

지능적 전략계획시스템 설계를 위한 지식기초 의사결정지원체제와 인공신경망과의 결합

이건창*

Synergism of Knowledge-Based Decision Support Systems and Neural Networks to Design an Intelligent Strategic Planning System

This paper proposes a synergism of neural networks (NN) and knowledge-based decision support system (KBDSS) to effectively design an intelligent strategic planning system. Since conventional KBDSS becomes inoperative partially or totally when problem deviates slightly from the expected problem-domain, a new DSS concept is needed for designing an effective strategic planning system, where strategic planning environment is usually turbulent and consistently changing. In line with this idea, this paper develops a NN-based DSS, named ConDSS, incorporating the generalization property of NN into its knowledge base. The proposed ConDSS was extensively operated in an experimentally designed environment with three models: BCG matrix, Growth/Gain matrix, and GE matrix. The results proved very promising when encountered with unforeseen situations in comparisons with conventional KBDSS.

I. 서 론

1970년대에 들어와서 Gorry 와 Scott Morton [1971]이 DSS (Decision Support System)라는 용어를 처음 사용한 후, 기존의 MIS와 DSS의 유사점과 차이점에 대해서 많은 학자들 사이에 논란이 있었다 [Alter, 1977; Bonczek, et al., 1980; Keen & Scott Morton, 1978]. 궁극적으로 확실한

결론이 나오지는 못했지만, 학자와 실무자들 사이에 DSS가 의사결정자에게 문제해결 과정 전체를 자동화하기가 여의치 못한 상황에서 적절한 의사 결정 정보를 제공하는 '컴퓨터에 기초한 정보체제' (computer-based information systems)를 의미한다는 사실을 널리 인식케 해주는 계기가 되었다 [Ginzberg & Stohr, 1981]. 좀더 엄밀하게 DSS를 정의하자면 DSS는 半구조적 (semi-structured)이고 非구조적 (unstructured)인 경영문제를 해결하

* 경기대학교 정보처리학과 교수

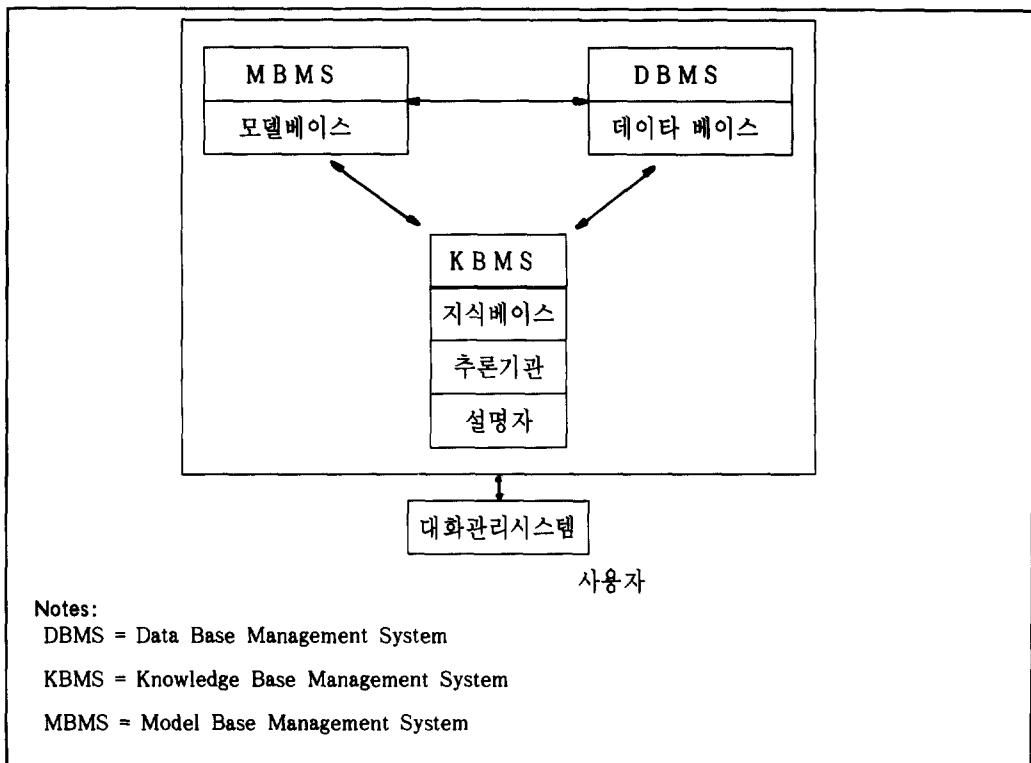
기 위해 의사결정자의 의사결정과정을 도와주는 컴퓨터 정보체계라고 말할 수 있다.

최근 인공지능 (AI: Artificial Intelligence)이나 전문가체제 (전문가체제 : Expert Systems)와 같은 새로운 정보기술이 대두되면서 기존 DSS 개념에 많은 변화를 가져왔다. 기존의 DSS는 주로 계량적인 모형에 의존하여 문제를 해결했기 때문에 의사 결정자의 의견이나 그밖에 계량화 할 수 없는 여러 가지 定性的인 (qualitative) 정보를 처리하기가 매우 어렵거나 불가능하였다. 그러나 AI/전문가체제가 대두되면서 이러한 난점이 해결되어 DSS의 문제해결 능력이 크게 배가되기에 이른 것이다. 그 결과 특정 문제영역에 대한 주관적인 지식 (knowledge)을 이용한 지식기초 DSS (knowledge based DSS), 즉 KBDSS 개념이 DSS 연구영역에 폭넓게 확산되었다. 현재까지는 KBDSS의 개발들에 대한 정확한 정의가 내려져 있지는 않지만 [Goul & Tonge, 1987], 일반적으로 KBDSS는 DSS의 구조에 전문가체제의 주요모듈을 결합한 형태로 인식되고 있다. Henderson [1987]은 그의 논문에서 DSS와 전문가체제를 결합하는 관점에서 DSS영역에서의 활발한 연구경향을 자세하게 소개하고 있다.

Sprague와 Carlson [1982]에 의하면 DSS의 구조는 데이터 베이스 관리시스템 (Data Base Management System), 모델 베이스 관리시스템 (Model Base Management System), 그리고 사용자와의 대화를 위한 대화 관리시스템 (Dialogue Management System) 등 세가지 주요 모듈로 구성되어 있다. 한편, 전문가체제 (Expert Systems)도 주지하는 바와같이 세가지 주요모듈로 구성되어 있다. 즉, 특정영역에 대한 휴리스틱 또는 규칙을 포함한 지식베이스 (knowledge base), 입력사실에 대해 지식베이스를 처리하는 추론기관 (inference engine), 그리고 결론까지의 추론과정을 보여주는 설명자

(justifier) 등이 그것이다 [Forsyth, 1984; Kastner & Hong, 1984; Waterman, 1986]. 그리고 이러한 각 전문가체제 모듈을 관장하는 지식베이스 관리 시스템 (Knowledge Base Management System)이 있다. 본 연구에서는 KBDSS를 DSS의 구조내에 전문가체제의 주요모듈을 포함한 개념으로 인식하고자 한다. 이러한 KBDSS의 일반적인 구조는 [그림 1]에 도시되어 있다. 따라서, 본 연구에서 언급하는 KBDSS는 기존의 순수한 전문가체제 보다 확장된 체제로서 DSS 개념에 기초하여 확장된 전문가체제 개념으로 인식할 수 있다.

그러나 KBDSS가 갖고 있는 지식베이스는 일반적으로 미리 정의된 문제영역내에서는 정해진 해를 제공할 수 있으나, 이 문제영역을 벗어난 상황하에서는 정확한 解를 주지 못하거나 이치에 맞지 않는 비현실적인 解를 제공하는 경우가 많다. 이러한 단점을 소위 '고원 효과' (mesa effect) [Caudill, 1990]라고 하는데, 결국 이러한 이유때문에 지식베이스 개발시 해당 문제영역을 '좁고 구체적' (narrow and specific)으로 잡아야 하는 것이다 [Waterman, 1986]. 이러한 지식베이스의 단점은 곧 KBDSS의 성과에 심각한 영향을 주므로, 결국 본 연구에서 대상으로 하고 있는 전략계획과 같은 복잡하고 그 문제환경이 급격하게 변하거나 또는 변할 소지가 많은 문제영역에서는 KBDSS의 성과가 크게 기대되기 어렵다. 결국 효과적인 전략계획을 위한 KBDSS를 구축하기 위해서는 새로운 기법이 개발되어야 할 필요성이 있는바, 이러한 관점에서 인공신경망, 즉 NN (Neural Network)을 이용한 지식베이스 개발은 매우 필요하고 의미있는 연구가 될 것이다. 왜냐하면 NN은 특정 문제영역에 대해서 학습을 하면 예상치 못한 상황하에서도 상당히 뛰어난 '일반화 효과' (generalization effect)를 발휘할 수 있기 때문이다. 결국 NN을 KBDSS의 지식베이스 개발에 사용하면 학습능력과 일반화효과를 기대할 수 있으므로 기존의 KBDSS보다 지능적인



[그림 1] KBDSS의 일반적인 구조

KBDSS를 구축할 수 있게 된다.

이러한 배경 하에 본 연구에서는 NN을 이용한 지식베이스 개발을 통하여 다음과 같은 세 가지 목적을 달성하고자 하며 아울러 그 실험 결과를 제시하고자 한다.

- 1) 고원효과를 극복하여 보다 지능적인 KBDSS를 구축하기 위한 노력의 일환으로 NN을 이용한 지식베이스 개발을 통한 새로운 KBDSS를 제시하고자 한다. 이렇게 새롭게 제시되는 KBDSS를 본 연구에서는 Connectionist¹⁾ DSS의 약자를 써서 ConDSS라고 칭하기로 한다.
- 2) 새로운 환경에 대한 일반화 효과가 좋고, 견고성 (robustness)과 학습성 (learnability)이 있고

수리적인 (numerical) 특성을 갖는 지식도 표현하는 인공신경망 지식베이스를 제시하고 그에 따른 추론기관 (Inference Engine)의 특성을 보여준다.

3) 이 ConDSS를 높은 수준의 비구조성(unstructuredness)이 내재하고 예측치 못한 상황이 많이 발생하는 전략계획 (Strategic Planning) 문제에 적용하여 그 성과를 기존의 KBDSS의 성과와 비교측정 하기로 한다.

II. 인공신경망의 개념적 기초와 특징

인공신경망, 즉 NN은 서로 연결되어 있는 다수

1) 일반적으로 NN을 Connectionist라고도 부른다.

의 ‘처리단위’ (PU: Processing Unit)들로 구성되어 있기 때문에 견고성과 학습성을 갖고 있다 [Zeidenberg, 1990; Lippmann, 1988]. 이러한 특징은 결국 NN을 구성하고 있는 다수의 PU와 이들 PU끼리의 상호연결성 (interconnections)에 기인한 것이다. PU는 생체내의 신경세포와 비슷한 것으로서 가중치화된 상호연결성으로 서로 연결되어 있다. [그림 2]는 역전파학습 (Back Propagation)을 이용한 三重 신경층 전향 (three layer feed-forward) NN을 도시하고 있다. 이 NN은 입력층에서 은닉층, 은닉층에서 출력층으로 각 PU가 서로 연결이 되어 있는 것이 특징이다. 각각의 PU는 주어진 학습자료를 학습하는 ‘학습기능’ (learning function)과 상호연결된 또다른 PU에 그 처리결과 (activation)를 보내는 ‘전달기능’ (transfer function)이 있다. 즉, j번째 PU는 하부신경층 (lower layer)으로부터 전달된 總純入力 (total net input) X_j 를 받아 들인다. 이는 다음과 같은 수식으로 표현된다

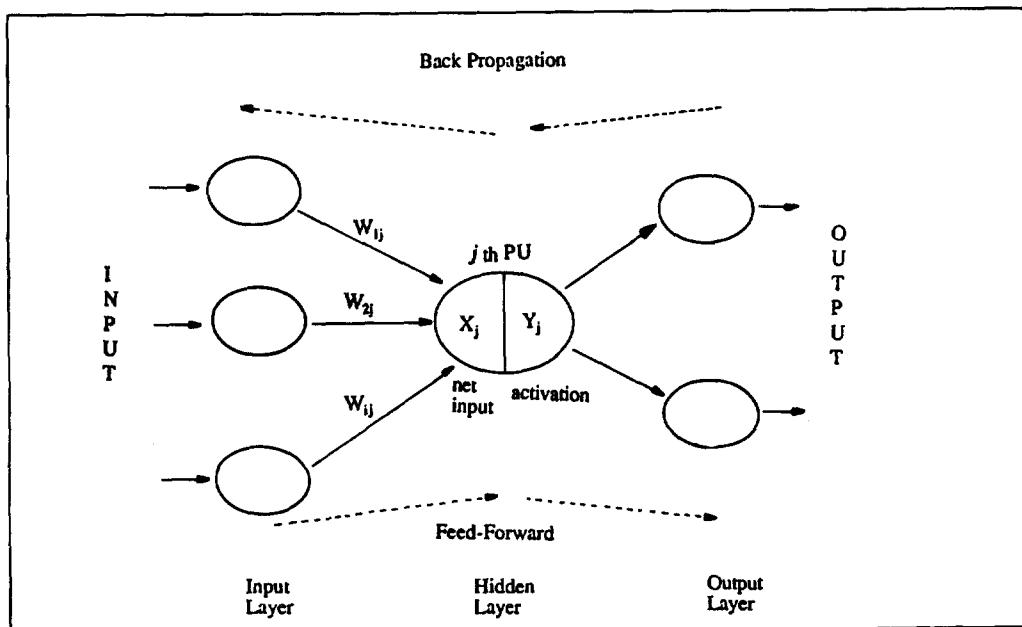
[Rumelhart et al., 1986].

$$X_j = \sum_i Y_i W_{ji} - \theta_j$$

여기서 Y_i 는 하부 신경층의 임의의 i번째 PU로부터의 출력이고, θ_j 는 j번째 PU의 경계치이다. 또한, W_{ji} 는 i번째 PU와 j번째 PU사이의 연결가중치이다. 이 경우 X_j 는 j번째 PU에 대한 순입력 (net input)이라고 하며 j번째 PU의 출력수준 (activity level) Y_j 는 다음과 같은 비선형 전이함수 (transfer function)에 의해 계산되어진다. [Rumelhart et al., 1986]

$$Y_j = 1/(1 + e^{-X_j})$$

이 식에서 볼수 있는 순입력 X 와 출력 Y 사이의 전이함수는 NN응용에 일반적으로 이용되는 S자형 함수 (sigmoid)이다.



[그림 2] BP에 의한 삼중 전향 NN 구조

[그림 2]에서의 입력층(input layer)은 환경과 상호반응하며 외부입력을 받아 NN에 전달하는 역할을 한다. 또한 출력층(output layer)은 주어진 외부입력에 대한 적절한 출력을 내보내는 역할을 한다. 한편 입력층과 출력층 사이의 신경망층을 중간층(intermediate layer) 또는 은닉층(hidden layer)이라고 하며, 이는 주어진 입력으로부터 특성을 추출하여 출력층으로 보내는 기능을 한다. 은닉층의 수와 PU규모의 결정은 주관적으로 결정되어 NN응용에 따라 달라지며 따라서 그 타당성은 실험을 통하여 확인하여야 한다 [Lippmann, 1988]. 그러나, 일반적으로 은닉층의 PU는 NN의 성과에 커다란 영향을 주지는 않는다고 알려져 있다. 만약 입력자료가 특성추출(feature extraction)이 용이하지 않은 자료로 구성되어 있으면 그러한 입력자료로부터 고차원의 특성을 추출하기 위해서는 여러개의 은닉층이 요구된다. 반면에 입력자료가 이미 어느 정도 고차원의 특성을 나타내고 있으면 하나 또는 두개 정도의 은닉층만 있어도 거의 모든 형태의 문제해결 공간을 구성할 수 있다 [Lippmann, 1988].

연결 가중치(connection weights)는 역전파학습[Rumelhart, et al., 1986]과 같은 감독학습(supervised learning)에 의해서 결정되거나 또는 경쟁학습[Rumelhart & Zipser, 1985]과 같은 비감독학습(unsupervised learning)에 의해서 결정된다. 역전파학습은 NN관련 응용에 있어서 가장 많이 이용되는바, 그 이유는 역전파학습이 갖는 넓은 응용력과 높은 일반화 능력에 기인한다. ConDSS에서도 같은 이유로 역전파학습을 채택하였다.

이와같은 NN의 數理的 측면과 幾何學的 측면은 다음과 같은 흥미있는 특성을 제공한다.

1) 견고성(robustness): NN은 일반적으로 오류극복성(fault tolerance)을 갖는데 이는 곧 특정 몇몇 PU에 오류가 발생하여도 NN의 전체적인 기능이 크게 영향을 받지 않음을 의미한다. 따라서

NN의 성과는 오류의 정도가 증가됨에 따라 점차적으로 감소하는 추세를 보이므로써 급격히 변하는 환경이나 예측치 못했던 환경에서 NN이 안정적으로 기능하는데 크게 이바지한다. 이러한 견고성이야 말로 NN을 경영의 가장 어려운 분야중 하나인 전략계획 분야에 효과적으로 적용될 수 있게끔 만드는 주요특성이 된다.

2) 학습성(learnability): NN은 주어진 학습 입출력자료로 부터 숨겨진 규칙성(regularities)을 찾아낼 수 있다. 이러한 규칙성은 NN내에 분산된 PU에 각각 저장되며 이는 결국 KBDSS의 지식베이스내의 지식에 해당한다. 이와 같은 NN의 지식은 수리적 가중치로 표현되고 학습기법에 의하여 어느 정도 자동적으로 얻을 수 있다는 점이 기존의 KBDSS 지식과 가장 다른 점이다.

III. 인공신경망과 KDBSS와의 결합

Ⅱ장에서 서술한 NN의 특징을 살펴보면, 결국 NN과 KBDSS가 결합됐을때 DSS영역에서 새로운 개념의 KBDSS를 구상할 수가 있다. 최근에 이러한 NN과 KBDSS와의 결합을 위한 여러 시도가 이루어져 왔다. 첫번째 형태의 결합은 NN의 구조내에서 IF-THEN 규칙을 수행하는 시뮬레이션 형태로 이루어졌다 [Samad, 1988]. 두번째 형태의 결합은 입력자료와 출력 자료와의 관계를 학습하기 위하여 NN에 기초한 학습방법을 이용하는 것이다 [Gallant, 1988]. 본 연구에서는 두번째 형태의 결합을 활용하기로 한다. 즉, 특정 문제영역에서 학습시킨 NN을 지식베이스로 하여 이를 추론과정에 이용하는 방식이다. KBDSS가 이같이 학습된 NN을 추론과정에 사용하면 NN이 갖고 있는 견고성과 학습성을 가질 수 있기 때문에 문제를 해결하는데 있어서 보다 폭넓은 일반화(generalization) 능력

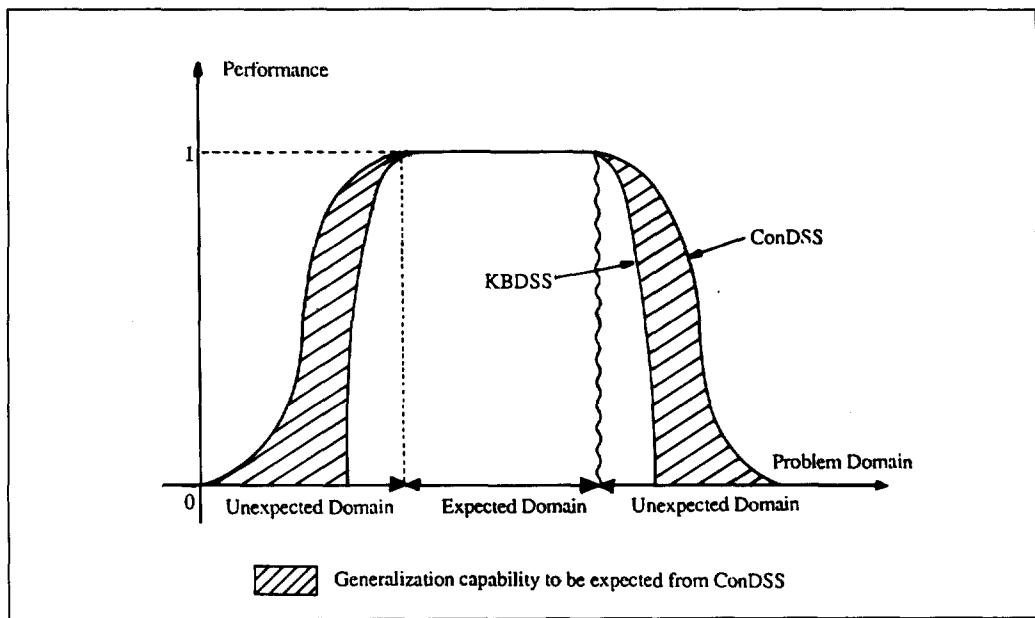
을 가질 수가 있으며 본 연구에서는 이를 ConDSS로 구현하였다. 이와 같이 특정 문제영역에서 학습된 NN을 지식베이스로서 사용하면 기존의 KBDSS와 비교하여 다음과 같은 세가지의 장점을 갖는 ConDSS를 구축할 수가 있다.

1) 특정 문제영역에 대한 입력자료와 거기에 대응하는 출력자료를 구할 수 있으면 규칙을 일일이 입력할 필요가 없기 때문에 시스템 개발시간이 상당히 줄어들 수가 있다. 이는 기존의 KBDSS가 필요한 규칙을 찾고 입력하기 위하여 많은 개발시간을 소요하는 것과 비교하면 좋은 대비가 된다. 이는 ConDSS의 지식이 학습결과 얻어지는 연결 가

중치라는 수치로 표현이 되기 때문에 가능한 것이다.

2) 기존의 KBDSS의 경우는 그 자체에 환경변화에 대한 메카니즘이 별도로 강구되어 있지 않는 한, 새로운 상황에 대처하기가 곤란하다. 그러나, ConDSS는 NN의 학습능력을 갖고 있기 때문에 새로운 상황이 발생하여도 점차적으로 자체기능을 향상시키므로써 이에 대처할 수가 있다.

3) 견고성을 갖고 있기 때문에 예측치 못한 상황 하에서도 근사추론 (approximate reasoning)이 가능하다.



[그림 3] KBDSS와 ConDSS의 고원효과 비교

[그림 3]에서는 기존의 KBDSS와 ConDSS에 있어서의 고원효과에 대한 비교그림이 도시되어 있다. 그림에서 보면 ConDSS의 경우 일반화능력 때문에 KBDSS보다 고원효과가 덜 나타나는 것을 알 수가 있다. 즉, 빛금친 부분은 ConDSS 사용시 기대되는 고원효과의 감소분으로서 이는 ConDSS가 사용하는 NN의 일반화 능력에 기인한 것이다.

인공신경망 전문가체제 연구중에서 가장 대표적이라고 할 수 있는 Gallant [1988]가 제시한 인공신경망 전문가체제는 본 연구의 ConDSS와 비교할 때 유사점과 상이점이 각각 존재한다. 이러한 비교를 하는 이유는 Gallant의 논문이 NN과 전문가체제를 결합하고자 하는 노력에 있어 가장 대표적인 논문이 되기 때문이다. 먼저 유사점부터 살펴보기

로 한다.

1) 개발의도가 비슷하다. 즉, 현재 존재하는 정보시스템인 전문가체제 또는 KBDSS와, NN기법을 결합하여 장점을 극대화하자는 것이다.

2) 실험의도가 비슷하다. 즉, NN과 결합된 정보시스템이 전문가체제 나 KBDSS와 같은 기존의 정보시스템이 해결하기 어려운 복잡한 문제를 풀 수 있다는 사실을 실험을 통하여 보여주기 위한 것이다.

차이점은 다음과 같다.

1) 구조적 일반성: Gallant가 제시한 구조는 일반적인 전문가체제 구조를 채택하고 있기 때문에 모델베이스나 데이터베이스와 같은 개념이 결여되어 있다. 그러나 ConDSS는 모델베이스와 데이터베이스를 갖고 있기 때문에 정성적인 (qualitative) 문제뿐만 아니라 계량적인 문제도 해결할 수가 있다.

2) 문제영역의 복잡성: Gallant는 대표적인 구조성 (structuredness)을 보이는 의료영역에 속한 문제를 예로 제시하였으나, ConDSS는 높은 비구조성 (unstructuredness)을 보이는 전략계획문제를 그 해당 문제영역으로 하고 있기 때문에 NN의 효과를 보다 현실적으로 보여줄 수 있다.

이밖에 인공신경망 전문가체제는 최근 많은 인공지능 학자들의 관심을 받고 있는 분야로서 다음과 같은 연구흐름을 갖고 있다.

1) 학습된 NN을 지식베이스로 사용하는 경우: 이는 다시 NN구조 자체를 추론기관화하여 기존의 전문가체제의 추론기관보다 학습기능과 일반화 기능이 보강된 추론기관을 만드는 경우와 [Samad, 1988], 학습된 NN을 기존의 전문가체제의 지식베이스 대신으로 사용하는 경우 [Poli et al., 1991; Bradshaw et al., 1988]로 구분될 수 있다.

2) 학습된 NN에서 지식을 도출하여 자체적인 설

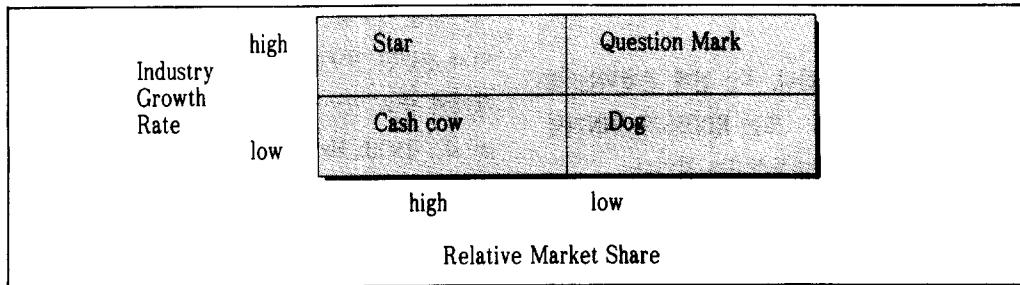
명기능을 갖고자 하는 경우:

이와 관련된 연구논문이 최근의 인공신경망 전문가체제의 주요 연구흐름이라고 말할 수 있다 [Baba et al., 1990; Hall and Romanuk, 1990; McMillan et al., 1991; Enbutsu et al., 1991; Elkins et al, 1992].

본연구는 학습된 NN을 지식베이스로 사용하는 경우에 해당되나, 종전의 인공신경망 전문가체제가 대부분 정형적인 엔지니어링 문제에 적용되었던 바, 본 연구는 경영과학 문제에서 가장 비정형화된 전략계획 문제에 이를 적용함에 그 특성이 있다고 하겠다.

IV. 전략계획문제

전략계획 (Strategic Planning) 영역에서는 지금까지 다양한 연구가 진행되어 왔다 [Abell & Hammond, 1979; Glueck, 1980; Larreche & Srinivasan, 1982; Porter, 1980; Rowe, et al., 1982]. 이는 주로 전략계획 자체의 이론적인 방향설정을 위한 연구가 대부분이었으나, 컴퓨터의 발달과 인공지능 기법의 발달에 따라 컴퓨터의 활용 및 지식베이스의 적용이 활발히 진행되어 왔다 [Holloway & Pearce, 1982; Mockler, 1989; Mockler & Dologite, 1991]. Mockler와 Dologite [1991]는 전략계획 분야에 있어서의 학계 및 산업계의 최근 연구동향을 체계적으로 정리하여 보고하였다. 그러나 이러한 연구동향에 있어서 전문가체제에 기초한 연구는 꽤 활발한 편이나, NN기법을 전략계획 의사결정을 위한 도구로서 본격적으로 적용한 연구는 거의 없는 실정이다. 더욱이 국내에서는 일반적인 전문가체제에 기초한 전략계획 연구도 거의 미미한 실정이다. 이같은 맥락하에 본 연구에서는 전략계획 분야에서 가장 많이 알려진 BCG 행렬, Growth/Gain 행렬, 그리고 GE 행렬을 전략대안(strategic



[그림 4] BCG 행렬

alternatives) 평가를 위한 도구로 사용하여 이를 기초로 NN을 이용한 지식베이스 구축 및 그에 따른 새로운 개념의 ConDSS를 제시하고자 한다.

본 연구에서 사용하는 전략대안 평가를 위한 세 가지 전략계획 모델 중, BCG 행렬은 가장 잘 알려진 방법인데, 이는 기업이 생산하는 제품의 상대적 시장점유율 (relative market share)과 해당 산업의 성장속도 (industry growth rate)를 비교하여 그 위치를 2차원 평면에 표시한다. 이때 상대적 위치에 따라 그 제품은 "star", "cash cow", "question mark", "dog"라고 분류된다. 이는 [그림 4]에 도시되어 있다.

star로 분류된 제품은 가장 높은 수익을 가져올 수 있다고 기대되는 제품이지만, 반면에 그 제품이 시장에서 차지하는 전략적 우위를 계속 지키기 위해서는 상당량의 현금지출 (cash outflows)이 요구되는 제품이다. 따라서, star제품은 시장의 성장속도가 둔화되고 성숙기에 접어들게 되면 기존의 전략적 위치를 변화시킬 만한 새로운 event가 일어나기 어렵기 때문에 궁극적으로는 가장 안정적인 수익을 가져다 줄 수 있는 cash cow제품이 될 가능성이 크다. question mark 제품은 시장점유율을 높히기 위해서 많은 현금지출이 필요한 제품이다. 그러나 현금지출 결과, 해당 제품이 새로운 star제품

이 되어 궁극적으로는 미래의 cash cow가 될 가능성도 있지만, 반면에 현금지출 결과가 실패하여 쇠약의 상태인 dog가 될 수도 있어 그 기업의 제품 배합 (product mix) 대상에서 탈락될 수도 있다. 이러한 BCG행렬은 구조가 간단하고 해석 또한 쉽기 때문에 현재까지도 전략계획 분야에서 많이 쓰이고 있다. 그러나 BCG행렬은 시장전략을 반영하는 요소가 두가지 밖에 없어서 복잡다단한 시장상황을 충분히 반영할 수가 없다. 따라서 이러한 방법외에도 본 연구에서는 Growth/Gain 행렬, GE 행렬등을 추가로 사용하였다.

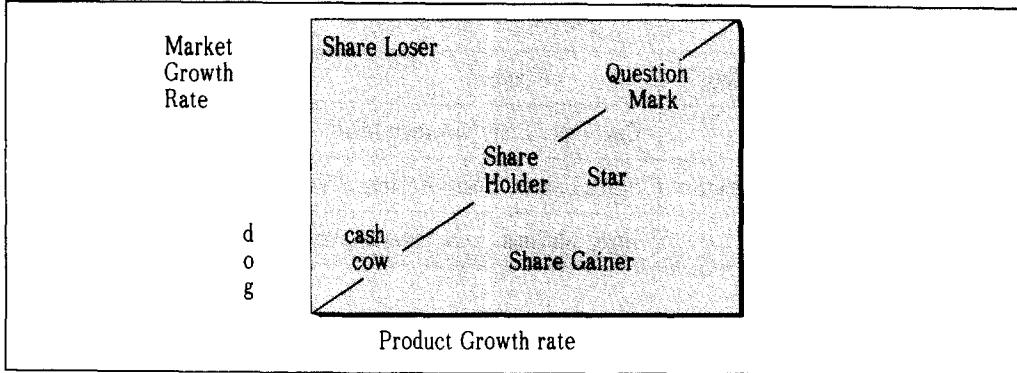
Growth/Gain 행렬은 시장성장 (market growth rate)과 대비하여 각 제품의 성장률 (product growth rate)을 표현한다. 이는 제품의 성장률을 x축에, 시장의 성장률을 y축에 표시하여 시장점유율이 증가되는 제품²⁾의 경우는 대각선 아래에, 그리고 시장점유율을 잃어가는 제품³⁾은 대각선 위에 표현한다. 시장점유율을 유지하는 제품⁴⁾은 대각선 상에 표시되어 각 제품의 시장내에서의 점유율의 상태를 한눈에 파악할 수 있게끔 한다. [그림 5]는 Growth/Gain 행렬을 보여주고 있으며 특히 BCG 행렬에서의 cash cow, star, question mark, 그리고 dog 제품의 가장 이상적인 위치도 표시하고 있다.

사업평가 (Business Assessment) 행렬 또는 GE

2) 이를 Share Gainer라고 한다.

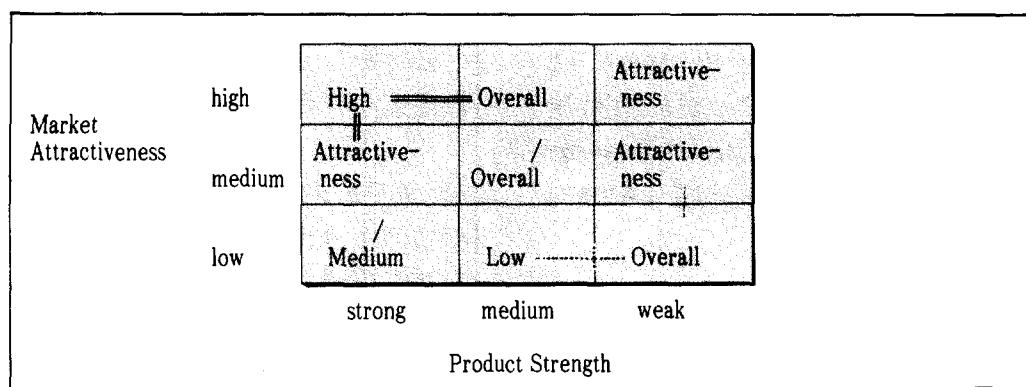
3) 이러한 제품을 Share Loser라고 한다.

4) 이를 Share Holder라고 한다.



행렬은 市場誘引度 (market attractiveness)와 제품의 강점 (product strength)을 복합적으로 평가하여 그 결과를 2차원 평면에 도시한다. 따라서 GE 행렬을 그리기 위해서는 이러한 두 가지 요소와 관련이 있는 여러 경영전략 요인들을 선정하여 이에 적당한 가중치를 주어 최종 값을 구한 후 이를 GE 행렬에 표시하여야 한다. 따라서 GE 행렬은 다른 두 가지 방법에 비해 그기가 조금 까다롭지만 다른 두 방법이 고려하지 못하는 다양한 전략요인들을 고려할 수 있기 때문에 많은 유용한 정보를 제공할 수 있다. [그림 6]은 3x3 GE 행렬을 표시하고 있으며 시장내에서의 제품의 전략적 위치를 High, Medium, Low로 3등분하고 있다 [Abell & Hammond, 1979].

이와 같은 세 가지 전략계획 모델에 의한 제품별 입력자료 특성치를 정리하면 <표 1>과 같다. 결국 본 연구에서 대상으로 하고 있는 전략계획 문제는 한 제품에 대해 시장상황⁵⁾과 그 제품의 여러 전략적인 요인을 고려하여 가장 유리한 구체적인 ‘시장 점유율 전략’ (market share strategy)과 ‘생산전략’ (production strategy)을 수립하는데 있다. 시장점유율 전략이란 해당제품의 시장구매력에 관한 전략으로서 해당제품의 전망이 좋다고 판단되면 이를 증가시키기 위한 투자전략을 의미하고, 그렇지 않



5) 본 연구에서는 특히 경쟁기업 제품의 전략적 상태를 대표적인 시장상황으로 보았다.

〈표 1〉 입력자료에 대한 특성치

Portfolio Models	Features
BCG matrix	Cash Cow, Star, Question Mark, Dog
Growth/Gain matrix	Share Gainer, Share Holder, Share Loser
GE matrix	High, Medium, Low (overall attractiveness)

다고 판단되면 유지, 축소, 또는 시장으로부터 완전철수를 위한 전략을 의미한다. 이와같은 의미에서 볼때, 본 연구에서 고려하고 있는 시장점유율 전략은 increase, maintain, decrease, 그리고 withdraw 이다. 한편, 생산전략은 해당제품에 대한 전략적 판단에 따라 그 제품의 생산을 현재의 생산 수준 보다 확장 또는 감소시키거나, 아니면 생산을 유지 또는 중단하는 것을 의미한다. 결국 본 연구에서 고려하는 생산전략은 네가지로서, augment, sustain, decrease, cease가 그것이다.

V. ConDSS의 설계

1. 인공신경망 지식베이스 구축

본 연구에서는 ConDSS를 C 언어를 이용하여 구축하고 이를 PC에 구현하였다. ConDSS의 근간인 '인공신경망 지식베이스' (Neural Network Knowledge Base)를 구축하기 위한 몇가지 단계를 살펴보면 다음과 같다.

1단계: 학습자료 수집

학습자료는 임의의 기업을 대상으로 하여 27개의 학습자료가 수집되었고 해당 기업은 7개의 제품을

생산한다고 가정되었다 [Lee, 1985]. 각각의 학습자료는 7개 제품중 어느 하나를 나타내는 것이고, 이러한 학습자료중 6개는 cash cow, 8개는 star, 9개는 question mark, 4개는 dog로 분류되었다. 본 연구에서는 ConDSS의 일반화 효과를 좀더 명확히 보기 위하여 학습자료를 두 그룹으로 나눠서 그룹A는 20개⁶⁾의 학습자료를 갖고, 그룹B는 19개⁷⁾의 학습자료를 갖게 하였다. 이들 두 그룹의 학습자료는 그 구성상 성격이 서로 다르다. 즉, 그룹A의 경우는 학습자료중에 dog가 빠져 있으나 시험자료에는 dog가 포함되어 있어서 이경우 ConDSS가 어떻게 일반화 효과를 보일 수 있는지가 분석대상이 되겠다. 반면에 그룹B의 경우는 학습자료안에 모든 종류의 제품이 포함되어 있다. 따라서 이경우의 ConDSS는 그룹A보다 일반화 효과가 더 좋을 것이라고 예측이 된다. 결국 이러한 두 종류의 학습자료를 통하여 서로 다른 일반화 효과를 보이는 인공신경망 지식베이스를 구축할 수가 있다.

2단계: NN구조 결정

입력층의 PU는 해당 기업에 해당되는 부분뿐만 아니라, 경쟁 기업에 해당되는 부분도 포함되어 있다. 이는 효과적인 전략계획 구축을 위해서는 경쟁기업 제품의 전략적 상황까지 고려하여야 할 필요가 있기 때문이다. 해당 기업의 경우는 BCG에서 4개,

6) 그룹A는 cash cow 6개, star 8개, question mark 6개로 구성되었다. 따라서 그룹A를 학습자료로 하면 시험자료 (test samples)의 갯수는 7개가 된다.

7) 그룹B는 cash cow 4개, star 6개, question mark 7개로 구성되어 있어서 시험자료는 8개이다. 그룹A와는 달리 그룹B는 4가지 종류의 제품을 골고루 갖추고 있다는 것이 특징이다.

Growth/Gain에서 3개, GE에서 3개하여 도합 10개의 PU로 구성되어 있다. 반면에 경쟁 기업의 경우는 BCG에서 4개, Growth/Gain에서 3개 하여, 도합 7개의 PU로 구성되어 있다. 경쟁기업의 경우 GE행렬이 빠져 있는데, 그 이유는 GE행렬을 구하려면 전략요인에 관한 정보가 필요한 바, 경쟁기업에 대한 그러한 정보는 사실상 입수가 어렵다고 판단되기 때문이다. 따라서 입력층은 총 17개의 PU로 구성되어 있고 이러한 입력층을 도시하면 [그림 7]과 같다. 각 입력 PU에 대한 입력값은 0 또는 1이다. 즉, 임의의 제품특성에 해당되는 PU들에 한해서 1의 값이 입력되고, 나머지 PU는 0이 입력된다.

온너층은 입력층으로 부터의 입력을 처리하여 그 출력값 (activation)을 출력층으로 연결하는 역할을

담당하고 있고, 이를 기하학적으로 보면 결국 이미 언급한 바와 같이 입력값으로부터 특성치를 뽑아내는 기능을 갖는다고 말할 수 있다. 따라서, 이러한 은너층은 주어진 문제에 대한 해결공간 (solution space)을 형성시키고 NN에 탄력성을 제공하는 역할을 담당한다. 은너PU의 갯수는 NN의 성과에 그다지 큰 영향을 주지 않는다고 알려져 있기 때문에 [Caudill, 1989; Dutta & Shekhar, 1988] 본 연구에서는 은너PU의 갯수를 10으로 고정시켰다.

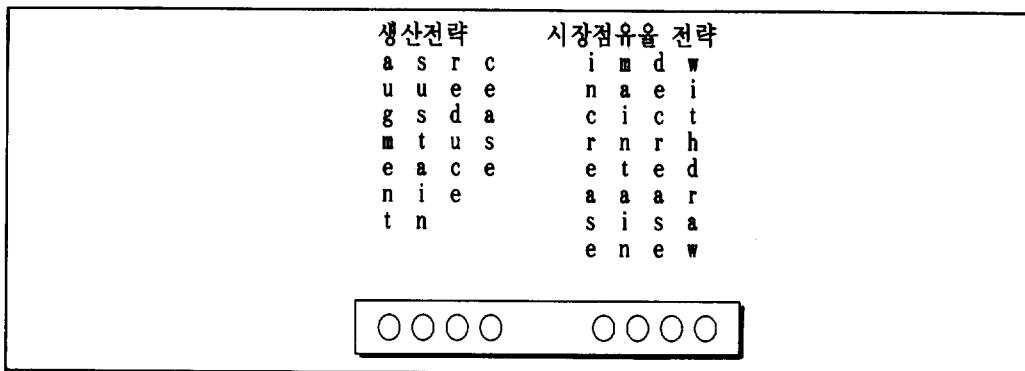
ConDSS가 제공하는 해가 생산전략 (production strategy)과 시장점유율 전략 (market share strategy)이기 때문에, 출력층의 PU도 그에 따라 두 그룹으로 나눠진다. <표 2>는 ConDSS가 제공하는 출력값을 정리한 것이다.

해당 기업				경쟁 기업			
BCG	Growth/Gain	GE		BCG	Growth/Gain		
○○○○	○○○	○○○		○○○○	○○○		
c s q d	s s s	h m l		c s q d	s s s		
a t u o	h h h	i e o		a t u o	h h h		
s a e g	a a a	g d w		s a e g	a a a		
h r s	r r r	h i		h r s	r r r		
t	e e e	u		t	e e e		
c i		m		c i			
o o	g h l			o o	g h l		
w n	a o o			w n	a o o		
	i l s				i l s		
m	n d e			m	n d e		
a	e e r			a	e e r		
r	r r			r	r r		
k				k			

[그림 7] 입력층의 PU구성

<표 2> ConDSS에 의한 결론

Strategy Category	Conclusions
Production	Augment, Sustain, Reduce, Cease
Market Share	Increase, Maintain, Decrease, Withdraw



[그림 8] 출력층의 PU구성

이에 따라 출력층의 PU도 8개로 결정되었으며 이중 4개는 생산전략 PU이고, 나머지 4개는 시장점유율 전략 PU에 해당된다. [그림 8]은 출력층의 PU구성도를 보여주고 있다.

이상의 NN구조를 연결하면 [그림 9]와 같다.

3단계: 학습

본 연구에서는 역전파학습 방법 [Rumelhart, et al., 1985]을 이용하여 주어진 학습자료로부터 연결 가중치를 구한다. 이러한 역전파학습 방법은 다음과 같이 단계별로 설명될 수 있다.

1) 우선 주어진 NN의 각PU에 -1.0에서 1.0까지의 난수를 할당하여 초기화 시킨다.

2) 입력층으로부터 입력자료를 받아 주어진 전이 함수에 의한 출력값을 구한 다음 이를 출력층까지 계속한다. (Forward Pass)

3) 출력층에서 나온 값과 (이를 'NN 출력값'이라고 한다.) 해당 입력자료의 실제 출력값과를 비교한 다음,

3.1) 그 차이가 미리 정한 한계값을 초과하면, 연결 가중치를 다음과 같은 가중치 조정식 (weight adaptation rule)에 의해 조정한다.

$$\Delta W_{ji}(t+1) = -\epsilon \nabla E(t) + \alpha \Delta W_{ji}(t)$$

여기서 $\nabla E(t)$ 는 최소자승오류의 부분미분치

(partial derivative)를 의미하며 ϵ 는 학습률 (learning rate)로서 가중치 조정속도에 영향을 준다. 한편, α 는 모멘텀 (momentum)으로서 가중치의 조정 폭에 영향을 준다. 이러한 가중치의 조정은 출력층으로부터 시작되어 은닉층, 그리고 다시 입력층으로 내려온다. (Backward Pass) 그런 다음 다시 2) 단계를 반복한다.

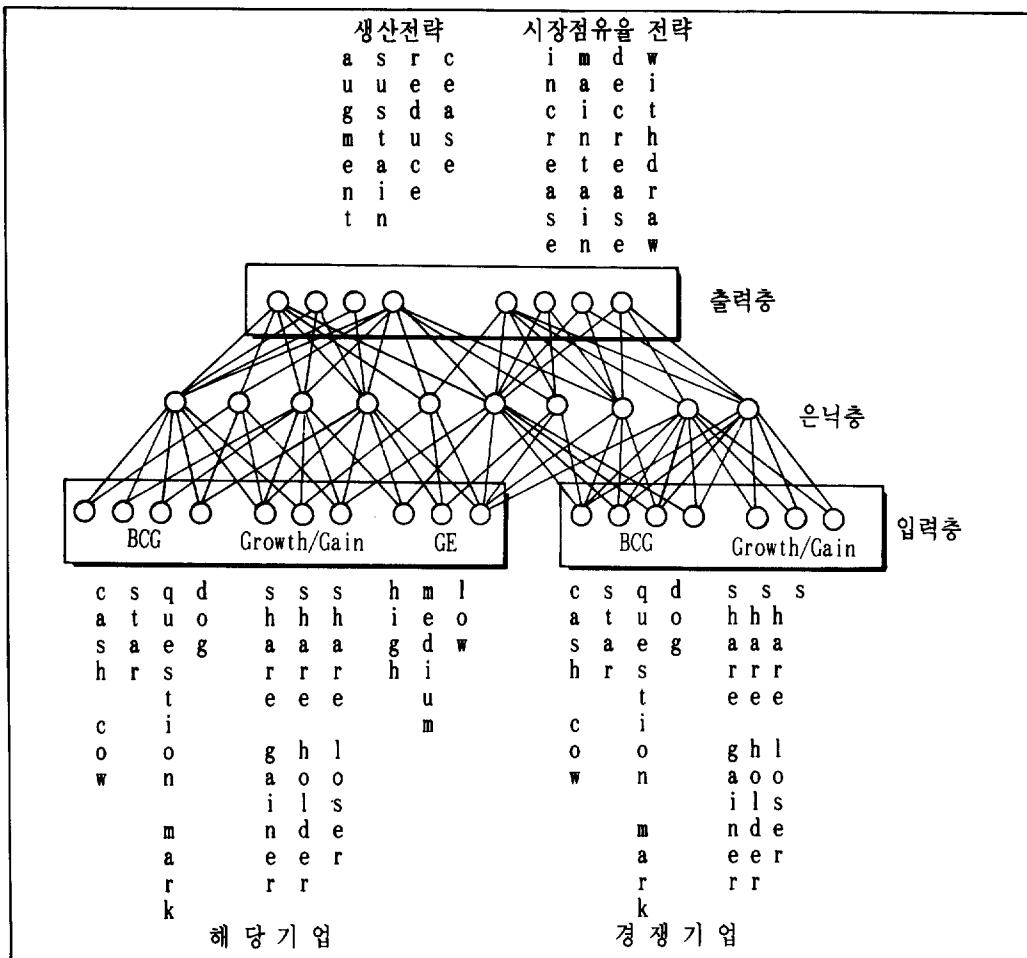
3.2) 그 차이가 미리 정한 한계값 이하로 줄어들면 이는 가중치가 거의 수렴했다는 의미이므로 학습을 중단한다. 이때의 연결 가중치가 ConDSS의 인공신경망 지식베이스가 된다.

2. 문제해결 과정

IV장에서 언급한바 있는 전략계획 문제는 다음과 같은 7단계를 통하여 ConDSS 구조내에서 해결할 수 있다.

1) 주어진 제품의 특성치 (features)를 BCG 행렬, Growth/Gain 행렬, GE 행렬에서 뽑아내서 이를 특성치 벡터 (features vector)로 구성한다.

2) 각 제품에 대한 특성치 벡터를 입력자료로 하여 이를 NN으로 학습하여 인공신경망 지식베이스를 만든다.



[그림 9] NN 전체 구성도

3) 이러한 전략계획 문제에 대한 일반적인 지식 베이스⁸⁾ (conventional knowledge base)를 만든다.

4) 학습하지 않은, 즉 일반적인 지식베이스가 해당 지식을 갖고 있지 않은 새로운 사실이 사용자에 의해 입력되면

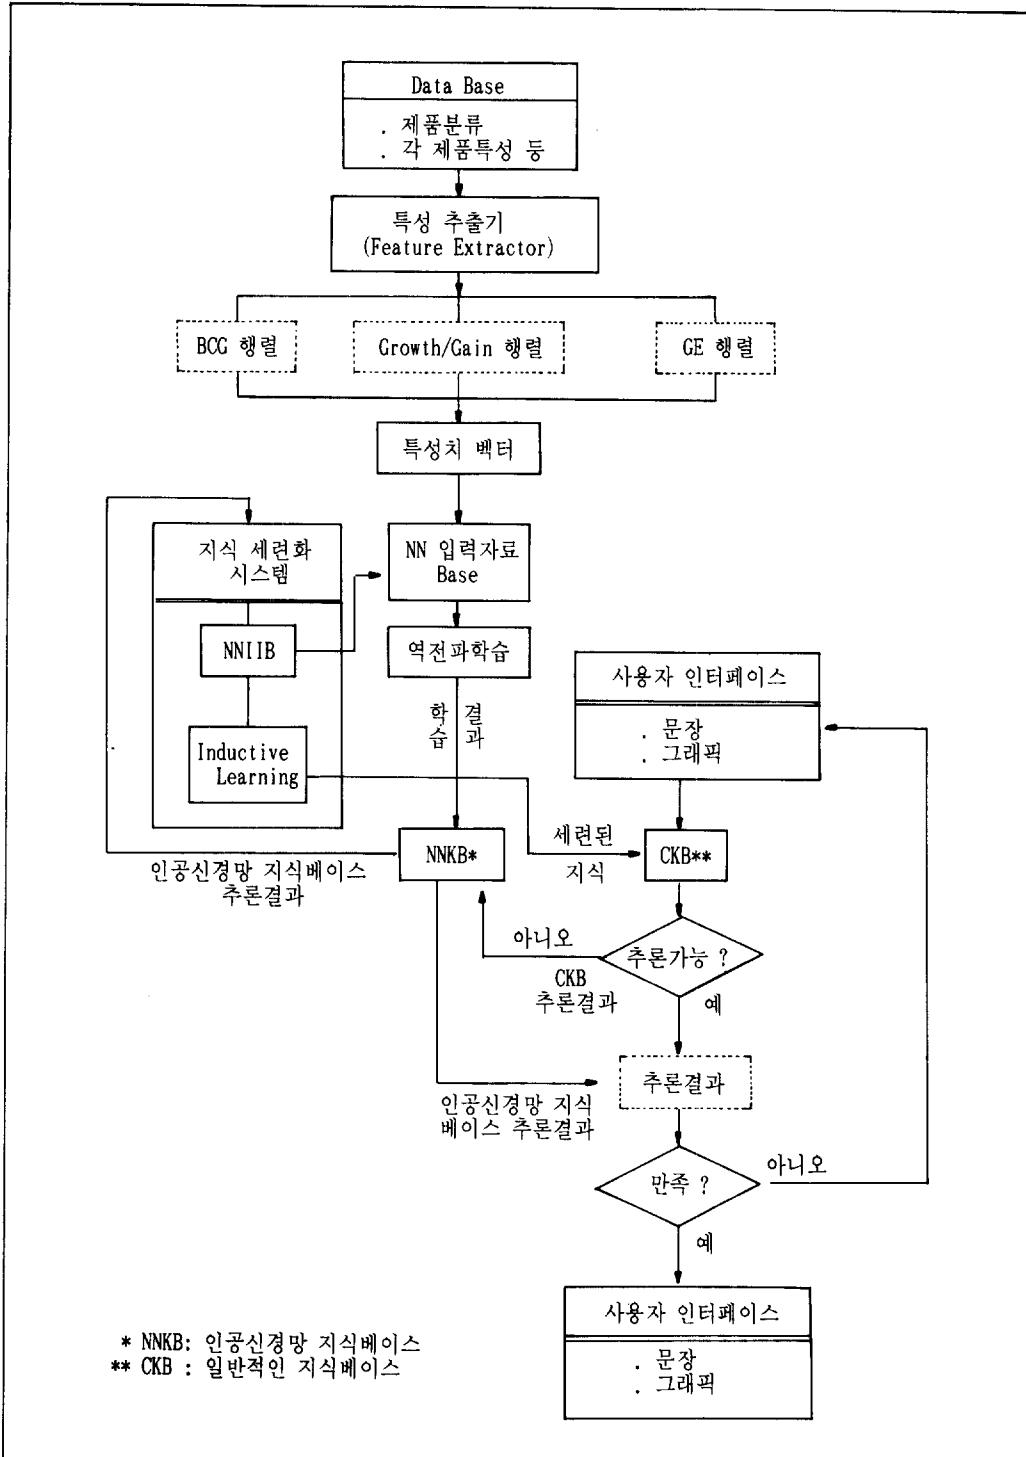
4.1) 이는 기존의 일반적인 지식베이스가 해결 할 수가 없기 때문에 이러한 사실은 인공 신경망 지식베이스로 추론이 된다. 추론은 제품의 주어진 특성과 가장 알맞는 시장점

유율 전략과 생산전략을 동시에 제시하는 것이다.

4.2) 인공신경망 지식베이스로 추론된 결과는 별도의 'NN 추론사례베이스' (NN Infere- nce Instance Base: NNIIB라 약함)에 저장한다.

4.3) 사용자 인터페이스 (User Interface)에 의해 결과가 제시된다. 본 연구에서는 Statement와 Graphic 인터페이스를 동시에

8) 이는 기존의 IF-THEN 방식의 지식베이스를 의미한다. 이러한 형태의 지식베이스는 이미 서술한 바와 같이 지식베이스 관리가 어렵고 또한 새로운 상황에 대한 추론기능이 약하다.



[그림 10] ConDSS 문제해결 과정

고려한다.

5) 이미 일반적인 지식베이스가 갖고 있는 지식과 관련이 있는 사실이 입력이 되면 이는 일반적인 지식베이스에 의해서 추론이 된다.

6) NNIIB에 저장되어 있는 추론사례는 사후적으로 그 성과를 평가하여 이를 귀납적 학습방법(inductive learning)에 의해 새로운 지식을 뽑아서 이를 일반적인 지식베이스에 적용한다. 또한 NN 학습을 통하여 인공신경망 지식베이스를 조정한다. 이는 인공신경망 지식베이스와 일반적인 지식베이스의 상호협동에 의한 지식세련화(knowledge refinement) 작업의 한 일환이다.

7) ConDSS에 의해 제시된 전략이 만족스러우면 문제해결 과정은 끝나지만, 그렇지 않으면 다시 1

단계부터 반복된다.

이상과 같은 ConDSS 문제해결 과정을 도시하면 [그림 10]과 같다.

VII. 실험결과

ConDSS에 의한 실험자료와 그 실험결과는 각각 〈표 3〉, 〈표 4〉 그리고 〈표 5〉와 〈표 6〉에 요약되어 있다. 이표에서 QM은 question mark, CC는 cash cow를 의미하며, 또한 *는 ConDSS에 의해서 정확히 추론되었음을 의미한다.

〈표 3〉 전체 자료중 그룹 A를 제외한 실험 자료

BCG	GE	Growth/Gain	Competitor's BCG	Strategy	
				Production	Market Share
QM	Low	-	Star	cease	withdraw
QM	Low	Share Gainer	QM	reduce	decrease
QM	Low	Share Loser	QM	sustain	decrease
Dog	High	Share Gainer	Dog	reduce	maintain
Dog	High	Share Loser	Dog	augment	maintain
Dog	High	-	Cash Co	cease	withdraw
Dog	Low	-	-	cease	withdraw

〈표 4〉 전체자료중 그룹 B를 제외한 실험자료

BCG	GE	Growth/Gain	Competitor's BCG	Strategy	
				Production	Market Share
Cash Cow	Low	Share Gainer	Dog	reduce	maintain
Cash Cow	Low	Share Loser	Dog	augment	maintain
Star	Low	Share Gainer	-	reduce	maintain
Star	Low	Share Loser	-	augment	maintain
QM	Low	Share Gainer	QM	reduce	maintain
QM	Low	Share Loser	QM	augment	decrease
Dog	High	-	Cash	cease	withdraw
Dog	Low	-	-	cease	withdraw

〈표 5〉와 〈표 6〉에서 실험된 실험자료는 ConDSS가 전혀 학습하지 않았던 자료이다. 이는 〈표 3〉과 〈표 4〉에 정리되어 있는 바와 같다. 즉, ConDSS는 오직 학습자료를 통한 지식만을 가지고 이와같이 전혀 학습하지 않았던 시험자료를 인식하여야 하는 것이다. 이러한 상황에서 ConDSS는 꽤 높은 인식도를 보여주고 있다. 이러한 인식능력은 일반화 효과라고 알려져 있는데, 특히 다양한 학습자료를 이용하여 학습했을때 더 높은 일반화 효과를 보여준다. 이는 본 연구에서도 확인된 결과이다. 즉, 〈표 5〉의 경우는 그룹A로 학습한 후 〈표 3〉으로 실험한 결과이고, 〈표 6〉은 그룹B로 학습한 후 〈표 4〉로 실험한 결과이다. 결과에서도 알 수 있는 것처럼 〈표 5〉의 경우보다는 〈표 6〉의 경우가 더 높은 인식도를 보여주고 있다. 왜냐하면 그룹B의 경우가 그룹A의 경우보다 더 다양한 학습자료를 갖고 있기 때문이다. 그러나, 〈표 5〉의 경우에도 2번째 시험자료와 7번째 시험자료는 실제자료와 비교할 때

매우 유사한 값으로 인식되기 때문 ConDSS의 견고성을 보여준다.

고원효과의 측면에서 살펴봐도 ConDSS는 기존의 KBDSS보다 훨씬 우수한 효과를 보여주고 있다. 본 연구에서는 VP-Expert [1987]라는 전문가체제 shell을 이용하여 symbolic한 지식을 갖는 일반적인 지식베이스를 구성하여 이를 실험하였다. [그림 11]은 일반적인 지식베이스의 일부분을 보여주고 있다. 그 결과 이와같은 순수한 symbolic 지식만을 갖는 KBDSS는 〈표 3〉과 〈표 4〉에서와 같은 실험자료를 전혀 인식하지 못하였다. 그러나 인공신경망 지식베이스를 갖춘 ConDSS는 〈표 5,6〉에 요약된 것과 같이 이러한 문제를 극복할 수가 있었다.

〈표 5〉 학습자료 그룹 A에 의한 시험결과

Test Sample	Type	Production Strategy		Market Share Strategy	
		actual	ConDSS	actual	ConDSS
1	QM	cease	sustain	withdraw	decrease
2	QM	reduce	sustain	decrease	decrease
3	QM*	sustain	sustain	decrease	decrease
4	Dog*	reduce	reduce	Maintain	Maintain
5	Dog*	augment	augment	Maintain	Maintain
6	Dog	cease	augment	withdraw	Maintain
7	Dog	cease	reduce	withdraw	decrease

〈표 6〉 학습자료 그룹 B에 의한 시험결과

Test Sample	Type	Production Strategy		Market Share Strategy	
		actual	ConDSS	actual	ConDSS
1	CC*	reduce	reduce	Maintain	Maintain
2	CC*	augment	augment	Maintain	Maintain
3	Star*	reduce	reduce	Maintain	Maintain
4	Star*	augment	augment	Maintain	Maintain
5	QM*	reduce	reduce	Maintain	Maintain
6	QM*	augment	augment	decrease	decrease
7	Dog	cease	augment	withdraw	Maintain
8	Dog	cease	cease	withdraw	Maintain

```

rule 1
if product_BCG_position = SW_of_BCG
then product_type = cash_cow;

rule 5
if competitor_product_BCG_position = SW_of_BCG
then competitor_product_type = cash_cow;

rule 9
if product_GE_position = HS_of_GE
or product_GE_position = HM_of_GE
or product_GE_position = MS_of_GE
then product_strength = High_Overall_Attractiveness
display
"This product can be called as a strong product because it belongs to the area of High Overall Attractiveness";

rule 12
if product_growth_rate > market_growth_rate
then product_market_share = share_gainer;

rule 15
if competitor_product_growth_rate > market_growth_rate
then competitor_product_market_share = share_gainer;

rule 18
if competitor_product_market_share = share_gainer
then increasing_market_share = relatively_difficult;

rule 20
if product_type = cash_cow
and product_strength = High_Overall_Attractiveness
and competitor_product_type = dog
then product_overall_type = potential_cash_cow;

rule 37
if product_type = cash_cow
and product_strength = High_Overall_Attractiveness
and product_market_share = share_gainer
then production_strategy = reduce
and market_share_strategy = maintain

```

[그림 11] 일반적인 지식베이스의 지식

VII. 결 론

본 연구에서는 인공신경망을 이용한 지식베이스 개발을 통하여 문제 환경이 변하여도 상황변화에 보다 지능적으로 대처할 수 있는 ConDSS개념을 제시하였다. 이러한 ConDSS는 기존의 KB-DSS보다 일반화 효과와 학습능력이라는 측면에서 가능성을 보여 주었다. 그러나 본 연구의 한계점은 다음과 같다.

- 1) 보다 충분한 실제 전략계획 자료를 획득하기가 쉽지 않기 때문에 본 연구에서 제시하는 ConDSS개념을 실제 상황하에서 적용하기가 어렵다는 것이다.
- 2) 학습된 인공신경망으로부터 일반화된 규칙을 뽑는 과정을 보다 정형화하여야 할 필요성이

있다.

이와 같은 문제점을 극복하기 위하여 필자는 모 전자회사에 대한 자료를 받아 이를 토대로 연구를 진행하고 있으며, 또한 본 연구를 위한 프로토타입으로 한글로 사용자 인터페이스가 가능한 본격적인 프로그램을 C언어로 개발하고 있다. 이 프로토타입에는 다양한 전략 시뮬레이션 (strategic simulation), 예측, 그래픽, 규칙생성기 등 여러가지 메뉴가 포함되어 있어서, 보다 유용한 전략계획 수립에 도움을 주고자 설계되어 있다. 이에 대한 결과는 또 다른 연구논문을 통하여 곧 발표할 예정이다.

참 고 문 헌

- Abell, D.F. and J.S. Hammond, *Strategic Market Planning: Problems and Analytical Approach*, Prentice-Hall, Englewood Cliffs, NJ, 1979.
- Alter, S.L., "A taxonomy of decision support systems", *Sloan Management Review*, Fall 1977, 39-56.
- Baba, K., I. Enbutsu and M. Yoda, "Explicit representation of knowledge acquired from plant historical data using neural network", *International Joint Conference on Neural Networks*, San Diego, 1990, Vol. 3, 155-160.
- Bonczek, R.H., C.W. Holsapple and A.B. Winston, "Future directions for developing decision support systems", *Decision Sciences*, Vol. 11, 1980, 616-631.
- Bradshaw, G., R. Fozzard and L. Ceci, "A connectionist expert system that actually works", *International Joint Conference on Neural Networks*, San Diego, Calif., Vol. 1, 1988, 248-255.
- Caudill, M., "Using neural nets: representing knowledge: Part 1", *AI Expert*, Dec. 1989, 34-41.
- , "Using neural nets: Hybrid expert networks: Part 6", *AI Expert*, Nov. 1990, 49-54.
- Dutta, S. and S. Shekhar, "Bond rating: A non-

- conservative application of neural networks", *Proceedings of the IEEE International Conference on Neural Networks*, Vol. II, San Diego, Calif., 1988, 443-450.
- Elkins, L.R., A. Farsaie and D.A. Valdez, "An artificial neural networks approach to machine learning", *Proceedings of the 5th Florida Artificial Intelligence Research Symposium*, 1992, 39-43.
- Enbutsu, I., K. Baba and N. Hara, "Fuzzy rule extraction from a multilayered neural network", *International Joint Conference on Neural Networks*, Seattle, 1991, Vol. 2, 461-465.
- Forsyth, R. (Eds.), *Expert Systems: Principles and Case Studies*, Chapman and Hall, 1984.
- Gallant, S.I., "Connectionist expert systems", *Communications of the ACM*, Vol. 31, No. 2, Feb. 1988, 152-169.
- Ginzberg, M.J., and Stohr, E.A., "Decision support systems: issues and perspectives", Presented at the *NYU Symposium on Decision Support Systems*, New York, May 1981, 21-22.
- Glueck, W.F., *Business Policy and Strategic Management*, McGraw-Hill, 1980.
- Gorry, G.A. and M.S. Scott Morton, "A framework for management information systems", *Sloan Management Review*, Vol. 13, No. 1, Fall 1971, 55-70.
- Goul, M., and F. Tonge, "Project IPMA: Applying decision support system design principles to building expert-based systems", *Decision Sciences*, Vol. 18, 1987, 448-467.
- Henderson, J. "Finding synergy between decision support system and expert systems research", *Decision Sciences*, Vol. 18, 1987, 333-349.
- Holloway, C. and J.A. Pearce II, "Computer assisted strategic planning", *Long Range Planning*, Vol. 15, No. 4, 1982, 56-63.
- Kastner, J.K. and S.J. Hong, "A review of expert systems", *European Journal of Operational Research*, Vol. 18, 1984, 285-292.
- Keen, P.G.W. and M.S. Scott Morton, *Decision Support Systems: An Organizational Perspective*, Addison-Wesley, 1978.
- Larreche, J.C. and V. Srinivasan, "STRATPORT: A model for the evolution and formulation of business portfolio strategies", *Management Science*, Vol. 28, No. 9, 1982, 979-1001.
- Lee, H.K., "Interactions of long-term planning and short-term planning: An intelligent DSS by post model analysis approach", Unpublished Master Thesis, Dept. of Management Science, Korea Advanced Institute of Science and Technology, 1985.
- Lippmann, R.P., "An introduction to computing with neural nets", *IEEE ASSP Magazine*, Vol. 3, No. 4, 1988, 4-22.

- McMillan, C., M.C. Mozer and O. Smolensky, "Learning explicit rules in a neural network", *International Joint Conference on Neural Networks*, Seattle, 1991, Vol. 2, 83-88.
- Mockler, R.J., *Knowledge-Based Systems for Strategic Planning*. Prentice-Hall, Englewood Cliffs, NJ, 1989.
- Mockler, R.J., and D.G. Dologite, "Knowledge-based systems to support strategic planning decision making", *Proceedings of the Twenty-Fourth Annual Hawaii International Conference on System Sciences*, Vol. 3, 1991, 173-180.
- Poli, R., S. Cagnoni, R. Livi, G. Coppini, and G. Valli, "A neural network expert system for diagnosing and treating hypertension", *IEEE Computer*, March 1991, 64-71.
- Porter, M.E., *Competitive Strategy: Techniques for Analyzing Industries and Competitors*, Macmillan, NY, 1980.
- Rowe, A.J., R.O. Mason and K. Dickel, *Strategic Management & Business Policy: A Methodological Approach*, Addison-Wesley, Reading, Massachusetts, 1982.
- Rumelhart, D.E., G.E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. I: Foundations, (Eds.) D.E. Rumelhart and J.L. McClelland, MIT Press, 1986.
- Rumelhart, D., and D. Zipser, "Feature discovery by competitive learning". *Cognitive Science*, Vol. 9, 1985, 75-112.
- Samad, T., "Towards connectionist rule-based systems". *International Joint Conference on Neural Networks*, San Diego, Calif., Vol. 2, 1988, 525-532.
- Sprague, R.H. and T.D. Carlson, *Building Effective Decision Support Systems*, Prentice-Hall, 1982.
- VP-EXPERT: Rule-Based Expert System Development Tool**, Paperback Software, 1987.
- Waterman, D.A., *A Guide to Expert Systems*, Addison Wesley, 1986.
- Zeidenberg, M., *Neural Network Models in Artificial Intelligence*, Ellis Horwood, England, 1990.
- Rumelhart, D.E., G.E. Hinton, and R.J. Williams,

◇ 저자소개 ◇



저자 이건창은 성균관대학교 경영학과를 졸업하고, KAIST 경영과학과에서 석사 및 박사학위를 취득하였다. 학위취득후 동남투자자문(주) 조사분석부에서 인공지능을 이용한 지능형 주식투자시스템은 설계 및 개발하였으며, 1990년 3월부터 경기 대학과 경영정보학과 조교수로 근무하여 현재에 이르고 있다. 그의 주요 관심분야는 시뮬레이션, 인공신경망이론 및 퍼지이론을 이용한 전문가시스템 개발에 있으며, 특히 변화하는 환경에 능동적으로 적응할 수 있는 자기적응(Self-Evolving) 능력이 있는 전문가 시스템 개발에 관심이 있다. 주요응용분야는 전략계획 (Strategic Planning) 부분과 경영예측 (Business Forecasting) 부문이다.