

論文95-32B-12-16

이종분산 고장 진단을 위한 지식표현 방법 및 진단 방법의 개발

(Development of a Knowledge Representation Scheme and Diagnosis Mechanism for Heterogeneous Distributed Fault Diagnosis)

安 英 愛 *, 朴 宗 熹 *

(Young Ae, An and Jong Hee, Park)

요 약

이종의 기계들로 이루어진 복잡한 제조공정들로 구성된 제조환경을 위한 고장진단 시스템을 개발한다. 이 시스템은 개별기계들에 대한 진단을 위주하는 기존의 고장진단 시스템과 달리 공장전체의 관점에서 통합적인 진단을 목표로 한다. 공정에서 발생하는 물리적인 소리나 전기적 신호등의 진단 신호들과 더불어 제품의 품질 특성치를 이종의 시스템들을 통합하는 공통적인 진단 변수로 이용한다. 시스템의 구성요소는 진단지식의 표현방법과 진단메카니즘으로 대별된다. 이종의 기계들에 관한 이질적인 진단지식들은 관련 공정에서 발생되는 여러가지 데이터들 사이의 인과관계로 균일하게 표현된다. 이 방법은 한 공정에서는 결과로 사용되는 데이터가 다른 공정에서는 원인이 될 수도 있다는 사실이 반영될 수 있다는 의미에서 유연성이 있다. 진단 방법은 기본적으로 확률적인 추론에 기초한다. 이 확률적인 진단방법은 여러개의 원인을 동시에 고려할 수 있고, 또한 그들 사이의 복합적 증상을 고려할 수 있다는 점에서 기존의 진단 방법들에 비해 일반적인 고장의 경우에 적용될 수 있는 진단방법이다. 개발된 방법과 알고리즘들을 전형적인 예에 적용시킨 결과를 통해 시스템을 검증한다.

Abstract

An integrated fault diagnosis system for heterogeneous manufacturing environments is developed. This system has a contrast with existing diagnosis systems in the respect that they are mostly for diagnosing faults on individual machines. In addition to the usual (e.g., audio, electrical) diagnostic signals, the characteristics of products from the machines are considered as the unifying diagnostic parameters among heterogeneous machines in the diagnosis. The system is composed of a knowledge representation scheme and a diagnostic query processing mechanism. Its knowledge representation scheme allows the diagnostic knowledges from heterogeneous unit diagnostic systems to be uniformly expressed in terms of the causal relations among relevant data items. It is flexible in the sense that causes for one relation can be effects for another may be reflected on our knowledge representation scheme. The diagnosis mechanism is based on a probabilistic inferencing method. This probabilistic diagnosis mechanism provides more general diagnosis than existing ones in that it accommodates multiple causes and takes complication among causes into account. These scheme and mechanism are applied to a typical example to demonstrate how our system works.

I. 서 론

* 正會員, 慶北大學校 電子工學科

(Department of Electrical Eng. Kyungpook National University)

接受日字: 1995年1月27日, 수정완료일: 1995年12月6日

개별 기계들이나 중요한 부품에 대한 고장 진단 시스템 개발 방법^[1,2]에 많은 연구가 이루어져 왔는데 rule 기반의 방법, 프레임 기반의 방법, 패턴 인식에

기초한 방법 등의 다양한 방법론이 제안되었다^[3,4,5]. 공장 전체에 대한 고장 진단을 수행하기 위해서는 이러한 개별기계들에 관한 고장 진단 기능들의 유기적 통합이 필요하다. 서로 기능이나 성능이 다르고 분산되어 있는 단위 생산 장치의 개별적 고장 진단 시스템을 공장 전체에 관한 종합적인 진단에 의해 단위기계의 고장이 원인이 아닌 복합적인 원인에 의한 문제의 발견도 가능하게되고 사람의 개입과 오류를 최소화할 수 있으며, 신속한 고장 진단 및 대처를 가능하게 한다. 그러나 생산 라인 혹은 공장 전체에 대한 고장 진단 시스템에 대한 연구는 기초 기술이 개발되는 단계이다^[6].

본 논문에서는 이종의 개별 기계들에 관한 다중의 감지 신호 및 품질 특성치들에 기초하여 종합적인 진단을 가능하게 하는 이종 고장 진단시스템을 개발한다. 이를 위해서 먼저 이종의 개별기계들에 관한 지식들을 종합적으로 표현할 수 있도록 전체 진단 시스템을 위한 지식 표현 방법을 제안한다. 고장 진단을 하기 위해서는 이종의 개별 기계들의 복잡한 동작들을 모델링하는 것은 실제적으로 용이하지 않다. 따라서 실험적 혹은 관찰된 데이터와 정보 및 전문가의 경험을 통한 지식들을 효과적으로 통합할 수 있는 방법이 필요하다. 그리고 제안된 지식 표현 방법을 토대로 시스템의 고장 진단을 할 수 있는 방법을 개발한다. 이 방법은 확률적 추론 메커니즘에 근거하여 인과관계를 계량화하는 방법으로 정확한 진단을 가능하게 하고 넓은 적용 범위를 가진다.

본문의 구성은 2장에서는 본 연구와 관련된 연구들을 살펴본다. 3장에서는 이종 분산 고장 진단 시스템의 전체적 구조에 대해서 살펴보고, 4장에서는 공장 전체에 대한 통합 고장 진단 시스템을 위한 전체 지식 표현 방법을 제안한다. 그리고 5장에서는 제안된 지식 표현 방법을 이용하여 고장 진단 질의를 처리하기 위한 확률적 추론 방법을 제시한다. 마지막으로 6장에서는 결론과 앞으로의 연구 방향에 대해서 설명된다.

II. 관련 연구

진단 문제 해결 방법을 모델링하는 시스템의 경우에 구조화된 지식과 확률적 지식 등의 적어도 두 가지의 지식이 사용된다. 따라서 진단에 사용되는 지식의 표현 방법과 불확정 인자(uncertainty factor)의 처리는

지능적 진단 추론 시스템을 성공적으로 구현하는데 필수적이다. 고장의 증상과 그 증상의 원인에 대한 관계는 관련된 데이터 아이템들간의 관계로 표현되며 특히 인과관계(causal association)가 가장 중요하다. 따라서 진단 문제 해결을 위한 인과관계의 표현과 확률적 지식을 결합하는 기존의 방법에 대해서 살펴본다. 그리고 개별 고장 진단 시스템을 통합하는 모델을 개발하는데 기초가 되는 정보 시스템들의 통합에 관련된 연구들을 살펴본다.

1. 진단 문제 해결을 위한 확률적 인과 모델에 관한 연구

Failure Propagation Tree(FPT)는 전체 생산 시스템의 전파되어진 고장의 위치를 표현하는 구조이다^[8]. 이는 제조업의 공정을 기능적 측면에서 계층적으로 모델링한 계층적 공정 계획도(Hierarchical Process Plan)에 의해 만들어진다. 계층적 공정 계획도의 모든 공정은 바람직한 작업을 위하여 만족되어야 하는 선행 조건(pre-condition)과 공정의 결과로 이루어지는 후행 조건(post-condition)의 관계로 표현된다. 이러한 선, 후행 조건은 공정의 입, 출력 관계만을 나타냄으로써 구성 공정의 기능은 무시함으로써 전체 생산 시스템을 구성하는 이종의 공정들을 일괄적으로 모델링할 수 있다. 그러나 이러한 FTP는 고장이 발생할 수 있는 모든 공정에 대해서만 알려줄 뿐이지 실질적인 고장 진단의 수행 업무를 최적화하기 위한 추론 능력, 예컨대 확률적 분석 추론 능력이 없다.

Influence Diagram^[9]은 전체 시스템에 대한 진단 고려 대상이 되는 중요한 모든 변수들과 이들의 모든 인과관계 및 상호관계를 graph-theoretic 방법으로 표현하고 있다. 이 모델은 decision node를 포함하여 표현한다는 것 외에는 흔히 알려진 bayesian network, belief network, causal network과 유사하다^[10,11]. 하지만 일단 주어진 고장 진단 문제가 Influence Diagram 모델을 이용하여 표현되면 확률적 관계들은 graph 레벨에서 다루어진다. 즉 topological transformation을 이용하며, 확률적 추론 방법으로 greedy algorithm을 적용시킴으로써 일관성 있는 고수준의 추론을 할 수 있다. 그러나 진단 고려 대상이 되는 변수들의 수가 많아지면 topological transformation을 이용하기가 복잡해지고 또한 계산상의 복잡성으로 인하여 실용성이 저하된다.

고장의 증상과 증상에 따른 원인들을 표현하는 대부분의 확률적 causal model들^[6,12]은 고장요인들의 집합과 증상들의 집합의 영역을 확연히 구분하고 있어 고장요인들간의 영향성 및 의존성에 대한 고려를 배제하고 추론을 한다. 특히 [6]에서 제시한 진단 추론 메카니즘에서는 고장요인들간의 영향성을 고려하고 있으나 고장요인들의 집합을 항상 두개로 고정시키고 이들 사이의 의존성 정도를 고려하는 정도에 그친다.

본 연구에서 제안하는 모델은 진단 대상 시스템에 관련된 전체 증상들과 모든 원인들의 관계를 명백하고 포괄적으로 표현할 수 있고, 또 소개된 여러 모델들의 단점들을 보완하기 위해서 아래의 특징들을 고려한다.

- 1) 진단 고려 대상이 되는 데이터 아이템들의 상호 관계 특히 인과 관계를 토대로 graph 레벨에서 표현한다.
- 2) 표현된 모델을 바탕으로 확률적 추론 메카니즘을 적용할때 계산상의 복잡성을 줄임으로써 큰 진단 문제도 다룰 수 있도록 한다.
- 3) 하나의 증상에 관련된 원인이 다른 진단 문제의 측면에서 볼 때는 증상이 될 수 있다는 포괄적이고 실제적인 개념, 즉 고장요인들의 집합과 증상들의 집합을 static 하게 고정시키는 것이 아니라 주어진 진단 질의에 따라 유동적인 변화가 있음을 유념해 두고 모든 증상들과 모든 원인들, 그리고 증상들간의 혹은 원인들간의 영향성 및 의존성의 관계를 모두 표현할 수 있도록 한다.
- 4) 확률적 추론 메카니즘을 구현할때 고장 요인들간의 영향성 및 의존성을 전부 고려함으로써 보다 정확한 진단 결과를 얻는다.

2. 시스템의 통합 모델에 관한 연구

종류와 성능이 서로 다른 개별 정보 시스템들을 구성 시스템으로 하는 전체 통합된 시스템을 모델링하는 연구가 많이 이루어지고 있다^[12]. 그러나 이들은 구성 시스템들의 입력과 출력을 접촉점들로 간주해 버리기 때문에 구성 시스템들간의 밀접한 통합을 할 수가 없어 사용자에게 구성 정보 시스템의 능력을 개별화하여 명시하는 정도에 그친다.

[13]에서 제안된 통합 모델은 독립적이고 개별적인 전문가 시스템들이 시스템 레벨에서가 아닌 rule 단위로 그들의 지식을 공유할 수 있어 시스템들간의 밀접한 통합이 가능하다. Function Graph는 데이터

아이템들 사이의 유추적 관계성 및 제한적 의존성의 측면에서 각 구성 시스템들의 지식을 표현함으로써 전체 지식으로 공유하도록 설계되었다. 이 모델은 본 논문에서 제안하고자하는 개별적 고장진단 시스템들의 통합을 위한 주요 개념들에 대한 기본 아이디어를 제공한다.

III. 이종 분산 고장 진단 시스템의 전체적 구조

기존의 독립적인 시스템들을 통합적으로 이용하기 위해서는 그러한 시스템들 각각이 무슨 지식들을 가지고 있는지 그리고 각 시스템들의 지식이 서로 어떻게 관계가 있는지 등에 대한 다양한 meta-knowledge가 요구되어 진다. 이러한 지식들을 표현하기 위해 각 시스템들의 지식들을 통합 시스템의 입장에서 표현할 수 있도록 하는 전체 지식 표현 스키마(Global Knowledge Representation Scheme)가 필요하다. 한편, 이러한 지식을 이용하여 전체 시스템의 관점에서 총괄적인 진단을 위한 처리 메카니즘이 필요하다.

통합된 고장 진단 시스템의 전체 구조는 그림 1과 같이 한 개의 총괄적 관리 모듈(Global Administration Module)과 여러 개의 각 구성 시스템에 대한 지역적 관리 모듈(Local Administration Module)의 두 레벨로 구성된다.

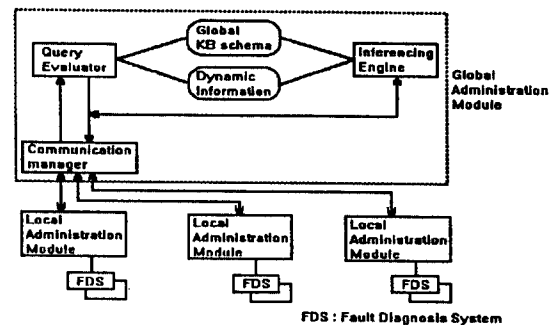


그림 1. 통합 고장진단 시스템의 전체구조

Fig. 1. Overall structure of integrated fault diagnosis system.

통합 시스템의 고장진단 메카니즘을 간단히 설명하면 개별적 고장 진단 시스템(Fault Diagnosis Systems)에 사용자에게 의하여 고장 진단 질의가 발생하면 지역적 관리 모듈에서는 사용자의 질의를 분석하여 필요하면 전체 시스템의 관점에서의 처리를 위해서 총괄

적 관리 모듈로 보낸다. 이렇게 보내어진 고장 진단 질의는 총괄적 관리 모듈의 전체 지식 베이스를 이용하여 추론부에 구현된 질의의 global 처리 방법인 확률적 추론 메카니즘에 의해 공장 전체의 관점에서 질의의 해당 즉, 고장 진단을 구해 낼 수 있다. 질의의 global 처리에 의해 구해진 진단 결과는 질의가 발생된 지역적 관리 모듈로 되돌려진다.

분산 고장 진단 시스템을 구성하는 개별 진단 시스템의 일반적인 구조는 다중 센서 검출부와 이들을 이용하여 진단하는 진단부로 구성되어 있다. 다중 센서 검출부는 여러개의 센서로 부터 얻은 여러 고장 신호들을 검출하여 기초적인 신호 처리 및 분석을 행하는 곳이고, 진단부는 각각의 고장 신호 처리의 결과를 종합적으로 고려하여 장치의 상태를 진단하는 곳이다. 진단 시스템에는 분석의 기능은 없는 단순한 신호감지 기능만 가진 것부터 전문가 시스템과 같이 고도의 진단이 가능한 시스템까지를 포괄한다. 공장의 개별 기계들에 관한 개별적 고장 진단 시스템들을 통합함으로써 생산라인 전체나 공장 전체의 고장 진단 시스템을 구축할 수 있다.

IV. 고장진단을 위한 지식의 표현 방법

1. 지식의 정적인 면의 표현

인과관계나 상호의존성등의 지식은 주로 rule과 constraint를 사용하여 표현할 수 있다. 이러한 rule 들에서 추론되는 지식은 관련된 데이터 아이템들을 매개로 하는 “마디가 있는 경로”들로 표현될 수 있다 [13]. 이러한 마디를 형성하는 데이터 아이템들의 구조적 상호관계를 지식의 정적인 면이라고 부른다. 이러한 지식의 정적인 면은 전체 데이터베이스 스키마에 의해 표현되어진다. 전체 데이터베이스 스키마는 질의자에게 이중의 rule 기반의 시스템들이 사용하는 데이터 아이템들에 대한 전체적인 뷰를 제공한다.

고장 진단을 위한 지식표현의 일례를 보이기 위해 여러 개의 단위 기계 들을 거쳐서 간단한 부속품을 생산하는 공장을 예로 들어보겠다. 이 공장을 구성하는 기계 장치들은 첫째 쇠판을 일정한 크기로 절단하는 기계 장치(절삭 공정)와, 둘째로 절삭 공정을 거친 쇠판의 각면을 깎는 기계 장치(연삭 공정)가 있으며, 셋째로 연삭 공정을 마친 쇠판에 한 개의 구멍을 뚫는 기계 장치(드릴링 공정)가 있으며, 마지막으로 드릴링

공정에서 만들어진 구멍을 다듬는 기계 장치(엔드-드릴링 공정)가 있다. 각 공정들은 일정 순서로 이루어지고 있으며, 각 공정의 기계 장치를 진단하기 위해 사용되어지는 데이터 아이템들에 대한 전체 데이터베이스 스키마는 객체 지향 데이터 모델 [7]을 이용하여 그림 2와 같이 나타낼 수 있다.

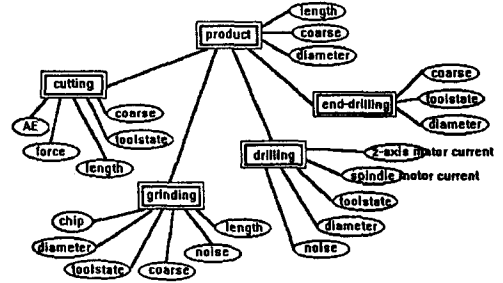


그림 2. 예제 도메인에 관한 전체 데이터베이스 스키마

Fig. 2. A global database scheme for example domain.

그림 2를 간단히 설명하면 사각형으로 표현된 생산 제품(product), 절삭공정(cutting), 연삭공정(grinding), 드릴링공정(drilling), 엔드-드릴링공정(end-drilling)을 나타내는 클래스가 있으며, 개별적 기계 장치에 대해 고장 진단에 사용되는 데이터 아이템들이 해당 클래스의 에트리뷰트가 된다.

2. 지식의 동적인 면의 표현

전체 시스템에 대한 고장 진단을 위해서 데이터 아이템들 사이의 상호 의존성의 관계, 즉 특정 데이터의 변화에 대해서 영향을 받는 데이터 아이템은 무엇인지를 알아야 한다. 이런 관계성을 데이터 아이템들 사이의 “동적 관계성”이라 하며 고장 진단 시스템들이 포함하고 있는 지식의 동적인 면을 표현하는 것은 데이터 아이템들 사이의 이런 동적 관계성을 표현하는 것을 말한다. 이러한 지식의 동적인 면을 표현하기 위해 논문에서는 통합된 고장 진단 시스템을 위한 지식 표현 방법으로 Influence Graph(IG)를 제안한다.

Influence Graph

Influence Graph(IG)는 개별 기계들에 관한 지식의 동적인 면을 표현하기 위한 것이며, 통합 진단 시스템에 의한 고장 진단의 기초가 되는 전체 지식 표현 스키마이다. $IG=(N,E)$ 는 두 가지 기본 요소 즉, 노

드의 집합, N, 과 에지의 집합, E, 로 구성된다. 노드는 지식 유추 경로에서의 마디에 해당하며 구체적으로 고장 진단 지식을 표현하는 rule에 포함된 데이터 아이템들로서 고장 진단에 사용되는 에트리뷰트들이다.

센서를 통해 검출된 여러 고장 감지 신호들은 단위 기계 장치의 고장 진단을 내릴 때 이용된다. 그러나 개별 기계에 대한 고장 감지 신호들만을 매개로 다른 단위 기계의 고장과 일일이 인과 관계로 연관짓기는 전문적인 지식이 너무많아 불가능하다. 이러한 고장 감지 신호들과는 달리 하나의 기계의 생산품의 품질 특성치는 관련 공정상에 있는 다른 기계의 생산품의 품질 특성치에 영향을 미치게 된다. 그래서 공장 전체를 이루는 단위 기계들의 상태를 고장감지 신호와 함께 생산품의 품질 특성치를 매개로 파악하면 고장발생 위치를 공장전체의 관점에서 종합적으로 파악할 수 있다.

여러 공정을 거치는 제품의 경우, 동일한 품질 특성치라도 공정에 따라 다른 에트리뷰트로 취급될 필요가 있다. 이런 공간적, 시간적 구분은 에트리뷰트의 구별성(distinctiveness)을 높여 고장 진단의 국지성(locality)을 제고시킨다.

IG에서의 에지는 그것의 앞 노드와 뒷 노드 사이의 동적 관계성을 표현한다. 예를 들어 고장 진단 rule R1에 의해서 cutting.force 에트리뷰트와 cutting.toolstate 에트리뷰트를 나타내는 두 노드와 두 노드 사이에는 에지가 형성된 IG를 나타낼 수 있다(그림 3에서의 네모로 표시한 부분).

R1 : IF cutting.force < 500 [N]
THEN cutting.toolstate = TOOLWEAR .

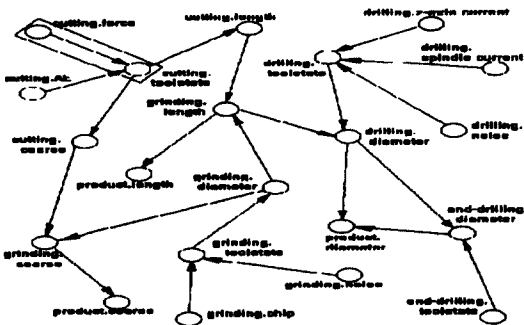


그림 3. 예제 도메인에 관한 Influence Graph
Fig. 3. An Influence Graph for example domain.

이런 방법으로 개별 기계들의 고장진단에 관한 지식

을 IG로 표현함으로써 이종의 기계들의 고장진단에 관한 지식을 통일적으로 표현할 수 있게 된다. 고장 진단의 측면에서 살펴볼 때 전체 지식 표현 스키마인 IG에서 표현된 고장 진단에 사용된 에트리뷰트들 사이의 상호 의존성의 관계의 표현은 고장에 관련된 에트리뷰트들간의 영향성을 표현한 것이다. 결국 IG는 고장의 원인들과 초래되는 증상들의 인과 관계를 종합적으로 표현한 것이다.

그림 3에서는 표시되지 않았지만 IG에는 위의 두 가지 기본 요소(노드와 에지)외에 전체 시스템에 대한 고장 진단 질의의 처리시 사용될 확률 인자값들이 명시된다. 확률 인자값들은 각 노드가 고장 원인으로 발생하는 확률값(p_i)과 인과 관계성에 관한 정보인 조건부 인과성 확률값($c_{i,j}$)의 두 가지이다. p_i 는 각 노드에 명시되고, $c_{i,j}$ 는 각 에지에 명시된다. 이들 확률 인자값들에 관한 설명은 V장에서 자세히 설명된다.

V. Global 고장 진단 질의 처리 방법

질의 처리 방법의 핵심은 고장 진단에 사용되는 데이터 아이템들의 인과 관계를 기반으로 표현된 IG에 확률적 추론 방법을 적용시키는 것이다. 본 논문에서 제안하는 확률적 추론 방법이 고장 진단에 관련된 기존의 확률적 추론 방법과 구별되는 특징들을 보면 :

- 1) 다른 관련 연구들^[6,12]은 증상들의 집합과 고장 요인의 집합들이 항상 고정적으로 주어지지만 본 논문에서 연구하고자 하는 확률적 추론 방법에서는 질의에 주어진 증상들의 집합에 따라서 고장 요인들의 집합이 다르게 정해진다. 따라서 각 질의에 주어진 증상들의 집합에 따라 고장요인들의 집합을 IG로부터 새로이 구해야 한다.
- 2) 다른 관련 연구들^[6,9,12]은 고장 요인들 상호간의 의존성 및 영향성이 없다고 간주하고 추론을 했지만 본 연구에서는 지식 표현 방법으로 제안한 IG에 표현된 고장요인들 상호간의 영향성을 함께 고려함으로써 보다 정밀하고 정확한 진단을 한다.
- 3) 본 논문은 동시 발생한 다수의 고장요인에 대한 진단 문제도 고려한 보다 일반적인 진단 방법이다.

1. 확률적 추론을 위한 기본 개념 및 정의
고장 진단에 필요한 요소는 $P=(D, S, C, D_r, S_r$

)로 정의된다. 여기서

- D 질의에 주어진 증상을 일으킬 수 있는 모든 고장요인(disorder)들의 집합, $= \{ d_1, d_2, \dots, d_n \}$
- S D가 일으킬 수 있는 모든 증상(symptom)들의 집합, $= \{ s_1, s_2, \dots, s_k \}$
- $C \subseteq D \times S$ D와 S 사이의 인과관계
- $D_I \subseteq D$ 개별적 질의에 대해 실제 일어난 증상을 모두 설명할 수 있는 고장요인들의 집합
- $S^- \subseteq S$ S 중에서 실제 나타난 증상들, 즉 고장 진단 질의에서 주어지는 증상들의 집합

예를 들어 그림 4의 IG에 대해 다음과 같은 질의가 주어졌을때 집합 D와 S를 구해 보겠다.




그림 4. 예제 질의를 위한 Influence Graph의 예 Fig. 4. Influence Graph for example query.

예제 질의 : 노드 1과 노드 3이 고장 증상으로 나타났을때 고장요인은 무엇인가?

- $D = \{ \text{노드}2(d_2), \text{노드}4(d_4), \text{노드}5(d_5), \text{노드}6(d_6), \text{노드}8(d_8) \}$
- $S = \{ \text{노드}1(s_1), \text{노드}3(s_3), \text{노드}7(s_7), \text{노드}9(s_9) \}$

[정의 1] 인과성 사건 : 어떤 $d_i \in D$ 와 $s_j \in S$ 에 대해서 $s_j : d_i$ 는 d_i 가 실제로 s_j 를 초래하는 사건을 나타낸다. 즉 d_i, s_j 둘다 발생하고 s_j 가 실제로 d_i 에 의해서 초래되어지지만 하면 인과성 사건 $s_j : d_i$ 는 참이다.

본 논문에서는 지식 표현을 위해 사용한 영향성에 따른 인과 관계성을 나타내었기 때문에 인과성 사건 $s_j : d_i$ 은 IG의 각 에지의 개념의 구체화를 의미한다.

예를 들어 d_i 와 s_j 가 둘다 발생했음지라도 s_j 가 d_i 에 의해 초래된 것이 아니라면 $s_j : d_i$ 는 거짓이다. 따라서 인과성 사건은 구별되는 기본 사건임이 명백하다.

[정의 2] $P(s_j : d_i | d_i)$ 를 d_i 가 주어졌을때의 s_j 의 조건부 인과성 확률(conditional causal probability)이라 한다.

$P(s_j : d_i | d_i) = \frac{P(s_j : d_i) \wedge d_i}{P(d_i)} = \frac{P(s_j : d_i)}{P(d_i)}$ 이기 때문에 조건부 인과성 확률은 주어진 d_i 가 s_j 를 초래하는 평균 횟수를 나타낸다. 이것은 베이시안 방법에서 사용되었던 조건부 확률 $P(s_j | d_i)$ 를 사용하는 것보다 d_i 와 s_j 사이의 인과 관계성의 정도를 더 잘 나타낸다. 예를 들어 d_1 은 s_1 을 초래할 수는 없지만 d_2 는 s_1 을 초래할 수 있다고 가정하자. 그러면 d_1 와 s_1 사이의 인과 관계성 정도는 분명히 0이어야 한다. 그러나 만약 d_1 과 d_2 가 동시에 일어났을 경우, 그때 $P(s_1 | d_1)$ 는 0보다 클 것이다. 반면 $s_1 : d_1$ 은 항상 거짓이기 때문에 $P(s_1 : d_1 | d_1) = 0$ 이다.

2. 확률적 추론 메카니즘

본 논문의 확률적 추론의 목표는 고장 진단 질의에서 주어진 S^- 에 관해서 D_I 집합들에 대한 상대적 가능성도 함수(Relative Likelihood Function), $L(S^-, D_I)$ 를 계산하여 가능성이 큰 고장요인들의 집합(D_I)을 추론해 내는 것이다. 진단 문제의 확률적 추론을 위해 사용되어지는 모든 정보는, 즉 모든 원인 사건 $d_i \in D$ 에 대한 $0 < P(d_i) < 1$ 와 인과성 사건 $s_j : d_i$ 에 대한 $0 \leq P(s_j : d_i | d_i) \leq 1$ 은 주어진다고 가정한다. 이들 정보는 실험적, 경험적 데이터 그리고 전문가의 지식으로 부터 얻을 수 있다. 수식을 간략히 하기 위해서 $P(d_i)$ 를 p_i 로, $P(s_j : d_i | d_i)$ 를 $c_{i,j}$ 로 표시하겠다.

$$P(D_I | S^-) = \frac{P(S^- | D_I) * P(D_I)}{P(S^-)}$$

$$P(D_I) = \prod_{d_i \in D_I} (p_i)$$

$P(S^- | D_I)$ 를 주어진 $c_{i,j}$ 의 형태로 표현되어지는 식으로 구한다. $P(s_j : (d_1 \wedge \dots \wedge d_r \wedge d_{r+1}))$ 를 편의상 $P(s_j : d_1 \wedge \dots \wedge d_r \wedge d_{r+1})$ 로 표시한다.

[정리 1] $D_I = \{ d_1, \dots, d_r \} \subseteq D$ 이고 $s_j \in M$ 이라 할때

$$P(s_j | D_I) = P(s_j : d_1 \wedge \dots \wedge d_r | d_1 \wedge \dots \wedge d_r) = 1 - \prod_{d_i \in D_I} (1 - c_{i,j})$$

- [증명] i) $r = 1$ 일때, $P(s_j; d_1 | d_1) = c_{1,j} = 1 - (1 - c_{1,j})$
 ii) $r \geq 1$ 에 대해서도 맞다고 가정하자.
 iii) $r+1$ 에 대해서도 유효함을 보이면 아래와 같다.

$$P(s_j; d_1 \wedge d_2) = P(s_j; d_1 \wedge d_2) + P(s_j; d_2 \wedge d_1) - P(s_j; d_1) \wedge (s_j; d_2)$$

$$P(s_j; d_1 \wedge \dots \wedge d_r \wedge d_{r+1}) = P(s_j; d_1 \wedge \dots \wedge d_r) \wedge d_{r+1} + P(s_j; d_{r+1} \wedge d_1 \wedge \dots \wedge d_r) - P(s_j; d_1 \wedge \dots \wedge d_r) \wedge (s_j; d_{r+1})$$

모든 고장요인들이 독립적으로 발생한다고 가정하면

$$= P(s_j; d_1 \wedge \dots \wedge d_r | d_1 \wedge \dots \wedge d_r) * P(d_{r+1} \wedge d_1 \wedge \dots \wedge d_r) + P(s_j; d_{r+1} | d_{r+1}) * P(d_1 \wedge d_2 \wedge \dots \wedge d_r \wedge d_{r+1}) - P(s_j; d_1 \wedge \dots \wedge d_r | d_1 \wedge \dots \wedge d_r) * P(d_1 \wedge d_2 \wedge \dots \wedge d_r \wedge d_{r+1}) * P(s_j; d_{r+1} | d_{r+1})$$

양변을 $P(d_1 \wedge d_2 \wedge \dots \wedge d_r \wedge d_{r+1})$ 로 나누면

$$P(s_j; d_1 \wedge \dots \wedge d_r \wedge d_{r+1} | d_1 \wedge \dots \wedge d_r \wedge d_{r+1}) = P(s_j; d_1 \wedge \dots \wedge d_r | d_1 \wedge \dots \wedge d_r) + P(s_j; d_{r+1} | d_{r+1}) - P(s_j; d_1 \wedge \dots \wedge d_r | d_1 \wedge \dots \wedge d_r) * P(s_j; d_{r+1} | d_{r+1}) = (1 - \prod_{i=1}^r (1 - c_{i,j})) + c_{r+1,j} - (1 - \prod_{i=1}^r (1 - c_{i,j})) * c_{r+1,j} = 1 - \prod_{i=1}^{r+1} (1 - c_{i,j})$$

[정의 3] 상대적 가능도 함수 $L(S^-, D_1)$ 는 $P(S^- | D_1)$ 와 $P(D_1)$ 의 곱으로 정의한다.

$$L(S^-, D_1) = P(S^- | D_1) * P(D_1) = \prod_{s \in S^-} (1 - \prod_{d \in D_1} (1 - c_{i,j})) * \prod_{d \in D_1} \prod_{s \in effects(d) - S^-} (1 - c_{i,j}) * \prod_{d \in D_1} P_d$$

이렇게 구해진 각 D_1 의 상대적 가능도 함수값으로부터 주어진 진단 문제에 대한 가능한 D_1 의 순위를 정할 수 있다.

3. 고장요인들간의 영향성을 고려한 확률적 추론
 앞 절에서 제시한 확률적 추론 메카니즘은 모든 고장요인들이 서로 독립적으로 발생한다고 가정하고 유추했다. 그러나 일반적으로는 본 논문에서 제안한 지식 표현 방법인 IG를 바탕으로 확률적 추론을 하기 위해서는 고장요인들 사이의 영향성을 고려해야 한다.

두 개 이상의 고장요인들간의 영향성을 고려한 경우를 살펴보자. 그림 5의 (a)와 (b)에서 증상 $S^- = \{s_3\}$ 으로 주어지고 $D_1 = \{d_1, d_2\}$ 로 주어졌을때 $L(S^-, D_1)$ 를 각각 구해보자. 우선 가장 간단한 예로 그림 8의 (a)처럼 노드 1이 노드 2에 영향을 미치고 노드 2는 노드 3과 노드 4에 영향을 미치는 경우를 살펴보자.




그림 5. 고장 요인들간의 영향성이 있는 경우
 Fig. 5. Case of considering influences among fault causes.

고장요인들의 집합 $\{d_1, d_2\}$ 로 $S^- = \{s_3\}$ 을 설명할 수 있으려면 첫째, 노드 1이 발생하고 노드 1의 발생에 관계없이, 즉 노드 1에 영향을 받지 않고 노드 2가 발생해서 노드 3을 초래한 경우와 둘째, 노드 1이 발생해서 노드 1의 영향을 받아 노드 2가 발생해서 노드 3을 초래한 경우 그리고 셋째로 노드 1이 노드 2를 초래해서 노드 3을 초래함과 동시에 노드 1에 관계없이 노드 2가 발생해서 노드 3을 초래한 경우를 고려해야 한다.

$$\begin{aligned} \text{따라서 } L_1(S^-, D_1) * L_3(S^-, D_1) * L_2(S^-, D_1) &= p(d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_3; d_2 | d_2)) \\ &+ p(d_1) * p(d_2; d_1 | d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_3; d_2 | d_2)) \\ &- p(d_1) * p(d_2; d_1 | d_1) * p(s_3; d_2 | d_2) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_3; d_2 | d_2)) \\ &= p(d_1) * p(d_2) * c_{2,3} * (1 - c_{2,4}) + p(d_1) * c_{1,2} * p(d_2) * c_{2,3} * (1 - c_{2,4}) \\ &- p(d_1) * c_{1,2} * c_{2,3} * p(d_2) * c_{2,3} * (1 - c_{2,4}) \\ &= p(d_1) * p(d_2) * (1 - (1 - c_{2,3})(1 - c_{1,2} * c_{2,3})) * (1 - c_{2,4}) \end{aligned}$$

그리고 그림 8의 (b)는 (a)의 경우이다 추가로 노드 1이 노드 3에 직접적인 인과 관계성이 있는 경우가 덧붙여진 경우다. 이 경우에도 각 노드간의 모든 경우들을 고려하여 $L(S^-, D_1)$ 를 구해 보면

$$L(S^-, D_1) = p(d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_3; d_2 | d_2)) + p(d_1) * p(s_3; d_1 | d_1) * p(d_2) * (1 - p(s_3; d_2 | d_2))$$

$$\begin{aligned}
 &+ p(d_1) * p(d_2 | d_1 | d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_4; d_2 | d_2)) \\
 &- p(d_1) * p(s_3; d_1 | d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_4; d_2 | d_2)) \\
 &- p(d_1) * p(d_2; d_1 | d_1) * p(s_3; d_2 | d_2) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_4; d_2 | d_2)) \\
 &- p(d_1) * p(s_3; d_1 | d_1) * p(d_2; d_1 | d_1) * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_4; d_2 | d_2)) \\
 &+ p(d_1) * p(s_3; d_1 | d_1) * p(d_2; d_1 | d_1) * p(s_3; d_2 | d_2) \\
 &\quad * p(d_2) * p(s_3; d_2 | d_2) * (1 - p(s_4; d_2 | d_2)) \\
 &= p(d_1) * p(d_2) * (1 - (1 - c_{1,3})(1 - c_{2,3})(1 - c_{1,2} * c_{2,3})) * (1 - c_{2,4})
 \end{aligned}$$

[정의 4] 노드 A와 노드 B 사이에는 인과 관계성이 없지만 노드 A와 노드 C가 인과 관계성이 있고, 노드 C와 노드 B가 인과 관계성이 있다면 노드 A와 노드 B는 A-C-B의 '경로(path)'로 '간접 인과 관계성'이 있다고 말한다.

[정의 5] 경로상에 있는 모든 노드들간의 조건부 인과성 확률의 곱을 '조건부 간접 인과성 확률'이라 한다.

위의 그림 5의 (b)와는 달리 (a)는 실제로 노드 1과 노드 3사이에는 인과 관계성이 없지만, 노드 2가 가능성 있는 고장요인들 집합 D_I에 포함되어 있기 때문에, 노드 2를 거치는 노드 1과 노드 3사이의 인과 관계성을 간접적으로 유추해 낼 수 있다.

$$\begin{aligned}
 \text{따라서 } L(S^-, D_I) &= P(S^- | D_I) * P(D_I) \\
 &= \prod_{s \in S^-} [1 - \prod_{d \in D_I} (1 - c_{i,j}) \prod_{\text{path}(d_i \in D_I, s \in S^-)} (1 - c_{i,j}(\text{path}))] \\
 &\quad * \prod_{d_i \in D_I} \prod_{s_j \in \text{effects}(d_i) - S^-} (1 - c_{i,j}) * \prod_{d_i \in D_I} P_i
 \end{aligned}$$

여기서 path(d_i ∈ D_I, s_j ∈ S⁻)는 D_I내의 모든 d_i와 s_j 사이의 간접 인과 관계성을 유추해 내는 것을 의미한다. 그리고 C_{i,j}(path)는 각 경로에 대한 간접 조건부 인과성 확률을 표시한 것이다.

4. 확률적 추론 메카니즘의 적용 예

그림 4의 IG를 바탕으로 예제 질의에 대하여 앞에서 개발된 확률적 추론에 의한 진단을 수행해 본다. 먼저 고장요인 집합의 부분 집합 중에서 실제 일어난 증상들을 모두 설명할 수 있는 고장요인들의 집합 D_I를 구하면 ({d₄}, {d₂, d₄}, {d₂, d₈}, {d₄, d₈}, {d₂, d₄, d₅}, {d₂, d₄, d₈}, {d₂, d₄, d₈}, {d₂, d₅, d₈}, {d₂, d₆, d₈}, {d₄, d₆, d₈}, {d₂, d₄, d₅, d₆}, {d₂, d₄, d₅, d₈}, {d₂, d₄, d₆, d₈}, {d₄, d₅,

d₆, d₈}, {d₄, d₅, d₆, d₈}, {d₄, d₄, d₅, d₆, d₈})이다.

지금부터 상대적 가능성도 함수 L(S⁻, D_I)를 실제로 구해 보자. 예를 들어 D_I를 {d₂, d₄, d₈}로 했을 경우에는

$$\begin{aligned}
 L_1 &= (1 - (1 - c_{2,1})(1 - c_{4,1})(1 - c_{8,1})) * (1 - (1 - c_{2,3})(1 - c_{4,3}) \\
 &\quad (1 - c_{8,3})) = 0.8372
 \end{aligned}$$

$$L_2 = (1 - c_{2,7}) * (1 - c_{4,7}) * (1 - c_{8,9}) = 0.1120$$

$$L_3 = p_2 * p_4 * p_8 = 0.2 * 0.1 * 0.2 = 0.0040$$

$$\therefore L(\{d_2, d_4, d_8\}, \{s_1, s_3\}) = L_1 * L_2 * L_3 = 0.0003751$$

그러나 D_I가 {d₂, d₅, d₆, d₈}로 했을 경우에는 고장요인들 사이에 영향성이 있다. 즉 노드 5의 고장은 노드 2와 노드 6에 영향을 미쳐 고장을 초래할 수 있고 또 노드 6의 고장이 노드 2와 노드 8의 고장을 초래할 수 있다. 따라서 먼저 각 고장요인들과 증상간의 경로를 찾아내어 간접 인과 관계성을 유추해서 조건부 간접 인과성 확률을 구한다.

D_I가 {d₂, d₅, d₆, d₈}일때 5-2-1, 6-2-1, 5-6-2-1, 5-6-8-3, 6-8-3의 4개의 경로가 있다. 따라서 c_{5,1(5-2-1)} = 0.63, c_{6,1(6-2-1)} = c_{6,2} * c_{2,1} = 0.72, c_{5,1(5-6-2-1)} = c_{5,6} * c_{6,2} * c_{2,1} = 0.648, c_{5,1(5-6-8-3)} = 0.9 * 0.5 * 0.9 = 0.405, c_{6,3(6-8-3)} = 0.5 * 0.9 = 0.45 의 조건부 간접 인과성 확률을 구할 수 있으며, L(S⁻, D_I)는 아래와 같이 구해진다.

$$\begin{aligned}
 L_1(S^-, D_I) &= (1 - (1 - c_{2,1})(1 - c_{5,1(5-2-1)})(1 - c_{5,1(5-6-2-1)}) \\
 &\quad (1 - c_{6,1(6-2-1)})(1 - c_{8,1})) *
 \end{aligned}$$

$$\begin{aligned}
 &\quad (1 - (1 - c_{2,3})(1 - c_{5,3(5-6-8-3)})(1 - c_{6,3(6-8-3)}) \\
 &\quad (1 - c_{8,3})) = 0.9639
 \end{aligned}$$

$$L_2(S^-, D_I) = (1 - c_{2,7}) * (1 - c_{8,9}) = 0.56$$

$$L_3(S^-, D_I) = 0.2 * 0.2 * 0.1 * 0.2 = 0.0008$$

$$\therefore L(S^-, D_I) = 0.00043183$$

예제 질의에 대한 최종의 확률적 추론 결과를 아래 표 1에 나타내었다. 구해진 가능성 있는 고장 요인들의 집합들의 상대적 가능성도 함수값의 순위를 바탕으로 최적의 고장 진단 결과를 얻을 수 있다. 표 1의 결과에 따르면 예제 질의의 최적의 해답은 고장 요인들의

집합 $\{d_2, d_8\}$ 이며 이것은 노드 1과 노드 3의 고장은 노드 2와 노드 8이 고장 요인으로 설명될 수 있음을 의미한다.

표 1. 예제 질의의 확률적 추론 결과
Table 1. Results of example query via probabilistic inferencing.

D_i	$L_1(S', D)$	$L_2(S', D)$	$L_3(S', D)$	$L(S', D)$	Ranking
$\{d_1\}$	0.02	0.2	0.1	0.004	2
$\{d_2, d_4\}$	0.092	0.14	0.02	0.0002576	8
$\{d_2, d_8\}$	0.81	0.56	0.04	0.018	1
$\{d_1, d_8\}$	0.182	0.16	0.02	0.0005824	4
$\{d_2, d_4, d_8\}$	0.097	0.007	0.004	0.000002716	14
$\{d_2, d_4, d_8\}$	0.0978	0.035	0.002	0.000006846	13
$\{d_2, d_4, d_8\}$	0.8372	0.112	0.004	0.000375	7
$\{d_2, d_5, d_8\}$	0.8667	0.056	0.008	0.000382	6
$\{d_2, d_8, d_8\}$	0.8748	0.56	0.004	0.0021	3
$\{d_1, d_8, d_8\}$	0.1901	0.032	0.002	0.00001217	10
$\{d_2, d_4, d_5, d_8\}$	0.0996	0.07	0.0004	0.000000278	16
$\{d_2, d_4, d_5, d_8\}$	0.9033	0.0112	0.0008	0.0000081	11
$\{d_2, d_4, d_8, d_8\}$	0.9292	0.112	0.0004	0.000041628	9
$\{d_2, d_5, d_8, d_8\}$	0.9639	0.56	0.0008	0.0004318	5
$\{d_1, d_5, d_8, d_8\}$	0.1941	0.0096	0.0004	0.0000007453	15
$\{d_2, d_4, d_5, d_8, d_8\}$	0.9671	0.112	0.00008	0.0000086652	12

VI. 결 론

지금까지 이중의 개별 생산 기계 장치에 대해 다중의 감지 신호와 품질특성치에 기초하여 진단을 하는 이중의 rule 기반의 고장 진단 전문가 시스템들을 통합하는 모델을 제안했다. 이 진단 시스템 모델의 특징은 제조업의 생산 라인이나 공장 전체를 구성하고 있는 단위 기계 장치들에 대해 이미 존재하고 있는 rule 기반의 고장 진단 전문가 시스템들을 통합하여 공장 전체 시스템의 관점에서 모든 구성 시스템들의 총괄적인 고장 진단을 할 수 있다는 것이다.

이를 구체화하기 위해서 이중의 고장 진단 전문가 시스템들이 포함하고 있는 실험적 혹은 관찰된 데이터와 정보 및 전문가의 경험을 통한 지식들을 효과적으로 융합하는 방법으로 통합 시스템의 전체 지식 표현 방법인 Influence Graph를 제시했다. 제안된 Influence Graph를 통하여 전체 시스템을 구성하는 모든 고장 진단 전문가 시스템들이 포함하고 있는 지식의 동적인 면을 표현할 수 있다. 그리고 Influence Graph를 바탕으로 고장 진단 질의의 총괄적 처리를 위해서 확률적 추론 메카니즘을 개발하였다. 이 메카니즘은 고장 진단에 사용되는 모든 에트리뷰트들의 인과

관계성을 기초로 주어진 조건부 인과성 확률 및 조건부 간접 인과성 확률을 기반으로 가능성 있는 고장요인들의 집합을 구하여 각 집합들에 대한 상대적 가능성도 함수 $L(D_i, S')$ 를 구함으로써 최적의 해답을 얻을 수 있게 한다.

본 논문에서 제안한 모델의 가장 큰 장점은 구성 시스템들이 가지고 있는 지식들이 진단 문제에서 가장 중요한 관건이 되는 원인과 증상의 인과 관계에 관련된 정보들로 쉽게 이용되고, 효율적으로 융합되고, 그리고 충분히 활용되었다는 것이다. 또 이제껏 다루기 힘들었던 고장요인들간의 모든 영향성 및 의존성을 고려하여 진단 결과를 추론해냄으로써 보다 정확하고 일반적인 고장 진단 추론 방법을 제시했다.

참 고 문 헌

- [1] Tou, J.T., "Design of Expert Systems for Integrated Production Automation," *Journal of Manufacturing Systems*, Vol. 4, No. 2, 1985, pp. 147-156.
- [2] W.B.Rouse, "Model of Human problem Solving: Detection, Diagnosis, and Compensation for System Failures," *Automatica*, Vol. 19, No. 6, 1983, pp. 613-625.
- [3] F.Bergadano and L.Saitta, "A General Framework for Knowledge-based Pattern Recognition," *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 1, No. 2, 1987, pp. 189-205.
- [4] Robert Milne, "Strategies for Diagnosis," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol.SMC-17, No.3, May/June 1987, pp. 333-339.
- [5] Sunderesh S.H. and Andrew K., "Analysis of Expert Systems in Manufacturing Design," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. SMC-17, No. 6, November/December 1987, pp. 898-912.
- [6] Kwangsue Chung and Julius T.Tou.

- "Knowledge-based approach to fault diagnosis and control in distributed process environments," *Applications of Artificial Intelligence IX*, SPIE Vol. 1468, 1991, pp. 323-332.
- [7] 황의철, "품질경영", 전영사, 1991
- [8] Shaw Jen Chang, "Failure Propagation Trees for Diagnosis in manufacturing Systems," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol.21, No24, July/August 1991.
- [9] Ashutosh R. and Alice M.A., "Topological Framework for Representing and Solving Probabilistic Inference Problems in Expert Systems," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 18, No. 3, May/June 1988, pp. 402-414.
- [10] Luca C. and Pietro.T., "An Approach to the Compilation of Operational Knowledge from Causal Models," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 22, No. 4, July/August 1992, pp. 772-789.
- [11] Jin H Kim and Judea Pearl, "A Computational Model for Causal and Diagnostic in Inference Systems," *Application Artificial Intelligence*, 1983, pp. 190-193.
- [12] Peng.Y. and Reggia, J.A., "A Probabilistic Causal Model for Diagnostic Problem Solving - Part I and II: Integrating Symbolic Causal Inference with Numerical probabilistic Inference," *IEEE Trans. on Systems, Man, and Cybernetics*, Vol.SMC-17, No.2, March/April 1987, pp.146-162.
- [13] Park J.H. and Su S., "An Integrated Approach to Knowledge Sharing among Heterogeneous Rule-based systems," *Journal of Applied Intelligence*, 1991, pp.583-592.
- [14] 윤재웅 양민양 박화영, "이중신호에 의한 공구 파손 검출에 관한 연구," 대한 기계학회 논문집, 제 16권, 제 4호, 1992, pp.707-722
- [15] 김화영 안중환, "공작 기계 지능화를 위한 다중 감시 시스템의 개발," 한국 정밀공학회지, 제10권, 제 4호, 1993, pp.143-151

 저 자 소 개



安 英 愛(正會員)
 1992年 경북대학교 전자공학과
 졸업(학사). 1995年 경북대학교
 전자공학과 대학원 졸업(석사).
 현재 LG전자 영상디스플레이
 연구소 연구원.

朴 宗 熹(正會員) 第 32卷 B篇 第 1號 參照
 현재 慶北大學校 電子工學科 助教授