

상호 이익을 위한 학습 에이전트 기반의 효율적인 다중 속성 협상 시스템

박 상 현[†] · 양 성 봉^{††}

요 약

본 논문에서는 상거래에 참여한 구매자와 판매자가 협상을 통하여 서로의 이익을 보장하면서 합의를 도출 할 수 있는 협상 에이전트 시스템을 제안하였다. 제안 시스템은 기존의 협상 에이전트 시스템에 기계 학습을 적용함으로써, 학습 에이전트의 도입이 협상의 효율성에 어떤 영향을 미치는지 고찰하고자 하였다. 구매자 및 판매자 에이전트는 상품의 다중 속성을 고려하여 협상을 수행하며, 구매자와 판매자의 이익은 Multi-Attribute Utility Theory를 이용하여 표현하였다. 본 연구에서 제시된 학습 가능한 협상 에이전트는 Faratin이 제안한 협상 시스템의 제안 생성(counter offer) 과정에 인공신경망을 통한 점진적 학습 기법을 추가함으로써 협상의 효율성을 증가시키는데 목적이 있다. 점진적 학습 기법을 이용한 협상 에이전트 시스템의 경우, 동일한 협상 조건하에서 상대방 제안과의 유사도(similarity)를 바탕으로 제안을 생성하는 기존의 다른 협상 에이전트 시스템과 비교하였을 때 좋은 협상 결과를 보여 주었으며, 협상 수행시간에 있어서는 매우 빠른 성능을 보여주었다. 따라서 협상 결과 및 협상 수행 시간을 동시에 고려하였을 때 기존의 협상 시스템에 비하여 효율적인 협상 능력을 보여 주었다.

An Efficient Multi-Attribute Negotiation System using Learning Agents for Reciprocity

Sanghyun Park[†] · Sung-Bong Yang^{††}

ABSTRACT

In this paper we propose a fast negotiation agent system that guarantees the reciprocity of the attendants in a bilateral negotiation on the e-commerce. The proposed negotiation agent system exploits the incremental learning method based on an artificial neural network in generating a counter-offer and is trained by the previous offer that has been rejected by the other party. During a negotiation, the software agents on behalf of a buyer and a seller negotiate each other by considering the multi-attributes of a product. The experimental results show that the proposed negotiation system achieves better agreements than other negotiation agent systems that are operated under the realistic and practical environment. Furthermore, the proposed system carries out negotiations about twenty times faster than the previous negotiation systems on the average.

키워드 : 기계학습(Machine Learning), 인공신경망(Artificial Neural Network), Multi Attribute Utility Theory, Trade-off Mechanism, 협상 전략(Negotiation Strategy)

1. 서 론

전자상거래에 있어서 소프트웨어 에이전트는 상품 검색에서부터 구매자의 취향에 맞는 상품의 추천 등 다양한 분야에서 활용되고 있다. 특히 구매자 및 판매자를 대신하여 협상을 수행하는 협상 에이전트는 그 중요성에도 불구하고 현실 생활에 적용될 수 있는 수준의 연구 결과는 미비한 실정이다. 이것은 협상과정에서 소비자의 구매행위에 영향을 미치는 요소들을 명확히 정의하고 적용하기가 힘들며,

협상의 성공 여부가 구매 이후 소비자 및 판매자의 만족도와 같이 추상적인 요인에 따라 결정되는 경우가 많기 때문이다. 따라서 실제 협상에 사용되는 이러한 다양한 속성(attribute)들을 포괄할 수 있는 협상 알고리즘의 개발 및 적용은 매우 어려운 실정이다.

협상 에이전트와 관련된 연구로써 제시된 Persuader[1] 시스템의 경우, 다중 속성을 고려하여 에이전트간 상호 작용을 수행 할 수 있는 방안을 제시하였다. 그러나 협상에 참여한 에이전트들의 행동은 상대 에이전트의 설득에 초점이 맞추어져 있어, 타협안을 찾기 위해서는 자기 자신 또는 상대방이 가지고 있는 신념(beliefs)에 대한 변화가 불가피하다. Persuader 시스템은 협상이 타결되더라도 협상 참여

[†] 준 회 원 : 연세대학교 대학원 컴퓨터학과

^{††} 정 회 원 : 연세대학교 컴퓨터산업공학부 교수

논문접수 : 2003년 3월 25일, 심사완료 : 2003년 11월 17일

자들이 가지고 있는 고유한 생각, 즉 특정 속성에 대한 선호도와 같은 신념은 변화되지 않을 수 있다는 사실을 고려하지 않는다.

Kasbah[2] 시스템의 경우, 협상 진행 과정에서 협상에 참여한 각 에이전트의 특성을 보장하고, 협상 전략(negotiation strategy)의 선택을 통하여 협상을 진행 하는 다중 전략을 사용하고 있다. 그러나, 협상과정에서 가격이라는 단일 속성만을 고려하고 있으며, 협상 전략의 선택에 있어서 완전한 자율성을 보장하지 못한다는 단점이 있다.

Faratin[3]의 연구에서는 오프라인에서와 같은 실제적인 협상 환경하에서 협상에 참여한 두 에이전트의 상호작용을 위한 메커니즘을 제시하였으며, 이러한 상호작용을 수행할 수 있는 아키텍처의 구현에 초점을 두고 있다. 즉, 에이전트의 상호 작용을 위한 프로토콜을 설정하고, 설정된 프로토콜에 따라 협상에 참여한 두 에이전트는 상호 작용을 통하여 타협안에 접근 하게 된다. Faratin이 제시한 에이전트 시스템에서는 다중 속성에 대한 고려와 함께 에이전트간 상호 작용을 통한 타협안의 도출이라는 점에서, 기존의 협상 시스템에 비하여 실제 협상 환경에 대한 반영도가 높다는 장점이 있다. 그러나, 협상 전략에 있어서 근사해법에 의한 방법을 사용함으로써, 타협된 제안이 구매자 및 판매자 입장에서 최대 이익을 제공한다는 보장을 할 수 없다. 또한 타협안을 도출하는데 있어 수행 시간을 고려하지 않는다는 사실은 전자상거래에서 중요한 특성 중 하나인 실시간 협상의 관점에서 볼 때 활용성이 떨어진다고 볼 수 있다.

본 연구에서는 인공지능망을 이용한 점진적 학습(incremental learning)기반의 협상 에이전트 시스템을 제안하였다. 제안된 학습 기반 에이전트 시스템은 Faratin이 제시한 협상 에이전트 시스템의 장점 중 하나인 에이전트간 상호 작용을 통한 협상 알고리즘을 적용하였으며, 이와 함께 협상 수행 시간 및 협상 결과를 동시에 고려하여 협상 효율성을 향상시키는데 목적이 있다. 제안된 학습 기반 협상 시스템의 효율성을 검토하기 위하여, 기존의 협상 시스템과 함께 다양한 성향을 가지는 구매자 및 판매자 데이터들이 용한 협상 실험을 수행하였다.

논문의 구성은 다음 장에서 협상 에이전트 모델에 대하여 소개하였으며, 3장에서는 본 연구에서 제안된 점진적 학습 기반의 협상 에이전트 시스템을 제시하였다. 또한 제시된 협상 에이전트 시스템과의 비교를 위하여 기존의 trade-off mechanism을 적용한 협상 시스템에 대하여 언급하였다. 4장에서는 구매자와 판매자 데이터의 생성 및 실험 환경에 대하여 소개하였으며, 5장에서는 점진적 학습 기반의 협상 시스템과 다른 협상 에이전트 시스템과의 실험 결과를 비교

및 분석하였다. 6장에서는 결론과 연구 진행 방향을 제시하였다.

2. 다중 속성 협상 모델

2.1 Multi-Attribute Utility Theory

본 연구에서 구매자 및 판매자의 이익은 Multi-Attribute Utility Theory(MAUT)[7]를 이용하여 표현하였다. MAUT는 협상 대상에 대하여 단일 속성(single attribute)만을 고려하는 것이 아니라 다중 속성(multi-attribute)을 고려하여 이익을 평가하며, 따라서 각 속성들은 다른 속성들에 대한 상대적 가중치(weight)를 가진다.

MAUT에서 유틸리티 함수는 각 속성에 대한 가중치와 제안값에 대한 평가 함수를 이용하여 표현할 수 있다. 제안 집합은 n 개의 속성들에 대한 제안값을 원소로 갖는 집합으로써, 협상에서 하나의 “제안”을 의미한다. 따라서 유틸리티 함수를 통해 계산된 결과값은, 임의의 제안을 구매자 또는 판매자의 입장에서 평가한 이익으로 생각할 수 있다. 제안 집합에 대한 유틸리티 함수 $V^k(X)$ 는 다음 식 (1)과 같이 표현된다.

$$V^k(X) = \sum_{i=1}^n (w_i^k \cdot v_i^k(x[j_i])), \quad \sum_{i=1}^n w_i^k = 1, \quad 0 \leq v_i^k \leq 1 \quad (1)$$

여기서 k 는 구매자 에이전트(b) 또는 판매자 에이전트(s)이며, $J = \{j_1, j_2, \dots, j_n\}$ 는 속성 j_i 의 집합 ($1 \leq i \leq n$)이고, $X = \{x[j_1], x[j_2], \dots, x[j_n]\}$ 는 속성 j_i 에 대한 제안 집합이다. 또한 $x[j_i]$ 는 속성 j_i 에 대한 제안값이며, w_i^k 는 속성 j_i 에 대한 에이전트 k 의 가중치이고, $v_i^k(x[j_i])$ 는 속성 j_i 의 제안값에 대한 에이전트 k 의 평가함수를 나타낸다.

2.2 평가 함수

유틸리티 함수는 언급한 바와 같이 각 속성에 대한 가중치와 제안값에 대한 평가함수로 나타낼 수 있다. 제안값에 대한 평가함수는 임의의 속성에 대한 희망값(request)과 협상 허용값(allowable value)을 이용하여 표현하였다. 여기서 희망값이란 각 속성에 대하여 에이전트가 획득할 수 있는 최대값을 의미하며, 협상 허용값이란 협상과정에서 각 속성에 대하여 상대방에게 최대한 허용할 수 있는 경계값을 의미한다.

- ① 임의의 속성에 대하여 희망값이 협상 허용값보다 큰 경우 :

$$v_i^k(x[j_i]) = \frac{x[j_i] - \text{협상 허용값}}{\text{희망값} - \text{협상 허용값}}, \quad 0 \leq v_i^k \leq 1 \quad (2)$$

② 임의의 속성에 대하여 희망값이 협상 허용값보다 크지 않은 경우 :

$$v_i^k(x[j_i]) = \frac{\text{협상 허용값} - x[j_i]}{\text{협상 허용값} - \text{희망값}}, 0 \leq v_i^k \leq 1 \quad (3)$$

2.3 다중 속성 상거래 모델

본 연구에서는 구매자와 판매자 한 쌍이 참여하는 양자간 협상(bilateral negotiation)에 대하여 고려하였다. 구매자와판매자가 참여하는 양자간 협상에서의 협상 결과와 수행 능력은 다수의 구매자 및 판매자가 동시에 참여하는 다자간 협상으로의 확장에 있어서 기본적인 요인이므로, 본 연구에서는 빠른 수행 시간 내에 양자간 타협안을 찾는 것에 초점을 두고자 한다. 여기서 구매자와 판매자 사이에 존재하는 타협안이란, 양자간 이익이 어느 한쪽으로도 지나치게 치우치지 않으면서 서로에게 보다 많은 이익을 보장하는 제안으로 정의하였다.

협상 에이전트 시스템은 다양한 품목의 전자상거래에 적용이 가능하며, 본 논문에서 가정한 협상 모델은 중고자동차를 다량 보유하고 있는 판매업자들과 소비자들 사이의 전자상거래로 설정하였다. 중고차는 소비자의 다양한 성향을 반영할 수 있고, 신차와는 달리 단종된 모델에 대한 거래도 가능하므로 모델의 종류가 다양하다. 또한 동일 모델의 자동차라 하더라도 제품의 속성에 따라 선택의 폭이 넓어 유동적인 협상조건을 반영할 수 있다는 장점을 가지고 있다.

협상에 대한 속성으로는 가격, 주행거리, 보증조건의 세 가지 항목을 고려하였다. 협상 모델에서 판매자는 동일한 모델에 대하여 가격, 주행거리, 보증조건이 서로 다른 자동차들을 다수 보유하고 있으며, 구매자는 판매자가 제시하는 특정 모델의 자동차를 구매하고자 하는 최종 소비자로서 가정하였다. 판매자와 구매자는 모두 각 속성에 대하여 가중치와 함께 희망값 및 협상 허용값을 갖는다. 구매자 및 판매자 에이전트는 이러한 구매자와 판매자의 상품 속성에 대한 각종 정보를 제공받아 협상을 진행한다. 여기서 협상에 참여하는 두 에이전트들은 서로 상대방의 협상 정보들을 알지 못하는 상태로 가정하였다. 본 연구에서 협상 데이터 집합은 협상에 참여하는 판매자 및 구매자 한 쌍의 데이터를 의미하며, <표 1>과 <표 2>에서는 각각 판매자 및 구매자 데이터에 대한 일례를 보여준다.

<표 1>에서 구매자는 판매자가 판매하고자 하는 모델의 자동차를 200만원에 사고자 하며, 가격에 대하여 다른 속성, 즉 주행거리 및 보증조건에서 판매자가 좋은 조건을 제시한다면 550만원까지 양보할 수 있음을 나타내고 있다.

또한 동일 모델에 대하여 5000km 정도 주행한 자동차를 선호하고 있으며, 가격 및 보증조건에서 판매자가 유리한 조건을 제시한다면 100,000km까지 주행한 자동차도 협상 가능함을 나타낸다. 보증조건은 24개월을 요구하고 있으나 역시 가격 및 주행거리와 관련하여 좋은 조건을 제시한다면 12개월까지 양보할 수 있음을 보여주고 있다. 여기서 구매자는 가격을 협상에서 가장 중요한 속성으로 보고 있으며 그 다음으로 주행거리 및 보증조건의 순서로 속성에 대한 중요도를 평가하고 있다. <표 2>의 경우 판매자의 입장에서는 협상 정보를 나타내고 있으며, 각 항목은 <표 1>과 동일한 의미를 가진다.

<표 1> 구매자의 속성 테이블

속 성	구 분	속성값	가중치
가격 (만원)	희망값	200	0.5
	허용값	550	
주행거리 (km)	희망값	5000	0.3
	허용값	100000	
보증조건 (개월)	희망값	24	0.2
	허용값	12	

<표 2> 판매자의 속성 테이블

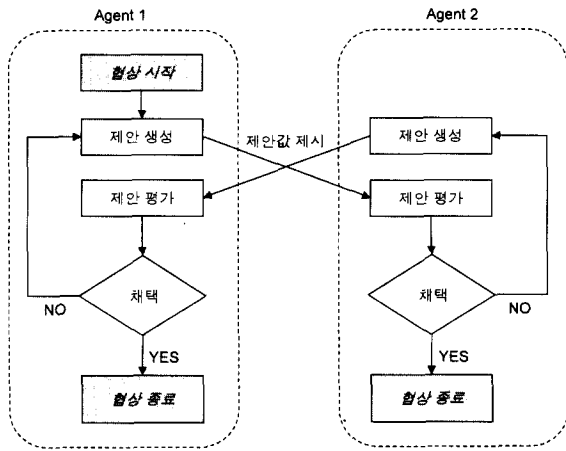
속 성	구 분	속성값	가중치
가격 (만원)	희망값	600	0.4
	허용값	300	
주행거리 (km)	희망값	150000	0.4
	허용값	1000	
보증조건 (개월)	희망값	6	0.2
	허용값	18	

2.4 다중 속성 협상 진행 과정

다중 속성을 통한 협상에서는 동일한 유틸리티 값을 가지면서 각 속성에 대한 평가값의 조합이 서로 다른 제안을 생성할 수 있으며, 이와 같이 동일한 유틸리티를 가지는 다양한 제안들의 집합이 이루는 궤적을 iso-value curve[1]라고 한다. 특정 모델의 중고 자동차에 대한 구매자 에이전트 및 판매자 에이전트들은 각 속성에 대한 선호도와 희망값 및 허용값에 대한 정보를 가지고 있으며, 이들 에이전트는 속성에 대한 가중치와 속성값의 조합에 따라 iso-value curve에 존재하는 새로운 제안을 생성, 상대 에이전트에게

제안한다. 여기서 새로운 제안의 생성은 협상 수행 시간 및 협상 결과의 효율성에 큰 영향을 미친다. 기존의 협상 에이전트 시스템[4]에서 사용된 방법은 자신의 iso-value curve 상에 존재하는 제안들 중 상대 에이전트의 제안과 가장 유사한 제안을 상대에게 제시하는 방식을 사용하고 있다.

이와 같은 접근방식에서는 상대방에 대한 정보, 즉 각 속성에 대한 상대방의 가중치 정보를 알고 있을 때 협상의 효율성이 매우 높게 나타난다[4]. 그러나 모든 상거래에 있어서, 상대방에게 자신의 정보를 노출할 수 있는 것은 아니므로 상대방의 가중치 정보를 모르는 상태에서 iso-value curve 상의 많은 제안들 중 상대방의 제안과 유사성이 높은 제안을 찾는 것은 쉽지 않다.



(그림 1) 협상 에이전트 시스템에서의 협상 절차

본 연구에서 각 협상 시스템에서의 협상과정은 (그림 1) 과 같이 [3]에서 제시된 절차를 따른다. 먼저 양자간 협상에 참여한 임의의 에이전트가 상대 에이전트에게 제안을 하고, 제안을 받은 상대 에이전트는 그 제안을 평가하여 받아들이거나(accept), 그렇지 않은 경우 수정된 제안(counter-offer)을 상대방에게 제시한다. 제안에 대한 평가 알고리즘 및 구매자와 판매자의 유틸리티는 앞에서 언급한 방법을 따른다. 협상이 진행되는 동안 새롭게 제안한 수정제안이 이전 제안보다 좋은 평가를 받지 못할 때, 에이전트는 자신의 유틸리티를 일부 낮추게 되며, 낮아진 유틸리티에 해당되는 제안을 다시 상대 에이전트에게 제시하도록 설정하였다.

3. 다중 속성 협상 에이전트 시스템

오프라인에서와 같은 협상 환경하에서 협상에 참여한 두 에이전트의 상호작용을 위한 메커니즘으로써 제시된 trade-off mechanism[4]은 deliberative mechanism[3]의 일종으로, 오프라인에서의 협상 환경에 대한 반영도가 높고, 에이

전트간 상호작용에 대한 메커니즘을 구현한다는 장점이 있으나, 타협안에 도달하는데 있어 수행 시간에 대한 개념을 고려하지 않는다는 점은 온라인의 실시간 특성이나, 향후 다자간 협상으로의 확장에 있어 문제가 될 수 있다.

3.1 Trade-off mechanism

Trade off mechanism은 제안 집합 J 내에서, 한 속성에 대한 평가값을 낮추고 그 만큼의 손실된 값을 다른 속성들로부터 보상 받는 방법이다. 이렇게 함으로써 자신이 이전에 제시했던 제안과 동일한 유틸리티를 유지하면서 상대방의 입장에서 좀 더 유리할 수 있는 수정된 제안을 제시할 수 있다. 즉, 상대 에이전트로부터 받은 제안 Y 에 대하여, 자신이 가장 최근에 제안했던 제안 X 와 동일한 유틸리티를 가지는 제안집합 가운데 상대 에이전트의 제안 Y 와 가장 유사도가 높은 수정제안 Z 를 상대방에게 제시하게 되며, 이것을 다음과 같이 식 (4)로 표현할 수 있다.[4]

$$tradeoff_k(X, Y) = Z \quad (4)$$

여기서 k 는 판매자 또는 구매자 에이전트를 의미하며 X 와 Y 는 에이전트 k 가 상대방에게 제시하였던 제안과 상대방 에이전트가 에이전트 k 에게 제시하였던 제안을 의미한다. 그리고 Z 는 $V^k(Z) = V^k(X)$ 를 만족하면서 Y 와 유사도(similarity)가 높은 임의의 제안 집합으로써, 에이전트 k 가 상대방에게 제안하게 될 수정 제안을 의미한다.

상대방의 가중치 정보를 알고 있다는 가정하에서는 가중치 정보를 이용하여 자신의 제안과 상대방 제안과의 유사도를 계산할 수 있다. 따라서 상대방의 제안 Y 와 유사도가 높은 수정제안 Z 를 통하여 구매자 및 판매자 모두에게 높은 유틸리티를 제공하는 타협안을 찾을 수 있다[4]. 그러나 실제 협상 과정에서와 같이 상대방의 가중치 정보를 알지 못하는 상황에서는 상대방의 제안 Y 와의 유사도를 평가할 수 있는 방법을 가정하여야 하며, 본 논문에서는 두 제안간 기하학적 거리(Euclidean distance)에 근거한 유사도[4,5]를 이용하였다.


3.2 점진적학습 기반의 협상 시스템

3.2.1 점진적 학습기법 구현을 위한 인공 신경망

본 연구에서는 trade-off mechanism에서 제시된 구매자 및 판매자 이익의 설정 방식과 협상 절차를 따르면서, 제안 생성 알고리즘에 인공신경망을 이용한 점진적 학습 기법을 추가하여 협상 효율성을 높이고자 하였다. 전자상거래에 있어서 협상의 특성은 온라인의 실시간 특성 및 불특정 다수

의 거래에 있으므로 이러한 협상의 특성상 일괄학습(batch learning)과 같은 오프라인 학습 방법보다 점진적 학습기법과 같은 온라인 학습 방법이 더 적합하며[5], 점진적 학습기법의 구현을 위하여 인공신경망을 이용하였다.

(그림 2)는 제안된 협상 모델에 사용된 인공신경망의 구성을 나타내고 있다. 여기서 입력 및 출력 노드의 수는 각각 협상 모델의 속성 수에 대응된다. 따라서, 제시된 협상 모델에서의 속성 수에 따라 입력 및 출력 노드의 수는 3이 되며, 입력 노드의 값은 제안 집합의 각 속성값에 대응된다. 여기서 속성값이란 앞에서 언급한 2.2절의 평가 함수에 의해 계산되는 제안의 평가값으로써, 0과 1사이의 값으로 표현된다. 은닉층(hidden layer) 및 출력층(output layer)에서의 활성화함수(activation function)는 sigmoidal function을 사용하였으며 가중치의 초기값은 모두 0으로 설정하였다.



(그림 2) 제안된 협상 모델의 점진적 학습기법 구현을 위한 인공신경망 구성

3.2.2 초기 학습과정

본 연구에서 제시된 인공신경망을 이용한 점진적 학습기법은 초기 학습과정과 실시간 학습과정으로 나누어진다. 초기 학습과정은 입력값 및 목표값 한 쌍의 반복 학습을 통하여 인공신경망의 가중치를 초기화하는 과정이다. 초기 학습과정에서 입력값은 자신의 첫 번째 제안값을 0과 1사이의 값으로 변환한 ‘속성값’으로 설정한다. 또한, 목표값은 두 제안간 거리 기반의 유사성(distance based similarity)을 기준으로 했을 때 iso-value curve 상에 존재하는 제안 집합 중 상대방의 첫 번째 제안집합과 가장 유사한 제안값을 0과 1사이의 값으로 변환한 속성값으로 설정한다. 이후 인공신경망의 학습을 통하여 가중치를 조정함으로써, ‘실시간 학습과정’에서의 가중치 초기값을 설정하게 된다.

(그림 2)에서 보는 바와 같이 은닉층에서의 가중치를 a_{ih} , 출력층에서의 가중치를 b_{hk} , 그리고 신경망을 통해 나온 출

력값을 o_k , 목표값을 t_k 라고 할 때, 은닉층 및 출력층에서의 error term δ_k , δ_h 은 각각 다음과 같다.

① 출력층의 노드 k 에서의 error term δ_k

$$\delta_k = o_k(1 - o_k) (t_k - o_k) \tag{5}$$

② 은닉층의 노드 h 에서의 error term δ_h

$$\delta_h = o_h(1 - o_h) \sum_{k \in \text{outputs}} b_{hk} \delta_k \tag{6}$$

은닉층 및 출력층에서의 가중치 w_{mn} 의 조정(update)은 $w_{mn} \leftarrow w_{mn} + \leftarrow \eta \delta_n x_{mn}$ (단, η = learning rate)로 표현될 수 있으므로 제시된 인공신경망의 경우 가중치 a_{ih} 및 b_{hk} 의 조정은 다음의 식 (7)과 같이 표현할 수 있다.

$$\begin{cases} a_{ih} \leftarrow a_{ih} + \eta \delta_h x_{ih} \\ a_{hk} \leftarrow b_{hk} + \eta \delta_k x_{hk} \end{cases} \tag{7}$$

초기 가중치는 모두 0으로 설정되어 있으며, 따라서 정해진 한 쌍의 입력값 및 목표값에 대하여 첫 번째 역전파 수행시 δ_h 값이 0이므로($\because b_{hk} = 0$), 가중치 a_{ih} 값은 모두 0이 된다. 그리고 가중치 b_{hk} 의 경우, δ_k 가 0이 아니므로($\because o_k, t_k \neq 0$) 가중치 b_{hk} 는 0이 아닌 임의의 값을 가지게 된다. 두 번째 역전파를 통한 가중치 조정과정에서는 이전의 역전파 수행시 b_{hk} 가 0이 아닌 값을 가지고 있으므로, a_{ih} 값도 0이 아닌 임의의 값을 가지게 된다. 이와 같은 가중치 조정을 반복함으로써 초기 학습과정에서는 ‘실시간 학습과정’에서 사용될 인공신경망의 가중치 초기값을 0이 아닌 임의의 값으로 설정하게 된다.

3.2.3 실시간 학습과정

실시간 학습 과정은 인공신경망의 점진적 학습 방법을 이용한 제안의 생성 및 학습과정의 병행으로써, 인공신경망을 통해 나온 출력값은 상대방에게 제시하는 ‘제안’이 되고, 생성된 제안을 상대방이 거절했을 때, 반복 학습을 위하여 이 제안을 인공신경망의 입력값으로 설정하게 된다. 실시간 학습과정에서의 제안생성 및 학습과정을 살펴보면, 먼저 상대방으로부터 거절된 제안을 다시 인공신경망의 입력값으로 설정하고 목표값으로는 현재의 유틸리티 값을 이용하여 인공신경망의 학습과정, 즉 가중치 조정 과정을 수행하게 된다. 예를 들어 상대방에게 제안한 제안값이 상대방으로부터 거절되었다면, 각 속성에 대한 평가 함수를 통하여 거절된 제안값(200만원, 2만Km, 18개월)을 0과 1사이의 값을 갖는 속성값(0.766, 0.648, 0.687)으로 변환하고, 이 값을 인공신경망에 대한 입력값으로 설정하여 인공신경망의 가중치를 조정하는 학습과정을 수행한다. 이 때 인공신경망의

출력값은 평가함수의 $x[j]$ 를 구하는 과정을 통하여 다시 제안값으로 환원되어 상대방에게 제안하게 될 수정제안을 구성하게 된다. 학습을 위한 목표값으로 설정되는 유틸리티 값은 제안 교환 회수가 일정 값에 도달하는 동안에도 협상이 타결되지 않는 경우 일정 비율만큼 감소된다. 만약 현재 협상에 참여한 협상 참여자의 유틸리티가 0.7을 유지하는 경우, 100회의 제안 교환에도 불구하고 서로 타협점을 찾을 수 없다면 유틸리티를 0.01만큼 낮추어 이것을 목표값으로 재설정하여 학습 과정이 진행된다. 이와 같은 학습과정 및 수정 제안과정은 상호이익의 조건에 맞는 협상 타협안이 도출될 때까지 반복 수행된다.

4. 실험

4.1 구매자 및 판매자 데이터 생성

본 연구에서는 상호 이익의 보장이라는 동일 조건하에서 trade-off mechanism을 이용한 협상 시스템을 구현하여 점진적 학습 기반 협상 에이전트 시스템에서의 협상 결과와 비교하였다.

판매자의 협상 데이터는 각 속성에 대하여 다음 <표 3>의 생성 구간내에서 임의로 생성하였으며, 실험을 위하여 200개의 판매자 데이터를 생성하였다. 구매자의 데이터는 판매자와 협상이 가능하도록 하기 위하여, 생성된 판매자 데이터를 기본으로 <표 4> 및 <표 5>에서 제시된 방법을 통하여 생성하였다. 즉, 생성된 200명의 판매자와 협상하기 위한 구매자의 데이터 중 100개는 <표 4>에서 제시된 생성 구간에서, 나머지 100개의 데이터는 <표 5>에서 제시된 생성 구간에서 데이터를 생성하였으며, <표 4>와 <표 5>를 기준으로 구성된 판매자 및 구매자 데이터 쌍을 각각 협상 데이터 집합(I), (II)로 표기하였다. 각 속성에 대한 가중치는 <표 3>에서와 동일한 방법으로 생성하였다. <표 5>를 통한 구매자 데이터의 경우 <표 4>에 의한 구매자 데이터에 비하여 협상 구간에 있어서 판매자와의 유사도가 높다. 약어의 표기는 <표 3>에서 제시된 약어와 동일하다.

<표 3> 판매자의 협상 데이터 생성

속 성	구 분	생성 구간	가중치 생성 구간
가 격(만원)	희망값(Pmax)	[500, 1000]	[0.4, 0.6]
	허용값(Pmin)	[150, 300]	
주행거리(km)	희망값(Rmax)	[30000, 100000]	[0.2, 0.4]
	허용값(Rmin)	[10000, 20000]	
보증조건(개월)	희망값(Wmin)	[6, 12]	1 - {가격의 가중치} - {주행거리의 가중치}
	허용값(Wmax)	[14, 36]	

<표 4> 구매자 데이터의 각 속성에 대한 생성 구간 I

속 성	구 분	생성 구간
가 격(만원)	희망값	$P_{min} + (P_{max} - P_{min}) \times [-0.4, 0.1]$
	허용값	$P_{max} + (P_{max} - P_{min}) \times [-0.4, 0.1]$
주행거리(km)	희망값	$R_{min} + (R_{max} - R_{min}) \times [-0.4, 0.1]$
	허용값	$R_{max} + (R_{max} - R_{min}) \times [-0.4, 0.1]$
보증조건(개월)	희망값	$W_{max} + (W_{max} - W_{min}) \times [-0.1, 0.4]$
	허용값	$W_{min} + (W_{max} - W_{min}) \times [-0.1, 0.4]$

<표 5> 구매자 데이터의 각 속성에 대한 생성 구간 II

속 성	구 분	생성 구간
가격(만원)	희망값	$P_{min} + (P_{max} - P_{min}) \times [-0.25, 0.1]$
	허용값	$P_{max} + (P_{max} - P_{min}) \times [-0.25, 0.1]$
주행거리(km)	희망값	$R_{min} + (R_{max} - R_{min}) \times [-0.25, 0.1]$
	허용값	$R_{max} + (R_{max} - R_{min}) \times [-0.25, 0.1]$
보증조건(개월)	희망값	$W_{max} + (W_{max} - W_{min}) \times [-0.1, 0.25]$
	허용값	$W_{min} + (W_{max} - W_{min}) \times [-0.1, 0.25]$

4.2 실험 환경

생성된 200개의 구매자 및 판매자 데이터는 다양한 성향을 가지는 구매자 및 판매자의 속성 데이터들을 의미한다. 제안된 학습 기반 협상 시스템의 효율성을 검토 하기 위하여, 기존의 협상 시스템과 함께 200개의 협상 데이터 집합을 이용하여 실험을 수행하였다. 기본적으로 상호 이익이라는 가정하에서 실험을 수행하였으며, 따라서 어떠한 협상 시스템을 통해 합의된 타협안이라도 양자간 이익의 차는 0.03이하가 되도록 설정하였다. 상호 이익의 가정하에서, 협상 결과에 대한 평가는 판매자 및 구매자 이익의 합으로 설정하였다.


Faratin[4]이 제안한 trade-off mechanism의 경우 상대방에 대한 정보를 이용하여 협상을 수행하는 경우가 그렇지 않은 경우보다 유틸리티 측면에서 유리하였다. 따라서 본 실험에서는 상대방에 대한 가중치 정보를 이용하여 협상을 수행하는 시스템(Information-Similarity System, ISS) 과 단순히 상대방 제안과의 거리를 이용하여 유사도를 예측하는 협상 시스템(Noninformation-Similarity System, NSS), 그리고 유사도를 전혀 고려하지 않고 임의로 제안을 생성하는 시스템(Random System, RS) 등 세가지 협상 시스템을 본 논문에서 제안한 점진적 학습 기반 협상 시스템(ANN-Incremental Learning System, AILS)과의 비교를 위한 시스템으로 구현하였다.

본 논문에서 제안한 점진적 학습기반 협상 시스템의 경우, 인공지능망의 가중치를 초기화 하기 위한 초기 학습과정에서, 입력값 및 목표값의 반복 학습회수는 1000회이며 실시간 학습과정에서 목표값의 감소비율은 0.01로 설정하였다. 또한 학습율(learning rate)은 초기 학습 과정 및 실시간 학습과정에서 0.01로 설정하였다.


5. 실험 결과

(그림 3)과 (그림 4)는 협상 데이터 집합(I) 및 협상 데이터 집합(II)의 개수에 따른 각 협상 시스템의 협상 결과에 대한 평균값을 나타내고 있다. 그림에서 하나의 협상 데이터는 협상에 참여한 구매자 및 판매자 데이터 한 쌍을 의미하며, y축은 데이터 집합의 개수에 따른 판매자 및 구매자 이익의 합에 대한 평균값을 의미한다. 협상 데이터 집합의 종류에 관계없이 협상 결과는 ISS가 가장 좋은 결과를 보였으며, AILS, NSS, 그리고 RS의 순서로 좋은 협상 결과를 보여주었다. ISS를 제외하고 동일한 협상 조건에서 실험한 나머지 세가지 협상 시스템의 경우 AILS가 가장 좋은 협상 결과를 보여주었다.


(그림 5)와 (그림 6)은 협상 데이터 집합(I)과 협상 데이터 집합(II)에 대하여 ISS에서의 결과값을 기준으로 했을 때 다른 세가지 협상 시스템의 결과값이 나타내는 상대 오차를 보여주고 있다. ISS는 상대방의 가중치 정보를 알고 있다는 가정하에서 협상을 진행하므로 좋은 협상 결과를 줄 수 있으며, 따라서 결과값을 비교하기 위한 기준 시스템으로 설정하였다. RS의 경우 협상 데이터에 따라 매우 이산적인 오차 분포를 보였으며, 상대 오차는 다른 시스템에 비하여 비교적 크게 나타났다. AILS의 경우 오차의 분포는 NSS와 비슷한 경향을 보이거나 전체 협상 데이터 집합을 고려할 때 상대 오차에 있어서는 NSS에 비하여 좋은 결과를 보여주었다.




(그림 3) 협상 데이터 집합(I)의 개수에 따른 각 협상 시스템에서의 평균 결과값



(그림 4) 협상 데이터 집합(II)의 개수에 따른 각 협상 시스템에서의 평균 결과값



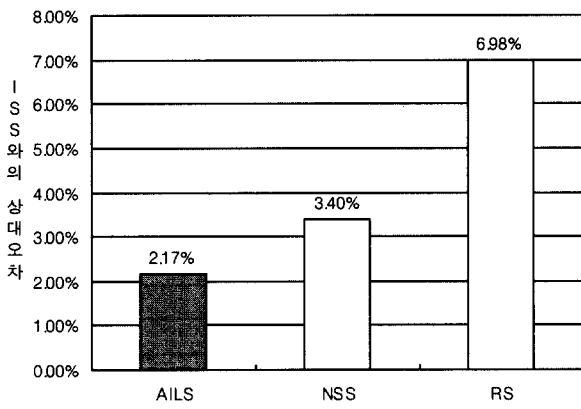
(그림 5) ISS와의 상대 오차 : 협상 데이터 집합(I)




(그림 6) ISS와의 상대 오차 : 협상 데이터 집합(II)

(그림 7)은 두 개의 협상 데이터 집합 내 모든 협상 데이터에 대한 ISS와의 평균오차를 나타내고 있다. 협상 데이터 집합(I)에 대하여 AILS는 ISS와의 평균 오차가 2.17%로써 NSS에서의 3.40%보다 우수한 결과를 보여주었다. 협

상 데이터 집합(II)의 경우 AILS는 ISS와의 평균오차가 1.84%로써 협상 데이터 집합(I)에 비하여 개선된 결과를 보여주었다. NSS의 경우 3.43%로써 협상 데이터 집합(I)에서의 결과와 비슷한 오차를 보였다. 전체적으로 협상 데이터 집합(I) 및 (II)에 대하여 AILS가 NSS보다 우수한 협상 결과를 보여주었으며, AILS의 경우 협상 데이터 집합(II)에서의 결과가 협상 데이터 집합(I)에서의 결과에 비하여 다소 개선된 결과를 보여주었다. 한편, RS의 경우 다른 협상 시스템에 비하여 협상 데이터 집합의 종류에 관계없이 오차가 매우 컸다.



(a) 협상 데이터 집합(I)

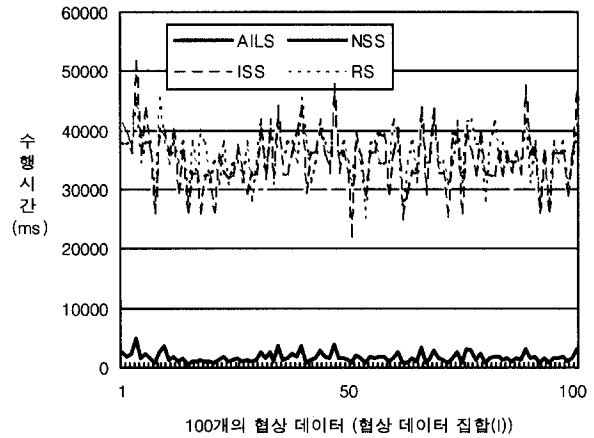


(b) 협상 데이터 집합(II)


(그림 7) 각 협상 데이터 집합에 대한 ISS와의 오차 평균(%)

(그림 8)은 협상 데이터 집합(I)에 속하는 각각의 협상 데이터에 대하여 ISS, NSS, RS, 그리고 AILS에서의 협상 수행 시간을 나타내고 있다. ISS, NSS 및 RS는 AILS에 비하여 협상 데이터 집합에 따라 수행 시간의 편차가 심하였으며, 동일한 개별 협상 데이터의 경우 ISS 및 NSS 시스템은 서로 비슷한 수행 시간을 보여주었다. AILS의 경우 다른 두 시스템에 비하여 매우 빠른 수행 시간을 보였으며 협상 데이터 집합에 따른 영향이 비교적 적었다. 협상 데이터 집


합(II)의 경우도 (그림 8)과 유사한 경향을 보여 주었다.



(그림 8) 100개의 협상 데이터(협상 데이터 집합(I))에 대한 각 시스템에서의 협상 수행 시간



(a) 협상 데이터 집합(I)



(b) 협상 데이터 집합(II)

(그림 9) 협상 데이터 집합에 대한 각 협상 시스템의 평균 협상 수행 시간

(그림 9)에서는 협상 데이터 집합(I)과 협상 데이터 집합(II)에 대한 평균 수행 시간을 나타내고 있다. 협상 데이터 집합(I)에 대하여 AILS의 평균 수행 시간은 1.7초로써, NSS

의 평균 수행시간 34.2초에 비하여 약 20배 빠른 수행시간을 보여주었다. 모든 협상 시스템에 대하여 협상 데이터 집합(II)에서의 수행시간이 협상 데이터 집합(I)에 비하여 빠른 결과를 보여주었다. 협상 데이터 집합(II)에서 AILS는 평균 1.1초의 수행시간을 보였으며 NSS 및 ISS는 평균 30초 정도의 수행시간을 보여주었다. 전자 상거래 협상의 특성 중 하나인 온라인, 실시간 특성에 비추어 볼 때, 협상 결과 및 협상 수행 시간을 동시에 고려한다면, AILS가 NSS보다 효율적인 협상 능력을 보여주었다.

6. 결 론

본 연구에서는 기존의 trade-off mechanism을 이용한 협상 시스템을 기반으로, 제안 생성 과정에 인공지능망을 통한 점진적 학습기법을 추가하여 협상 효율성을 증가시키고자 하였다. 기존의 협상 시스템[4]에서 제안한 바와 같이 상대방 제안과의 유사도에 근거한 제안 생성 시스템과 상대방의 가중치 정보를 알고 있다는 가정하에서 협상을 수행하는 시스템, 그리고 유사도를 고려하지 않고 iso-value curve상에 존재하는 임의의 제안을 제시하는 시스템을 구현하여 본 연구에서 제안한 학습 기반 협상 시스템과의 협상 결과를 비교하였다. 논문에서 가정한 협상에서의 타협안은 협상 참여자 중 어느 한쪽으로도 이익이 치우치지 않도록, 양자간 이익의 차를 매우 작은 범위로 유지하면서 서로에게 높은 이익이 되는 제안이며, 따라서 협상 결과에 대한 평가는 구매자 및 판매자 이익의 합으로 설정하였다.

전자상거래에서의 협상이 가지는 불특정 다수간 거래 및 실시간 특성 등의 협상 환경을 고려할 때, 상대방의 가중치 정보를 모두 알고 있다는 ISS의 가정은 매우 큰 제약 사항이 된다. 따라서 전자상거래의 현실적인 협상 조건을 기반으로 한 AILS 및 NSS 시스템의 경우, 제안된 협상 시스템인 AILS가 수행시간 및 협상 결과에 있어 더욱 효율적인 협상 능력을 보여주었다.

NSS는 수정제안을 생성함에 있어서 상대방 제안과의 유사도에 의존하고 있으며, 따라서 상대방에 대한 협상정보를 알지 못하는 상황에서의 trade-off mechanism을 이용한 협상 시스템은 수행 시간 뿐만 아니라 협상 결과에 있어서 만족스럽지 못한 결과를 보여주었다. 제안된 AILS의 경우 협상이 진행되는 동안 상대방이 채택하지 않았던 자신의 이전 제안들을 중심으로 점진적 학습 기법에 기반한 제안 생성과정을 이용함으로써 NSS에 비하여 더욱 신속하게 구매자 및 판매자의 이익을 극대화할 수 있는 타협안을 도출하였다.

본 연구에서는 기존의 협상 에이전트 시스템에 학습 기법을 추가함으로써 상호이익의 조건을 충족시키면서 전자

상거래의 실시간 특성을 만족시킬 수 있는 협상 에이전트 시스템의 가능성을 확인할 수 있었으며, 향후 점진적 학습 기법의 알고리즘 개선과 함께 다자간 협상으로의 확장을 위하여 추가적인 연구를 수행하고자 한다.

참 고 문 헌

- [1] Sycara, K., "Multi-Agent Compromise via Negotiation," *Distributed Artificial Intelligence*, Vol.2, pp.119-139, September, 1989.
- [2] Chavez, A. and Maes, P., "Kasbah : An Agent Marketplace for Buying and Selling Goods," *Proc. 1st international Conference on the Practical Application of Intelligent Agents and Multi-Agent Technology*, 1996.
- [3] Faratin, P., Sierra, C., Jennings, N. R. and Buckle, P., "Designing Responsive and Deliberative Automated Negotiators," *Proc. AAAI Workshop on Negotiation : Settling Conflicts and Identifying Opportunities*, Orlando, FL, pp. 12-18, 1999.
- [4] Faratin, P., Sierra, C. and Jennings, N. R., "Using similarity criteria to make negotiation trade-offs," *Proc. 4th Int. Conf. on Multi-Agent Systems(ICMAS-2000)*, Boston, USA, pp. 119-126, 2000.
- [5] V. Soo and C. Hung, "On-Line Incremental Learning in Bilateral Multi-Issue Negotiation," *First International Joint Conference on Autonomous Agents and Multi-Agent Systems*, July, 2002, Italy, 2002.
- [6] Keeney, R. L. and Raiffa, H., *Decisions with Multiple Objectives*, Cambridge University Press, 1993.
- [7] Barbuceanu, M. and Lo, W., "A multi-attribute utility theoretic negotiation architecture for electronic commerce," *Proc. Fourth International Conference on Autonomous Agents*, 2000.
- [8] Ryu, Y. U. and Hong, S. C., "Negotiation Supports in a Commodity Trading Market," *Proc. 31st Hawaii International Conference on System Sciences*, 1998.
- [9] Krovi, R., Graesser, A. C. and Pracht, W. E., "Agent Behaviors in Virtual Negotiation Environments," *IEEE Transactions on Systems, Man and Cybernetics-Part C : Applications and Reviews*, Vol.29, No.1, pp.15-25, 1999.
- [10] Ueyama, J. and Maderia, E. R. M., "An Automated Negotiation Model for Electronic Commerce," *Proc. 5th International Symposium on Autonomous Decentralized Systems*, pp.29-36, 2001.
- [11] Smith, M., *Neural Networks for Statistical Modeling*, International Thomson Computer Press, 1996.

박 상 현

e-mail : psh@cs.yonsei.ac.kr

1996년 연세대학교 기계공학과 학사

2001년 연세대학교 기계공학과 석사

1995년~1999년 대한항공 항공우주사업

본부 연구개발팀

2001년~현재 연세대학교 컴퓨터과학과 박사과정

관심분야 : 전자상거래, 소프트웨어 에이전트

양 성 봉

e-mail : yang@cs.yonsei.ac.kr

1981년 연세대학교 공학사

1984년 Univ. of Oklahoma 컴퓨터과학 석사

1992년 Univ. of Oklahoma 컴퓨터과학 박사

1993년~1994년 전주대학교 전자계산학과 전임강사

1994년~현재 연세대학교 컴퓨터산업공학부 부교수

관심분야 : 전자상거래, 그래픽스, 인터넷 컴퓨팅