

인공신경망과 퍼지규칙 추출을 이용한 상황적응적 전문가시스템 구축에 관한 연구

A Study on the Self-Evolving Expert System using Neural Network and Fuzzy Rule Extraction

이건창 · 김진성

Kun-Chang Lee and Jin-sung Kim

성균관대학교 경영학부

Abstract

Conventional expert systems has been criticized due to its lack of capability to adapt to the changing decision-making environments. In literature, many methods have been proposed to make expert systems more environment-adaptive by incorporating fuzzy logic and neural networks. The objective of this paper is to propose a new approach to building a self-evolving expert system inference mechanism by integrating fuzzy neural network and fuzzy rule extraction technique. The main recipe of our proposed approach is to fuzzify the training data, train them by a fuzzy neural network, extract a set of fuzzy rules from the trained neural network, organize a knowledge base, and refine the fuzzy rules by applying a pruning algorithm when the decision-making environments are detected to be changed significantly. To prove the validity, we tested our proposed self-evolving expert systems inference mechanism by using the bankruptcy data, and compared its results with the conventional neural network. Non-parametric statistical analysis of the experimental results showed that our proposed approach is valid significantly.

Key Words : fuzzy extraction, fuzzy expert system, fuzzy neural network, bankruptcy prediction

1. 서론

기존의 전문가시스템의 지식베이스는 그 지식의 형태들이 대부분 일반적인 If-Then 형태의 규칙(rule)들로 이루어져 있다. 이러한 일반적인 규칙에 Zadeh[33] 교수의 퍼지집합의 개념을 적용하여 일반화한 것이 퍼지규칙이다. 그러므로, 퍼지규칙은 불완전하고 불확실한 실세계의 정보를 설명하는데 매우 적합하다. 그러나, 퍼지규칙을 기반으로 하는 전문가시스템의 지식베이스를 구성하기 위해서는 특정 분야별 전문가의 많은 노력과 규칙의 일반화에 따르는 여러 가지 어려움이 있다. 이러한 어려움을 극복하기 위한 방안의 하나로 지식베이스를 인공신경망으로 대체하는 방법에 대한 여러 가지 연구가 이루어졌다[3, 5, 9, 20, 22, 27, 31]. 지식베이스를 인공신경망으로 대체하는 가장 큰 이유는, 인공신경망이 자료에 대한 뛰어난 학습능력을 가지고 있고, 학습자료에 대한 지식을 인공신경망 내부의 연결가중치로 가지고 있으므로 전문가시스템의 지식베이스를 구축하는 수고를 덜어주기 때문이다. 그러나, 인공신경망은 각 노드(node)들 사이의 연결가중치를 사용하여 추론을 하기 때문에 추론과정에 대한 설명을 할 수 없다는 단점이 있다. 이러한 단점을 보완하기 위해 인공신경망으로부터 규칙을 추출하여 지식베이스를 동적으로 활용하는 연구가 활발하게 이루어졌다[11, 12, 14, 15, 21]. 최근에는 이러한 연구와 함께 퍼지이론을 인공신경망과 결합해서 전문가시스템의 활용범위를 확대하고자 하는 연구들[1, 2, 4,

6, 7, 8, 10, 13, 16, 17, 18, 19, 23, 24, 25, 26, 28, 29, 30, 32]도 여러 분야에서 이루어지고 있다. 이들 연구에서 인공신경망의 입출력자료를 퍼지화하는 가장 큰 이유는 퍼지화된 입출력자료가 일반 입력자료에 비해서 퍼지규칙의 추출이 용이하며, 실제 상황을 더욱 가깝게 설명할 수 있기 때문이다. 이러한 전문가시스템 개발에 관한 기존연구의 흐름은 다음과 같이 크게 세 가지로 유형으로 요약할 수 있을 것이다.

- 유형 1 : 인공신경망
 - 유형 2 : 인공신경망과 규칙추출
 - 유형 3 : 퍼지인공신경망
- 유형 1은 일반적인 인공신경망 학습기법을 전문가 지식이 필요한 분야에 활용하는 연구를 의미한다. [3, 5, 9, 11, 20, 22, 27, 31].
- 유형 2는 인공신경망으로부터 규칙을 추출하여 전문가시스템 지식베이스로 활용하는 연구이다. [11, 12, 14, 15, 21]
- 유형 3은, 퍼지이론을 인공신경망에 접목함으로써 인공신경망의 추론능력과 설명력을 높이고자 한 연구를 의미한다. 여기에는 퍼지규칙과 인공신경망의 결합이 포함되어있다. [1, 2, 4, 6, 7, 8, 10, 13, 16, 17, 18, 19, 23, 24, 25, 26, 28, 29, 30, 32].

이러한 연구방법론을 이용한 전문가시스템은 다음과 같은 장점을 가지고 있다.

첫째, 퍼지규칙을 이용하여 실제 상황과 유사한 추론이 가능하다. 둘째, 퍼지규칙에 의한 인공신경망 추론결과의 설명이 가능하다.

접수일자 : 2000년 5월 23일

완료일자 : 2001년 2월 20일

- 셋째, 퍼지인공신경망을 이용한 불확실성하의 추론이 가능하다.
그러나, 위의 기존연구들은 다음과 같은 단점들도 갖고 있다.
- 첫째, 퍼지멤버십 함수를 시스템 구축 전에 미리 정의해 놓기 때문에 기존의 데이터베이스와 연동된 동적인 퍼지 멤버십 함수 결정이 어렵다.
- 둘째, 퍼지지식베이스가 단순히 인공신경망의 추론결과만을 설명하는데 사용될 뿐, 실제적으로 전문가나 일반 의사결정자의 추론에 활용되지 않는다.
- 셋째, 전문가시스템 퍼지지식베이스와 퍼지인공신경망의 결합을 통한 퍼지지식베이스의 동적인 업데이트 능력을 고려하지 않았다.
- 넷째, 퍼지인공신경망에서 퍼지규칙을 추출하는 경우, 향후 퍼지지식베이스의 크기와 확장성을 고려하여 퍼지지식베이스를 최적화하는 연구가 미흡하다..
- 다섯째, 퍼지인공신경망은 비선형 문제를 해결할 수 있다는 장점을 갖고 있음에도 불구하고, 기존의 연구들이 대부분 패턴인식, 음성인식과 같은 단순 클러스터링 자료를 사용하여 실험결과들을 밝히고 있다.

지금까지의 기존연구 조사를 통해서 알 수 있는 것은 전문가시스템에 상황적응성을 부여하기 위해서는 전문가시스템의 가장 중요한 부분인 지식베이스를 주변환경과의 지속적인 정보교환을 통하여 수정 및 보완하는 메커니즘이 필요하다는 것이다. 그러나, 지금까지의 기존연구들을 살펴보면 몇 가지 형태의 규칙추출 방법들은 제시하고 있으나, 불확실성을 포함하고 있는 과거 자료에 대한 학습과 이를 통한 규칙의 추출 및 프루닝, 그리고 지식베이스 생성과 지속적인 유지보수 방법에 대한 일련의 하이브리드 형태의 메커니즘은 제공하지 못하고 있다. 특히, 시간이 지남에 따라서 인공신경망의 학습자료는 증가하는데 이에 따라서 규칙들을 추출하고 과거에 사용하던 지식베이스내의 지식들과 충돌하는 지식들을 제거하고 갱신하는 작업들에 대한 연구는 부족한 편이다. 따라서, 본 연구에서는 상황의 변화에 따라 전문가시스템 지식베이스의 규칙들을 새롭게 생성, 확장 또는 세련화 하는 과정을 통하여 규칙의 수와 범위를 변화시켜 나갈 수 있는 퍼지인공신경망과 퍼지규칙 추출 알고리즘 기반의 상황적응 메커니즘을 제안하고자 한다. 이와 같은 기존연구의 장단점과 본 연구에서 제시하고자 하는 전문가시스템의 상황적응 메커니즘의 지원 기능을 비교·정리하면 다음 [표 1]과 같다.

표 1. 기존연구와 본 연구의 비교

기능	모형	전문가시스템 모형			
		유형1	유형2	유형3	유형4
클러스터링		○	○	○	○
자료에 대한 자동학습		○	○	○	○
시계열자료 예측		○	○	△	○
퍼지규칙 추출		×	×	△	○
동적인 퍼지멤버십함수의 계산		×	×	△	○
데이터마이닝 지원		○	○	○	○
퍼지지식베이스와 인공신경망의 하이브리드 추론		×	×	×	○
인공신경망 학습에 의한 퍼지지식베이스의 자동 업데이트		×	×	×	○
퍼지지식베이스의 최적화		×	×	△	○

- 유형 1 : 인공신경망
- 유형 2 : 인공신경망과 규칙추출

- 유형 3 : 퍼지인공신경망
- 유형 4 : 상황적응 퍼지지식베이스 (본 연구에서 제안함)
- ○ : 연구가 활발한 상태
- △ : 일부 연구가 이루어진 상태

[표 1]의 내용을 다시 한번 정리하면, 기존의 연구들은 추론과정에서 동적인 퍼지멤버십 함수의 계산과 퍼지지식베이스와 인공신경망의 하이브리드 추론기능에 대한 연구가 미흡하다. 그리고, 이 밖에도 인공신경망 학습에 의한 퍼지지식베이스의 자동 업데이트와 퍼지지식베이스 최적화에 관한 연구가 미흡한 실정이다. 따라서, 본 연구에서는 위에서 언급한 기존연구들이 갖는 장점들을 충분히 살리면서도, [표 1]의 모형4와 같이 단점들을 보완한 전문가시스템의 상황적응 메커니즘을 제시하고자 한다.

본 연구에서 제안하는 전문가시스템은 크게 퍼지인공신경망과 퍼지지식베이스를 기반으로 한 퍼지지식 획득계층과 사용자인터페이스, 추론 및 검증모듈을 기반으로 한 추론계층으로 나뉘어져 있다[그림 1]. 특히, 본 연구에서는 전문가시스템의 상황적응성을 제고하기 위하여 퍼지인공신경망으로부터 퍼지규칙을 추출하는 알고리즘과 퍼지규칙을 프루닝하는 알고리즘을 제시한다. 퍼지규칙 추출 알고리즘은 퍼지인공신경망이 상황변화에 따라 획득한 동적 지식을 If-Then 형태의 퍼지규칙으로 표현하는데 매우 유용한 도구가 될 수 있으며, 프루닝 알고리즘은 규칙들간의 충돌과 중복성을 제거하여 퍼지지식베이스를 최적화 할 수 있다. 이와 같은 과정을 통하여 퍼지인공신경망과 퍼지지식베이스는 새로운 상황에 적용할 수 있는 상태로 세련화되며, 효과적인 하이브리드 추론이 가능하다. 본 연구에서는 상황적응 메커니즘과 전문가시스템의 상황적응 과정을 다음과 같이 정의하고자 한다.

“상황적응 메커니즘이란 자료의 퍼지화, 인공신경망 학습, 퍼지규칙 추출 알고리즘 및 퍼지규칙에 대한 프루닝 알고리즘을 이용하여 기존의 전문가시스템의 고정화된 지식베이스를 확장해 나가는 방법이다.”

본 연구에서 제안하는 상황적응 메커니즘의 장점을 살펴보면 다음과 같다.

- 첫째, 퍼지규칙들을 기반으로 추론하므로 부적절한 정보 및 경험이 없는 자료에 대한 근사추론이 가능하다.
- 둘째, 지속적인 주변환경과의 정보교환을 통해 상황적응적 퍼지지식베이스를 구성하므로 전문가시스템의 상황적응성을 높인다.
- 셋째, 퍼지규칙 추출을 통하여 의사결정자에게 추론결과에 대한 구체적인 근거를 제공할 수 있다.
- 넷째, 퍼지규칙 추출 알고리즘을 이용하여 생성된 퍼지규칙들은 일반 전문가시스템의 지식베이스로도 활용 가능하다.
- 다섯째, 인공신경망에 의한 자료학습과 퍼지규칙 추출기능을 데이터마이닝에 활용할 수 있다.

본 연구에서 제안하는 이러한 전문가시스템의 상황적응 메커니즘을 그림으로 도시하면 다음 [그림 1]과 같다.

[그림 1]의 상황적응 메커니즘에서 주요기능을 정리하면 다음과 같다.

- 첫째, 퍼지지식 획득계층의 퍼지인공신경망 모듈에서는 퍼지 멤버십함수를 이용하여 입력력 자료값을 퍼지화 한 후에, 퍼지인공신경망과 역전파(BP: backpropagation) 학습 알고리즘을 이용하여 자료를 학습한다.
- 둘째, 퍼지인공신경망의 학습이 완료된 후에는 퍼지지식베이스

스 모델에서 퍼지규칙 추출 알고리즘을 이용하여 퍼지 인공신경망 내부에 저장된 정보를 정형화된 퍼지규칙 형태로 추출한다. 특히, 퍼지지식베이스 모듈은 향후 환경변화에 따라 추가되는 퍼지지식과 기존의 퍼지지식베이스를 비교하여 퍼지지식베이스를 정제하고 관리한다.

셋째, 퍼지규칙을 이용하여 퍼지지식베이스를 구축하고, 프루닝 알고리즘을 이용하여 퍼지지식베이스를 세련화한다.

넷째, 퍼지지식베이스를 이용하여 실제 사례를 추론하고, 추론의 성과를 검증한다.

다섯째, 적절한 추론결과를 얻을 수 없는 경우에는 퍼지인공신경망 추론을 실시하고, 그 결과를 다시 퍼지지식베이스에 저장한다.

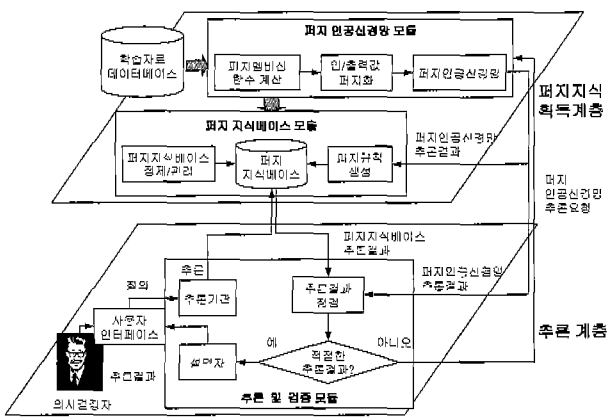


그림 1. 전문가시스템 상황적응 메커니즘

이를 위한 본 논문의 구성은 다음과 같다. 2장에서는 인공신경망 입·출력값들을 퍼지화하는 기법에 대해서 설명한다. 3장에서는 퍼지인공신경망으로부터 퍼지규칙을 추출하는 방법을 소개한다. 4장에서는 본 연구에서 제시하는 퍼지인공신경망과 퍼지규칙 추출 알고리즘 기반의 상황적응 메커니즘을 기업도산 자료에 이용하여 기존의 실험들과 비교해 봄으로써 예측력을 검증해 보기로 한다. 5장에서는 결론 및 향후연구 방향을 제시하기로 한다.

2. 인공신경망 입·출력값의 퍼지화

본 연구에서는 다음과 같은 세 가지 형태의 입력자료와 퍼지멤버십 함수를 사용하기로 한다.

- 첫째, 숫자값(numeric value)
- 둘째, 문자값(linguistic value)
- 셋째, 숫자와 문자의 조합(numeric & linguistic)

(1) 퍼지멤버십 함수를 이용한 입력값 퍼지화

입출력값의 퍼지화에는 Mitra & Pal[23,24]의 연구에서 사용한 퍼지멤버십 함수를 사용하였으며, 입력값이 숫자인 경우와 문자인 경우, 그리고 문자와 숫자의 조합인 경우로 나누어 퍼지멤버십 함수값을 계산하는 과정은 다음과 같다.

① 문자형 입력값의 퍼지화

문자형 입력값은 L(Low), M(Medium), H(High) 세 개의

퍼지구간으로 표현하며, 각 퍼지구간에 대해서 다음과 같이 퍼지멤버십함수값을 계산한다.

$$\begin{cases} low = \{ \frac{0.95}{L}, \frac{0.6}{M}, \frac{0.03}{H} \} \\ medium = \{ \frac{0.7}{L}, \frac{0.95}{M}, \frac{0.7}{H} \} \\ high = \{ \frac{0.2}{L}, \frac{0.6}{M}, \frac{0.95}{H} \} \end{cases} \quad (1)$$

② 숫자형 입력값의 퍼지화

입력값이 숫자형으로 주어진 경우에는 다음과 같은 π -퍼지멤버십함수를 이용하여 퍼지멤버십함수값을 구한다.

$$\pi(F_j; c, \lambda):$$

위 식은 입력값 F_j 를 가지고 각 퍼지구간의 중심값(c)과 반경(λ : radius, $\lambda > 0$ 퍼지구간의 중심점에 대한 π -함수의 반경)에 의해서 퍼지멤버십함수값을 계산하는 것을 의미한다. 구체적인 계산과정은 다음과 같다.

$$\pi(F_j; c, \lambda) = \begin{cases} 2 \left(1 - \frac{|F_j - c|}{\lambda} \right)^2, & \text{for } \frac{\lambda}{2} \leq |F_j - c| \leq \lambda \quad \text{--- (a)} \\ 1 - 2 \left(\frac{|F_j - c|}{\lambda} \right)^2, & \text{for } 0 \leq |F_j - c| < \frac{\lambda}{2} \quad \text{--- (b)} \\ 0, & \text{otherwise} \quad \text{--- (c)} \end{cases} \quad (2)$$

식 (2)의 (a),(b),(c)가 의미하는 바는 다음과 같다.

- (a) 입력값과 각 퍼지구간의 중심값의 차이의 절대값이 해당 퍼지구간의 $\lambda/2$ 와 λ 사이에 해당하는 경우의 적용식
- (b) 입력값과 각 퍼지구간의 중심값의 차이의 절대값이 해당 퍼지구간의 0 과 $\lambda/2$ 사이에 해당하는 경우의 적용식
- (c) 나머지 경우는 퍼지멤버십함수값을 0에 가까운 값으로 한다. 그 이유는 해당 퍼지구간에 거의 속하지 않는다고 보기 때문이다.

다음 [그림 2]는 F값이 0.1~0.9인 경우에 식(2)를 이용하여 계산한 퍼지멤버십 함수값을 그래프로 나타낸 것이다.




그림 2. 식 (2)에 의해 계산한 퍼지멤버십 함수값 그래프

지금부터 각각의 계수값에 대한 계산과정을 살펴보기로 하자. 여기에서 c 와 λ 는 각각의 L, M, H 퍼지구간에 대해서 별도로 다음과 같이 계산한다.

• F_{jmax} : 입력패턴의 상한값 / F_{jmin} : 입력패턴의 하한값

• f_{denom} : 퍼지구간의 중첩도를 조절하기 위한 인수로서 0~1 사이값으로 한다. 이 값이 커지는 경우 λ 값이 작아 지므로 경사각이 급한 퍼지곡선이 이루어지고, 아울러 중첩영역 또한 줄어들게 된다. 따라서, 이 값은 반복적인 실험에 의하여 계산할 수 있다. 참고로 본 연구에서는 0.8을 사용하였다.

$$\lambda_{medium(F_i)} = \frac{1}{2}(F_{jmax} - F_{jmin}) \quad (3-1)$$

먼저, 입력된 학습자료 중에서 최대값과 최소값을 찾아내서 이들의 차이값을 이등분한 값을 퍼지구간 medium의 반경으로 사용한다.

$$c_{medium(F_i)} = F_{jmin} + \lambda_{medium(F_i)} \quad (3-2)$$

퍼지구간 medium의 중심값은 입력값중 최소값과 medium의 반경을 더한 값으로 한다.

$$\lambda_{low(F_i)} = \frac{1}{f_{denom}}(c_{medium(F_i)} - F_{jmin}) \quad (3-3)$$

퍼지구간 low의 반경은 medium의 중심값에서 입력값중 최소값을 뺀 값에 $1/f_{denom}$ 을 곱한 값으로 한다. 이와 유사한 방식으로 나머지 퍼지구간의 중심값과 반경을 각각 다음과 같이 구한다.

$$c_{low(F_i)} = c_{medium} - 0.5 * \lambda_{low(F_i)} \quad (3-4)$$

$$\lambda_{high(F_i)} = \frac{1}{f_{denom}}(F_{jmax} - c_{medium(F_i)}) \quad (3-5)$$

$$c_{high(F_i)} = c_{medium(F_i)} + 0.5 * \lambda_{high(F_i)} \quad (3-6)$$

③ 숫자와 문자값의 조합인 경우

먼저, 숫자에 대한 퍼지멤버십함수값을 구하고 난 후에 다음 식을 이용하여 퍼지멤버십함수값을 조정한다. 다음과 같이 다섯 가지 입력이 있는 경우, 각각의 조건에 따라 식을 적용한다. 여기에서 c_{prop} 는 각각의 c_{low} , c_{medium} , c_{high} 값을 의미한다.

■ 경우 1 :

$$\mu(\text{about } r_1) = \{\mu(r_1)\}^{1.25} \quad (4-1)$$

• 해석 1 : 숫자값 r_1 에 대한 퍼지멤버십함수값을 먼저 구한 후에, 퍼지멤버십함수값을 다시 1.25승 하여 조정된 퍼지멤버십함수값을 구한다. 나머지 경우에 대한 계산식은 다음과 같으며, 해석은 식 (4-1)과 유사하다.

■ 경우 2 :

$$\mu(\text{less than } r_1) = \begin{cases} \{\mu(r_1)\}^{1/2} & \text{if } r_1 \geq c_{prop} \\ \{\mu(r_1)\}^2 & \text{otherwise} \end{cases} \quad (4-2)$$

■ 경우 3 :

$$\mu(\text{greater than } r_1) = \begin{cases} \{\mu(r_1)\}^{1/2} & \text{if } r_1 \leq c_{prop} \\ \{\mu(r_1)\}^2 & \text{otherwise} \end{cases} \quad (4-3)$$

■ 경우 4 :

$$\mu(\text{between } r_1 \text{ and } r_2) = \{\mu(\text{less than } r_1) * \mu(\text{greater than } r_2)\}^{1/2} \quad (4-4)$$

■ 경우 5 :

$$\text{no information} = \left\{ \frac{0.5}{L}, \frac{0.5}{M}, \frac{0.5}{H} \right\} \quad (4-5)$$

(2) 퍼지멤버십 함수를 이용한 출력값 퍼지화

퍼지인공신경망 출력값에 대한 Low, Medium, High 세 개의 퍼지구간이 있고, 이들간의 중첩영역은 다음 [그림 3]과 같이 표시할 수 있다.




그림 3. 퍼지구간의 중첩영역

출력값에 대해서는 다음과 같은 퍼지멤버십 함수를 적용한다. 그리고, 계산된 퍼지멤버십함수값을 퍼지인공신경망의 기대값으로 사용한다. 예를 들어, i 번째 입력벡터 F_i 에 대한 출력값은 다음과 같은 퍼지멤버십함수를 이용하여 계산한다.

$$\mu_k(\vec{F}_i) = \frac{1}{1 + \left(\frac{Z_{ik}}{F_d}\right)^{F_e}} \quad (6)$$

Z_{ik} : i 번째 패턴과 k 번째 클래스의 평균값과의 가중치 거리

F_d : denominational fuzzy generator

F_e : exponential fuzzy generator

$d_j = \mu_j(\vec{F}_i)$: j 번째 출력노드의 기대값

(3) 2 Bit XOR(Exclusive OR) 문제에 대한 입-출력값의 퍼지화 예

입출력값의 퍼지화에 대한 예를 보이기 위하여, 간단한 2 Bit XOR 문제를 적용하여 보았다. 다음 [표 2]에서는 2개의 출력값이 있는데 첫번째 값이 0.9이면 출력값이 1이고 두번째 값이 0.9이면 출력값은 0을 의미한다. 먼저 입출력값의 퍼지화를 위하여 0은 0에 가까운 실수값인 0.1로, 1은 0.9로 표기하였다. 따라서, $F_{jmax}=0.9$, $F_{jmin}=0.1$ 이 된다. 그리고, 식 (3-1)~(3-6)을 이용하여 low, medium, high 각 퍼지구간에 대한 λ 와 c 값을 다음과 같이 구할 수 있다.

여기에서 f_{denom} 값은 0.8을 사용하였다.

$$\lambda_{medium(F_i)} = 0.50 \quad \lambda_{low(F_i)} = 0.40 \quad \lambda_{high(F_i)} = 0.50,$$

$$c_{medium(F_i)} = 0.50 \quad c_{low(F_i)} = 0.25 \quad c_{high(F_i)} = 0.75$$

이와 같이 계산된 퍼지구간값(λ 와 c)을 기초로, 식(2)의 퍼지멤버십함수를 적용하면 [표 3]과 같이 입출력값에 대한 퍼지멤버십함수값을 구할 수 있다. [표 3]의 출력값에 대한 퍼지멤버십함수값은 식(6)에 의해서 구한 것이다.

표 2. 2 Bit XOR 문제 입력자료

입력		출력(기대값)		출력 결과의 해석
0.1	0.1	0.1	0.9	(= 0)
0.1	0.9	0.9	0.1	(= 1)
0.9	0.1	0.9	0.1	(= 1)
0.9	0.9	0.1	0.9	(= 0)

표 3. 퍼지멤버십 함수에 의해 표현된 2 bit XOR 문제

입 력						출력(기대값)	
0.82	0.00	0.00	0.82	0.00	0.00	0.005	0.999
0.82	0.00	0.00	0.00	0.00	0.82	0.999	0.005
0.00	0.00	0.82	0.82	0.00	0.00	0.000	0.005
0.00	0.00	0.82	0.00	0.00	0.82	0.005	0.999

3. 퍼지인공신경망 학습과 퍼지규칙 생성

본 연구에서는 21(입력층)×20(은닉층)×2(출력층)개의 노드로 구성된 일반적인 3계층 퍼지인공신경망을 사용하였다. 퍼지인공신경망의 학습기법은 본 연구에서 검증하고자 하는 시계열 자료의 학습에 적합하며, 이미 많은 연구를 통해 그 성능을 검증 받은 오류 역전파 학습알고리즘을 사용하였다. 실험자료 및 인공신경망 모형에 대한 보다 자세한 설명은 4장 실험 및 결과에서 설명하기로 하고, 지금부터 퍼지인공신경망 학습이 완료된 후에 퍼지규칙을 추출하는 알고리즘을 살펴보기로 하자.

(1) 퍼지규칙 추출

본 연구에서는 Mitra & Pal[24]의 연구에서 사용한 퍼지규칙 추출 알고리즘을 수정하여 사용하였다. 본 연구와 Mitra & Pal[24]의 연구의 가장 큰 차이점은 이들은 일반적인 퍼지 연산자인 T-Norm(퍼지교집합)과 S-Norm(퍼지합집합) 연산을 사용하는 인공신경망으로부터 규칙을 추출하였다는 점이다. T-Norm과 S-Norm 퍼지연산자를 사용하는 경우, 인공신경망으로부터 퍼지규칙을 추출하는 것이 용이하나, 본 연구에서 실험하고자 하는 시계열 자료와 같은 경우에는 이러한 연산자를 그대로 사용할 수 없다. 그 이유는 이들 연산자가 자료의 시계열 정보를 계산할 수 없기 때문이다. 따라서, 본 연구에서는 Mitra & Pal[24]이 제시한 4단계(Input representation, forward pass, querying, justification) 퍼지규칙 추출 알고리즘을 다음과 같이 3단계의 퍼지규칙 추출 알고리즘으로 변형하여 사용하고자 한다.

- 단계 1 : 역추적에 의한 경로생성 (path generation by backtracking)
- 단계 2 : 선택된 특성들에 의한 구문생성 (clause generation)
- 단계 3 : 결과값에 대한 확신도 부여 (certainty measure)

단계별 세부 작업내용을 살펴보면 다음과 같다.

- 단계 1 : 역추적에 의한 경로생성
 - H 계층(출력층)에서 출력노드 i 에 positive한 영향을

주는 중간노드 j 를 찾는다. 즉, 연결가중치 $w_{ji}^{H-1} > 0$ 인 경우에 H-1 계층에서 노드 j를 선택한다. 이와 같은 방법으로 하면 H-1 계층에서 mH-1개의 노드에 대해 연결가중치 집합 a를 다음과 같이 정의할 수 있다.

$$\{a_1^{H-1}, a_2^{H-1}, \dots, a_{mH-1}^{H-1}\}$$

- 이와 같이 선택된 H-1계층의 j번째 노드의 연결가중치 집합은 다음과 같이 표기할 수 있다.

$$w_{j0}^{H-1}$$

- 입력층에서는 먼저, 입력노드값(y_k^{H-2})이 0.5 이상인 값을 선택한다. 그 후, 이 노드와 은닉층 노드의 연결가중치(w_{ki}^{H-2})를 출력노드에서부터 중간노드까지의 누적된 누적연결가중치(wet_{kj}^{H-1})에 더해서 합이 가장 큰 경우를 출력층에서 입력층까지의 최우선 연결선(경로)으로 선택한다. 이를 식으로 표현하면 다음과 같다.

$$y_k^{H-2} > 0.5$$

$$wet_{kj}^{H-1} = \max_{kj^{H-1}} [wet_{kj^{H-1}} + w_{kj^{H-1}}]$$

- 나머지 경로에 대한 우선순위는 다음과 같이 net impact를 계산하여 선택된 노드의 가중치 집합을 내림차순으로 정렬하여 결정한다.

$$net\ impact = y_k^{H-2} * wet_{kj}$$

■ 단계 2 : 선택된 경로에 대한 구문생성

경로생성과정에서 생성된 노드집합과 가중치집합을 사용하여, 전형적인 If-Then 형태의 규칙으로 구문을 생성하며 구문 생성시에는 다음과 같은 2가지 조건이 있다.

- 조건 1 : 다음 식이 만족할 때까지 정렬된 순서로 If-Then 규칙에 의해 구문들을 생성한다.

$$\sum_{k_s} wet_{k_s} > 2 \sum_{k_n} wet_{k_n}$$

k_s = 구문생성 단계에서 현재 선택된 노드

k_n = 구문에 의해 선택되지 않아서 현재 노드의 집합에 남아있는 나머지 입력노드

- 조건 2 : 선택된 입력노드(k)에 대한 언어적 특성을 다음 식에 의해 결정한다. 여기에서 u는 각 언어적 특성 클래스를 의미하며, u_{sl} 은 현재 선택된 클래스를 의미한다.

$$u_1 = (k_1 - 1) \bmod 3 + 1$$

$$prop = \begin{cases} low & \text{if } k_{sl} - 3(u_{sl} - 1) = 1 \\ medium & \text{if } k_{sl} - 3(u_{sl} - 1) = 2 \\ high & \text{otherwise} \end{cases}$$

이상과 같이 선택된 노드들에 대해 특성값을 결정한다. 그리고, 퍼지규칙의 AND 구문은 각 입력속성에 대해서 기본적으로 사용하며, OR 구문은 입력값의 퍼지구간이 중첩될 때 사용한다.

■ 단계 3 : 출력값에 대한 확신도 부여

출력값에 대한 확신도(certainty measure)는 일반적으로 다음 식과 같이 구한다.

$$cert_i^H = \frac{y_i^H}{\sum_{i=1}^m y_i^H} \quad (7)$$

식 (7)은 j번째 출력노드의 값(y_j)을 모든 출력노드의 합으로 나누는 것을 의미한다. 그리고, 확신도의 크기에 따라서 5가지 linguistic hedge를 부여한다.

- 경우 1: *very likely for* $0.8 \leq cert_i^H \leq 1$
- 경우 2: *likely for* $0.6 \leq cert_i^H < 0.8$
- 경우 3: *more or less likely for* $0.4 \leq cert_i^H < 0.6$
- 경우 4: *not likely for* $0.1 \leq cert_i^H < 0.4$
- 경우 5: *unable to recognize for* $cert_i^H < 0.1$

다음 표 4는 이러한 단계별 퍼지규칙 추출과정을 의사코드로 표현한 것이다.

표 4. 학습된 퍼지인공신경망으로부터의 퍼지규칙 추출과정

```

퍼지규칙 추출():
{
  for(i=0; i < 출력층 노드; i++)
    노드집합1 = 출력층에서의 승자노드;

  for(j=0; j < 출력층의 승자노드 수; j++) {
    for(i=0; i < 중간층 노드; i++) {
      노드집합2 = 승자노드와 연결된 중간층 노드중에서
      연결가중치가 양수인 노드
      누적가중치 집합1 = 노드집합 2에 속하는 중간층
      노드들의 승자노드와의 연결가중치값
    }

    for(i=0; i < 노드집합 2; i++) {
      for(j=0; j < 입력층 노드; j++) {
        노드집합3 = 노드집합 2의 노드들과 연결된 입력층
        노드중에서 연결가중치가 양수인 노드
        누적가중치 집합2 = 누적가중치집합 1의 i 번째
        연결가중치값 + 노드집합 3에 속하는 입력층
        노드들의 노드집합 2와의 연결가중치값
      }

      누적가중치 집합 2의 오름차순 정렬();

      for(i=0; i < 누적가중치 집합 2; i++) {
        if(동일한 노드에서 두개의 퍼지특성이 선택된 경우)
          OR 구분생성;
        else i 번째 입력노드의 특성에 의한 If 구분생성;
        if(현재 퍼지규칙생성에 사용된 연결가중치의 합 > (아직
        규칙생성에 쓰이지 않는 연결가중치의 합 * 2)) break;
      }
    } /* 퍼지규칙 추출의 기본 과정 */
  }
}
    
```

지금까지 퍼지규칙 추출 알고리즘에 대해서 살펴보았다.

(2) 퍼지규칙의 세련화

퍼지지식의 세련화에 대해서 살펴보기로 하자. 본 연구에서는 퍼지지식을 세련화하기 위하여 Liu[21]와 Setnes[28]가 제안한 퍼지규칙 프루닝 알고리즘을 확장한 개선된 프루닝 알고리즘을 제안한다. 그 이유는 이들 연구에서 퍼지규칙의 우선 순위와 중요도가 고려되지 않았기 때문에, 실제로 중요한 규칙이 제거될 수도 있기 때문이다. 그러나, Liu[21]가 제안한 프루닝 알고리즘이 동일한 퍼지규칙을 제거하고, Setnes[28]의 연구에서도 마찬가지로 퍼지규칙의 유사도를 측정하는 것은 매우 중요한 공헌이라고 할 수 있다. 따라서, 본 연구에서는 출력값의 확신도(CF)를 기준으로 다음 [표 5]와

같은 개선된 프루닝 알고리즘을 제안하고자 한다.

표 5. 유전자 알고리즘을 사용한 구조적 자기구성 지도의 최적화 퍼지규칙 프루닝 알고리즘

```

sort-on freq(Data-without-Duplicates);
Rule Generation:
I = 0;
while (Data is NOT marked)
  generate shortest Ri (i'th Rule) to cover the current
  pattern and differentiate it from patterns in other categories;
  mark all the patterns covered by Ri;
  I++;

Rule Clustering:
cluster rules according to their class labels;
Rule Pruning:
1. replace general rules with more specific one;
2. remove noise rules;
3. eliminate redundant rules;
4. eliminate conflict rules;

Eliminate Conflict Rules:
1. compute certainty factor;
2. compare certainty factor;
3. remove the rule which have low CF;
    
```

규칙의 유사성과 중복성은 다음과 같이 유사도(similarity measures)를 측정하여 제거한다.

$$s = S(A,B) = \frac{1}{1 + D(A,B)}, \quad s \in (0, 1]$$

여기에서 A, B는 두 개의 퍼지구간에 대한 멤버십값을 의미하며, D()는 두 개의 퍼지구간의 Distance를 구하는 함수를 의미한다 (Gustafson & Kessel 1979).

$$D_r(A, B) = \left(\sum_{j=1}^m |\mu_A(x_j) - \mu_B(x_j)|^r \right)^{\frac{1}{r}}, \quad r \geq 1$$

위 식에서 r은 상수값이고, μ 는 퍼지멤버십 함수를 의미한다. 이 밖에 퍼지지식베이스 내에서 일반규칙(general rule)과 특수규칙(specific rule), 노이즈 규칙(noise rule), 중복규칙(redundant rule)은 다음 [그림 4]와 같은 개념하에서 제거하였다.




그림 4. 퍼지규칙의 세련화 기준

위의 그림에서 보면 A, B, C, D 네 개의 퍼지규칙에 의해 생성된 퍼지구간이 보이는데 이 중에서 C는 일반규칙으로 볼 수 있고, A, B는 특수규칙이라고 볼 수 있다. 따라서, 이 경우에는 C를 버리고 A, B 만을 지식베이스에 남겨 놓는다. 그리고, D같은 경우에는 A와 중복되는 것을 볼 수 있으며,

경우에 따라서 D는 B와 겹치는 부분이 많기 때문에 A 입장에서 보면 노이즈 규칙이라고도 볼 수 있다. 따라서, 이러한 규칙 D는 제거한다. 충돌규칙(conflict rule)은 위의 [그림 4]에서 A와 B를 동시에 가리키는 규칙을 의미하고, 이 경우에는 확신도 값이 큰 쪽의 퍼지규칙을 남기고, 나머지는 제거한다.

(3) 2 bit XOR 문제를 이용한 퍼지규칙 추출

[표 3]의 XOR 문제를 퍼지인공신경망으로 학습한 후 생성된 퍼지규칙이 [표 6]에 정리되어 있다.

표 6. 2 bit XOR 문제에 의해 생성된 퍼지규칙

입력값	생성된 규칙	확신도
0.1 0.1	IF F1 = low AND F2 = low Then class = very_likely_for_2	97.48
0.1 0.9	IF F2 = high AND F1 = low Then class = very_likely_for_1	97.92
0.9 0.1	IF F1 = high AND F2 = low Then class = very_likely_for_1	97.75
0.9 0.9	IF F2 = high AND F1 = high Then class = very_likely_for_2	98.04

학습된 자료 이외에 새로운 자료가 입력될 경우 먼저, 퍼지지식베이스에 의해 추론을 실시한다. 퍼지지식베이스에서 적절한 추론이 이루어지지 못한 경우에는 새로운 자료를 이용하여 퍼지인공신경망을 재학습한 후 새로운 퍼지규칙을 생성한다. 추가로 사용된 입력자료와 이 때, 생성된 퍼지규칙들이 [표 7]에 정리되어 있다.

표 7. 새로운 2 bit XOR 입력패턴에 의해 생성된 규칙 (*: 새롭게 생성된 규칙)

입력값	생성된 규칙	확신도
0.4 0.6	* IF F2 = high OR F2 = medium AND F1 = low OR F1 = medium Then class = very_likely_for_1	97.84
0.5 0.5	* IF F2 = medium AND F1 = medium Then class = very_likely_for_2	86.96
0.7 0.6	* IF F2 = high OR F2 = medium AND F1 = high Then class = very_likely_for_2	97.76
0.2 0.3	IF F1 = low AND F2 = low Then class = very_likely_for_2	98.21
0.1 0.9	IF F2 = high AND F1 = low Then class = very_likely_for_1	97.92
0.7 0.8	IF F2 = high AND F1 = high Then class = very_likely_for_2	98.72
0.1 0.2	IF F1 = low AND F2 = low Then class = very_likely_for_2	97.74
0.4 0.3	* IF F1 = low OR F1 = medium Then class = very_likely_for_2	97.41

4. 실험 및 결과

학습자료는 국내기업의 도산/비도산을 예측하기 위한 자료이며 79년부터 91년까지의 과년도 자료 중 79년에서 84년까지의 자료를 기초로 만들어졌다. 전체 66개 입력자료로 구성되어 있으며 각 입력자료는 7가지 재무비율의 입력값과 2개의 도산/비도산의 출력값으로 구성되어 있다. 실험에 사용된 자료를 살펴보면 84년도 상반기 자료를 학습자료로 사용하였고 84년도 하반기 자료를 검증자료로 사용했다.

표 8. 재무비율 특성표

구분	재무비율
성장성	순이익증가율
수익성	총자본경상이익율
	배당율
안정성	자기자본비율
유동성	당좌비율
활동성	자기자본회전율
	고정자산회전율

표 9. 퍼지화 하기 전의 기업도산자료 예

입력	출력
-1.21 0.77 0.72 0.88 0.96 1.14 1.39	0.1 0.9

[표 9]에서 출력값이 0.1, 0.9인 경우에는 클래스1(도산)을 의미하고, 0.9, 0.1인 경우에는 클래스2(비도산)를 의미한다. 다음 [표 10]은 기업도산 자료를 퍼지화한 값을 보여준다. 입력노드의 각 특성은 3차원특성으로 바뀌고, 출력노드값은 멤버십값으로 계산된다. 그러므로, 전체 입력노드수는 21(7×3)개이며 출력노드수는 2개가 된다. 이 구조는 인공신경망의 구조를 말하기도 한다. 실험에 사용된 퍼지인공신경망의 구조는 입력층(21) × 중간층(20) × 출력층(2) 으로 이루어져 있다.

표 10. 퍼지화 후의 기업도산자료 예(퍼지인공신경망 학습자료)

<입력값>	0.859 0.828 0.010 / 0.010 0.100 0.880 / 0.010 0.100 0.990 / 0.010 0.100 0.881 / 0.010 0.745 0.908 / 0.010 0.100 0.977 / 0.010 0.100 0.957
<출력값>	0.004975 0.999800

위와 같은 퍼지 입력자료를 퍼지인공신경망을 이용하여 학습한 후, 다시 2차로 퍼지지식베이스 모듈에서 퍼지규칙을 생성한다. 이 때, 퍼지규칙은 If-Then 형태로 생성하여 전문가시스템의 초기 퍼지지식베이스를 구축한다. 전체 66개 학습자료에 대해서 생성된 규칙들 중에서 동일규칙, 유사규칙, 충돌규칙들은 앞에서 언급한 프루닝 알고리즘을 이용하여 제거하였다. 그 결과, 학습자료 66개에 대해서 총 32개의 퍼지규칙이 생성되었으며 여기에 대한 예는 다음 [표 11]과 같다.

[표 11]에서 CNF는 확신도를 의미한다. 이와 같이 초기 퍼지지식베이스를 구축한 후에 전문가시스템에 사용자에게 의해서 새로운 입력값(질의)이 추가로 주어진 경우에는 새로운 입력값을 참고로 전문가시스템 퍼지지식베이스와 퍼지인공

표 11. 기업도산자료에 의해 생성된 퍼지규칙 예

```

RULE 1
IF   F3 = high
    AND F5 = high
    OR  F5 = medium
    AND F7 = medium
Then class = very_likely_for_1 CNF 98.68;

RULE 2
IF   F2 = high
    AND F1 = low
    OR  F1 = medium
    AND F5 = medium
    OR  F5 = high
Then class = very_likely_for_2 CNF 99.23;

RULE 3
IF   F2 = high
    AND F5 = medium
    OR  F5 = high
    AND F7 = high
    OR  F7 = medium
Then class = very_likely_for_2 CNF 97.69;

RULE 4
IF   F3 = high
    AND F5 = low
    OR  F5 = medium
    AND F7 = high
Then class = very_likely_for_1 CNF 95.93;
    
```

신경망을 이용하여 추론을 진행하며, 올바른 추론결과에 도달하지 못한 경우에는 퍼지인공신경망을 이용하여 추론과 재학습을 실시한다. 퍼지인공신경망의 재학습이 완료된 후에는 새로운 퍼지규칙을 추출하여 기존의 퍼지지식베이스를 확장한다. 실험에서는 총 100개의 추가 실험자료에 의해서 41개의 퍼지규칙이 생성되었다. 그러나, 이를 프루닝 알고리즘을 이용하여 기존의 퍼지지식베이스와 결합한 결과 최종적으로 총 34개의 퍼지규칙을 가지는 퍼지지식베이스로 확장할 수 있었다. 이러한 결과는 프루닝에 의해서 대부분의 규칙들이 갖고 있는 충돌과 중복성이 제거되었기 때문에 얻을 수 있는 결과이다. 따라서, 프루닝이 지식베이스 유지에서 차지하는 의미는 대단히 중요하다고 볼 수 있다. 단, 여기에서 주의할 점은 기존의 퍼지지식베이스와 새로운 퍼지규칙들을 결합할 때, 규칙들의 우선순위를 결정하는 문제가 전문가시스템의 예측력을 크게 좌우한다는 것이다. 따라서, 본 연구에서는 여러 번의 실험 과정에서 규칙의 우선순위를 바꾸면서 학습자료에 대한 예측력을 비교하였고 그 결과, 최고의 예측력을 갖는 최종적인 퍼지지식베이스를 구축할 수 있었다. 다음 [표 12]는 생성된 퍼지규칙의 일부 예이다.

이와 같은 퍼지지식베이스의 상황적응 메커니즘은 전문가시스템의 예측력을 높이는데 매우 커다란 영향을 준다. 본 논문에서 제안한 상황적응 메커니즘은 기존의 전문가시스템 지식베이스의 유지, 보수에 대한 수고를 덜어주며 예측에 대한 효율성을 높여준다. 다음 [표 13]은 [표 10]과 같은 형태의 기업도산 자료를 본 연구에서 제안한 상황적응 퍼지지식베이스를 이용해서 예측한 결과를 기존의 세 가지 모형에 의한 예측결과와 비교한 것이다.

표 12. 기업도산에 관한 새로운 실험자료에 의해 추가되는 퍼지규칙의 예

```

RULE 1
IF   F5 = high
    OR  F5 = medium
    AND F1 = medium
    OR  F1 = high
    AND F6 = high
Then class = likely_for1 CNF 70.96;

RULE 2
IF   F5 = high
    AND F1 = medium
    OR  F1 = low
    AND F6 = high
Then class = very_likely_for_1 CNF 92.99;
    
```

표 13. 4가지 모형의 예측력의 비교

추론 방법	일반 인공신경망 (모형1)	퍼지 인공신경망 (모형2)	퍼지 지식베이스 (모형3)	상황적응 퍼지지식베이스 (모형4)
평균 예측력	73/100 (73 %)	72/100 (72 %)	75/100 (75 %)	80/100 (80 %)

[표 13]의 실험결과는 각각의 모형에 대해서 반복실험을 실시한 후에 얻은 평균예측력이다. 이를 자세히 살펴보면, 본 연구에서 제안하는 상황적응 퍼지지식베이스(모형4)에 의한 예측력이 기존 모형의 예측력보다 우수한 것을 확인할 수 있다. 본 연구에서는 추가로 모형간의 평균예측력의 차이를 통계적으로 검증하기 위하여 비모수검정방법에서 ANOVA에 해당하는 크루스칼-왈리스(Kruskal-Wallis) 검증을 실시하였다. 검증결과를 정리하면 다음 [표 14]와 같다.

표 14. 크루스칼-왈리스 검증

순위			
	모형	N	Mean Rank
SCORE	1	5	7.30
	2	5	5.00
	3	5	11.70
	4	5	18.00
	Total	20	
검정통계량 (집단변수: 모형)		SCORE	
Chi-Square		14.143	
df		3	
Asymp. Sig.		.003	
Exact Sig.		.000	
Point Probability		.000	

위의 [표 14]를 보면 본 연구에서 제안하는 4번째 모형이 가장 평균예측력이 좋을 수 있다. 즉, 각 방법별 평균순위위가 모형 4의 경우 18로서 모형 1,2,3과 비교해 볼 때 각각 11,13,7의 큰 차이를 보이고 있다. 그리고, 네가지 모형의 평균 예측력의 차이를 검증한 결과, 근사유의도가 0.003, 정확한 유의도가 0.000으로서 5% 유의수준에서 모형간의 평균예측력에 통계적으로 유의한 차이가 있음을 알 수 있다. 따라서, 본 연구에서 제안한 상황적응 메커니즘의 평균예측력이 나머지 모형1,2,3에 비해 통계적으로 유의하게 높다는 것을 증명하였다. 여기에 추가로 평균예측력의 차이가 비교적 적

은 모형3과 모형4에 대해서 보다 정확한 예측력의 차이를 검증하기 위하여 비모수검정에서 사용하는 두평균간의 차이를 검증하는 방법인 콜모고로프-스미르노프 (Kolmogorov-Smirnov) 방법을 적용한 결과는 다음 [표 15]와 같다.

표 15. 콜모고로프-스미르노프 검정

SCORE		
Most Extreme Differences	Absolute	1.000
	Positive	1.000
	Negative	.000
	Kolmogorov-Smirnov Z	1.581
	Asymp. Sig. (2-tailed)	.013
	Exact Sig. (2-tailed)	.008
	Point Probability	.008

위의 결과를 보면 역시 정확한 유의도가 0.008로서 이 또한, 5% 유의수준에서 모형간의 평균예측력의 차이가 확실히 있음을 알 수 있다. 이상 [표 14]와 [표 15]에서 본 바대로 본 논문에서 제안하는 모형인 상황적응 퍼지지식베이스 모형이 나머지 다른 모형들 보다 (즉, 일반 인공신경망모형, 퍼지인공신경망모형, 퍼지지식베이스 모형) 더 예측력이 좋음이 통계적으로 검증되었다.

5. 결론 및 향후 연구방향

본 연구실험 결과 퍼지인공신경망 전문가시스템의 상황적응 메커니즘은 다음과 같은 장점과 공헌도를 가진다는 것을 알 수 있다.

- 첫째, 퍼지값과 퍼지규칙을 이용하여 추론을 실시하고, 실제계에 제공하는 불확실한 정보 및 부정확한 자료에 대한 근사추론이 가능하다.
- 둘째, 퍼지인공신경망의 추론근거를 퍼지규칙을 통하여 설명이 가능하므로, 추론과정에 대한 설명이 가능하다.
- 셋째, 퍼지인공신경망으로부터 퍼지규칙을 추출하여 퍼지지식베이스를 자동 구성하므로, 기존의 전문가시스템 지식베이스로도 활용 가능하다.
- 넷째, 퍼지인공신경망을 이용하여 신규 자료에 대한 학습이 가능하고, 이와 함께 퍼지지식베이스의 세련화 작업이 연결 가능하므로, 전문가시스템 지식베이스의 상황적응성을 향상시킨다.
- 다섯째, 학습이 종료된 퍼지인공신경망에 잘못된 실험자료가 입력되는 경우에도, 인공신경망이 기본적으로 갖고 있는 견고성과 프루닝 알고리즘을 기반으로 이를 보정할 수 있는 능력이 있다.
- 여섯째, 프루닝 알고리즘을 이용하여 퍼지인공신경망에서 추출된 퍼지규칙들간의 충돌 및 중복성 문제를 해결하고, 퍼지지식베이스를 최적화 할 수 있다.

그러나, 본 논문에서 제공하는 전문가시스템 상황적응 메커니즘은 다음과 같은 몇 가지 한계점이 있다.

- 첫째, 환경 변화에 따른 퍼지인공신경망 구조의 동적인 변형을 고려하지 않았기 때문에, 이러한 경우에는 인공신경망 모형을 변경해야 하고, 따라서 퍼지지식베이스 전체도 변형해야 한다는 부담이 있다.
- 둘째, 다양한 입력자료에 대한 퍼지구간의 확장을 고려하지

않고 있다.

셋째, 전문가시스템 추론에서는 기존의 인간 전문가지식이 중요함에도 불구하고, 이를 퍼지지식베이스와 연결하는 방법이 고려되지 않았다.

따라서, 본 연구에 대한 향후 연구방향으로는 다음과 같은 것을 제시할 수 있다.

- 첫째, 환경 변화에 따른 퍼지구간의 확장 및 변화에 대한 연구 둘째, 퍼지인공신경망 구조의 변형에 따른 퍼지지식베이스의 동적인 변형에 관한 연구
- 셋째, 기존의 다수 전문가 지식과 퍼지지식베이스를 결합하는 경우, 이를 충돌없이 결합하는 알고리즘에 대한 연구 등이 필요하다.

참 고 문 헌

- [1] 광근창, 이대중, 유정용, 전병근, "CFCM과 퍼지 군동화를 이용한 퍼지규칙의 자동생성," *한국 퍼지 및 지능시스템학회 논문지*, 제10권, 3호, pp. 194-202, 2000.
- [2] 이말래, 황수철, 김기태, "퍼지 IF-THEN 규칙의 자기동조법(A Self-tuning Method of Fuzzy IF-THEN Rules)", *한국정보과학회논문지*, vol.21, No.9, pp. 1683-1691, 1994.
- [3] 이진창, 김명종, 김혁, "기업도산 예측을 위한 귀납적 학습지원 인공신경망 접근방법: MDA, 귀납적 학습 방법, 인공신경망 모형과의 성과비교", *경영학 연구*, 제23권 제2호, pp. 109-144, 1994.
- [4] 이승준, 주영훈, 박진배, "바이러스-진화 유전 알고리즘을 이용한 퍼지 모델링," *한국 퍼지 및 지능시스템학회 논문지*, 제10권, 5호, pp. 432-441, 2000.
- [5] 정용관, 윤영섭, "인공신경망 모형을 이용한 주가의 예측가능성에 관한 연구," *재무관리연구*, 제15권 제2호, pp. 369-399, 12월 1998.
- [6] 정혜천, 권순학, 이말래, "경제 신경회로망에 의한 계층적 퍼지 클러스터링," *한국 퍼지 및 지능시스템학회 논문지*, 제10권, 1호, pp. 1-5, 2000.
- [7] 조성원, "신경망과 퍼지논리를 이용한 최대수요전력 제어시스템에 관한 연구," *한국 퍼지 및 지능시스템학회 논문지*, 제9권, 4호, pp. 420-425, 1999.
- [8] Belarbi, K. and Titel, F., "Genetic Algorithm for the Design of a Class of Fuzzy Controllers: An Alternative Approach," *IEEE Transactions on Fuzzy Systems*, vol. 8, no. 4, pp. 398-405, August 2000.
- [9] Bell, T.B., "Neural Nets or the Logit Model? A Comparison of Each Model's Ability to Predict Commercial Bank Failures," *Intelligent Systems in Accounting, Finance and Management*, vol. 6, pp. 249-264, 1997.
- [10] Cai, L.Y. and Kwan, H.K., "Fuzzy Classification using Fuzzy Inference Networks," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 28, no. 3, pp. 334-347, June 1998.
- [11] Fu, L.M., "Rule Learning by Searching on Adapted Nets", *Proceedings of the AAAI*, pp. 590-595, 1991.

- [12] _____, "Knowledge-Based Connectionism for Revising Domain Theories", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 1, pp.173-182, January 1993.
- [13] Halgamuge, S.K. and Glesner, M., "Neural Networks in Designing Fuzzy Systems for Real World", *Fuzzy Sets and Systems*, vol. 65, pp. 1-12, 1994.
- [14] Hayashi, Y., "A Neural Expert Systems with Automated Extraction of Fuzzy If-Then Rules and Its Application to Medical Diagnosis", *Advances in Neural Information Processing Systems(NIPS)*, vol. 3, Edited by R. P. Lippman, J. E. Moody and D. S. Touretzky, pp. 578-584, 1991a.
- [15] _____, "An Architecture for Hybrid Expert Systems", *Proceedings of International Joint Conference on Neural Networks*, Singapore, pp. 2773-2778, November 1991b.
- [16] Hirota, K., "OR/AND Neuron in Modeling Fuzzy Set Connectives", *IEEE Transactions on Fuzzy systems*, vol. 2, no. 2, pp. 151-161, May 1994.
- [17] Isshiki, H., and Endo, H., "Learning of Expert's Knowledge by Neural Network and Deduction of Fuzzy Rules by Powell's Method", *Proceedings of the 2nd International Conference on Fuzzy Logic & Neural Networks*, pp. 95-98, 1992.
- [18] Jang, J.S.R., "ANFIS : Adaptive-Neural-Network-Based Fuzzy Inference System", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665-685, May/June 1993.
- [19] Juang, C.F. and Lin, C.T., "An On-Line Self-Constructing Neural Fuzzy Inference Network and Its Applications," *IEEE Transactions on Fuzzy Systems*, vol. 6, no. 1, pp.12-32, February 1998.
- [20] Lee, K.C., Han, I., and Kwon, Y., "Hybrid Neural Network models for Bankruptcy Predictions", *forthcoming in Decision Support Systems*, 18, pp. 63-72, 1996.
- [21] Liu, H., "Efficient Rule Induction from Noisy Data," *Expert Systems With Applications*, vol. 10, no. 2, pp. 275-280, 1996.
- [22] Maher, J.J. and Sen, T.K., "Predicting Bond Ratings Using Neural Networks: A Comparison with Logistic Regression," *Intelligent Systems in Accounting, Finance and Management*, vol. 6, pp. 59-72, 1997.
- [23] Mitra, S. and Pal, S. K., "Self-Organizing Neural Networks As a Fuzzy Classifier", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 24, no. 3, pp. 385-399, March 1994a.
- [24] _____, _____, "Logical Operation Based Fuzzy MLP for Classification and Rule Generation", *Neural Networks*, vol. 7, no. 2, pp. 353-373, 1994b.
- [25] Pal, N.R. and Pal, T., "On Rule Pruning using Fuzzy Neural Networks," *Fuzzy Sets and Systems*, vol. 106, pp. 335-347, 1999.
- [26] Pedrycz, W., "A Referential Scheme of Fuzzy Decision Making and Its Neural Network Structure", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 21, no. 6, pp. 1593-1604, November/December 1991.
- [27] Schumacher, M., Robner, R., and Vach, W., "Neural Networks and Logistic Regression: Part I," *Computational Statistics & Data Analysis* 21, pp. 661-682, 1996.
- [28] Setnes, M., "Supervised Fuzzy Clustering for Rule Extraction," *IEEE Transactions on Fuzzy Systems*, vol. 8, no. 4, pp. 416-424, August 2000.
- [29] Shann, J.J. and Fu, H.C., "A Fuzzy Neural Network for Rule Acquiring on Fuzzy Control System," *Fuzzy Sets and Systems*, vol. 71, pp. 345-357, 1995.
- [30] Takagi, H. and Hayashi, I., "NN-Driven Fuzzy Reasoning", *International Journal of Approximate Reasoning*, vol. 5, pp. 191-212, 1991.
- [31] Tsujino, K, and Nishida, S., "Integration of Decision Trees and Neural Networks for Hybrid Knowledge Acquisition", *Proceedings of Japan/Korea International Joint Conference on Expert Systems*, pp. 17-22, 1994.
- [32] Yen, J. and Wang, L., "Application of Statistical Information Criteria for Optimal Fuzzy Model Construction," *IEEE Transactions on Fuzzy Systems*, vol. 6, no. 3, pp. 362-372, August 1998.
- [33] Zadeh, L.A., "The Role of Fuzzy Logic in The Management of Uncertainty in Expert Systems," *Fuzzy Sets and Systems*, 11, pp. 199-227, 1983.

저 자 소 개



이건창 (Lee Kun-chang)

현재 성균관대학교 경영학부 교수로 재직 중이다. 성균관대학교 경영학과를 졸업하고, 한국과학기술원 (KAIST) 경영과학과에서 경영정보시스템 전공으로 석사 및 박사학위를 취득하였다. 주요관심분야는 전자상거래, 퍼지인식도, 협상지원시스템, 지식경영, 인터넷 마케팅 등이다.



김진성 (Kim Jin-sung)

현재 성균관대학교 경영학부 대학원 박사 과정에 재학중이다. 주요 관심분야는 인공지능 기법을 이용한 의사결정지원, 인공지능 경영, 인터넷비즈니스, 웹협상지원시스템 등이다.