

# 인공지능 연구에서의 통계적 방법

차운옥<sup>1)</sup>

## <요약>

인공지능 연구의 두 가지 접근방법인 기호주의와 연결주의에 대해 간단히 알아보고, 인공지능 연구의 어떤 분야에 어떤 통계적 방법이 사용되고 있는지 조사하였다. 기호주의 방식에서 통계학이 많이 사용되고 있음을 알 수 있고, 특히 전문가 시스템에서의 불확실성 처리문제와 Bayesian 학습방법, 패턴인식 분야 연구에서 Bayes 이론이 중요 한 역할을 하는 것을 알 수 있다.

## 1. 서론

인공지능이란 사람들의 행위에서 지능을 연상할 수 있는, 즉 언어를 이해하고 사물을 인식하고 학습하며, 지식과 경험을 토대로 추론하고 문제를 해결하는 등의 기능을 갖춘 컴퓨터를 개발하고자 하는 연구분야이다.

인공지능 연구는 크게 보아 두 가지 접근 방법에 의해 이루어진다고 볼 수 있다. 첫째는 기호주의 방식이다. 이 방법에서는 주어진 문제에 대하여 기본이 되는 개념, 이들 간의 관계 및 제약조건, 구체적인 사실들을 정해진 기호체계 내에서 기호들의 집합으로 표현한 후, 이 기호들을 적절히 변형하고 조작함으로서 추론, 의사결정, 학습 등을 수행할 수 있다고 보는 것이다. 두번째 방법은 연결주의 방식이다. 인공지능을 실현하기 위해서는 학습이나 언어, 인식이나 감각의 본질에 대한 이해가 필요하며, 인간의 두뇌를 모방한 인공 신경망을 구성하여 정보처리의 최소 단위인 뉴런(neuron)들이 협동적, 경쟁적 상호작용을 하도록 하여 전체적이고 종합적인 정보처리를 해야 한다고 보는 견해이다.

인공지능의 주요 연구분야는 기초 연구분야로 지식표현(knowledge representation), 탐색(search), 문제풀이(problem solving), 정리증명(theorem proving), 추론(reasoning), 기계학습(machine learning), 인공신경망(artificial neural network), 인공지능 언어(language)등이 있고, 응용 연구분야로서는 전문가 시스템(expert system),

1) 한성대학교 이공대학 정보전산학부 조교수, 서울시 성북구 삼선동 2가 389

자연언어 이해(natural language understanding), 영상 및 패턴인식(vision, pattern recognition), 로보틱스(robotics), 자동 프로그래밍(automatic programming), 컴퓨터 이용 교육(intelligent computer aided instruction, intelligent tutoring) 등이 있다.

본 연구에서는 인공지능 연구에서의 두 가지 접근방법에 대해 간단히 알아보고, 각 방법에서 어떤 문제에 어떤 통계적 방법이 사용되었는지 조사하고, 통계적 방법의 인공지능 연구에 대한 기여를 살펴보도록 한다. 이렇게 함으로써 앞으로의 인공지능 연구에서 어떤 분야에 어떤 통계적 기법이 적용가능 할 것인지에 대한 생각을 할 수 있을 것이다.

## 2. 인공지능 연구

### 2.1 기호주의 방식

사람들이 일상적으로 쉽게 활용하는 추론능력은 다양한 종류의 사물과 그들 사이의 관계에 대한 방대한 정보와 상식과 지식을 필요로 한다. 컴퓨터에게 인간과 같은 능력을 부여하려면, 관련된 지식이 신속히 처리되어 타당한 추론 결과를 만들어 내거나 특정한 질문에 답할 수 있도록, 지식을 체계화시켜 기억장치 속에 저장시킬 수 있어야 한다.

인공지능에서 사용되는 지식의 종류로는 문제분야에 관한 지식, 대상세계에서 성립하는 법칙이나 경험에 의한 법칙, 문제를 해결하는데 어떤 지식이 필요한지에 대한 지식에 관한 지식(meta-knowledge)등이 있다. 이러한 지식들은 정확하게 표현하는데 많은 어려움이 있으며, 지식의 양도 많고 끊임없이 변화하는 특징을 가진다. 따라서 지식을 컴퓨터 내부에 어떻게 저장하느냐가 중요한 문제가 되며, 저장된 지식을 쉽게 수정, 삭제할 수 있어야 하고 새로운 지식을 쉽게 삽입도 할 수 있어야 한다.

지식을 컴퓨터에 표현하는 방법에 대해서 많은 연구가 있어 왔는데, 다루고자 하는 문제의 성격과 그 문제에 따른 추론방법, 지식의 종류에 따라 알맞은 방법을 사용하여야 한다. 또, 한가지 방법만 사용할 것이 아니라 여러 방법을 같이 사용하여 해당 문제분야에 대한 지식을 효과적으로 표현하여야 한다. 대표적인 지식표현 방법으로는 서술논리를 이용하는 방법, 의미 네트워크에 의한 방법, 프레임(frame)에 의한 방법, 스크립트(script)에 의한 방법, 규칙을 이용하는 방법, 믿음 네트워크(belief network)에 의한 방법 등이 있다. 또 각각의 지식표현 방법에서, 주어진 사실로부터 새로운 사실을 추론해내는 추론 방법에 대해서도 많은 연구가 이루어졌다.

인간이 사고하는 이유는 주어진 문제를 해결하고자 하기 때문이고 자기의 목적을

달성하기 위해서이므로, 인공지능에 대한 많은 연구가 문제 풀이 분야에 집중되어 왔다. 인공지능에서의 문제풀이는 단순한 계산이 아닌 시행착오적 방법에 의한 문제해결 방법을 의미한다. 즉 이 방법에서는 가능한 수많은 해들이 놓인 공간에서 탐색(search)에 의해 하나의 해를 찾음으로써 문제를 해결한다. 그러므로 인공지능이 대상으로 하는 것은 알고리즘화 되지 않는 비정형적인 문제이고 탐색형 추론을 필요로 하는 문제이다. 문제풀이 방법으로는 상태공간을 이용하는 방법과 문제 축소 방법이 있다. 문제해결을 위한 탐색방법에 대해서 많은 연구가 이루어졌는데, 그 중에서 경험으로부터 얻은 규칙을 사용하는 휴리스틱(heuristic) 탐색은 원하는 해답을 효율적으로 찾을 수 있는 매우 중요한 방법이다.

인간의 가장 두드러진 특징은 새로운 것을 배우고 변화하는 환경에 적응할 수 있는 학습능력을 가지고 있는 것이다. 만일 컴퓨터도 이와 같은 학습능력을 가질 수 있다면 지능을 가진 인간과 유사한 적응력을 가질 수 있게 될 것이다. 인공지능에서는 학습을 '프로그램이 하나의 문제를 수행한 후에 그 추론과정에서 얻은 경험을 바탕으로 시스템의 지식을 수정 및 보완하여, 다음에 그 문제나 또는 비슷한 문제를 수행할 때에는 처음보다 더 효율적이고 효과적으로 문제를 해결할 수 있는 적응성'이라고 정의 한다. 과연 컴퓨터가 배우는 능력을 갖출 수 있느냐에 대해서는 논란이 많이 있다. 학습에서는 새로운 지식의 습득과 새로운 정보의 추론이 중요하므로, 컴퓨터는 단순히 자료를 인식하는 것만이 아니라, 새로운 정보를 통하여 자신의 경험으로부터 얻은 지식을 수정하고 보다 정확한 지식으로 개선해 나가는 능력을 갖추어야 한다. 컴퓨터에 학습능력을 부여하는 방법으로는 귀납법, 연역법, 유추법 등이 있다.

이상의 기호주의 연구 방법에서는, 인간의 지능이 어떻게 동작하는지에 상관없이 인간의 지능적 사고를 단순히 기호 논리적 체계로 모형화해서 단지 컴퓨터가 지적인 능력을 가질 수 있도록 하면 된다고 생각하는 것이다.

## 2.2 연결주의 방식

이 방식에서는 인간의 두뇌가 어떻게 생겼으며 어떻게 동작하는지를 알아내어 그 원리를 바탕으로 새로운 모델을 구축해야 한다는 것이다. 두뇌의 동작원리에 대해서 그 동안 많은 연구가 있었지만 아직까지 밝혀진 것이 별로 많지 않기 때문에 이 방법에도 한계는 있다.

뉴런은 세포체와 수상돌기, 축색으로 구성되어 있고, 각 뉴런에서는 다른 뉴런들로부터 수많은 입력을 받아 세포체에서 종합하여 처리한 정보를 축색돌기로 보내고, 축색돌기로 전달된 정보는 시냅스(synapse)를 통해 전기신호의 형태로 다른 뉴런들의

수상들기에 전달된다. 이와 같이 뉴런의 동작은 외부로부터의 정보를 판단하여 전기 신호를 낼 것인가 말 것인가를 결정하는 대단히 단순하고 기계적인 것이다. 또 뉴런들이 여러 가지 자극을 받는 사이에 어떤 규칙에 따라 연결방식이 조금씩 변해가면서 물체를 인식하거나 글을 읽거나 하는 학습이 이루어진다.

따라서 인간의 뇌의 동작원리와 기존의 직렬 컴퓨터간에는 근본적인 차이가 있는 것을 알 수 있다. 뇌에 저장되어 있는 정보는 직렬 컴퓨터에서처럼 기억장치의 특정한 주소에 저장되어 있는 것이 아니고 구조 전체에 걸쳐 적절히 분산되어 있고, 2진 기호로 저장되어 있는 것이 아니라 뉴런들이 강하게 또는 약하게 연결된 형태를 취하고 있다. 저장된 정보를 검색할 때에는 직렬 컴퓨터에서처럼 가상의 숫자로 된 번지에 의해서가 아니라 기억된 내용에 의해 검색되므로 내용주소방식이라 한다.

신경망의 동작을 수리적 모델로 제시한 연구는 1943년 맥클로(W. McCulloch)와 피츠(W. Pitts)에 의해서 이루어졌다. 그들은 뉴런의 모델로서, 여러 개 입력의 합이 일정 값보다 큰가, 작은가에 따라 0 또는 1 두 가지 출력 값을 갖는 이진소자 형태를 제시하였다. 1949년에는 심리학자 헬프(D. Hebb)이 오늘날 신경망의 학습규칙으로 가장 많이 사용하는 '헬프의 학습규칙'을 제안하였다. 우리의 두뇌 작용은 각각의 뉴런의 기능에 의한 것이 아니라, 상호간에 어떻게 연결이 되어 있으며 뉴런들 사이의 연결강도가 어떠한가에 따라 이루어지므로 뉴런간의 연결강도의 변화로서 학습을 실현시킬 수 있다는 것이다.

1957년 미국의 로젠블라트(F. Rosenblatt)는 뉴런과 유사한 단순 계산기능을 갖는 퍼셉트론(Perceptron)이라는 모델을 제시하고 뉴런간의 결합에 학습 능력을 부여한 패턴 인식 장치에 대해 연구하였다. 이 연구는 큰 호응을 얻어 그후 많은 연구들이 이루어졌는데, 이 시기는 뇌로부터 배우는 신경망 연구의 첫 번째 융성기라 할 수 있다.

그러나 1960년대 후반에 이르러서는 컴퓨터 하드웨어 기술이 눈부시게 발전하고 기호처리에 의한 논리적 정보처리의 우월성이 대두된 반면, 뇌의 계산 원리는 알려진 것이 별로 없고 앞으로 쉽게 밝혀질 것 같지도 않은 상황이 되었다. 1969년 미국의 민스키(M. Minsky)와 파퍼트(S. Papert)는 퍼셉트론 능력의 한계를 지적하고 논리기호의 순차형 처리를 위주로 하는 기호주의를 주장하여 이때부터 기호처리를 위주로 하는 인공지능 연구시대가 되고 신경망 연구는 암흑기를 맞게 된다. 그러나 이 시기에도 신경망의 기초 이론은 여러 학자들에 의해 확실히 축적되었다.

그 후, 1980년대에 들어서면서 신경망 연구는 부흥기를 맞게 된다. 신경망이 다시 활기를 띠게 된 직접적인 원인은, 초기의 낙관적인 전망에도 불구하고 기호주의에 의한 인공지능 연구가 한계에 부딪힌 데 있다고 할 수 있다. 왜냐하면 사람의 인지기능은 순차적 처리에 의한 기호처리만이 아니라 고도의 병렬처리를 수행하기 때문에 논

리와 기호처리 한 면에만 의지한 연구는 계산량의 폭발적인 증가와 같은 어려움을 극복하지 못하였기 때문이다.

이때부터 신경망의 많은 모델들이 나오게 되어 이론뿐만이 아니고 여러 용용문제의 연구가 활발히 진행되고 있다. 신경망 연구는 기존의 직렬 컴퓨터를 이용하여 신경망을 모의실험하는 방법과, 하드웨어적으로 신경 컴퓨터를 구현하는 방법으로 이루어지고 있다. 신경망 모델의 특징으로는 예제를 통한 학습이 가능하다는 점, 정보를 분산된 형태로 저장하여 네트워크가 일부 파손되더라도 제대로 작동되는 결합허용 시스템이라는 점, 병렬 분산처리가 가능하다는 점 등을 들 수 있다.

지금까지 인공지능 연구의 두 가지 접근방법에 대해 알아보았다. 앞으로는 이들 두 방법을 상호보완적으로 사용하여 인공지능 분야의 연구가 이루어져야 할 것이다.

### 3. 기호주의에서의 통계적 방법

#### 3.1 전문가 시스템에서의 불확실성 처리

기호주의 인공지능 연구의 용용분야로 상업적으로도 가장 성공을 거둔 분야는 전문가 시스템 분야이다. 전문가 시스템이란 인간의 전문적인 지식이 필요한 정도의 어려운 문제를 풀기 위해 전문가들의 과제 수행과정을 컴퓨터가 대신할 수 있도록 하는 지적인 프로그램을 말한다.

전문가 시스템은 지식베이스, 추론엔진, 지식획득 부시스템, 설명 부시스템, 사용자 인터페이스 등으로 구성되며, 효율적인 전문가 시스템이 되기 위해서는 전문가의 지식을 완전하게 추출하여 지식베이스에 저장하는 문제, 지식을 이용하여 원하는 해를 구하는 추론과정, 사용자에게 추론의 결과를 설명해 줄 수 있는 인터페이스(interface) 기능 등이 잘 이루어져야 한다.

인간은 일상생활에서 애매한 표현을 사용하고 애매한 지식을 이용하는 경우가 많이 있다. 따라서 컴퓨터가 인공지능을 가지고 인간이 원하는 바를 제대로 수행하기 위해서는 불확실하거나 부정확한 사실, 또 불충분한 지식을 표현할 수 있어야 하고 불확실성 하에서의 추론도 할 수 있어야 한다.

전문가시스템에서의 불확실성의 원인은 다음과 같다[1].

##### (1) 정보의 비신뢰성(unreliability of information)

전문가로부터의 전문지식이 전부 완전하고 정확할 수는 없다.

##### (2) 지식표현언어의 부정확성(imprecise descriptive language)

전문가가 자연언어로 표현한 지식을 지식베이스에 형식언어(formal language)로

정확하게 표현하기가 어렵다.

(3) 불완전 정보에 의한 추론(inference with incomplete information)

불완전한 정보에 의한 추론결과는 불확실성이 더욱 파급된다.

(4) 다수의 전문가로부터의 전문지식의 불일치(disconsensus of expertise from multiple experts)

전문가 시스템에서의 불확실성은, 전문가 시스템 사용자로부터 비롯되는 관찰된 사실이 내포하는 것과, 전문가로부터의 전문지식이 내포하는 것으로 나누어 볼 수 있다. 이러한 불확실성은 시간이 경과할 수록 누적되어 처음에는 문제해결에 큰 영향을 미치지 않을 수도 있으나 나중에는 이를 고려하지 않으면 좋은 결과를 얻을 수가 없게 된다. 따라서 전문가시스템에서 불확실성을 다루는 것은 매우 중요한 문제이며 이를 해결하기 위해서 불확실성을 표현하는 방법과 이로부터 문제를 해결할 수 있는 추론 방법이 필요하다.

불확실성 추론(reasoning under uncertainty)은 불확실성의 표현, 결합 및 전파방법에 따라 크게 정성적(qualitative, non-numerical)방법과 정량적(quantitative, numerical)방법으로 구분한다.

정성적 방법에서는 불확실성을 언어적 용어(linguistic term)를 사용하여 표현하는데 McDermott & Dole의 “default 추론방법”, Kleer의 “가정에 근거한 진리 유지방법(ATMS)”, Cohen의 “Endorsement” 방법 등이 있다. 이 방법들에서는 언어적 용어를 사용함으로써 어떤 사건, 규칙, 가설 등에 대해 특정 전문가의 주관적인 불확실 정도가 다른 사람에게 객관적으로 전달될 수 있다. 그러나 언어 자체의 모호성에 의해 불확실 증거를 결합하는 규칙을 정의하기가 매우 어렵고 수학적 기반이 약하여 실제문제 영역에 적용되지 못하고 대부분 연구상태에 머물고 있다.

정량적 방법에서는 불확실성을 단일값, 또는 [하한, 상한]의 범위 값으로 표현하여 추론과정을 거치면서 불확실성을 표현한 값인 불확실도를 전파하고 결합하는 방법이다. 여기에는 Bayesian 방법, Certainty Factor 방법, Dempster-Shafer 방법, Fuzzy 추론방법 등이 있다.

불확실성을 처리하기 위하여 확률이론을 이용하는 Bayesian 방법에 대해 알아본다. Bayes 법칙은 아래와 같다.

$$P(d_i/e) = \frac{P(d_i) \times P(e/d_i)}{\sum_j P(d_j) \times P(e/d_j)}$$

여기에서 각  $d_i$ 들은 서로소(disjoint)이며  $P(d_i)$ 는 사전확률(prior probability)이다. 증거(evidence)  $e$ 가 주어졌을 때  $d_i$ 의 사후확률(posterior probability)  $P(d_i/e)$ 를 구하기

위해 현실적으로 구하기 쉬운  $P(e/d_i)$ 를 이용하는 것이다.

광물질 탐사를 조언하는 전문가 시스템 PROSPECTOR는 전문가의 주관적인 확률(subjective probability)을 이용하는 Bayesian 방법을 사용하여 실제 문제해결에서 큰 효과를 나타내어 성공적인 전문가 시스템의 하나로 불리고 있다. PROSPECTOR에서의 불확실성 처리 방법에 대해서 간단히 알아본다.

PROSPECTOR에서는 전문가로부터 얻은 지식을 규칙(rule)형태로 표현하여 지식베이스를 구성하며 지식베이스는 추론망(inference network)을 형성하게 된다. 이때 각 링크는 해당 규칙의 믿음의 정도를 나타내는 주관적인 확률값을 가진다.

사용자가 추론 망의 아래 부분에 있는 노드의 참, 거짓의 확률값을 알 때, 원하는 가설  $H_i$ 의 조건확률  $P(H_i/e_1 \& e_2 \dots)$ 을 구하기 위해 이 값들이 추론망을 전파(propagate)하게 된다[2]. 이때 기반이 되는 것이 Bayes 법칙이다.

아무런 정보가 주어지지 않았을 때, 각 명제  $H$ 는 사전확률  $P(H)$ 를 가지고 있다고 가정하고, 이 사전확률은 전문가로부터 얻는다. 증거들이 하나씩 알려지면서 이로 인한 사후확률을 계산하게 된다. 이 값을 구하기 위하여 다음의 식들을 사용한다.

#### (1) Proior odds

$$O(H) = \frac{P(H)}{P(\bar{H})} = \frac{P(H)}{1 - P(H)}$$

#### (2) Posterior odds

$$O(H/E) = \frac{P(H/E)}{P(\bar{H}/E)} = \frac{P(H/E)}{1 - P(H/E)}$$

#### (3) Likelihood ratio

$$LS = \frac{P(E/H)}{P(E/\bar{H})}$$

#### (4) Odds likelihood

$$O(H/E) = LS \times O(H)$$

식 (4)는 증거  $E$ 가 있는 경우에 가설  $H$ 에 대한 Odds가 LS만큼 변화된다는 것을 의미한다.

Bayes 법칙은 증거에 대한 확실성이 완전히 참이거나 거짓일 경우에 사용될 수 있다. 그런데 실제로는 사용자가 증거에 대한 확실성을 완전히 알 수가 없고 확실의 정도만 알 수 있는 경우가 대부분이다. 발견되는 증거에 대한 사용자의 믿음의 정도(degree of confidence)를 가지고 사후확률을 계산하기 위해서는 보간법(Interpolation)을 사용한다. 즉  $E'$ 가 증거  $E$ 에 대한 믿음의 정도를 나타낸다고 볼 때  $P(H/E')$ 는

$P(H/E)$  와  $P(H/\bar{E})$  사이에 존재하므로  $P(H/E')$ 를  $P(E/E')$ 의 선형함수로 보고 보간법으로 그 값을 구한다.

실세계의 문제를 해결하기 위해서는, 가설  $H$ 에 대하여 여러 개의 증거들이 영향을 미치는 경우와 증거들이 논리적으로 결합한 경우를 처리할 수 있어야 하며, PROSPECTOR에서는 다음과 같이 한다.

(1) 여러 개의 증거가 있는 경우

$$O(H/E_1', E_2', \dots, E_n') = \prod_{i=1}^n L_i' \times O(H)$$

여기에서  $L_i' = \frac{O(H/E_i')}{O(H)}$  이고,  $E_i$ 는 서로 독립적이다.

(2) 증거들이 논리적으로 결합된 경우( $E_i$ 들은 서로 동질(consonant)이라고 가정)

만일  $E = E_1$  and  $E_2$  and  $\dots$   $E_n$ 이면  $P(E) = \min P(E_i)$

만일  $E = E_1$  or  $E_2$  or  $\dots$   $E_n$  이면  $P(E) = \max P(E_i)$

만일  $E = \text{not } E$  이면  $P(E) = 1 - P(E)$

PROSPECTOR에서는 확률이론에 근거하여 실세계의 문제를 잘 해결하였지만 여러 가지 가정하에서 Bayes 이론을 특별한 방법으로 수정하여 사용하였다. 순수한 Bayesian 방법으로 추론 망에서 확률을 전파하는 방법에 대한 연구가 많이 이루어졌는데, Pearl은 계층적으로 구성된 믿음 네트워크(belief network)에서 확률 값을 전파시킬 때 Bayes 법칙을 이용할 수 있도록 Belief parameter, Communication message, Updating rule들을 정의한 효과적인 방법을 제시하였다[3]. 믿음 네트워크는 지식을 컴퓨터에 나타내는 방법으로써 방향그래프(directed graph)로 표현된다. 노드는 명제(proposition) 또는 변수(variable)를 나타내고, 링크는 연결된 명제들 사이의 직접적인 인과관계를 나타내고 조건확률(conditional probability)값으로 관계의 강약을 나타낸다. 믿음 네트워크는 인과 네트워크(causal network)라고도 한다. Kim은 계층적 인과 네트워크(Hierachical causal network)상에서 믿음의 정도를 수정할 수 있는 방법을 제안하였으며[4], 이후 많은 관련 후속연구가 이루어졌다[5,6,7,8,9,10]. 그리고 또 다른 통계적 추론방법으로는 믿음 네트워크를 clique tree로 재구성하여 불확실성을 처리하는 방법[11,12]이 있고, 확률논리(Probabilistic logic)에 의한 방법[13]이 있다.

Dempster-Shafer 불확실성 처리 방법[14]은 Bayesian방법을 확장한 개념을 사용한다. 이 방법의 특성은 불확실성을 확률과 같이 하나의 값으로 나타내는 것이 아니고 구간으로 표현하는 것이다. Spiegelhalter는 확률이 전문가 시스템의 불확실성을 다루는데 가장 좋은 방법이라고 주장하며[15], Lindley는 불확실성을 다루는 다른 모든 방

법들은 다 확률을 이용하면 더 잘 설명이 된다고 주장한다[16]. 따라서 확률이론에 기반을 둔 Bayesian 방법은 불확실성 해결연구의 주류를 차지하고 있으며 이에 대한 많은 연구가 이루어지고 있다.

### 3.2 통계기반 전문가시스템(Statistics-Based Expert Systems)

확률이론과 통계에 의한 전문가 시스템은 기존의 규칙베이스 전문가 시스템과는 지식을 지식베이스에 저장하는 방법과 지식이 추론엔진에서 처리되는 방법에서 완전히다르다. 판별분석(Discriminant Analysis)에 의한 전문가시스템은 의학진단이나 고장진단 같은 진단문제(diagnosis problem)에 적용할 수 있고, 실제로 구현하기 쉬운 추론엔진을 설계할 수가 있다.

판별분석은 2개 이상의 모집단에서 추출된 표본들의 정보를 이용하여 이 표본들이 어느 모집단에서 추출된 것인지를 결정해 줄 수 있는 기준을 찾아주는 분석기법이다. 표본들이 어느 모집단으로부터 추출되었는지 알 수 있는 훈련표본(training sample)으로부터 잘못 분류되었을 때 발생하는 기대비용(expected cost of misclassification)이나 잘못 분류될 확률(total probability of misclassification)을 최소로 해주는 확률변수들의 함수를 구해 이 기준을 가지고 어느 모집단에서 추출되었는지 모르는 새로운 시험표본(test sample)을 어느 하나의 모집단으로 분류해 준다[17].

판별분석에 의한 전문가 시스템의 지식베이스는 판별함수와 관련되는 파라미터로 구성되고, 추론엔진은 알고 있는 값들로부터 판별함수를 계산하는 프로그램이나 프로시저로 구성된다. 판별함수 계산방법은 모집단의 수와 가정분포, 공분산 행렬이 같은 경우와 다른 경우에 따라 달라진다.

회귀분석과 같은 다른 통계적 분석방법도 비슷한 방법으로 지식베이스와 추론엔진을 구축하여 통계기반 전문가 시스템으로 개발할 수 있다[18].

### 3.3 기계학습(Machine learning)

일반적으로 인공지능 프로그램에 필요한 지식베이스는 지식공학자가 전문가를 인터뷰하는 과정을 통해서 구축되는데, 이러한 과정의 많은 부분은 기계학습에 의해 해결될 수 있다. 기계학습에는 주어진 예제로부터 이들이 암시적으로 표현하고 있는 개념을 추출해내는 귀납적 방법(inductive method, similarity-based learning), domain이론에 근거하여 하나의 주어진 예제를 설명하면서 개념적인 domain지식을 보다 구체적이고 활용성 있는 지식으로 변화시키는 연역적 방법(deductive method,

explanation-based learning), 일정한 분야에 적용할 수 있는 대표적인 사례들을 기억하고 있다가 새로운 문제를 해결하는 과정에서 유사한 사례를 이용하여 문제를 해결하는 사례기반 학습(case-based learning)등이 있다.

귀납적 방법에서 확률이론은 데이터베이스로부터 믿음 네트워크(belief network)를 생성하는 Bayesian 학습방법에 사용된다. Bayesian 학습은 예측(prediction)의 중간단계인 데이터로부터 가설을 생성하는 문제로 생각할 수 있다. 우선 주어진 데이터 하에서의 각각의 가설에 관한 조건확률이 추정되고, 이 사후확률을 이용하여 가설로부터 예측이 이루어진다.

데이터 D와 가설  $H_1, H_2, \dots$  이 주어져 있고, X에 관한 예측에 관심이 있다고 하자. 각각의  $H_i$ 는 X의 분포를 결정한다고 가정한다. Bayesian 학습은 다음과 같이 나타낼 수 있다.

$$P(X|D) = \sum_i P(X|D, H_i)P(H_i|D) = P(X|H_i)P(H_i|D)$$

여기에서 모든  $H_i$ 에 대해서  $P(H_i|D)$ 값의 계산이 필요한데 많은 경우에 구하기가 힘들다. 따라서 일반적으로는 근사값으로서  $P(H_i|D)$ 를 최대로 해주는  $H_i$ 를 사용한다. 그러한  $H_i$ 를 MAP(maximum a posteriori) 가설  $H_{MAP}$ 라 하면

$$P(X|D) \approx P(X|H_{MAP})P(H_{MAP}|D)$$

로 나타낼 수 있다.  $H_{MAP}$ 을 찾는 것이 문제인데 Bayes 법칙

$$P(H_i|D) = \frac{P(D|H_i)P(H_i)}{P(D)}$$

에서  $P(D)$ 는 고정 값이므로  $H_{MAP}$ 을 구하려면  $P(D|H_i)P(H_i)$ 가 큰 값이면 된다.  $P(D|H_i)$ 는 주어진 가설  $H_i$  하에서 데이터 D가 관찰될 확률을 나타내고  $P(H_i)$ 는 사전 확률이다. 보통 사전확률들은 같은 값들로 주어지는 것이 적절한 경우가 많으므로  $P(D|H_i)$ 가 큰 경우를 택하면 된다[19].

### 3.5 패턴인식(Pattern Recognition)

패턴은 사람이 인지할 수 있는 물리적으로 표현된 정보의 외형을 말하며, 인식이란 패턴을 구체적인 부류로 확정하는 일을 말한다. 보통 패턴인식이라 하면 컴퓨터에 의한 대상들의 자동인식을 뜻하고, '문자인식', '음성인식', '화상인식'으로 나눌 수 있다.

일반적인 패턴인식 단계는 다음과 같다. 먼저 카메라, 마이크 등을 이용하여 관측된 자료는 다소의 불필요한 정보를 가지고 있으므로, 컴퓨터 인식을 위해 필요한 자료만을 얻어내는 전처리(preprocessing)과정을 거치고, 다음은 입력된 패턴을 인식하기 용이한 작은 단위로 분할(segmentation)하고, 여러 가지 다른 환경 하에서 관측된 패턴의 크기, 길이 등을 정규화(normalization)하게 된다. 특징추출(feature extraction)단계에서는 인식에 중요한 실마리가 되는 특징을 얻어내고, 이 특징을 비교하여 패턴분류(pattern classification)를 하게 된다. 각 단계의 일부 순서를 바꾼다든지, 일부는 생략할 수 있다.

패턴인식에 사용되는 통계적 방법을 알아본다[20].

### (1) 특징 추출

특징 추출의 목적은 정보의 손실없이 패턴의 차원을 줄여, 중복성(redundancy)을 없애고 인식에 필요한 시간 및 기억공간을 줄이는데 있다. 특징 추출은 관측값의 집합을 특징량으로 변환하는 과정이라고도 할 수 있다. 즉 인식할 패턴을 패턴벡터  $x=(x_1, x_2, \dots, x_n)'$ 로 변환시켜주는 것이다. 특징을 선택할 때에는 부류간의 상이점과 부류내의 공통점을 잘 표현하도록 하는 것이 중요하다. 특징 추출방법에는 엔트로피(entropy) 최소화 방법, Karhunen-Loeve 변환 방법, 함수적 근사를 통한 방법, 발산개념을 응용하는 방법 등이 있다.

#### 1) 엔트로피 최소화 방법

모든 패턴부류가 정규분포를 이루고 같은 공분산행렬을 가지고 있다는 가정 하에서 패턴벡터의 차원을 줄이는 변환을 유도하는 방법이다. 엔트로피는 불확실성(uncertainty)에 대한 통계적 측정값으로서, 주어진 패턴 벡터 전체에 대해서 집합내의 분포에 대한 유용한 측정값은 모집단 엔트로피(population entropy)이며 다음과 같이 주어진다.

$$H = -E_p(\ln P)$$

여기에서  $P$ 는 패턴 모집단의 확률밀도이며  $E_p$ 는  $P$ 에 대한 기대값 연산자이다. 엔트로피 개념은 최적 특징 추출의 적절한 기준으로 사용될 수 있다. 즉 주어진 조건하에서 패턴부류의 엔트로피를 최소로 하는 특징들을 선택하는 것이다.

#### 2) Karhunen-Loeve변환

이 방법은 확률변수에 대한 지식을 요구하지 않고 특징추출에 대한 또 다른 접근방법을 제공한다.

#### 3) 함수적 근사를 통한 방법

패턴 부류의 특징들이 관측된 데이터를 바탕으로 결정된 함수  $f(x)$ 에 의해 특징 지

위지면 특징추출과정은 함수적 근사문제로 볼 수 있다. 표본 패턴  $x_1, x_2, \dots, x_n$  으로부터 특징함수  $f(x)$ 의 값을 구할 때, 어떤 성능기준이 최적화 되도록  $f(x)$ 에 대한 근사함수를 찾는 것이다. 함수적 근사값을 찾는 방법은 함수적 전개에 의한 방법, 통계적 근사방법, kernel 근사방법이 있다.

#### 4) 발산개념을 용용하는 방법

발산(divergence)개념은 임의의 분포로 구성된 쌍 간의 적절한 거리척도로서, 두 모집단을 구별할 경우의 난이도를 나타낸다. 공분산이 동일한 두 개의 정규분포에 대한 발산은 두 분포간의 Mahalanobis 거리와 동일하다. 발산개념은 오류확률기준에 필요 한 측정값의 갯수를 결정하거나 특징들을 정렬하는데 사용되며 발산 최대화를 통해 부류들 간의 구별을 최대화시키는 특징이 추출될 수 있다.

### (2) 패턴분류

패턴분류는 미지의 패턴이 주어졌을 때 그 패턴이 어느 범주에 속하는가를 결정하는 것이다. 패턴분류 방법은 크게 통계적 접근방법, 구문론적 접근방법, 신경망을 이용한 접근방법이 있다. 통계적 접근방법은 통계적인 가정에 바탕을 두고, 특징 벡터를 유한 개의 부류들 중의 하나로 배정한다. 결정함수 사용 방법, 거리함수에 의한 방법, Bayes 이론에 의한 방법, 은닉 마르코프 모델(Hidden Markov Model)에 의한 방법이 있다.

#### 1) 결정함수 사용방법

일련의 결정함수를 계산해서 각각의 입력을 유한한 갯수로 구성된 부류중의 하나로 배정한다. 결정함수는 각 부류에 대한 대표적인 패턴을 사용하여 생성할 수 있다. 두 부류의 경우 선형 결정함수의 값이 0보다 큰지, 작은지에 따라 분류하며 두 부류 이상인 경우도 고려할 수 있고, 일반화된 결정함수도 생성할 수 있다.

#### 2) 거리함수 사용방법

일반적인 패턴분류에서는 부류가 확정되어 있고, 결정함수도 이미 알고 있는 경우가 많다. 그러나 경우에 따라서 부류가 확정되어 있지 않거나, 부류가 정해져 있어도 그 안에서의 패턴의 분포가 흩어져 있어 한 개의 식별함수로는 기술이 곤란한 경우도 있다. 몇 개의 부류로 분할하는 것을 군집화(clustering)라 한다. 군집을 형성할 때에는 두 개의 패턴이 동일 군집에 속하는지 여부를 결정할 필요가 있으며, 패턴간의 거리를 정의해야 한다. 흔히 사용하는 방법에는 K-means 알고리즘과 Isodata 알고리즘이 있다.

#### 3) Bayes 이론에 의한 방법

기초적인 통계적 결정이론으로부터 Bayes 분류 규칙을 유도하는 방법이다. 이 방법에서는 각 패턴 부류를 특징 지우는 확률 밀도함수에 대한 지식이 필요하므로 이러한

밀도를 추정하는 것이 중요한 문제가 된다. 이 방법은 분류시의 오류율과 평균 오분류 비용을 최소화시키므로 통계적인 관점에서 최적의 성능을 나타낸다.

#### 4) 은닉 마르코프 모델에 의한 방법

다양한 변화를 내포하고 있는 입력패턴을 확률적으로 모델링할 수 있는 은닉 마르코프 모델[21]은 상태라고 불리는 N개의 노드와 이들 간의 전이를 나타내는 링크로 구성된 그래프로 표현된다. 그래프의 각 노드에 공간적인 특성을 모델링하는 관측심별 확률분포(observation symbol probability distribution)와 초기 상태 확률분포(initial probability distribution)가 저장되어 있으며, 각 링크에는 관측열의 시간적인 특성을 모델링하는 상태 전이 확률분포(state transition probability distribution)가 저장되어 있다. 이 모델은 이중 확률과정(stochastic process)으로서 상태 선정에 관한 확률과정과 매 상태마다 패턴이 발생될 출력확률(output probability)에 관한 확률과정으로 구성된다. 이 모델을 이용하여 패턴을 분류하고 모델을 학습시키는 일은 다음의 세 가지 문제로 요약된다. 첫째, 주어진 모델에 대하여 하나의 출력 기호열이 생성되는 확률을 구하는 것인데 이것은 이미 만들어진 모델을 이용하여 출력 기호열에 해당하는 패턴의 분류를 하는 것이다. 둘째, 주어진 관측 기호열 즉 모델의 출력에 적당한 상태 전이열을 찾아내는 것으로서 이것은 시스템의 분석을 위해 필요하다. 셋째, 주어진 관측 기호열이 생성될 확률이 최대가 되도록 모델 파라미터를 조정하는 일로서, 이것은 시스템의 학습에 해당한다. 은닉 마르코프 모델은 응용분야에 따라, 모델의 난이도에 따라 여러 가지 형태의 모델이 사용된다.

### 4. 연결주의에서의 통계적 방법

#### 4.1 신경망 모델 - 볼쓰만 머신(Boltzmann Machine)

신경망은 패턴인식(pattern recognition), 영상처리(image processing), 최적화문제(optimization problem)등 기존의 방법으로는 잘 처리할 수 없는 문제들에 대해 효율적인 해결방법을 제시한다.

볼쓰만 머신은 상호결합형 Hopfield 신경망 모델과 같은 구조를 가지면서 확률적 상태이전을 하는 신경망 모델이다[22]. 이 모델에서 뉴런의 출력  $v_i$ 는 0 또는 1의 값을 갖고, 확률에 의한 판정이론을 도입하여 제 i번째 뉴런의 입력의 합이  $u_i$ 일 때 이 뉴런의 새로운 상태가 1이 될 확률은

$$p(v_i = 1) = \frac{1}{1 + \exp(-u_i/T)}$$

로 주어진다. 여기서  $T$ 는 네트워크의 온도인 양의 값이다. 입력신호  $v_i$ 가 클수록  $v$ 가 1이 될 확률은 높아지고, 그 정도는 온도  $T$ 에 의존하며 온도가 높을수록 이 확률을 나타내는 그래프는 완만해진다.

이 모델에서는 상태전이에 확률을 도입함으로써 에너지가 증가하기도 하고 감소하기도 하여 상태가 에너지 함수의 최소점에 수렴하는 평형상태에 도달한다. 평형상태에서 뉴런집단의 상태가  $a$ 로 될 확률  $p^{(a)}$ 는 볼쓰만 분포(Boltzmann distribution)

$$p^{(a)} = \frac{1}{Z} \exp(-E^{(a)}/T)$$

를 따른다.  $E^{(a)}$ 는 상태  $a$ 에 있어서의 네트워크 에너지이고  $Z$ 는 확률의 정규화를 위한 상수이다. 각 상태의 에너지 값을 정하는 에너지 함수는 뉴런간 연결강도나 뉴런의 임계값등의 네트워크 변수들에 의해 결정되므로 이 변수들을 적당히 조절함으로써 원하는 평형상태를 실현할 수 있다. 이렇게 네트워크의 변수들을 조절하는 것이 볼쓰만 머신에서의 학습이다.

볼쓰만 머신의 응용분야로는 패턴인식, 순회 판매원 문제(traveling salesman problem), 최적화문제의 근사해를 구하는 문제 등이 있다.

## 5. 결론

통계학의 어떤 분야가 인공지능 연구에 기여를 하고 있는지 알아보았다. 인공지능 연구에서의 두 가지 접근방법중 기호주의 방법에서 통계학이 많이 사용되고 있음을 알 수 있으며, 특히 전문가시스템에서의 불확실성 처리문제와 Bayesian 학습방법, 패턴인식 분야 연구에서 Bayes 이론이 중요한 역할을 하는 것을 알 수 있다.

앞으로의 인공지능 연구 방향은 인간 두뇌에서의 정보처리 작용을 보다 상세하게 이해하여 이를 통한 신경망 모델의 개선, 신경망과 기호처리에 의한 방법과의 결합, 병렬처리 컴퓨터의 기술 발전, 신경망을 하드웨어적으로 구현하기 위한 새로운 소자의 개발, 학습기능을 통해서 문제를 스스로 알아서 해결하는 쪽으로 진행될 것이다.

통계학의 방법론을 기존의 불확실성을 다루는 분야, 패턴인식 분야만이 아니라 다른 인공지능 연구분야, 예를 들어 요즈음 많은 관심을 끌고 있는 응용분야인 데이터베이스로부터 지식을 추출하는 문제(knowledge discovery in database 또는 data mining)등에 적용시킴으로서 좋은 결과를 얻을 수 있으리라 생각된다.

## 참고문헌

1. Ng, K. & Abramson, B. (1990), "Uncertainty Management in Expert Systems", *IEEE*, 29-48
2. Duda, R. O., Hart, P. E. & Nilsson, N. (1976), "Subjective Bayesian Methods for Rule-Based Inference Systems", *SRI Tech Note*, 124
3. Pearl, J. (1982), "Distributed Bayesian Processing for Belief Maintenance in Hierarchical Inference systems", *AAAI-82*
4. Kim, J. H. & Pearl, J. (1983), "A Computational Model for Causal and Diagnostic Reasoning in Inference Engines", *Proc. of 8th International Joint Conference on AI*, Karlsruhe, West Germany, 190-193
5. Pearl, J. (1986), "A Constraint-propagation approach to Probabilistic Reasoning", *Uncertainty in Artificial Intelligence*, 357-369
6. Pearl, J. (1986), "Fusion, Propagation and Structuring in Belief Networks", *Artificial Intelligence*, 29, 241-288
7. Pearl, J. (1988), *Probabilistic Reasoning in Intelligent Systems*, Morgan Kaufmann
8. Henroin, M. (1988), "Propagating uncertainty by logic sampling in Bayes' networks", *Uncertainty in Artificial Intelligence 2*, North-Holland, Amsterdam, 149-163
9. Cooper, G. F. (1990), "The Computational Complexity of Probabilistic Inference using Bayesian Belief Networks", *Artificial Intelligence*, 42, 393-405
10. Henroin, M. (1990), "An Introduction to Algorithm for Inference in Belief Nets", *Uncertainty in Artificial Intelligence 5*, North-Holland, Amsterdam, 129-138
11. Laurizen, S. L. & Spiegelhalter, D. J. (1988), "Local Computations with Probabilities on Graphical Structures and their Application to Expert Systems", *J. R. Statist. Soc. B*, 50, No.2, 157-224
12. Jensen, F. V., Oleson, K. G. & Anderson, S. K. (1990), "An Algebra of Bayesian Belief Universes for Knowledge-Based Systems", *Network*, V.20, 637-659
13. Nilsson, N. J. (1986), "Probabilistic Logic", *Artificial Intelligence*, 28, 71-87
14. Gordon, J. & Shortliffe, E. H. (1984), "The Dempster-Shafer Theory of Evidence", in *Rule-Based Expert Systems*, B.G.Buchanan and E.H.

- Shortliffe(ed.)
15. Spiegelhalter, D. (1986), "A Statistical View of Uncertainty in Expert Systems", in *Artificial Intelligence & Statistics*, W.A. Gale(ed), Addison-Wesley
  16. Lindley, D. V. (1987), "The Probability Approach to the Treatment of Uncertainty in Artificial Intelligence and Expert Systems", *Statistical Science*, V.2. No.1, 3-44
  17. Johnson, R. A. & Wichern, D. W. (1982), *Applied Multivariate Statistical Analysis*, Prentice-Hall, Inc., Englewood Cliffs, New Jersey
  18. Castillo, E. & Alvarez, E. (1991), *Expert Systems : Uncertainty and Learning*, Computational Mechanics Publications, Southampton, Boston
  19. Russell, S. J. & Norvig, P. (1995), *Artificial Intelligence - A Modern Approach*, Prentice Hall
  20. 이성환(1994), *패턴인식의 원리 I, II*, 홍릉과학출판사
  21. Rabiner, L. R. & Juang, B. H. (1986), "An Introduction to Hidden Markov Models", *IEEE ASSP Magazine*, 4-15
  22. Aarts, E. & Korst, J. (1989), *Simulated Annealing and Boltzmann machines : A Stochastic Approach to Combinatorial Optimization and Neural Computing*, John Wiley & Sons

# Statistical Methods in Artificial Intelligence Research

W. O. Cha<sup>1)</sup>

## Abstract

Two methods of Artificial Intelligence research, symbolic and connectionist approaches, have been reviewed briefly. Applications of statistical methods on the above approaches have also been investigated. Statistical methods are used mostly for symbolic approach. Particularly, Bayes theory plays an important role in handling uncertainty problems of expert system, Bayesian learning and pattern recognition.

---

1) School of International and Computer Engineering, Hansung University, Seoul, 136-792, Korea