

# 지식학습 능력을 갖는 전문가 시스템

김 호 용

(한국전기연구소 전력계통연구부장)

## 1. 서 론

최근, 각 선진 기술국들은 컴퓨터로 하여금 “어떻게 보다 인간처럼 사고, 판단하게 할 수 있을까?” 하는 컴퓨터 인간화에 집중적인 관심을 쏟고 있다. 특히, 이 타스크를 국가의 첨단 기술 사회화를 이루기 위한 최고의 목표로 삼고 로버티кс, 자연언어 처리, 전문가 시스템등 여러분야에서 응용 기초기술을 연구 개발하고 있다.

전문가 시스템은 인공지능의 한 분야로서, 특수한 영역에서 시간을 요하는 컴퓨터 프로그램의 처리과정이나 전문가의 추론과정을 모의하여, 고도 전문가 수준의 판단재여 능력을 구현하는 컴퓨터 프로그램이다. 또한 이 시스템은 경험적 지식이나 실세계 데이터에 수반되는 불확실성을 처리할 수 있는 능력을 가지며, 특히, 프로그램의 효율적 운용을 위해 지식베이스, 추론 엔진 그리고 유저 인터페이스로 구성되는 모듈별 구조를 갖는다. 전문가 시스템의 이와 같은 강력한 문제해결(problem Solving)능력은 주로 지식베이스의 품질에 좌우된다. 따라서 지식베이스는 전문가 시스템이 주어진 영역의 모든 상황변화에 적절한 문제해결 능력을 가질 수 있도록 개발되어 한다. 그러나 실제적으로, 실세계의 상황이 복잡하고 주어진 영역에서의 구조와 특성변화에 대한 예측이 어렵기 때문에 완전한 지식베이스를 얻기가 어렵다. 또한, 전문가 시스템 개발 과정에서 전문가들의 불확실한 지식 도입은 물론 지식엔지니어의 불확실

한 지식 인식으로 지식베이스의 유효성이 저하될 수 있다.

전문가 시스템 관련 연구자들은 이와같은 전문가 시스템의 단점을 보완하고 성능을 개선하기 위해 자기 스스로 기존 지식의 유효성을 검증하고 경험하지 못한 새로운 문제를 학습하여, 기존의 불확실한 지식을 수정하거나 새로운 지식을 생성하는 자기 학습 능력(Self-Learning Capability) [1-3]을 갖는 차세대 전문가 시스템 개발 연구를 새로이 시도하고 있다. 특히, 최근 전력계통 영역에서[4] 초기 개발된 지식의 유효성을 검정하고 동적으로 변화하는 계통운전 조건(Operating Point)에 대해 적절한 문제해결 능력을 가질 수 있도록 자기 학습 기능을 부여하는 전문가시스템이 발표되었으며, 이것을 필두로 앞으로 새로운 연구가 활성화될 전망이다.

따라서 본지에서는 자기 학습 기능을 갖는 차세대 전문가 시스템의 기능을 분석하고[3], 그 기능이 부여된 전력계통의 적용례를 설명함으로서 전문가 시스템의 진보적 학습 개념에 대해서 소개하고자 한다.

## 2. 자기 학습기능을 갖는 전문가 시스템

### 2.1 개요

최근 전문가 시스템기술은 가능적 문제 영역의 성질, 추론의 형식, 설명 기능 그리고 특히, 지식 인

식 방법에서 새로운 기술적 발전이 이루어지고 있다. 간단히 말해 기존의 전문가 시스템은 주로 규칙(rule)의 형태로 표시된 경험적 지식에 탐색공간 이외의 완전한 검색 공간의 이해를 제공하는 deeper 모델 형태가 추가 구성요소를 이용해 문제를 해결한다. 따라서 이 시스템은 2개 형태의 추론이 가능하다. 첫째는 기존의 전문가 시스템과 유사한 형식으로 경험적 규칙(heuristic rules)을 적용하여 추론하는 방법이며, 두번째는 대응하는 경험적 지식이 없을 경우 기존의 검색 기법의 다음으로 보다 깊은 검색 공간(deeper search space)을 발생시키고 그 공간을 탐사하는 추론 방법이다. 현재의 전문가 시스템의 대부분의 문제는 이 심층 추론(deep inference)과 이를 이용해 학습(learning)하는 기능 즉, 자기 학습 기능(self-learning)을 이용해 해결할 수 있다.

## 2.2 기존 전문가 시스템과의 비교

기존의 전문가 시스템과 자기학습 기능을 갖는 차세대 전문가 시스템의 비교는 표1과 같다. 표1은 새로운 문제에 대한 적용 능력, 해의 정당성 설명 능력 그리고 지식 인식능력에 대해 비교한다.

## 2.3 시스템의 구성 요소

표 1. 기존 전문가 시스템과 차세대 전문가 시스템 비교

비교항목	비교 내용
1) 새로운 문제에 대한 적응력	기존의 전문가 시스템은 새로운 상황이 경험적 규칙의 영역 밖에서 발생하였을 경우 전혀 그 기능을 발휘할 수 없다. 그러나 그러한 상황에서 차세대 전문가 시스템은 지식 구동식의 검색에 의존하지 않고 전통적 검색 기법들을 이용한다. 따라서 지식 구동식(knowledge-driven)의 검색에 비해 효율은 저하되나 이 기법들은 이론적으로, 다양한 종류의 문제를 해결 할 수 있기 때문에 갑작스러운 고장 대신에 완만한 성능 저하만을 가져온다.
2) 해의 정당성 설명 능력	기존의 전문가 시스템은 단순히, 문제의 해를 찾기까지 탐사된 경험적 규칙들을 역추적(backtrace)하여 그 해의 정당성을 설명한다. 그러나 대개, 추론 과정에서 다량의 지식이 탐사된 경우 해를 찾기까지 추적된 경로는 그 해의 정당성을 확인시켜 줄 만큼 신뢰할 만한 합리적 논증과 차이를 보이게 된다. 그러나 차세대 전문가 시스템의 경우 보다 깊은 검색공간의 이해를 통해 탐사된 경험적 규칙들의 단순한 회상을 초월한 보다 심층적이고 보다 신뢰할 만한 설명을 공식화 할 수 있다.
3) 지식 인식 능력	경험적 규칙들을 얻는 것은 사실 극히 어려운 작업이다. 대표적으로 전문가들이 확고한 경험적 규칙들을 얻기 위해서는 오랜시간이 걸린다. 그리고 그 얻어진 지식들도 결코 완전한 것으로 확신할 수 없으며, 연속적으로 변화한다. 또한 같은 문제에 대해서도 서로 다른 경험으로 전문가들 사이에 불일치성을 보인다. 차세대 전문가 시스템은 심층적 추론(deep inference)에 의해 새로운 경험적 규칙들을 획득할 수 있는 자기 학습 능력을 가짐으로서 이러한 현재의 문제점들을 해결 할 수 있다.

표 2. 차세대 전문가 시스템의 여러 구성요소

주 구성요소	지식표현 구성요소	문제해결 구성요소	학습 구성요소
부 구성요소	개념적 모델 사실적 모델	경험적 추론 심층적 추론	rule-extractor rule-integrator

전문가 시스템은 지식 표현 구성요소, 문제 해결 구성 요소, 그리고 사용자와의 대화, 설명 구성, 데 이타 수집을 지원하는 기타의 구성요소로 이루어 진다. 표2는 차세대 전문가 시스템의 구성요소를 도표로 설명한다.

### 2.3.1 지식 표현 구성 요소

지식 표현 구성요소는 개념적 모델(conceptual model)과 하나 이상의 사실적 모델(factual model)들로 이루어 진다. 개념적 모델은 논의 영계(universe of discourse)의 기본적 본질(entity), 그들의 가능한 성질과 관계, 어떠한 성질을 계산하기 위한 방법 그리고 사용자와 대화하기 위한 방법등을 표시한다. 사실적 모델은 개념적 모델에 의해 제공된 개념화(conceptualisations)를 이용하는 하나의 규정 문제에 대한 모든 사실들(facts), 중간 가설 그리고 최종 결론을 포함한다. 지식 표현 구성 요소는 일반적으로 frame-based이다. 이 frame-based 지식 표현은 여러 슬롯을 가지는 유니트들을 이용하여 지식을 구조화 한다. 그리고 정보는 defaults, rules, 계산을 위한 procedures의 형태로 표시될 수 있으며, 보다 특수한 유니트들로부터 상속될 수 있다.

### 2.3.2 문제 해결 구성 요소

기존의 전문가 시스템에서 문제 해결 구성 요소는 단순히 경험적 규칙들로만 이루어 진다. 하나의 규칙은 조건부와 그 조건부가 실제적 모델에서 만족될 경우 추론될 수 있는 실행부로 이루어진다. 그리고 이 규칙은 규칙집합(rule set)들로 구조화되며, 그들의 실행은 하나이상의 규칙들이 응용 가능할 때 어떤 규칙을 탐사해야 할지를 선택하는 제어구조에 의해서 결정된다. 최근, 이러한 조건이나 결론의 기능들을 보다 명확히 하기 위해서 하나의 규칙을 구조적으로 보다 강력하게 하는 발전적 변화가 이루어지고 있다. 즉 예로서 하나의 진단 규칙이 기조건(precondition), 대표적 징후, 불가능한 징후, 가능한 징후와 필요한 징후 등을 가질 수 있다. 이와같이 하나의 규칙을 보다 세련되게 구조화하는 것은 자기 학습을 위해서도 상당히 중요하다.

차세대 전문가 시스템은 심층 추론을 실행하는 추적 문제 해결 구성 요소를 갖는다. 이 구성요소는 주어진 영역의 보다 기초적이고 보다 심층적인 표현

을 반영하기 때문에 경험적 규칙들에 비해 훨씬 더 큰 검색 공간을 탐사한다. 대부분의 문제영역에서 심층 모델(deep model)이 가능하다. 예를들어, 대부분의 기술적 장비들은 설계에 의해서 제작되기 때문에 그 상세 분석과 내부 기능을 완전히 알 수 있다. 그러므로 근원적으로 철저한 탐사를 수행하는 것이 가능하다. 그러나 만약 그러한 탐사가 복잡한 기기를 요구하거나 관측의 비용이 아주 높을 경우 사실상 불가능하다. 이러한 사실에서 완만한 성능 저하가 있게된다.

### 2.3.3 학습 구성 요소

새로운 경험적 지식을 심층 추론의 결과로부터 발견하기 위해서는 3번째 구성 요소인 학습 구성요소를 필요로 한다. 이 구성요소는 2개의 부 구성요소를 가지는데, 하나는 심층 추론으로부터 규칙들을 발췌하는 rule-extractor이고 다른 하나는 그 규칙을 기존의 규칙 집합(rule-set)에 도입하는 rule-integrator이다. 그리고 새로운 개념을 이끌어내거나 규칙 집합을 최적화하기 위한 학습활동(learning operation)이 규칙집합상에서 실행될 수 있다.

### 2.3.4 개발 소프트웨어(tools)

현재 전문가 시스템을 개발하기 위해 가능한 상업용 소프트웨어는 상당수에 이르고 있으며, 점차 더욱 늘어날 추세이다. 이를 개발 툴은 특수한 규칙(IF/THEN) 공식화(formalism)를 지원하는 비교적 간단한 전문가 시스템 shell로부터 정교한 지식공학 환경에 이르기 까지 다양하다. 차세대 전문가 시스템은 그들의 여러 구성요소를 구현하고 통합하기 위해서 보다 정교한 클래스의 툴을 필요로 한다. 무엇보다도 주어진 모델을 표현하기 위한 frame-structured 표현, 경험적 지식을 표현하기 위한 규칙 공식화 그리고 심층 추론을 이끌기 위한 제약 조건의 공식화 등 다양한 공식화가 지원되어야 한다. 특히, 메타 표현(meta-representation)과 메타 추론(meta-reasoning)을 필요로 하는 이를 각각의 항목들에 관한 지식을 표현하는 것이 가능해야 한다. 예를들어, 경험적 규칙들을 표시하고 추론하는 것이 가능해야 한다.

지금까지 1절에서는 자기학습 기능을 자기학습 기능을 갖는 차세대 전문가 시스템에 대해서 기존 전

전문가 시스템과 여러가지 관점에서 특성을 비교하였으며, 그 시스템이 가져야 할 구성 요소와 그들에 대한 각각의 특징을 설명하였다. 따라서 다음절에서는 전문가 시스템의 학습 알고리즘으로서 효과적인 귀납적 학습(inductive learning) 기법을 설명한다. 그리고 계속해서 귀납적 학습 알고리즘을 이용한 자기 학습 전문가 시스템의 한 예로 전력계통의 전압제어 문제를 들며, 끝으로 배전계통의 비상/정상시 선로 재구성(network reconfiguration) 문제에 대한 적용 가능성은 검토한다.

### 3. 귀납적 학습(Inductive Learning)

전문가 시스템은 여러방법을 활용하여, 기본레벨로부터 heuristic 레벨에 이르기까지의 여러 레벨에서 분류(classification)과 예측(prediction)을 이용한다. 기본레벨에서 입력 데이터의 분류를 통해 의사결정(decision)이 얻어지며, heuristic 레벨에서 어느 경로를 탐사해야 할지 또는 어느 추론전략을 이용해야 할지를 결정하는 meta Decision을 가져온다. 전문가 시스템에서 부류(class)들은 명확한 규칙(rule) 또는 개념(concept)으로 표시된다. 그리고 비록 이러한 규칙들이 사용자에 의해 직접 제공될수 있다 하더라도, 기계적 지식습득(mechanical knowledge acquisition) 또는 Machine Learning : MA)이 더욱 경제적이고 신뢰적일 수 있다. MA의 목적은 합리적 시간 내에서 분별 규칙들을 찾는 효과적이고, 효율적이며 일반적인 방법을 발견하는 것으로서, Michalski의 AQ 학습 시스템 그리고 Rendell의 PLSI 학습 시스템은 적용분야에서 인간에 의한 학습보다 더욱 우월한 성능을 보였음이 알려졌다.

지금까지 이러한 자동학습(Automated Learning)을 위한 많은 알고리즘이 개발되었는데 SBL

(Similarity-Based Learnign)은 그중 하나로서 기존의 예(알려진 지식)들을 받아들인 다음 표시공간 근접도(Description-Space Proximity)를 이용함으로써 규칙을 만들어 내는 유사도를 근거로한 학습방법이다. 이러한 SBL을 이용한 다양한 알고리즘이 발표되었으나 이들은 공통적인 가정과 과정들을 공유한다. 이 SBL 시스템들은 설계가 적절히 이루어질 경우 동적이고 불확실한 환경에서 정확하고 효율적으로 학습할 수 있는 능력을 갖는다. 따라서 본장에서는 기존에 발표된 4개의 대표적인 SBL 시스템에 대해서 설명함으로써, SBL에 대한 이해를 돋고자 한다. 표3은 개념학습 시스템들의 특성들을 보인다.

#### 3.1 Learning 시스템의 필요특성

개념학습(Concept-Learning) 시스템은 실제로 하이아상의 타스크를 수행해야만 한다. 그리고 그 시스템은 올바른 개념을 만들어내야 하며 동시에 간결한 형식으로 규칙을 출력해야한다. 또한 합리적으로 빠르고 이용하기 편리해야 한다. 따라서 학습 시스템은 표 4와 같은 특성을 가져야한다.

#### 3.2 학습 알고리즘

학습 시스템은 개념(Concept) 또는 분류규칙(Classification Rule)들을 학습하기 위해서 의사결정 경로(decision tree : DT)와 ESR(Event Space Rectangle)과 같은 상이한 구조들을 이용한다. 그리고 또한 개념을 학습하기 위해서 specialization, generalization 또는 이들을 혼합한 형태의 유도 연산자(Inductive Operator)를 이용한다. 여기에 설명되는 4개의 학습 알고리즘들은 모두 공통적으로, 입력 이벤트가 두 부류(Class)중 어느 부류에 속하는가를

표 3. SBL 시스템들의 특성 비교

시스템 명칭	Inductive Operators	개념 형식	가설 형식	Incremental 능력	시스템 파라미터
ID3	Specialization	Decision Tree	Decision Tree	유	Simple
PLS1	Specialization	Various	확률 Regions	유	Simple
AQ	Generalization	Logic	Logic	유	Complex
PRG	Mixed	Logic	Logic Tree	유	Complex

표 4. 학습 시스템의 필요 특성

필요성질	내 용
● 개념의 정확성 (Concept Accuracy)	실세계 문제들은 대부분 극히 어렵기 때문에 정확한 목표 개념(Target Concept)을 얻는 것은 쉽지 않다. 따라서 학습 시스템은 군사 규칙을 출력한다. 개념의 정확성은 다음과 같이 표시할 수 있다. 개념의 정확성 = $1 - \frac{\text{부정확한 분별 수}}{\text{시험 이벤트들의 수}}$
● 개념의 간결성 (Concept Conciseness)	학습시스템의 또 다른 바람직한 특성은 출력개념의 간결성이다. 학습은 간혹 반복적일 수 있기 때문에 학습 속도를 개선하기 위해 간결성이 요구된다.
● 보조 정보 (Auxiliary Information)	보조 정보는 분별(Classification)을 지원하는 데이터를 말한다. 예를 들어 속성의 중요도 또는 개념의 확신도를 들 수 있으며, 이들은 분별속도나 개념의 신뢰도에 관한 정보를 제공한다.
● 범용 적용능력 (General Applicability)	학습 시스템은 다양한 영역이나 환경에서 이용할 수 있어야 하므로, 잡음관리와 incremental 학습 능력이 필요하다.
● 효율 (Efficiency)	간단한 문제에 대해서, 저속 프로세싱은 약간의 불편만을 가져오기 때문에 큰 고려대상이 되지 않는다. 그러나 실세계의 문제에서 실제적 학습을 위해서는 시스템의 효율이 상당히 중요하다. 학습 시스템은 공산과 시간 제약조건에 대해 특히, 시간 제약조건에 대해 효율적이어야 한다.

분별하기 위한 규칙이나 개념을 만들어내기 위해 먼저 교육 이벤트(Training Events)들의 입력을 필요로 한다. 그러므로 이들 시스템들의 출력도 유사하며, 그들의 표현 또한 거의 유사하다. 예를들면, DT가 ES(Event Space) 분할 표기와 거의 유사함을 알 수 있다.

보통 DT 한번에 하나의 속성(Attribute)을 처리한다. 만약 이벤트 X가 속성값들 ( $x_1, x_2, \dots, x_k$ )의 K번째 tuple이라면 그때 DT의 각 레벨은 k개의 속성들  $x_i (i < k)$  중의 하나에 대응하게 된다. 그리고 ES 분할 표기를 이용하는 앤고리즘 또한 DT에 근거를 둔 앤고리즘과 비슷하게 한번에 하나의 속성들을 처리한다.

4개의 학습 앤고리즘은 모두 DT나 ESR 표현을 이용한다. 이들 앤고리즘간의 중요한 차이는 그들이 구현하는 유도 연산자의 타입에 있다. Specialization 연산자는 이벤트들의 집합(Set)들을 분할한다. 반면에 Generalization 연산자는 단일 이벤트들이나 부분집합(Subset)들을 보다 확장된 집합으로 통합하는 것을 의미한다. 이들은 귀납적 추론에 반드시 필

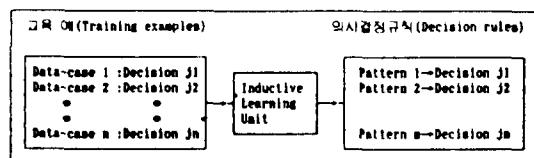


그림 1. 입력예로부터의 Inductive Learning

요한 단계이다. 표 3에 언급된 바와 같이 학습 앤고리즘 ID3와 PLS1은 Specialization 연산자를 이용하며, AQ는 Generalization을 그리고 PRG는 혼합형태 연산자를 이용한다. 그림 1은 교육예들로 부터의 귀납적 학습을 설명하는 그림이다.

귀납적 학습은 한 부류(class)의 개별예들의 표시로부터 그 부류의 표시식(Class description)을 추론해내기 때문에 교육예들은 그림 4에서와 같이 개별경우(Case)의 형태로 주어지며, 속성값들의 벡터로 표시된다. 그리고 개념(Concept)표기는 각 부류를 표시하기 위해 만들어진다. 귀납적 추론은 예제들부터 관측된 바와같이, 개념표기에 대해 Generalization과 Specialization들의 연속적인 반복 작업 과정으로 볼

수 있다. 그리고 이 과정은 모든 예제들과 일치하는 귀납적 개념 표기를 찾을 때까지 반복된다.

### 3.2.1 Star 알고리즘(AQ시스템)

이 방법은 Star 개념을 학습과정을 위한 근거(Basis)로 이용한다. 여기서 e를 학습해야 할 개념이라 하고, E를 같은 개념의 Counter examples 즉, Negative 예라하자. 우리는 만약 한 표기들의 집합이 예 e를 만족하면 그 집합이 그 예를 포함한다고 말할 수 있다. 여기서 E에 대한 e의 star는  $G(e/E)$ 로 표시되며, e를 포함하는 그러나 E의 negative 예들은 포함하지 않는 표시집합으로 정의된다.

이러한 스타 개념은 완전한 개념 표시를 찾는 문제를 단일 positive 예들에 대한 표기를 찾는 부분적 문제로 줄이기 때문에 유용하다. negative 예들은 표기(Descriptions)들을 제한하는 제약조건의 역할을 하기 때문에 star 요소에 포함되지 않는다. 이 스타 생성과정은 생성된 표기들이 모든 positive 예들을 포함하고, 반면에 Negative 예들이 포함되지 않을 때까지 반복한다. 이 스타방법은 복잡성을 완화시키기 위해 Beam 검색을 이용할 수 있는데, 이 Beam 검색은 한 스타의 표기들의 수를 미리 정의된 수 m, 즉 Beam 크기로 제한한다.

### 3.2.2 Tree Induction 알고리즘

TI(Tree Induction)는 Star 알고리즘에 비해 전체 예 집합을 가지고 시작하여 점진적으로 예들을 서브 그룹으로 분할한다. 각 서브그룹은 같은 값의 분기 속성(Branching Attribute)을 공유한다. 이 분기 처리과정은 각 서브그룹이 같은 부류에 속할 때에 비로소 끝난다. 이 알고리즘은 하나의 서브그룹을 이끄는 모든 분기속성들의 결합(Conjunction)을 통해 그 서브그룹의 예들에 대한 표기를 만들어내며, 같은 부류에 속하는 모든 서브그룹 표기들의 분리(Disjunction)를 이용하여 그 부류의 개념 표기(Concept Description)를 만들어낸다.

여기에 설명되는 TI(Tree Induction)와 확률적 학습(Probabilistic Learning) 알고리즘은 Branching Process를 사용하며, 특히 분기 속성들을 선택하기 위해 정보-이론 평가(Information-Theoretic Measures) 기법을 도입하여 사용한다.

Quinlan의 귀납적 학습시스템은 대표적 TI시스템으로 정보-이론 평가를 위해 엔트로피(Entropy)를 이용한다. 엔트로피는 Optimal 코딩에서 한 메시지의 정보량을 측정하기 위한 Information Theory에 이용되며, 모든 가능한 메시지들을 암호화하기 위해서 요구되는 평균 비트수에 근거를 둔다.

먼저,  $x_1 \dots x_n$ 의 확률  $q(x_1) \dots q(x_n)$ 을 가지는 n개의 가능한 메시지들이라 하자.

$$\text{여기서 } \sum_{i=1}^n q(x_i) = 1 \text{이다.}$$

주어진 메시지의 엔트로피는  $H(x) = -\sum_{i=1}^n q(x_i) \log_2 q(x_i)$ 로 표시된다.

여기서  $H(x)$ 는 메시지에 의해서 전송된 정보량으로 해석할 수 있다.  $H(x)$ 가 높으면 높을수록 메시지의 내용은 더욱 불확실한 것을 의미한다.

Decision Tree는 데이터가 주어지면, 그 데이터에 대한 분류(classification)를 지시하는 메시지를 발행하는 정보원(Information Source)로 간주할 수 있다. 그리고 Tree Node가 같은 부류에 속하는 데이터들만을 포함할 때 엔트로피가 0이 되는데 이것은 분류가 그 노드에 속하는 데이터에 대해 명확하다는 것을 의미한다. Decision Tree Induction은 정보 엔트로피를 최소화하는 분기결정을 위한 속성선택과정이다. 즉, 정보이득을 최대화하거나 서브그룹의 순수성을 개선하는 과정이다.

먼저, 노드 S가 부류 P의 p개의 데이터들과 부류 N의 n개의 데이터를 포함한다고 하자. 그리고 주어진 데이터가 부류 N에 속할 수 있는 확률이  $n/(p+n)$ , 그리고 부류 P에 속할 수 있는 확률이  $p/(p+n)$ 이라 가정하면, 메시지 p 또는 N을 만들기 위해 요구된 정보량은 다음식으로 구해진다.

$$H(S) = -(p/p+n) \log_2(p/p+n) - (n/p+n) \log_2(n/p+n)$$

학습 시스템은 초기 노드(Root Node)로 부터 출발하여 점차적으로 Tree 분기를 위한 속성들을 선택하여 DT를 발생시킨다. 즉, 각 노드 S에서 분기할 속성  $A_i$ 를 선택하여, 그 Tree를 m개의 서브 Tree로 분할한다. 여기서 m은  $A_i$ 가 nominal 변수일 때  $A_i$ 의 수가 되며, 그렇지 않을 경우  $A_i$ 의 이진분기(Binary Split)가 수행된다. 즉,  $A_i$ 가 Nominal 변수가 아닌 경우에 m은 2가 된다.

$A_i$ 의 k번째 값에 대응하는 k번째 서브 Tree가 부류 p에 속하는 pk개의 경우를 그리고 부류 N에 속

하는 nk개의 경우들을 포함한다고 하면, Ai를 분기 속성으로 가지는 Tree에 요구된 기대정보는 다음과 같다.

$$H(A_i) = \sum_{k=1}^m \frac{pk + nk}{p+n} = H(A_{ik})$$

그러므로 Ai에 대해 분기함으로서 얻는 정보는 Info-gain(Ai) = H(S) - H(Ai)가 된다.

따라서 ID3는 각 반복에서 DT를 발생시킬 때 모든 후보속성(Candidate Attribute)들을 검토하여, 정보이득값을 최대한 할 수 있는 속성을 선택함으로서, 더욱 동질의 구룹을 만들어낸다. 이 알고리즘은 각 그룹의 모든 예들이 같은 부류에 속할 때까지 계속 반복적으로 이루어진다.

Quinlan, Breiman, 그리고 Carter과 Catlett 등은 Tree의 규모를 줄이고 데이터의 잡음의 효과를 줄이기 위해서 Pruning 매카니즘을 이용한다.

### 3.2.3 Probabilistic 학습 시스템(PLS)

PLS 알고리즘의 유도 과정은 가능한 표기(Feature Space)들의 전체공간으로부터 시작하여, 그 공간을 두개의 영역 즉, 한 특정부류(Positive Examples)에 존재할 가능성이 높은 영역과 다른 한 부류(Negative Examples)에 존재할 가능성이 높은 영역으로 분할한다. 이 분할 작업은 정보-이론 접근에 따라 선택된 하나의 속성만을 이용하여, Stop 조건(Criterion)을 만족할 때까지 계속된다.

각 반복작업에서, Feature 공간내의 R의 영역은  $R = (r, u, e)$ 로 정의된다. 여기서 r은 Feature 공간내의 한 hyper-rectangular 영역이다. 그리고 u는 유틸리티함수이며, e는 한 영역에서 허용된 에러율이다. 정보-이론 접근은 바로 이 영역의 유틸리티를 근거로 하게되는데, 그 목적은 Feature 공간내의 상이성(dissimilarity)을 최대화하는 것이다. 따라서 그 분할 작업은 두 영역들의 유틸리티들의 차이(거리함수로 표시)를 최대화하는 것을 근거로 한다.

각 영역은 에러 측정값 e와 관계를 갖게되는데, 유틸리티의 좋은 정도(goodness)에 비례하여 e는 보다 낮은 값을 갖는다. 거리함수 d는 다음과 같이 정의할 수 있다.

$$d = \log u_i - \log u_2 - t * \log(e_1 * e_2)$$

그리고 PLS에 있어서, 각 영역의 최종 집합이 Decision Tree의 leaf 노드와 같기 때문에 그 표현형

식이 ID3와 거의 일치한다. 따라서 PLS의 Generation/Specialization은 ID3와 거의 유사하고, 두 알고리즘의 계산의 복잡성 또한 거의 동등한 수준이다.

## 4. 전압제어 전문가 시스템

본 절에서는 먼저, 기존의 전압제어 전문가 시스템(Voltage Control Expert System : VCES)을 설명한다. 그리고 다음으로 VCES의 학습 알고리즘으로 사용하기 위해 다소 변경된 Tree Modification에 대해서 설명하며, 끝으로 기존의 VCES의 문제점을 해결하기 위해 자기학습 기능이 부여된 전압제어 전문가 시스템의 구조와 특성을 간단히 설명한다.

### 4.1 기존의 전압제어 전문가 시스템

전력회사는 수용가에게 적정하고 효율적인 전력을 공급하기 위해서, 전력계통의 부하모선들의 전압을 적정범위내에서 유지, 관리해야 하는데, 일반적으로 유지해야 할 적정범위는 0.95p.u에서 1.05p.u이다. 따라서 만약 임의의 부하모선 전압이 이 범위내에서 벗어나게되면, 분로 커페시터에 의한 무효전력 제어, 변압기 텔 변경 그리고 발전기 단자전압등을 제어하여 부하 모선전압을 정상상태로 환원시켜야만 한다. VCES는 바로 이러한 무효전력/전압제어 문제를 해결하는데 있어 시스템 조작자를 지원하는 보조자의 역할을 하는 전문가 시스템으로, 전압문제 발생시 정확한 대응책을 제시하기 위해 다음과 같은 타스크를 실행한다.

- 1) 전압문제의 유형(과전압, 저전압)을 판별한다.
- 2) 전압문제 유형과 제어대상 기기의 감도에 근거하여, 문제모선에 대한 제어 우선순위를 결정한다.
- 3) 제어량을 결정한다.
- 4) 모든 문제모선들에 대한 제어효과를 추정한다.
- 5) 조류계산을 실행하여, 모든 문제모선들의 추정 전압이 정상범위내에 있는지를 확인함으로서 제안된 제어효과를 검증한다.

타스크 2, 3 그리고 4는 감도모델에 근거하는데, 이 모델은 식(1)으로 표시된다. 이 식에서 감도율은 전압에 대한 무효전력의 부분 도함수를 포함하는 자

코비안의 역(inverse)로부터 얻어진다.

$$Vi = dij * ui \quad (1)$$

여기서  $Vi$ =전압 편차

$Ui$ =가해질 제어량

$dij$ =감도율

일반적으로, 정상 운전 조건하에서 유효전력/위상각, 무효전력/전압관계 사이에는 커플링 효과가 거의 존재하지 않는다. 따라서, 전압편차(voltage deviation)가 미소할 때 감도모델은 좋은 응답예측을 제공한다. 다시 말하면, 경미한 전압 문제에 대해서, VCES는 그 전압을 적정범위로 환원시키기 위해 어떠한 제어 대상 기기를 얼마의 제어량으로 제어해야 할지를 정확히 결정할 수 있는 능력을 갖는다. 그리고 대개 이러한 문제는 한번의 반복작업(iteration)으로 해결되는데, 이것은 VCES에 의해서 제시된 제어들을 타스크 5의 조류계산을 이용하여 검증함으로서 확인된다. 그러나 만약 이 검증작업에서 전압문제가 확인되면, VCES는 추가적으로 더많은 제어대상기기를 선택해야 하며, 이 작업을 2차 반복작업(second iteration)이라 한다.

대부분의 경우에서 VCES는 한번의 반복작업으로 문제를 해결할 수 있으나, 전압문제가 심각한 경우 감도에 의해서 오차(error)가 발생되기 때문에 저전압 한계(0.95p.u.)를 근거로 설정된 기존의 제어량을 이용해서는 한번의 반복작업으로 전압문제를 해결할 수 없다. 따라서 이러한 경우 2차, 3차의 반복작업을 필요로 하게된다.

VCES의 이러한 결점은 저전압 한계(lower voltage limit)를 0.95에서 0.97, 0.98등으로 높여 무효전력 제어량을 높은 수준으로 조정함으로서 해결할 수 있다. 물론 이 조정은 초과 제어량(overestimation)을 가져올 수 있으나, 위에 언급된 부족 제어량(underestimation)의 문제를 해결하기 위해서는 반드시 필요한 작업이다. 따라서 이러한 상황에서 전문가 시스템의 효율과 성능을 개선시키기 위해서는, VCES가 스스로 학습하여 한번의 제어 시도로 전압문제가 해결되도록, 적절한 저전압 한계를 결정할 수 있는 자기 학습능력을 가져야 한다.

## 4.2 Tree Modification

### 4.2.1 Decision Tree 구성단계

의사결정 경로를 구성하는데 있어 주요한 타스크는 다음과 같다.

1) 각 속성에 대한 증분치(increment)를 결정하고 임계값(threshold)의 목록을 작성한다. 시험의 표시식은 다음과 같다.

$$[Ai <= tij ?] \quad (2)$$

여기서  $Ai$ =i번째 속성

$tij$ =j번째 임계값

시험에서 줄기마디는 2개의 자 마디로 나뉘어지는 데, 그중 하나가 시험을 만족하게 되고 하나는 실패하게 된다.

2) 하나의 줄기마디에서 최적시험을 탐색한다.

이 작업은 모든 가능한 시험에 대한 정보이득의 계산을 필요로 하는데, 만약 시험에서 정보이득을 얻지못할 경우, 그 줄기마디를 Deadend로 지정한다.

3) 새로운 마디의 유형(Leaf 마디)를 결정한다.

Leaf 마디들은 같은 단일 부류의 구성요소들을 포함하나, 줄기마디들은 다중 부류의 구성요소들로 이루어지므로 단일 부류의 구성요소들로 이루어 질때 까지 더욱 계속 확장되어 한다.

### 4.2.2 Tree Modification

학습방법의 유효성은 교육자료(training set)의 표현정도에 크게 좌우된다. 만약 교육자료가 특수한 패턴의 예를 포함하지 않는다면, 구성된 의사 결정경로는 그 포함되지 않은 패턴을 갖는 입력 예를 분별할 수 없게된다. 따라서 이 의사결정 경로가 완전한 분별능력을 갖기위해서는 적용영역에 대한 완전한 교육자료를 찾아야만 하나, 전력계통이 전압문제를 비롯한 대부분의 실시간 연속 제어 문제에서 가능한 시나리오의 수가 무한히 크기 때문에 실제적으로 불가능하다. 따라서 그러한 문제에 대해서는 다음과 같은 접근이 바람직하다.

1) 미리 결정된 일단의 예를 가지고 의사결정 경로를 구성한다.

2) 오류분별(misclassification)이 발생할 때마다 그 의사결정 경로를 교정함으로서 미리 시험된 모든 예들에 대한 정확한 분별능력을 갖도록 하여, 오류분별이 결코 일어나지 않게 한다.

분명히 이 접근은 모든 예를 이용하여 의사결정 구조를 완전히 재 구성함으로서 이루어질 수 있으

나, 이작업은 계산적으로 엄청난 시간비용을 필요로 하기 때문에, 그 의사결정 경로에서, 변경해야만 할 최소 부분을 확인하여 완전한 재구성의 복잡성을 피 할 수 있는 경로 변경(tree-modification) 알고리즘을 적용하는것이 바람직하다.

이 경로 변경 알고리즘은 오류 판별된 예를 가지는 마디로부터 시작하여 변경해야할 필요성이 있는 마디가 없을 때까지, 그 마디에 대해 한번에 한 레벨의 상위마디까지 역행 추적하는 것으로 그 새로운(오류 분별된) 예를 시험, 교정하기 위해서는 적어도 하나 이상의 마디를 변경해야 한다. 구체적으로 말하면, 먼저 오류 분별된 예를 교육자료에 추가한다. 그 다음 알고리즘을 이용하여, 그 예를 잘못 분별한 마디로부터 출발하여 그 새로운 예의 추가로 인하여 최적 시험(optimal testing)이 변경되어야 할지를 결정한다. 이때 만약 그 시험이 한 마디에서 변경되면 그 부 마디까지 탐색이 이루어지며, 그렇지 않을 경우 이 전에 탐색된 자 마디로부터 재구성 작업을 시작한다.

#### 4.3 자기학습 전압제어 전문가 시스템

그림 2는 자기학습 전압 제어 전문가 시스템(Self-Learning Voltage Control Expert System: SLVCES)과 그 교육환경을 보인다. SLVCES는 기존의 VCES에 학습 모듈을 추가한 것으로, 이 모듈을 이용하여 경로구성, 경로변경 그리고 저전압 한계를 결정하는 능력을 갖는다. 따라서 SLVCES는

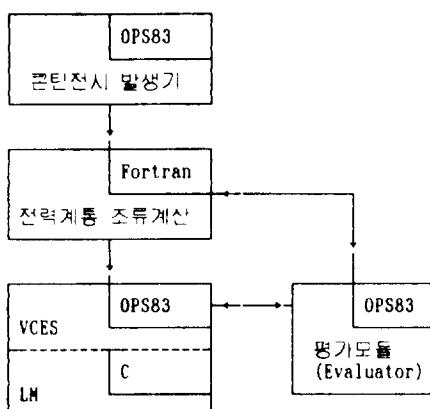


그림 2. 자기학습 전압제어 전문가 시스템(SLVCES)

전력계통의 전압제어에 대해 학습모듈(learning module : LM)에 의해서 구성된 의사 결정 경로(decision tree)를 탐색하여 해결하게 된다.

##### 4.3.1 자기학습 설계 및 적용

###### 1) 속성선택과 판별변수(Classification Parameter)

전압문제의 심각도(severity)를 효과적으로 판별하기 위해서는 주어진 전압문제의 특성을 정확히 나타낼 수 있는 관련 속성들을 선택해야만 하는데, 시뮬레이션 경험에 의하면 다음 속성들이 전압문제의 심각도를 판별하는데 가장 효과적이다.

n : 문제모선의 총수

av : 평균 전압 편차

Q : 최대 전압편차를 갖는 부하모선의 무효전력

전력문제는 분명히, 문제모선들의 수가 많으면 많을수록, 그리고 평균 전압 편차가 크면 클수록 더욱 심각하기 때문에 문제모선의 수와 평균전압 편차는 전압문제의 심각도를 판별하는 속성으로 반드시 필요하다. 또한 최대편차를 갖는 부하모선의 무효전력은 그 전압문제를 해결하기 위해서 얼마나 많은 제어량을 필요로 하는지를 보여주는 지표가 되기 때문에 하나의 속성으로 선택해야만 한다.

###### 2) 교육 자료(training set)

의사결정 경로의 유효성은 교육자료의 표현정도에 상당히 좌우된다. 따라서 전압문제의 영역에서 보다 유효한 의사 결정경로를 구성하기 위해서는 정확한 교육자료가 필요하며, 이 목적은 전압 문제의 심각도를 아주 세밀하게 구분함으로서 이를 수 있다. 그러나 실제적으로 앞에서 선택된 두 속성들이 연속값을 가지기 때문에 전압문제에 대한 모든 가능한 대상(예)를 포함하는 교육자료를 얻는 것은 불가능하다. 따라서 1차적으로 약간의 유효성이 저하되는 교육자료를 만들고 그 다음 학습작업을 통해 이 교육자료를 보다 정확하게 교정해야 한다.

###### 3) 의사결정 경로의 구성과 교정

앞에서 언급된 바와 같이 의사결정 경로 구성(tree-building) 타스크과정에서 연속값을 가지는 속성들은 각각의 속성에 대해 증분치를 선택하여 그 값을 이산화하여 표시한다. 각 속성들에 대한 증분치는 다음과 같다.

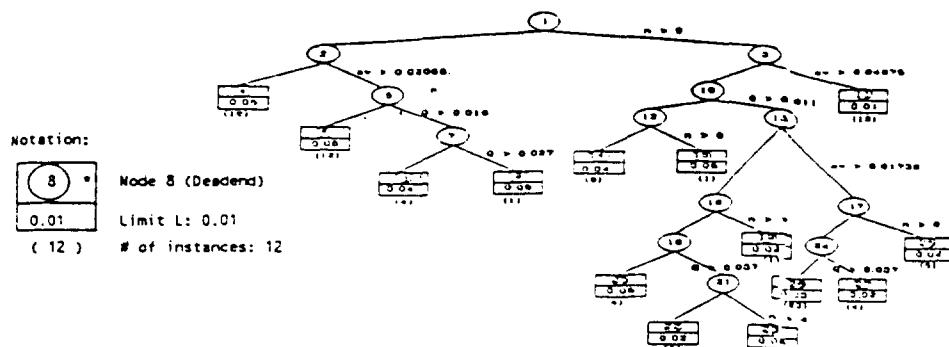


그림 3. 초기 구성된 의사결정 경로

표 5. 오류판별된 예

경우	n	av	Q	초기판별한계	교정된 한계
1	2	0.025846	0.081158	0.05	0.03
2	2	0.027070	0.327658	0.05	0.04
3	2	0.049540	0.184745	0.05	0.03

표 6. 시험 시나리오의 개요

시험 시나리오	콘틴전시의 총수
과 부하(load increased)	323
발전기 트립으로 인한 과부하	20
1선/발전기 트립	40
과부하에 의한 1선(singel line) 트립	529
2선/발전기 트립	6
과부하에 의한 2선(double line) 트립	56
발전기의 부족전압/발전기 트립	7
과부하에 의한 발전기의 부족전압	107
발전기 트립	1

n : 1

av : 0.00809

Q : 0.011

여기서 av와 Q의 중분자는 교육자료내에서 각 속성들에 대한 최대치와 최소치사이의 차를 10으로 나눈값이다. 그리고 n은 정수값을 가지기 때문에 중분치로서 1을 선택한다.

초기 교육자료를 이용하여 전압문제의 심각도를 판별할 경우, 교육자료 자체가 불완전하기 때문에

몇개의 전압 문제들에 대해서는 그 심각도를 오류판별할 수 있다. 이러한 경우 SLVCEs는 그 오류판별을 교정하기 위해 판별 경로 변경 알고리즘을 실행하게된다. 표5는 그림 2의 마디 9와 관련된 3개의 오류판별된 예를 보인다.

#### 4) 시험 예 (Test Cases)

시험 예에서는 부하 특성을 다소 변경한 IEEE-30 모선 시스템을 시험시스템으로 하여, SLVCEs의 기능을 설명하기 위해 먼저 베이스케이스를 모의하고 그다음 한, 두개의 라인 제거, 발전기 단자 전압 조정(낮춤), 부하모선의 무효전력 조정(높임), 발전기 트립 그리고 이들의 조합을 통하여 다양한 사고를 모의한다. 표6은 위의 방법에 의해서 만들어진 콘틴전시의 개요를 보인다.

#### 5) 시험 결과

학습 방법의 유효성을 보이기 위해서 2개의 시뮬레이션 작업을 실행한다. 표7은 VCES가 31개의 오류 판별된 예를 보이는 반면 SLVCEs는 11개의 오류판별된 예가 발생됨을 보인다.

표 7. SLVCEs에 의해 오류판별된 예

예	n	av	Q	오류판별 한계	교정된 한계
1	2	0.025846	0.081158	0.05	0.03
2	5	0.016669	0.315000	0.05	0.04
3	2	0.027070	0.327658	0.05	0.04
4	6	0.029309	0.010000	0.05	0.04
5	2	0.049540	0.184745	0.05	0.03
6	1	0.039666	0.083621	0.05	0.04
7	1	0.034766	0.254998	0.04	0.03
8	1	0.039709	0.083638	0.04	0.03
9	6	0.036119	0.010000	0.04	—
10	7	0.016226	0.312046	0.05	—
11	3	0.040199	0.279980	0.02	—

## 6. 결 론

전문가 시스템 개발과정에서 완전한 경험적 규칙들을 얻는 것은 극히 어려운 작업이다. 전문가들이 확고한 경험적 규칙들을 얻기위해서는 오랜 시간이 걸리며, 그 얻어진 지식조차 확인할 수 없다. 또한 같은 분야 지식도 전문가들 사이에서 큰 차이를 보일 수 있다.

이러한 상황에서 전문가 시스템이 보다 완전한 지식베이스를 얻어, 주어진 영역에서 기존의 고도 전문가 수준의 전문성을 갖는 완전한 전문가로 활약하기 위해서는 첫째 기존 지식의 유효성 검증을 통한 불완전한 지식 배제, 둘째 기존의 경험적 탐색 공간은 물론 보다 다양한 문제 해결 전략이 가능한 심층적 탐색공간을 제공하여 그로부터 새로운 문제 해결 지식을 학습하는 자기 학습 기능이 필요하다.

본지에서는 이러한 자기학습 기능을 갖는 전문가 시스템의 기능과 그들의 구성을 소개하였으며, 귀납적 학습 알고리즘을 검토하였다. 그리고 끝으로 전력계통에 대한 적용예로서 전압제어 전문가 시스템을 설명하였다.

아직 전문가 시스템의 자기학습 기능의 구현은 초보적 연구에 머물고 있으며, 그들의 학습 능력조차 낮은 수준에 불과하다. 그러나 전문가 시스템 연구자들은 기존 전문가 시스템의 문제점과 그 적용능력의 중요성을 인식하고 있기 때문에 보다 진보된 개념(데이터들로부터 이론과 원리를 학습하는)이 도입된 자기학습 전문가 시스템의 적용연구는 앞으로 여

러분야에서 폭넓게 이루어 질것으로 기대된다.

## 참 고 문 헌

- [1] B.Chandrasekaran, S. Mittal, "Deep versus compiled Knowledge Approches Diagnostic Problem Solving", Int.J.Man-Machine Studies, Vol. 19, pp 425-436, 1983
- [2] Davis, R., "Diagnostic Reasoning Based on Structure and Function : Paths of Iteration And the Locality Principle", Artificial Intelligence, Vol. 24, pp 347-410, 1984.
- [3] Luc Steels, "Second Generation Expert System", Future Generation Computer System, Vol. 1, No. 4, pp 213-221, June 1985.
- [4] Chen-Ching Liu, M. G. Lauby, et. al, "A Self-Learning Expert System for Voltage Control of Power System", Second Symposium on Expert Systems Application to Power System, pp 462-468, Seattle, Washington, July 17-20, 1989.
- [5] Davis, R., "Expert Systems: Where Are We? And Where Do You Go From Here?", AI Mag., Vol. 3, No. 2, pp. 3-22. 1982.
- [6] IEEE Press, Principles of Expert Systems.
- [7] Michalski, R., J. Carbonell and T. Mitchell(1984). Machine Learning. An Artificial Intelligence Approach. Springer Verlag. Berlin.
- [8] Steels, L. and W. Van De Velde(1985) Learning In Second Generation Expert Systems. Chapter 10 In Kowalik(ed.) Knowledge-Based Problem Solving. Prentice-Hall, Englewood Cliffs, New Jersey.