

## 화학 공정의 이상 진단을 위한 조업 지원 시스템의 개발

모경주\* · 정창욱\*\* · 이기백\* · 윤인섭\*

### Development of Operation Aided System for Fault Diagnosis of Chemical Process

Kyung Joo Mo\*, Chang Wook Jeong\*\*, Gibaek Lee\*, En Sup Yoon\*

#### 요약

본 논문에서는 화학공정의 이상 진단을 위한 지식 기반 조업 지원 시스템의 개발에 관하여 살펴보고자 한다.

조업지원 시스템에서 가장 핵심적인 부분은 공정에 비정상 상황이 발생한 경우 이를 감지하고, 공정에 발생한 증상들을 분석하여 이상의 근본 원인을 찾아내는 작업-이상 진단-이다. 이상 진단을 효과적으로 수행하기 위해서는 적절한 데이터의 해석이 매우 중요한데, 기존의 데이터 해석법들은 정상상태에 기반한 방법으로 동적 거동을 효과적으로 표현하기에는 어려움이 많다. 본 연구에서는 RBF에 기반한 신경망을 사용하여 동적인 거동을 효과적으로 표현할 수 있는 정성적인 데이터 해석 모듈을 구축하였으며, 이 모듈에서는 공정에서 측정된 정량적인 센서값들을 정성적인 정보로 가공하여 이상진단 모듈에 제공한다.

본 연구에서는 효과적인 이상진단을 위하여 기존의 인과관계 그래프 모델(Cause Effect DiGraph)에 기반한 두 가지 그래프 모델을 개발하였다. RCED(Reduced Cause Effect Digraph)는 공정의 측정 변수만으로 공정의 인과관계를 표현하는 오프라인으로 구축된 지식 베이스 모델이며, PGTT(Pattern Graph Through Time)는 공정에서 발생한 증상간의 인과관계를 실시간으로 나타내는 동적인 모델이다.

이상, 신경망에 기반한 정성적인 데이터 해석 모듈과 이상진단 모듈을 전문가 시스템 도구인 G2를 DEC AlphaStation 상에서 폴리프로필렌 공정에 대한 조업지원전문가 시스템을 구축하고 이를 적용하여 보았다.

주요어 : 조업지원, 정성적인 데이터 해석, 이상진단

\* 서울대학교 화학공학과 공정시스템실

\*\* 삼성엔지니어링 공정부

## 1. 서 론

현재의 화학공장에는 조업자를 돋기 위한 복잡한 제어 시스템이 설치되어 있다. 정상 조업 상태에서 제어 시스템은 공정 변수들을 정해진 범위 내에서 유지시켜주고, 심각한 이상이 발생한 경우에는 안전한 조업중단(shut down)을 위해 공장을 자동으로 트립(trip)시킨다. 조업자의 역할은 이 두 가지 상황의 사이에서 이루어진다. 이상이 심각한 상태로 발전하기까지 단계별로 관련된 변수들이 영향을 받게 되고 제어 시스템은 이 변수들의 변동을 조업자에게 알려준다. 이때, 조업자는 공정의 데이터를 해석하여 공정의 현재 상황, 이상의 발생 여부 및 그 원인을 판단하고 공정을 정상상태로 되돌리기 위한 적절한 조치를 취해야 한다.

이런 일련의 과정은 대개 짧은 시간 내에 정확하게 이루어져야 하지만, 여러 가지 이유로 인하여 조업자는 많은 어려움을 겪게 된다. 공정에 대한 조업자의 경험이 부족할 수도 있고, 경험하지 못한 이상이 발생하거나, 화학공정의 갖는 큰 상호 연관성(interaction), 에너지의 절약을 위한 공정의 병합화(integration)로 인한 공정의 복잡성 증대 등으로 인해 판단에 어려움을 겪을 수도 있다.

이와 같은 이유로 인하여 조업을 지원하기 위한 자동이상진단(automatic fault diagnosis)의 필요성이 점차 증대되고 있다(Dvorak, 1991).

이상진단 시스템의 구축에 있어서, 수학적 모델을 사용하는 경우 정확한 모델을 얻기가 어렵고, 계산 시간이 많이 걸리는 문제로 인하여 인과관계 모델을 사용하는 정성적인 방법들이 1970년대 이후에 제안되었다. 이와 같은 정성적 방법들에는 경험에 기반한 전문가 시스템, 인과관계 모델, 정성적인 시뮬레이션(qualitative simulation) 그리고 신경망을 이용한 방법 등이 있다(Beckett 등, 1991).

본 논문에서는 인공신경망과 인과관계모델을 이용한 폴리프로필렌 공정에 대한 조업지원시스템 개발에 대하여 다루고자 한다.

## 2. 이상의 감지와 정성적인 해석

이상 진단을 위해서는 센서로부터 들어오는 공정의 데이터를 해석하여 이를 유용한 정보로 추출하는 과정이 필요하다. 이와 같이 수치적인 센서값으로부터 유용한 정보를 추출해 내는 문제를 정성적인 해석(QI, Qualitative Interpretation)이라고 한다(Whiteley, 1992). 정성적인 해석은 이상의 감지(fault detection)와 센서 데이터로부터 이상 진단 시스템에서 사용하기 위한 정보를 추출하는 과정을 포함하고 있다.

여기서, 이상 감지(fault detection)란 센서의 패턴을 조사하여 데이터가 정상적인 조업을 의미하는지 비정상적인 상황을 의미하는지를 판단하여, 이상이 발생한 시간에 대한 정보를 발생시키는 작업을 의미한다. 그러므로, 정성적인 해석이란 이상의 발생 유무 판단을 포함한 폭넓은 정성적인 정보의 추출 과정을 의미한다고 할 수 있다.

화학공정의 조업은 수량적인 값을 바탕으로 이루어지지만, 이상 진단의 경우에는 수량적인 값들은 직접 사용하는 대신에 이를 정성적인 값으로 해석하여 사용한다. 즉, 온도, 압력, 유량과 같은 특정한 물리량을 실제값 대신에 기준값보다 ‘높다’, ‘낮다’, 또는 과거값보다 ‘증가’, ‘감소’ 등의 정성적인 정보로 가공하여 사용하는 것이다. 따라서, 센서의 데이터를 해석하여 이상진단 시스템에 제공하는 전처리 과정인 정성적인 해석 방법에 의하여 전체적인 시스템의 성능에 막대한 영향을 미치게 된다.

본 시스템의 개발에서는 정성적인 해석 부분을 진단을 위한 추론 활동으로부터 독립된 정보의 처리

과정으로 다루어 진단의 전처리 모듈로 독립적으로 구성하였다.

## 2.1 한계점검법(Limit Checking)과 Shewhart 차트

진단 시스템을 성공적으로 구현하기 위해서는 빠른 이상의 감지와 정확한 해석이 필수적이지만, 이러한 감지와 해석은 중요성에 비하여 상대적으로 연구가 부진하였다(Whiteley, 1992). 현재, 가장 간단하며 널리 사용되는 감지 방법은 한계점검법(limit checking method)이다. 한계점검법의 기본 형태는 다음과 같다.

$$Y_{\text{Min}} < Y(t) < Y_{\text{Max}} \quad (1)$$

여기서,  $Y(t)$  = 시간  $t$ 에서의 공정 데이터 값

$Y_{\text{Min}}, Y_{\text{Max}}$  = 하한값, 상한값

$$Q(t) = \begin{cases} +1, & \text{if, } Y(t) > Y_{\text{Max}} \\ 0, & \text{if, } Y_{\text{Min}} \leq Y(t) \leq Y_{\text{Max}} \\ -1, & \text{if, } Y(t) < Y_{\text{Min}} \end{cases} \quad (2)$$

즉,  $Y(t)$ 가 상한값이나 하한값을 넘었는지를 판단하여 센서값을  $-1, 0, +1$ (낮음, 정상, 높음)의 정보로

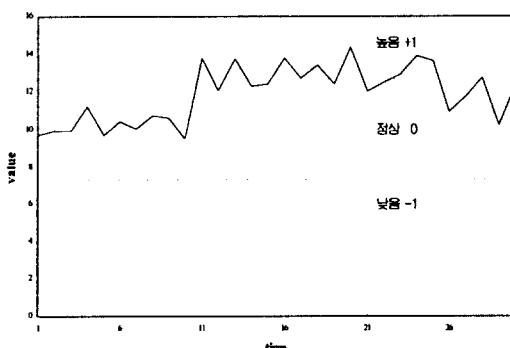


그림 1. 한계점검법

가공하는 방법으로, 적절한 상한값과 하한값의 선정이 매우 중요하게 된다.

한계점검법과 함께 통계적인 방법에 기반한 Shewhart 차트가 널리 사용된다. Shewhart 차트는 원래 통계적인 공정 제어와 품질의 관리를 위하여 제안된 것으로 중심선, 상한선, 하한선의 3개의 선으로 구성되어 있다. 중심선(CL : Center Line)은 목표값, 기준값 또는 평균값을 의미하며, 상한선(UAL : Upper Action Line)과 하한선(LAL : Lower Action Line)은 데이터의 변화를 감지하기 위한 선이다. 이때, 상한선과 하한선은 데이터가 표준 정규 분포를 따른다고 할 경우 표준편차(SD:Standard Deviation)를 기준으로 설정된다.

$$UAL = CL + k \cdot SD$$

$$LAL = CL - k \cdot SD$$

$$(k > 0)$$

표 1. 통계적인 공정 관리를 위한 보조적인 해석 법칙

- (1) 하나의 점이 상.하한값 밖에 있을 경우
- (2) 두개의 연속된 점이 부가된 경고선(warning line)과 인접한 상.하한값 사이에 있을 경우
- (3) 세개의 연속된 점 중 2개의 점이 경고선과 인접한 상.하한값 사이에 있을 경우
- (4) 5개의 연속된 점이  $3 \cdot SD$ 와  $SD$  사이에 있을 경우
- (5) 5개의 연속된 점 중 4개의 점이  $3 \cdot SD$ 와  $SD$  사이에 있을 경우
- (6) 7개의 연속된 점이 중심선의 한편에 치우쳐 있을 경우
- (7) 8개의 연속된 점이 중심선의 한편에 치우쳐 있을 경우

공정 데이터의 상태는 앞서 한계 점검법과 동일하게, 상한을 침범한 경우에는 ‘높음’, 하한을 침범한 경우에는 ‘낮음’으로 표현하며, 상한과 하한 사이에 있는 경우에는 ‘정상’으로 상태를 표현한다. 또한, 상한 하한의 침범여부 이외에도 표 1과 같은 보조적인 법칙들을 사용하여 통계적으로 공정의 데이터를 해석한다. 이때, 상한과 하한은 일반적으로  $k=3$ (즉,  $\pm 3 \times$  표준편차)을 사용한다.

그러나, 이 방법도 정상상태에 기반한 방법으로 화학공정과 같이 동적으로 변동되는 공정에는 적용하기가 어려우며, 한계점검법과 마찬가지로 적절한 상한, 하한을 결정하는 것이 전체의 성능에 막대한 영향을 미치게 된다.

화학공정의 경우 제품의 규격(specification)의 변화, 원료의 변화 등의 요소에 의한 외란(external disturbance)으로 인하여 동적인 거동을 보인다. 예를 들어, 생산량의 증가에 따라 공급량이 증가한 경우를 생각하여 보자(그림 2).

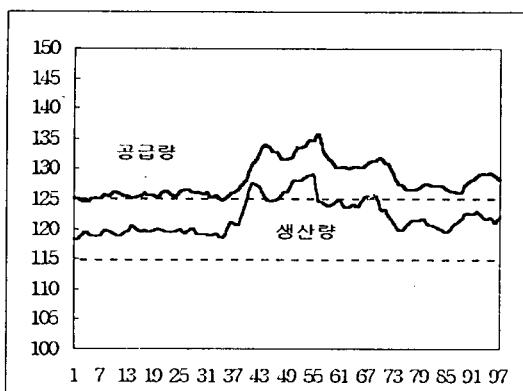


그림 2. 생산량의 증가에 따른 공급량의 변화

이 경우 공정의 상태가 정상임에도 불구하고, 정상상태에 기반한 한계점검법이나 통계적인 공정 제어 방법으로는 이상이 발생하였다고 데이터를 해석하게 된다. 따라서, 이와 같은 동적인 공정의 변화의 경

우에도 적절한 해석이 가능한 해석방법이 요구된다.

## 2.2 정황을 고려한 정성적인 해석

정성적인 해석에 있어서 다층 퍼셉트론과 그로스버그의 ART(Adaptive Resonance Theory) 신경망을 사용하여 해석한 경우(Whiteley, 1994), 시계열 데이터를 7가지의 삼각형 에피소드(triangular episode)로 표현한 경우 등이 연구되었다(Cheng, 1990).

화학공정의 동적 거동을 효과적으로 묘사하기 위하여, 신경망을 응용하여, 다음과 같은 3가지를 만족시키는 정성적인 해석 모듈을 구현하였다.

- ① 정황을 고려할 수 있는 능력
- ② 강력한 패턴 인식 능력
- ③ 패턴의 학습 능력

### 2.2.1 정황(Context) 의존적 해석

정황 의존적인 해석이란 특정 변수의 센서값 이외에 추가적인 정보를 가지고 해석하는 방법을 말한다. 즉, 변수 하나만을 대상으로 상한, 하한의 침범

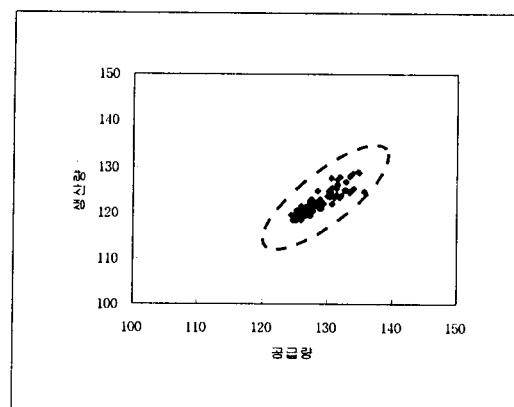


그림 3. 생산량의 변화에 따른 공급량의 변화

여부를 판단하던 방법 대신에 상호 관련이 깊은 변수들의 움직임을 동시에 고려하는 방법을 말한다.

앞서 살펴본 그림 2와 같은 경우를 살펴보자. 공급량과 생산량을 동시에 고려하기 위하여 이를 2차원 평면상에 표시하여 보자(그림 3). 그림에서 볼 수 있는 바와 같이 정상적인 경우에는 일정한 영역에 데이터들이 위치하는 것을 볼 수 있다. 따라서, 이러한 데이터가 존재 가능 영역에서의 패턴 인식을 수행하여 정성적 해석 방법을 구현할 수 있다.

### 2.2.2 신경망을 이용한 패턴 인식

상호 연관성을 가지고 동시에 변화되는 변수들의 패턴을 효과적으로 인식하기 위하여 본 시스템 개발에 있어서 RBF(Radial Basis Function)를 응용한 신경망을 사용하여 정성적인 해석 모듈을 구현하였다.

RBF는 전형적인 신경망과 같이 입력층을 포함한 3개의 층으로 구성되며, 널리 사용되는 다중 퍼셉트론과는 달리 입력값이 연결강도에 의한 가공없이 중간층으로 직접 입력된다(Gomm, 1994). 특히, RBF는 원의 형태로 영역을 구분하므로 직선의 형태로 영역을 구분하는 다중 퍼셉트론과는 달리 효과적인 패턴 인식을 수행하며, 외삽(extrapolation) 오차에 대하여 고려하지 않아도 된다(Leonard, 1990).

본 시스템에서는 RBF 형태의 활성함수로 영역을 구분하며, 새로운 패턴에 대한 클러스터의 할당은 그로스버그의 ART 신경망의 개념을 도입하였다. 이상과 같은 방법으로 공정 데이터로부터 다음과 같은 3가지의 값을 추출하여 이상 진단에 사용하였다.

- ① 상태(status) – 정상(0), 높음(+1), 낮음(-1)
- ② 경향(tendency) – 증가(+1), 감소(-1)
- ③ 시간 지표(time landmark) – 발생 시간

이상을 감지하고 상태값, 경향값, 시간 지표값을

얻기 위한 신경망의 구조는 그림 4와 같다. 이 신경망은 L개의 입력 노드, m개의 중간노드, 그리고 n개의 출력 노드로 구성되어 있다. 입력층에서는 입력노드에 입력된 시간 t에서의 센서값  $I(i, t)$ 이 연결 강도에 의한 가공 없이 중간노드로 직접 입력이 된다. 이때, 중간노드 하나하나는 입력 패턴의 클러스터(cluster)를 의미하며, 입력값에 대한 클러스터링을 수행하게 된다. 또한, 출력층은 클러스터가 포함된 클래스(class)를 의미하게 되며, 클래스는 부하변동, 밸브조작 등 프로세스에서 일어나는 사건(event)을 나타낸다.

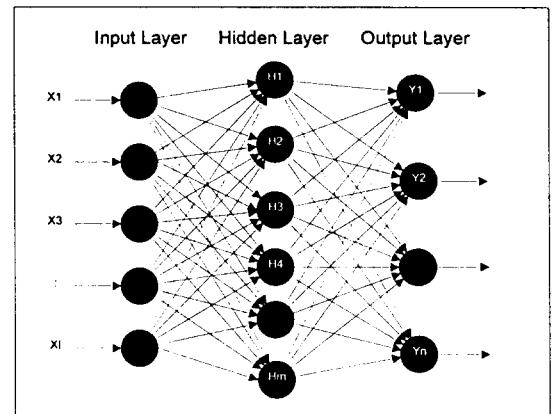


그림 4. RBF 신경망

입력층에서는  $-1$ 과  $+1$  사이의 값으로 정규화하여 입력하지 않고, 각 변수들의 실제 센서 데이터 값이 그대로 입력된다. 이 값들에 대해 입력층에서는 표준편차에 의하여 변수의 스케일(scale)을 조정하는 표준화 작업을 수행한다(그림 5). 이와 같이 표준화된 입력값들은 연결강도에 의한 가공 없이 직접 중간층으로 입력된다.

중간층에서는 입력된 센서값들을 분류하여 클러스터를 생성한다. 일반적으로 중간층의 활성 함수로는 가우스 분포의 확률함수를 사용하지만, 본 시스템에서는 계산상의 편의를 위하여 표준편차의 3배로 설정한 하드리미트(Hard-limit) 형태의 초입방체(hyper-

rcube)를 사용하여 클러스터링을 수행하였다(그림 6).

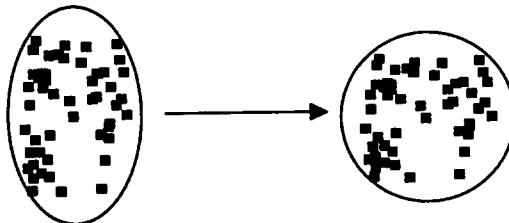


그림 5. 변수의 표준화

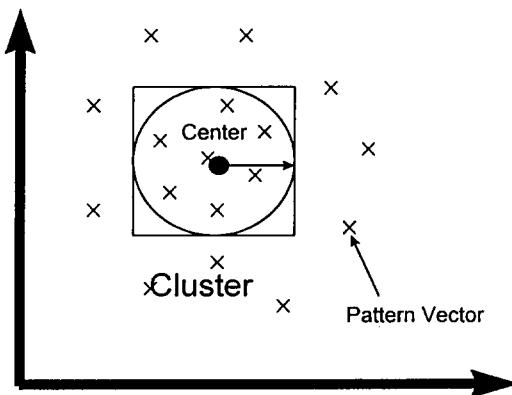


그림 6. 중간층의 클러스터링

중간노드 하나 하나는 서로 다른 패턴을 나타내는 클러스터를 의미하며, 클러스터의 계산은 다음과 같이 수행된다. 어떤 시각  $t$ 에서 입력변수  $i$ 의 값을  $I(i, t)$ 라고 하고 중간층 노드  $k$ 의 출력값을  $H(k)$ 라 하면,

#### 1 단계 : 최대 거리의 계산

$$D_i = \max_{i,t} \left( \frac{|I(i, t) - C_j(i, t)|}{3 \cdot SD_i} \right) \quad (4)$$

여기서  $i=1, 2, \dots, L$  for  $t=1, 2, \dots, R$

$SD_i = i$  번째 변수의 표준 편차

$C_j = j$  번째 중간노드의 중심

$L =$  입력노드의 개수

$R =$  슬라이딩 윈도우의 크기

$D_i =$  표준화된 입력과 중간노드의 중심간의 최대 거리

$C_j$ 는 클러스터의 중심값을 의미하며 입력 변수의 수와 동일한 수의 성분을 가지고 있다.  $SD_i$ 는 변수  $i$ 가 표준정규분포를 따르는 잡음을 가지고 있다고 할 때 잡음이 나타내는 표준편차이다. 따라서,  $D_i$ 는 중간층  $j$ 번째 노드의 성분과 입력층의 성분과의 표준화된 거리 중 가장 먼 거리를 의미한다.

#### 2단계 : 부피의 계산

$$A_i = D_i^L$$

$A_i =$  차원에서의 초기방체의 부피

만일, 일정시간 동안 공정변수들의 값이 기준값  $\pm 3$  SD 안의 값을 유지한다고 하면,  $D_i$ 는 1 보다 작으므로  $A_i$ 도 1 보다 작게 된다.

#### 3단계 : 최소 부피를 갖는 중간 노드 탐색

$$q = \text{Arg}(\min(A_j)), \text{ for } j=1, 2, \dots, M \quad (6)$$

$q =$  최소 부피를 가지는 중간 노드의 인덱스

$$H(q) = \begin{cases} 1, & \text{if } A_q \leq 1 \\ 0, & \text{if } A_q > 1 \end{cases} \quad (7)$$

$$H(j) = 0, \text{ for } j=1, 2, \dots, M (j \neq q)$$

출력층에서, 클래스  $k$ 에 해당하는 출력 노드의 출력은 다음과 같이 결정된다.

$$O(k) = \sum_{j=1}^M W_{kj} H(j) = W_{kq} H(q) \quad (8)$$

여기서,  $W_{kq}$ 는  $k$  번째 출력 노드와  $q$  번째 중간 노드사이의 연결강도를 의미한다.

중간노드에서의 학습은 경쟁에서 승리한 노드만이 학습에 참여하는 Winner-take-all 방식으로 수행된다.

먼저, 식 (4), (5), (6)에 의하여 중간층의 출력을 구한다.  $A_q$ 의 값이 1 보다 큰 경우에는 주어진 입력 값에 해당하는 클러스터가 저장된 패턴에 포함되어 있지 않으므로, 식 (9)에 의하여 중간층의 중심값을 갱신하고 새로운 클러스터를 할당하게 된다. 이는 그로스버그의 ART 신경망에서 사용되는 개념이다. 이때, 새롭게 생성된 클러스터의 중심값은 입력 데이터 값 자체가 된다.

$$C_q(i, t)(p) = C_q(i, t)(p-1) + \alpha_{q(p-1)} \cdot (I(i, t) - C_q(i, t)(p-1)) \quad (9)$$

$$\alpha_q(p) = \alpha_{q(p-1)} \cdot \beta$$

여기서,  $\alpha_q$ 는  $q$  번째 중간 노드의 학습률이며, 다른 중간노드들의 중심값에는 변동이 없다.

$$C_{new}(i, t) = I(i, t) \quad (10)$$

$$\alpha_{new}(0) = \alpha(0)$$

그리고, 클래스  $k$ 와 새롭게 생성된 중간노드와의 연결 강도는 다음과 같이 결정하면 된다.

$$W_{x\_new} = \begin{cases} 1, & \text{if } x=k \\ 0, & \text{if } x \neq k \end{cases} \quad (11)$$

### 2.2.3 경향값의 추출

경향값은 공정의 변수가 증가하고 있는지 감소하고 있는지를 나타내는 값이다. 입력 데이터에 잡음이 없다면 다음과 같은 간단한 식으로부터 경향값을 구해 낼 수 있다.

$$\frac{\partial x}{\partial t} \approx \frac{\Delta x}{\Delta t} = \frac{x_i - x_{i-1}}{\Delta t} \quad (12)$$

그러나, 실제 데이터는 항상 잡음을 가지고 있으므로 위와 같은 간단한 방법으로는 경향을 알 수 없다. 이동창(moving window)의 평균값의 비교나 선형 회귀를 통한 기울기 값을 구하는 방법 등이 제시되었지만, 이들은 모두 이동창의 크기에 민감하다는 단점을 지니고 있다.

본 연구에서는 이상의 감지 부분에서 사용되었던 신경망의 중간층의 학습 방법을 사용하여 경향값을 구하였다.

$$C(t) = \begin{cases} C(t-1) + \alpha(t-1) \cdot (x(t) - C(t-1)) & \text{if } C(t-1) - 3 \cdot SD \leq x(t) \leq C(t-1) \\ + 3 \cdot SD & \\ x(t), & \text{if } x(t) > C(t-1) + 3 \cdot SD \\ \text{or } x(t) < C(t-1) - 3 \cdot SD & \end{cases} \quad (13)$$

이와 같은 방법으로 3.SD안에서 발생한 잡음은 흡수되어 버리고 오직 3.SD범위를 넘어서는 값만이 새로운 클러스터를 생성하게 된다. 변수  $x$ 에 대하여 시각  $t$ 에서의 경향값은 새로운 클러스터가 생성될 때 얻어진다.

$$Tend(x, t) = \begin{cases} +1, & \text{if } C_{new}(t) > C(t-1) \\ -1, & \text{if } C_{new}(t) < C(t-1) \end{cases} \quad (13)$$

데이터 내에 존재하는 극점을 알기 위해서는 경향값들의 차이를 계산해 보면 된다. 다음과 같은 지표를 정의하자.

$$TCDI(x, t) = Tend(x, t) - Tend(x, t-1) \quad (14)$$

여기서 TCDI는 경향 변화 감지 지표(Tendency Change Detection Index)를 의미한다. 만약, TCDI 값이 0이 아니라면 이는 해당되는 변수의 경향이 달라졌음을 의미한다. 처음에는  $Tend(x, 0)=0$ 이 되므로 TCDI가 0이 아닌 경우는 표 2에 표시된 것과 같은 4가지 경우를 의미한다.

표 2. TCDI의 의미

Cases	$Tend(x, t-1)$	$Tend(x, t)$	TCDI	Meaning
1	0	1	1	Increase (initial)
2	0	-1	-1	Decrease (initial)
3	-1	1	2	Increase (extreme pt.)
4	1	-1	-2	Decrease (extreme pt.)

이상과 같은 방법으로 정성적인 해석 모듈은 각각의 공정 변수에 대하여 특정한 시각에서의 상태값과 경향값을 추출하여 이상 진단 모듈로 전달하게 된다.

즉, 입력 데이터를 중간 노드의 클러스터와 비교하여, 만족하는 클러스터가 없다면 이는 공정이 이제까지 학습한 상태에서 벗어난 것을 의미한다. 이 경우에는 상태값이 변화되었음을 감지하고, 감지된

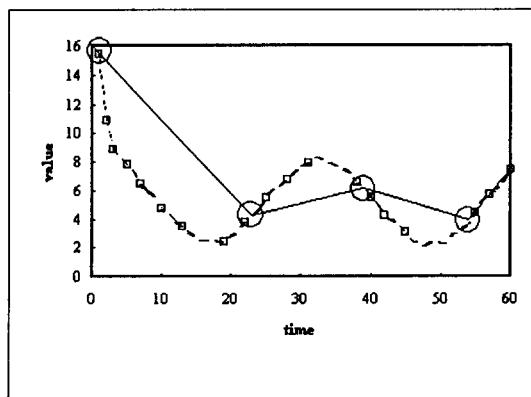


그림 7. 경향값의 추출

데이터에 대하여 경향값을 추출하며, 경향값은 앞서 말한 바와 같이 TCDI를 계산하여 나타낼 수 있다.

간단한 시계열 데이터의 경향값 추출에 대한 예를 그림 7에 나타내었다. 원은 TCDI가 0이 아닌 시간을 의미하며, 점선은 데이터 경향을 간략하게 나타낸 것이다. 만약, 공정 데이터에 잡음이 없다면 정확하게 극점을 추적할 수 있지만, 잡음을 고려하여  $3 \times$  표준 편차로 공정 데이터의 경향을 나타낸 경우이다.

### 3. 유향 그래프를 이용한 지식의 표현

유향 그래프(DiGraph)는 이상 진단을 위한 공정 지식을 간결하며 효율적으로 표현할 수 있는 방법으로 Iri.등에 의해 제안된 부호 유향 그래프(SDG: Signed DiGraph)가 널리 쓰이고 있다(Iri, 1979). 유향 그래프는 공정 변수를 의미하는 노드(Node)와 변수 간의 인과관계를 의미하는 간선/Branch으로 구성되어 있어, 공정에서의 이상 전파를 시각적으로 표현하여 줄 수 있다(그림 8).

본 연구에서는 효율적인 이상 진단을 위하여 기존의 SDG를 개선하여 RCED 모델과 PGTT 모델을 개발하여 사용하였다.

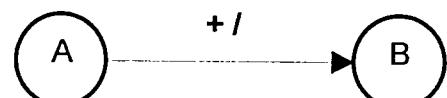


그림 8. 부호유향그래프

#### 3.1 RCED(Reduced Cause Effect Digraph)

RCED는 순서쌍 (R,S,c)로 표현되는데, R은 SDG에서와 동일하게 4개의 인자를 갖는 그래프로 R(N,

$B, i, t$ 로 표현된다. 여기서, 각각은 노드(Node), 간선(Branch), 그리고 시작 노드(initial node)와 종말 노드(terminal node)로 연결시키는 투사함수를 의미하며, SDG에서는 노드에 측정 변수와 미측정 변수를 모두 포함시키는데 비하여 본 연구에서 개발한 RCED에서는 측정 변수만을 포함한다. 순서쌍 ( $R, S, c$ )의 두번째 구성 요소는 RCED의 간선에  $\{+, -, +-\}$ ,  $0\}$ 의 원소 중 하나를 대응시키는 함수를 의미하는데, SDG의 경우에는  $\{+, -\}$ 의 두 가지만이 허용되었지만 RCED에서는 정방향 변화와 부방향 변화의 가능성을 모두 가지고 있는 경우-미측정 변수가 제거될 때 주로 나타남  $-$ 에는  $+-$ 로 표현하였다. 순서쌍의 세번째 구성요소는 간선이 유의하기 위하여 반드시 만족되어야 하는 조건에 대한 함수인데, 이러한 조건은 경험적인 인과 관계상의 변화를 표현하거나 제어상태나 공정의 상태에 따라 인과 관계가 변화하는 경우를 표현하는 경우에 유용하게 사용될 수 있다.

SDG에서 미측정 변수를 제거하여 RCED를 만드는 과정은 다음과 같다(그림 9).

노드  $N_i$ 와  $N_{i+1}$  사이에 간선  $b_1, b_2, \dots, b_n$ 으로 구성된 경로  $P$ —여기서,  $N_i$ 은 시작 노드,  $N_{i+1}$ 은 종말 노드,  $b_i$ 는  $N_i$ 와  $N_{i+1}$  노드 사이의 간선을 의미—가 있을 때, 단지  $N_i$ 와  $N_{i+1}$  노드만이 측정 변수라면 새로운 간선  $b_{new}$ 의 부호는 다음과 같이 계산된다.

```

if      value( $b_1$ )  $\times$  value( $b_2$ ) ...  $\times$  value( $b_n$ ) = +,
then    value( $b_{new}$ ) = +
else    value( $b_{new}$ ) = -.
  
```

그리고,  $N_i$ 와  $N_{i+1}$  사이에 적어도 2가지 이상의 경로가 존재하는 경우에 있어서 경로의 부호가 다를 수 있는데, 이 경우에는  $+-$  값이 할당된다. 이것은 공정의 변수가 증가의 영향과 억제의 영향을 동시에 줄 수 있음을 의미하며, 미측정 변수에 할당된 이상은

가장 근접한 측정 노드로 할당된다. 또한, 모든 간선은 조업 조건에 따른 컨디션에 의하여 할당된 값을 변경시킬 수 있다. 예를 들어, 제어 루프가 변동되거나, 조업 모드가 바뀌어 두 변수간에 인과관계가 없어진 경우에는 해당하는 간선에 0의 값을 할당하여 연결 관계를 제거하여 준다.

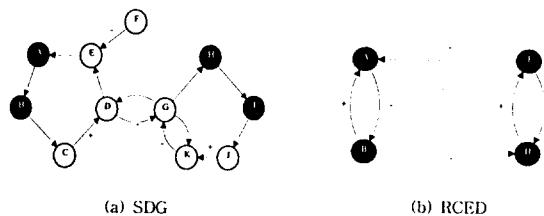


그림 9. SDG와 RCED

### 3.2 PGTT(Pattern Graph Through Time)

PGTT는 순서쌍 ( $P, g$ )으로 구성되는데,  $P$ 는  $[V, A, i, t]$ 로 표현되며, RCED와 유사하게 변수(Variable), 간선(Arc) 그리고, 시작 노드(initial node)와 종말 노드(terminal node)를 사상시키는 투사함수를 의미한다. 즉,  $V$ 는 특정시각에서의 공정의 물리량을,  $A$ 는 물리량간의 인과 관계가 존재함을 나타내며,  $g$ 는  $V$ 를 RCED상의 한 노드로 사상하는 함수이다.

RCED로부터 PGTT를 생성하는 순서는 다음과 같다(그림 10).

- ① RCED의 각 정점에 상태값(Status)을 할당한다.
  - ② 상태값이 0이 아닌 증상을 따로 저장한다.
  - ③ 증상들에 대하여 PGTT의 노드를 생성한다.
  - ④ 증상들의 TCDI를 조사하여 0이 아닌 경우에 PGTT의 노드를 추가한다.
  - ⑤ 추가로 생성된 노드와 과거에 생성된 PGTT 노드들간의 인과관계를 조사하여 인과관계가 만족되면 PGTT 상의 해당 노드에 간선을 추가한다.
- 이상과 같이 생성된 PGTT를 바탕으로 이상의 근본 원인(Root Cause)이 되는 노드를 찾고 여기에 할당된

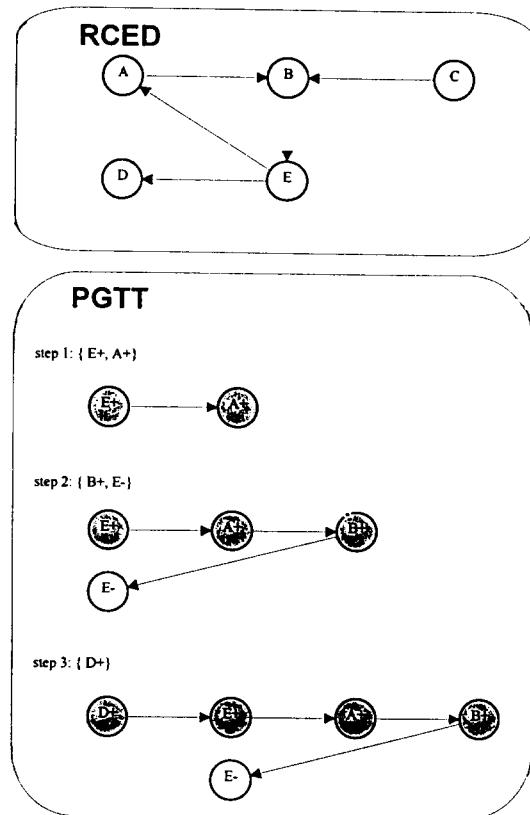


그림 10. RCED와 PGTT

이상 원인을 찾음으로써 이상 진단을 수행하게 된다.

### 3.3 근원 원인의 탐색 (Search of root causes)

이상 진단이란 관측 가능한 증상으로부터 공정 교란의 근본 원인을 찾는 문제이다. 근원원인정점이란 다른 공정 변수들의 변동을 설명할 수 있는 가장 근원이 되는 측정 변수를 의미한다. 그러므로, 진단 이란 PGTT상에서 근원 원인을 찾아내는 문제라고 할 수 있다.

시간  $t_k$ 에서 증상이 일어난 경우 PGTT를 생성하고, 깊이 우선 탐색 기법에 의하여 PGTT 상에서의 생성된 정점들의 연결 관계를 할당한다. 이때, PGTT가

서로 연결되지 않는다면 이 경우에는 한 가지의 이상으로 설명할 수 없으므로, 독립된 서브 그래프 그룹으로 나누어 이상진단을 수행하면 된다. 서브 그래프 그룹들은 서로 독립되어 노드를 공유하지 않게 된다.

근원원인정점을 찾기 위해서는 먼저 강력연결성분 (SCC : strongly connected components)을 탐색하여야 한다. 강력연결성분이란 한 개의 정점 혹은 복수개의 정점으로 이루어질 수 있는데, 서로 밀접한 관계를 가지고 있어서 구분할 수 없는 정점들의 집합을 의미한다(그림 11). 즉, 그림 11과 같은 PGTT에서는 A, B, C 세가지의 강력연결성분을 가지고 있는 셈이 된다. 이때, A의 경우에는 들어오는 화살표가 없으므로 진입차수가 0, 진출차수가 1, B의 경우에는 진입차수 1, 진출차수 1, 그리고 C의 경우에는 진입차수 1, 진출차수가 0이라고 정의한다. 진입차수가 0이라는 의미는 다른 변수들로부터 영향을 받지 않는다는 것으로, 다른 모든 변수들의 변동을 설명할 수 있다는 뜻이다. 이와같이 PGTT 상에서 강력연결성분을 탐색한 후, 진입차수와 진출차수를 조사하여 진입차수가 0인 강력연결 성분을 근원원인정점으로 할당하게 된다.

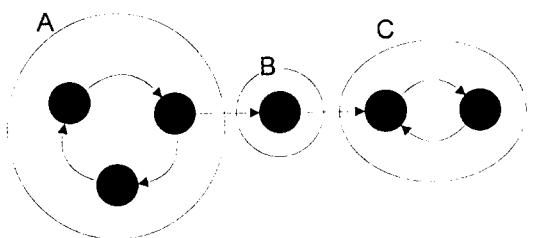


그림 11. 강력연결성분

또한, 공정의 변동이 조업자에 의하여 이루어졌는지를 판단하는 것이 중요하다. 만약, 공정의 변동이 조업자나 미리 계획된 설정점 변경에 의하여 이루어졌다면, 이러한 상황은 비정상 상황이라고 할 수 없

으므로, 조업자에 의하거나 미리 계획된 변경의 경우에는 이를 근원 원인 정점에서 제거해 주어야 한다. 공정에 영향을 미치는 근원원인이 복수인 경우를 생각하여 보자. 조업 조건 변경 중 공급 유량이 감소한 경우 PGTT는 그림 12와 같이 생성되고, 이상의 원인은 Vs-와 Fc-로 진단된다. 이때, Vs-는 정상적인 부하 변동을 의미하지만 Fc-는 이상을 의미하므로, 근원원인을 탐색하여 조업자의 정상적인 개입에 대한 경우는 이를 제거하여 주면 된다.

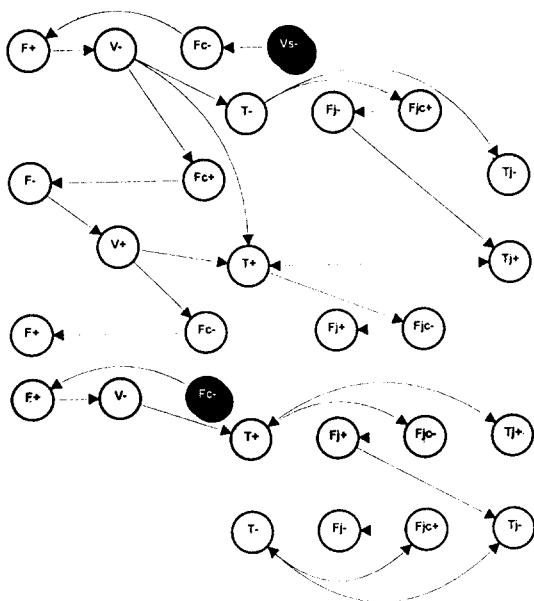


그림 12. 반응기에서 조업 조건 변경 중 Fc-로 인한 PGTT

### 3.4 이상 원인 후보의 제시

RCED의 각 노드에는 해당하는 이상 원인들의 목록들이 연결되어 있으므로, 근원원인정점을 찾아서 이 노드에 연결된 이상원인 목록이 공정에 이상을 일으킨 원인이 된다. 그러나, 미측정 변수를 제거할 때, 이 변수들에 할당된 이상원인들을 측정 변수에 할당하였기 때문에 이상원인 후보가 보통은 하나

이상의 복수로 제시하게 되므로, 공정의 조건을 검사하여 후보들을 검증하는 작업이 필요하게 된다. 이는 해당하는 이상 원인 후보에 공정의 지식을 바탕으로 필요 충분 조건을 할당하여 쓸모없는 해들을 제거할 수 있다.

## 4. 시스템의 개발

### 4.1 공정 개요

이상 설명한 정성적 해석 방법, RCED, PGTT를 기반으로 폴리 프로필렌 공정에 대한 이상 진단 시스템 FINDS/PP(Fault Isolation aNd Detection System/Polypropylene Process)를 개발하였다.

이 공정에는 유동 반응기 등 여러 가지 장치들이 포함되어 있으며, 원료의 정제 부분, 반응을 일으켜 제품을 생산하는 반응기, 생산된 고분자의 처리를 담당하는 부분으로 나누어 볼 수 있다. 프로필렌, 에틸렌과 수소가 원료로 공급되며, 침가제나 안정제의 종류에 따라 약 40여 종류의 폴리프로필렌을 생산하게 된다.

이상진단 시스템의 대상이 되는 부분은 조업의 핵심을 이루는 반응기 부분으로 유동화 반응기와 반응기 내부에서 발생하는 반응열을 제거하기 위한 열교환기, 터빈, 제어기와 밸브, 파이프 등으로 구성되어 있다(그림 13).

공정의 운전에서 가장 중요한 제어 변수는 반응기의 온도이다. 반응기의 온도가 높을 경우에는 반응기 내부의 고분자가 녹아 내리며 정상적인 유동을 방해하고 반응기의 각 부분을 막아버리게 된다. 반응기의 온도는 순환되는 가스를 냉각하는 열교환기의 냉각수 양으로 조절된다. 두 종류의 조축매가 순환 가스와 함께 유입되며, 주축매와의 비율, 조축매

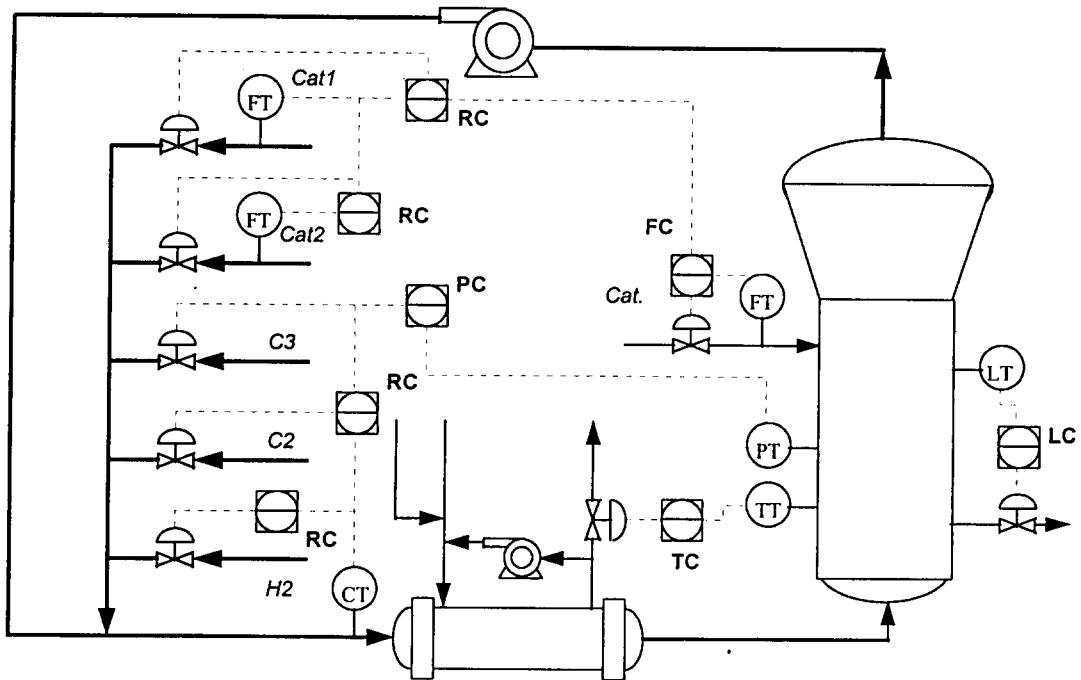


그림 13. 폴리프로필렌 공정

순환 가스의 비율이 제어된다. 주촉매는 반응기 옆의 노즐을 통해 주입된다. 반응기의 내부 압력은 프로필렌의 양으로 조절되며 제품의 사양을 만족시키기 위해서 순환가스의 성분을 분석한 후 에틸렌과 수소의 비율, 프로필렌과 에틸렌의 비율이 제어된다. 반응기의 수위는 유출되는 생성물의 양으로 조절된다.

#### 4.2 시스템의 구현

진단시스템에서 진단을 위한 모델은 조업 전문가와 엔지니어의 지식을 바탕으로 구축되었다. 특히, 유동화 반응기의 경우 동특성이 매우 복잡할 뿐 아니라, 고분자 반응이 진행되므로 이를 정량적으로 묘사하기가 매우 어렵다. 그러므로, 조업자와 현장 엔지니어와의 면담을 토대로 지식 베이스를 구축하였으며, 유동화 반응기의 수학적 모델식에 포함된 지식들도

추가하였다. 이를 토대로 공정의 인과관계를 시각적으로 표현하여 지식 베이스인 RCED 모델을 구축하였다(그림 14). 그림 14에서 **M** 표식은 하나의 공정 변수를 나타내는 것으로 측정 변수를 의미한다. **④** 표식은 노드에 할당된 이상 원인 후보를 저장하는 객체이며, **◎** 표식은 조업자가 1차적으로 영향을 주는 변수임을 의미한다. 마지막으로 **☒** 표식은 프로그램 상의 구현을 위한 링크를 표시하는 것으로 공정의 지식과는 관계가 없다.

그림 15, 16은 F와 O 표식에 해당하는 이상 원인 후보와 조업자에 관련된 객체를 보여주고 있다. 그림 15에서는 hf-sp002와 lf-sp002라는 두 개의 이상 원인 후보가 저장되어 있음을 볼 수 있고, 그림 16에서는 조업자가 일차적으로 영향을 주는 변수들에 대한 추가 정보를 볼 수 있다. 본 시스템에서 고려하는 변수의 수는 83개이며 다루는 이상 원인 후보는 모두

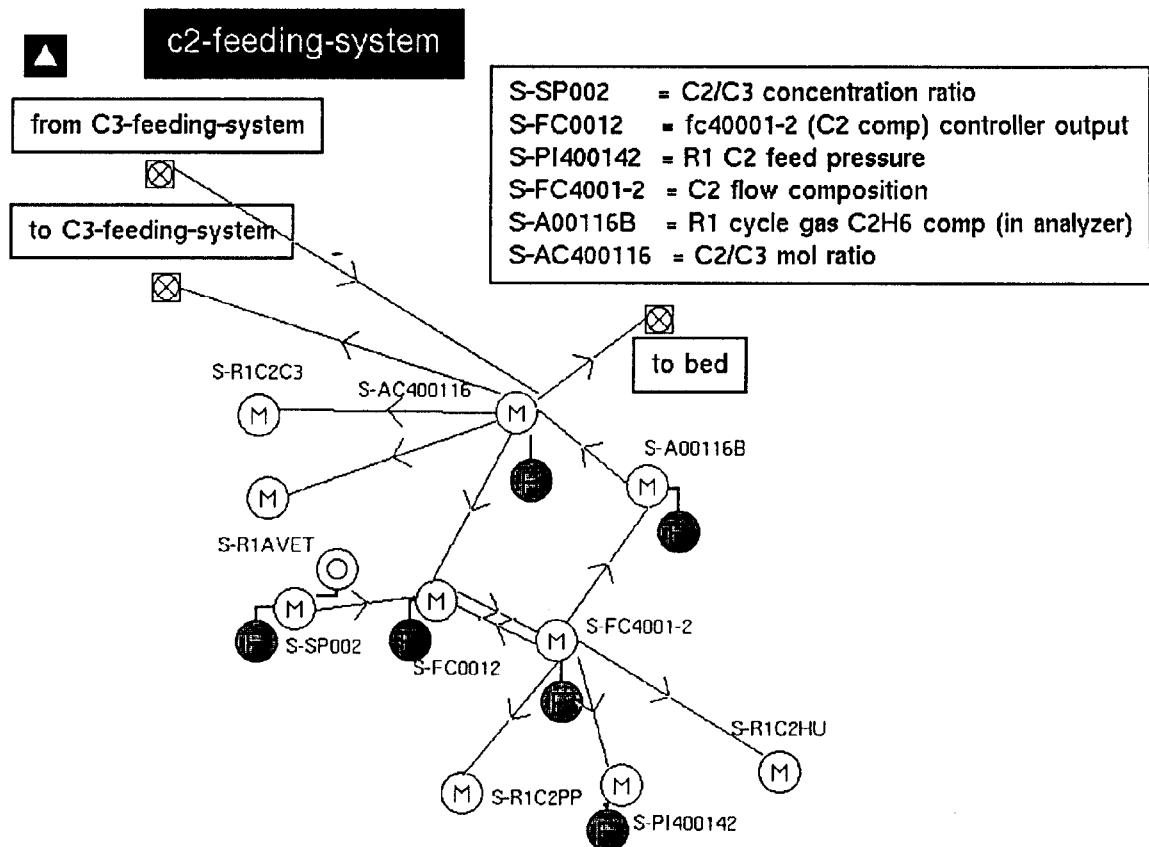


그림 14. PP 공정의 RCED의 예

a fault_origin	
Notes	OK
User restrictions	none
Names	none
Array length	2
Element type	symbol
Initial values	hf-sp002, lf-sp002

그림 15. 이상 원인 객체의 속성표

115개이다. 진단 시스템은 그림 17과 같이 독립적인 계층 구조로 모듈화 되어 있으며, 그림 18과 같은 그래픽 유저 인터페이스를 제공한다. 본 시스템에서는 제어기의 상태, 이상이 발생한 변수, 이상 원인 후보, 이상에 대한 대처 방안 등 각종 정보를 제공하여 조업자가 공정의 상태를 손쉽게 파악하고 필요한 조치를 취할 수 있도록 돋는다.

an operation	
Notes	OK
User restrictions	none
Names	none
Set point	s-sp002
Controlled variable	s-ac400116
Controller output	s-fc0012
Manipulated variable	s-fc4001-2
Operation information	ctrl-sp002

그림 16. 조업자 개입 관련 객체의 속성표

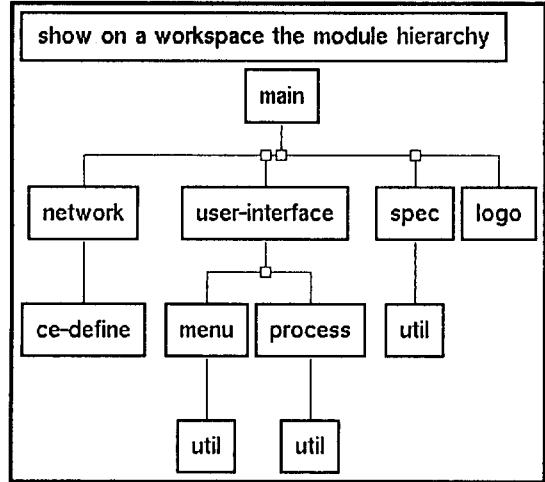


그림 17. FINDS/PP 모듈의 계층 구조

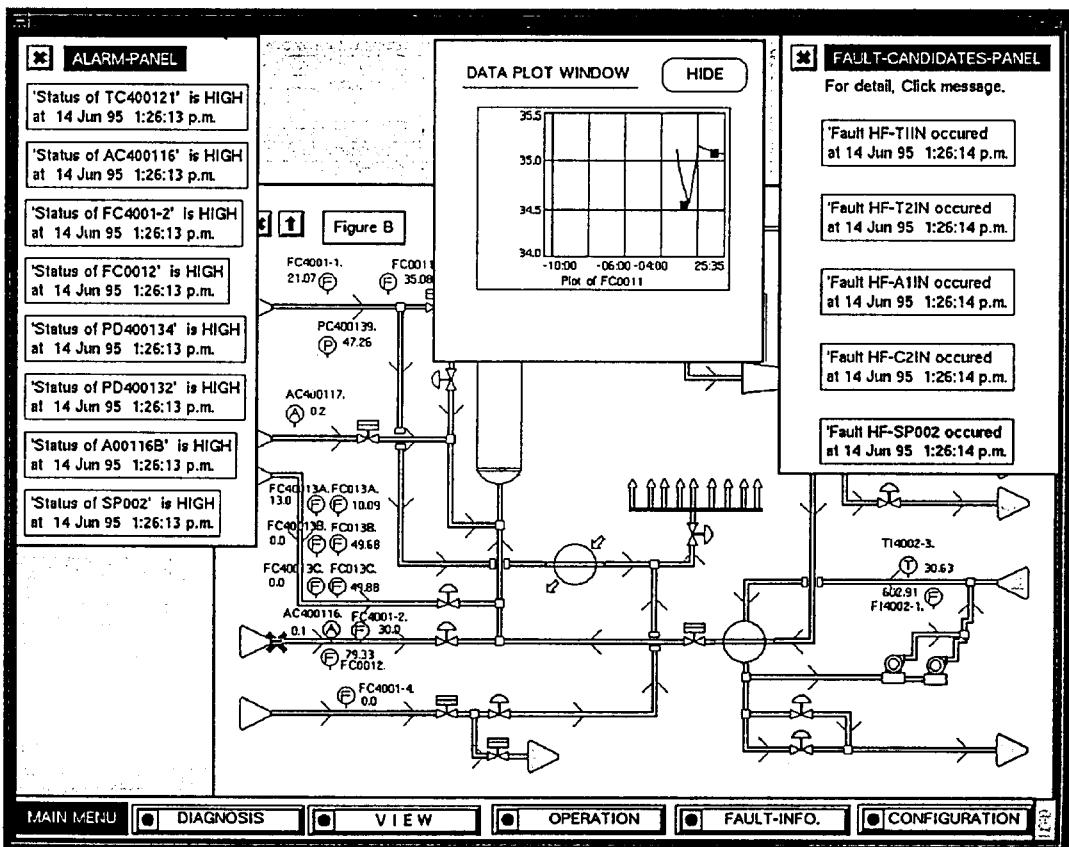


그림 18. 그래픽 유저 인터페이스

## 5. 결 론

폴리프로필렌 공정에 대한 조업 지원 전문가 시스템을 개발하였다. 이를 위하여 동적인 공정을 효과적으로 묘사할 수 있는 정성적인 해석모듈을 구현하고 두 가지의 원인결과 그래프 모델을 개발하여 이상진단모듈을 구현하였다.

동적인 공정 데이터의 정성적인 해석을 위하여 RBF 활성함수와 ART의 개념을 도입한 신경망을 사용하여 강력한 패턴인식 기능, 학습 기능을 가진 정성적 해석 모듈을 구현하였으며, 이상진단을 위하여 측정변수로만으로 구성된 원인결과 그래프 모델인 RCED를 개발하여 PP 공정의 지식베이스를 구축하였다. 구축된 지식베이스를 바탕으로 실시간으로 공정의 증상과 이상 원인을 실시간으로 추적하는 PGTT 모델을 구현하였다. 이를 전문가 시스템 개발 도구인 G2를 사용하여 DEC AlphaStation 상에서 시스템으로 구현하여 폴리프로필렌 공정의 모니터링과 이상 진단을 수행할 수 있는 조업지원시스템 FINDS/PP로 구현하였다. 구현된 시스템의 Off-line 테스트를 통하여 만족할 만한 결과를 얻을 수 있었다.

## 감 사

본 연구를 위하여 연구비를 지원하여 주신 포항공대 공정산업의 지능자동화연구센터(ERC)에 감사드립니다.

## 참 고 문 헌

- 1] Bechart, W.R. et al. "Fault Diagnosis Strategies for Chemical Plants : A Review of Competing technologies", *Proc. of PSE '91, Montebello, Canada*, II 12.1 (1991).
- 2] Chang, C.C., C.C. Yu., "On-Line Fault Diagnosis Using the Signed Directed Graph", *Ind. Eng. Chem. Res.*, **29**, 1290 (1990).
- 3] Cheng J. T.-Y. and G. Stephanopoulos, "Representation of Process Trends-II. The problem of scale and qualitative scaling", *Comput. Chem. Engng.*, **14**, 511 (1990).
- 4] Dvorak, D. and B. Kuipers, "Process Monitoring and Diagnosis : A Model-Based Approach", *IEEE Expert*, **6**, 67 (1991).
- 5] Gomm, J.B., "Self-Learning RBF Neural Network for On-line Process Fault Diagnosis", *5th international Symposium on Process System Engineering*, KyoungJu, Korea (1994).
- 6] Iri, M., K. Aoki, E. O'Shima and H. Matsuyama, "An Algorithm for Diagnosis of System Failures in the Chemical Process," *Comput. Chem. Eng.*, **3**, 489 (1979).
- 7] Isermann, R., "Process Fault Detection Based on Modeling and Estimation Methods-A Survey," *Automatica*, **20**, 387 (1984).
- 8] Kokawa, M., S. Miyazaki, S. Shingai, "Fault Location Using Digraph and Inverse Direction Search with Application", *Automatica*, **19**, 729 (1983).
- 9] Kramer M.A., and B.L. Palowitch, Jr, "A Rule-Based Approach to Fault Diagnosis Using the Signed Directed Graph," *AICHE J.*, **33**, 1067 (1987).
- 10] Leonard, J. and M.A. Kramer, "Radial Basis Function Networks for Classifying Process Faults," *IEEE Control System Magazine*, April, 31 (1991).
- 11] Mohindra, S. and P.A. Clark, "A Distributed Fault Diagnosis Method Based on Digraph Models :

- Steady-State Analysis," *Comput. Chem. Eng.*, **17**, 193 (1993).
- 12] Shiozaki, J., H. Matsuyama, E. O'Shima, M. Iri, "An Improved Algorithm for Diagnosis of System Failures in the Chemical Process", *Comput. Chem. Eng.*, **9**, 285 (1985).
- 13] Tarjan, R. E., "Depth First Search and Linear Graph Algorithms", *SIAM J. Computing*, **1**, 146 (1972).
- 14] Umeda, T., T. Kuriyama, E. O'Shima, H. Matsuyama, "A Graphical Approach to Cause and Effect Analysis of Chemical Processing Systems", *Chem. Eng. Sci.*, **35**, 2379 (1980).
- 15] Whiteley J. R. and J.F. Davis, "Knowledge-based Interpretation of Sensor Patterns", *Comput. Chem. Eng.*, **16**, 329 (1992).
- 16] Whiteley J. R. and J.F. Davis, "A Similarity-Based Approach to Interpretation of Sensor Data Using Adaptive Resonance Theory", *Comput. Chem. Eng.*, **18**, 637 (1994).
- 17] Wilcox, N. A. and D.M. Himmelblau, "The Possible Cause and Effect Graphs (PCEG) Model for Fault Diagnosis-I. Methodology," *Comput. Chem. Eng.*, **18**, 103 (1994).
- 18] Wilcox, N. A. and D.M. Himmelblau, "The Possible Cause and Effect Graphs (PCEG) Model for Fault Diagnosis-II. Application," *Comput. Chem. Eng.*, **18**, 117 (1994).
- 19] Yu, C.C. and C. Lee, "Fault Diagnosis Based on Qualitative/ Quantitative Process Knowledge", *AIChe J.*, **37**, (1991).
- 20] 정창욱, "화학공정의 이상진단을 위한 유향 그래프와 패턴 인식을 이용한 동적모델의 개발", 서울대학교 박사학위 논문, (1994).