는 지역적 대화 전이 신경망과 같다. 그러나, 전역적 대화

신경망을 이용한 대화체 문장의 담화 구조 분석

전이 신경망은 입력된 발화의 순서에 의해 인접한 바로 이전의 두 발화가 아니라, 바로 이전의 발화와 담화 구조 내에서 인접한 이전의 발화를 현재 발화의 결정 조건으로 사용한다. 즉, 담화 스택(discourse stack)을 이용하여 담화 구조 내에서 인접한 발화를 보고 현재 발화의 GAP을 결정하는 것으로 [식4]와 같이 정의될 수 있다. [식4]에서 DS_{top} 은 담화 스택의 TOP 즉, 발화 순서에 의한 바로 이전의 발화를 나타내고, $DS_{neighbor}$ 는 담화 구조 내에서 인접한 이전의 발화를 의미한다.


$$GR(F_n|D) \approx GR(F_n|DS_{top}, DS_{neighbor}) \quad (4)$$

담화 스택의 PUSH, POP은 지역적 대화 전이 신경망의 결과에 의존한다. 즉, 지역적 대화 전이 신경망의 결과가 GAP C이거나 GAP P이면 PUSH 오퍼레이션을 수행하며, E이면 POP 오퍼레이션을 수행한다. [그림5]는 [그림4]에 대한 스택 오퍼레이션 과정이다.



< 그림 5 : 담화 스택의 오퍼레이션 >

스택 오퍼레이션 과정에 의해 입력된 발화들은 [그림6]과 같은 담화 구조 트리를 가지로 나타내어 질 수 있다. [그림6]에서 알 수 있듯이 전역적 대화 전이 신경망에서 현재 발화의 GAP을 결정하기 위해 사용된 정보는 [그림4]의 (4), (5)번 발화가 아니라 (1)번 발화이다. 이것은 전역적 대화 전이 신경망이 담화의 전체 구조를 반영한다는 것을 보여준다.



< 그림 6 : 담화 구조 트리 >

6. 실험 및 평가

6.1 실험 데이터 분석

본 논문에서는 대화체 문장에서 담화 구조를 분석하기 위한 자료로 예약분야(호텔 예약, 항공 예약)의 대화 말뭉치를 이용하였다. 이 말뭉치는 실제 전화를 통해 예약하는 대화 내용을 전사하여 구축한 것이다. 이때, 실제 대화에 자주 발생하는 간투어나 시간적인 지연, 반복된 발화와 사투리 등은 본 논문의 주제와 거리가 먼 관계로 전사된 자료에는 나타나있지 않다[6]. 수집된 대화 말뭉치는 578개의 대화, 10285개의 발화로 구성되어 있다. 수집된 대화 말뭉치로부터 화행 확률과 입력 패턴을 추출하기 위해 대화 태깅(discourse tagging)을 행하였다. 대화 태깅의 초점은 현재 대화가 일어나는 시점의 주제를 중심으로 하여 맞추어 졌고, 현 단계의 주제에서 부주제로 넘어가는 경우는 그에 맞게 계층적으로 구성되게 하였다. 하지만 부주체인지 독립된 주제인지 불명확한 경우에는 가급적 독립적 주제로 나누어 전체적으로 담화 구조 트리에 균형이 유지되게 하였다. 태깅은 [그림7]과 같이 규격화된 대화들을 가지고 시작하여 각각의 대화 패턴마다 번호를 부여하였다. 지역적 대화 전이 신경망의 학습(training)은 수집된 578개의 대화 중에 100개를 제외한 478개의 대화(9316개의 발화)를 이용하였다. 전역적 대화 전이 신경망의 학습은 지역적 담화 구조 분석 결과 GAP E를 가지는 2507개의 발화를 이용하였다.

```

/SP/Agnt
/KS/어학연수 코스는 기숙사를 제공하고 있습니다.
/SA/response
/ST/[decl,pvg,present,no,none,none]
/DS/[2]


/SP/User
/KS/그럼 식비는 포함되어 있는 건가요?
/SA/ask-if
/ST/[yn_quest,pvg,present,no,none,그러면]
/DS/[2,1]
    
```

< 그림 7 : 대화 태깅의 예 >

6.2 신경망 구조 분석

학습과 실험에 사용한 신경망의 구조는 전방향 네트워크(feed-forward network)이며, 학습은 백프로퍼게이션 알고리즘(back-propagation algorithm)을 이용하

었다. 지역적 대화 전이 신경망의 입력은 54개의 노드로 구성하였다. 그 이유는 각 발화가 발화자에 대한 정보와 17개의 화행을 합쳐 18개로 구성되고, 3개의 발화가 입력으로 사용되기 때문이다. 실험적 결과에 의하면 은닉층(hidden layer)의 수는 1개, 노드수는 지역적 신경망은 27개로, 전역적 대화 전이 신경망의 경우는 36개로 하였다. 대화 신경망의 출력은 현재 발화와 이전 대화와의 관계를 나타내는 C, P, E 3개로 구성하였다. [그림8]은 본 논문에서 사용한 지역적 대화 전이 신경망의 구조이다.



< 그림 8 : 지역적 대화 전이 신경망의 구조 >

6.3 실험 결과 분석

6.3.1 지역적 대화 전이 신경망

9316개의 학습 패턴에 대해 2000 epoch의 학습을 수행한 결과 MSE가 0.07 정도에서 수렴하는 현상을 보였다. 이러한 현상은 4장에서 언급한 트라이그램 가정, 같은 구문 패턴이지만 다른 화행을 가지는 경우, 그리고 학습데이터에 포함된 오류에 기인한 것으로 보인다. 특히, 학습데이터에 포함된 오류가 많았는데 이것은 여러 사람이 나누어서 각기 대화 태깅을 하여 같은 구문 유형에 대해서도 서로 다르게 태깅된 패턴들이 존재하기 때문이다. [그림9]는 같은 구문 유형이지만 다른 화행을 가지는 경우의 예이다. [그림9]의 예는 화행 분석의 부담을 덜기 위해 정확한 화행 분석 결과를 입력 패턴으로 사용하지 않는 것에 가인하는 것으로, 예측된 분석 오류이다. 이러한 종류의 오류는 화행 분석 과정을 고려한다면 큰 부담이 되지 않을 것으로 보인다.

본 논문에서는 학습에 포함된 데이터와 그렇지 않은 데이터에 대해서 두 가지의 실험을 하였다. [표3]은 학습된 데이터를 이용한 실험의 결과이고, [표4]는 학습

에 포함되지 않은 100개의 대화(969개의 발화)를 이용한 실험 결과이다.

화행: inform
/SP/User
/KS/(저) 어른 둘 아이 하나인데요.
/ST/[decl,be,present,no,none,none]
/DS/[1]
화행: introducing-onself
/SP/User
/KS/저 그쪽 학술대회 참가할 예정인 사람인데요.
/ST/[decl,be,present,no,none,none]
/DS/[1]

< 그림 9 : 입력 패턴 오류의 예 >

< 표 3 : 실험 결과 1 >

Function	# of pattern	Right	Wrong	Unknown
WTA	9316	95.29	4.71	0.00
402040	9316	94.31	3.27	2.42

< 표 4 : 실험 결과 2 >

Function	# of pattern	Right	Wrong	Unknown
WTA	969	81.42	18.58	0.00
402040	969	78.22	14.45	7.33

6.3.2 전역적 대화 전이 신경망

전역적 대화 전이 신경망을 위한 학습 패턴을 만들기 위해서, 지역적 신경망에서 사용한 학습 패턴을 이용하였다. 즉, 학습 발음치에 포함된 각각의 대화에 대해서 그 흐름(또는 stack operation)을 직접 시뮬레이션(simulation)하면서 현재의 발화, 그 전의 발화, 담화스택 내에서 인접한 대화의 마지막 발화로 이루어지는 발화 트라이그램을 얻고 이에 대응하는 패턴의 트라이그램을 얻었다. 출력 패턴(output pattern)은 학습 발음치의 DS(dialogue segmentation) 정보를 이용하여 얻었다. 이렇게 하여, 2507개의 학습 패턴을 만들었고, 같은 방법으로 284개의 실험 패턴(test pattern)을 만들었다.

학습 결과가 대체로 좋았으므로 신경망의 파라미터(parameter)나 학습 방법에 대해서 많은 실험을 하지는

신경망을 이용한 대화체 문장의 담화 구조 분석

않았다. 은닉층의 노드 수와 모멘텀(momentum)을 쓸 것인지 등을 결정하기 위해 몇 가지의 실험을 한 결과, 은닉층의 노드 수는 18개보다는 36개가 좋고(1% 이상의 정확률), 모멘텀을 사용했을 때 얻는 학습의 효과는 소요되는 학습시간에 비해 별로 매력적이지 못했으므로 모멘텀을 사용하지 않기로 했다. 학습 패턴에 대한 2000 epoch의 학습결과와 실험 패턴에 대한 실험결과는 [표5], [표6]과 같다.

< 표 5 : 실험 결과 3 >

Function	# of pattern	Right	Wrong	Unknown
WTA	2507	99.24	0.76	0.00
402040	2507	99.16	0.56	0.28

< 표 6 : 실험 결과 4 >

Function	# of pattern	Right	Wrong	Unknown
WTA	284	92.25	7.75	0.00
402040	284	91.20	5.99	2.82

한 대화에서 전역적 대화 전이 신경망을 이용하여 대화 흐름을 결정해야하는 경우는 발화수의 20% 정도에 불과하므로, 한 대화 안의 발화 수가 10개라고 할 때, 실험 결과대로라면 $0.9^2=0.81(81\%)$ 정도의 대화당 정확도를 기대할 수 있다.

7. 결론 및 향후 과제

본 논문에서는 담화 분석을 위해 기존의 RDTN과 같은 역할을 하는 대화 전이 신경망을 제안하였다. 제안된 대화 전이 신경망은 지역적 대화 전이 신경망과 전역적 대화 전이 신경망으로 구성되었다. 지역적 대화 전이 신경망은 이전의 두 발화와 현재 발화와의 관계를 살펴서 현재 발화가 이전 대화의 연속인지, 새로운 대화의 시작인지, 아니면 부대화의 시작인지를 결정하는 역할을 한다. 전역적 대화 전이 신경망은 담화 스택과의 상호 작용을 통해 담화의 전체 구조를 살피고, 전체 담화 구조에서 현재 발화가 어떤 역할을 하는지를 결정한다. 이렇게 제안된 대화 신경망은 기존의 RDTN이 가지고 있던 몇가지 문제점을 해결해 주었다. 먼저, 대화 전이 신경망의 입력으로 RDTN과는 달리 정확히 분석된 화행이 아니라 발화의 표층 구조에서 추출할 수 있는 화행의 화를 이용함으로써 화행 분석의 결과에

대한 의존성 문제를 해결하였다. 그리고, 다량의 말뭉치로부터 학습에 의해 자동적으로 대화 신경망이 구성되기 때문에 기존 RDTN이 가지고 있던 확장성의 문제를 해결해 주었다.

본 논문에서 제안한 대화 신경망의 경우 입력 패턴을 추출하기 위해 단순히 발화자에 대한 정보와 화행 화를만을 이용하였다. 그러나, 이러한 방법은 다른 담화 구조에서 같은 입력 패턴이 추출되는 결과를 낳았다. 이러한 특징 추출의 문제를 보완하기 위해 두 발화간의 의미 유사도를 계산하고, 이것을 입력 패턴에 추가하는 방법을 생각해 볼 수 있다. 의미 유사도의 계산하는 방법으로는 시소러스(thesaurus)를 이용하는 것도 한 가지 방법이 될 수 있을 것이다. 또한, 제안된 대화 신경망의 경우 전역적 대화 전이 신경망의 결과가 지역적 대화 전이 신경망의 결과에 의존적이라는 문제점을 가지고 있다. 그러므로, 두 신경망의 의존도를 낮추는 구조적 측면에서의 연구나 두 개의 신경망이 상호 작용에 의해 서로의 에러를 감소시킬 수 있는 방법에 대한 연구가 필요할 것으로 보인다.

참고 문헌

- [1] 이현정, 한국어 대화체 문장의 화행 분석, 석사학위논문, 서강대학교, 1996.
- [2] 이현정, 서정연, "문장의 화행을 반영한 한-영 대화체 기계번역," *제9회 한글 및 한국어 정보처리 학술대회 논문집*, pp.271-276, 1997.
- [3] 이재원, 대화계획 기법을 이용한 대화분석 연구, 한국과학기술원, 석사학위논문, 1992.
- [4] 이재원, 서정연, 김길창, "인간의 대화를 이해하기 위한 대화계획의 인식 및 추적," *HCI'95 학술대회 논문집*, pp.14-22, 1995.
- [5] 최영림, 신경망을 이용한 한국어 격 분석기의 구현, 석사학위논문, 한국과학기술원, 1992.
- [6] 이재원, 서정연, 김길창, "통계적 화행처리를 이용한 한-영 대화체 기계번역에서의 효율적 대화분석 모델," 연구실 Technical Report, 1997.