

인공 신경 회로망을 이용한 화학공정의 이상진단 시스템

최 병민 윤 여홍 윤 인섭

서울대학교 공과대학 화학공학과

A Fault Diagnostic System for a Chemical Process using Artificial Neural Network

Byung Min Choi, Yeo Hong Yoon, En Sup Yoon

Department of Chemical Engineering

Seoul National University

ABSTRACT

A back-propagation neural network based system for a fault diagnosis of a chemical process is developed. Training data are acquired from FCD(Fault-Consequence Digraph) model. To improve the resolution of a diagnosis, the system is decomposed into 6 subsystems and the training data are composed of 0,1 and intermediate values. The feasibility of this approach is tested through case studies in a real plant, a naphtha furnace, which has been used to develop a knowledge based expert system, OASYS (Operation Aiding expert SYStem).

1. 서 론

화학공장의 규모가 커지고 공정이 복잡해짐에 따라 이상 발생에 따른 신속하고 정확한 대응에의 필요성이 증대되고 있다. 공장의 경보가 작동했을 때 그 원인을 탐색하기 위하여 조업자가 사용하고 있는 정보는 정보의 종류, 상호관련된 공정변수들의 값, 조업자의 공정에 대한 지식등이 있다. 즉 실제 조업하에서 조업자들은 각각 나름대로의 경험법칙(heuristic)과 물리적인 인파관계를 기반으로 공정의 경보에 대해 그 원인을 추론하고 대책을 수립하게 된다. 그러나 이런 경우 작업교대, 조업자의 변동, 휴가등의 이유로 조업자마다 추론을 달리할 수 있고 스트레스, 피로, 태만등과 불완전한 기억력으로 인하여 부정확한 추론을 할 수 있다. 따라서 컴퓨터를 이용한 공정의 감시와 이상진단이 필요하게 되었다. 이상진단 시스템을 구현하기 위해서는 수치데이터 뿐만 아니라 공정에 대한 지식 데이터가 필요하고 이것을 처리하기 위한 추론 능력도 필요하게 된다. 이와 같은 필요에 의하여 인공지능의 한 분야인 전문가 시스템을 공정의 이상진단에 응용

하려는 연구가 시작되었다.

이상진단 전문가 시스템에 필요한 지식기반을 구현하기 위한 지식 모델로서는 경험법칙을 계층구조로 나타낸 모델[6], 공정변수 상호간의 관계를 나타낸 SDG(Signed Directed Graph)를 이용한 모델[5], FCD(Fault Consequence Digraph)를 이용한 모델[10], Diagnostic Model Processor를 이용하는 방법[7], Artificial Neural Network를 이용하는 방법[3,4,8]등이 있다.

본 연구에서는 서울대학교에서 개발된 OASYS(Operation Aiding expert SYStem)[10]에서 지식 표현 방법으로 사용되고 있는 FCD를 이용하므로써, 납사 분해로의 이상 진파 유향을 BPN(Back-Propagation Network)[1,2,9]을 통하여 학습하여 이상진단에 이용하는 방법을 제시하였다.

2. 인공 신경 회로망(Artificial Neural Network)

(1) 연구배경 및 목적

인공 신경 회로망에 대한 연구는 인간 신경의 구조를 모방하여 그와 유사한 작용을 하게 하려는 의도에서 시작되었다. 실제로 일련의 자연적인 상황(화상이나 음성의 인식 등)을 인식하고 판단을 내리는 경우 인간의 두뇌는 컴퓨터보다 빠르다. 이는 기존의 컴퓨터가 수학적인 계산에 적합한 반면 인간의 신경은 병렬적인 구조를 가지고 있기 때문으로 알려져 있다.

이러한 연구는 hardware의 측면에서 neural computer를 개발하려는 방향과 함께 화상 문자 음성등의 인식, 로보트의 제어등에 그 이론이 응용되어 좋은 결과들을 보여주고 있다. 특히 근래에는 화학공학에 있어서의 dynamic modeling, sensor data interpretation, 이상진단등에 대한 연구가 활발히 진행되고 있는 중이다.

인공 신경 회로망은 기본적으로 주어진 문제의 처리속도

가 빠르며, 약간의 오란이 있어도 일관성 있는 결과를 얻을 수 있고, 변화하는 상황에의 적응성이 매우 좋다는 장점을 가지고 있다.

이러한 방법을 이상 진단에 적용한다면 위에서 지적한 장점들 이외에 다음과 같은 잇점을 얻을 수 있을 것으로 생각된다.

1. 방대한 지식베이스를 필요로 하지 않으므로 빠른 진단결과를 얻을 수 있다.
2. 구성이 매우 용이하며, 학습데이터의 변화만으로 타 공정에의 적용이 가능하다.
3. Sensor data를 추상화 하므로써 발생하는 정보의 유실을 방지할 수 있다.
4. 공정의 변화에 따른 적응이 용이하다.
5. 다중이상의 진단이 가능하다.[8]

따라서 본 연구를 통하여 인공신경회로망을 납사분해로의 이상진단에 이용 하므로써 진단을 고속화하고, 아울러 위에서 열거된 여러가지 장점들을 효과적으로 활용하고자 한다. 또한 시스템의 분할과 학습데이터 구성의 변화를 통하여 크고 복잡한 공정에의 적용 가능성을 검討해보고자 한다.

(2) BPN(Back Propagation Network)

인공 신경 회로망은 학습(learning)을 통하여 주어진 문제의 패턴을 인식하므로써 문제를 해결한다. 그 분류기준에는 여러가지가 있으나 학습 방법과 학습 데이터의 구성에 따라 그림 1과 같이 분류할 수 있다.

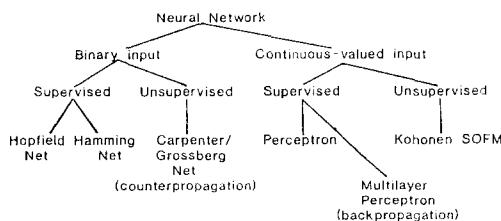


그림 1 인공 신경 회로망의 분류

이상 진단의 경우 증상과 이상원인의 관계에 의하여 학습데이터를 작성하여야 하며 공정 데이터가 연속적인 값을 가지므로 BPN을 사용하는 것이 가능하다.

일반적인 BPN의 구조는 그림 2와 같이 input, hidden, output layer로 구성되며 각 layer는 여러개의 node로 구성되어 있다. 본 연구에서는 3 layer로 구성된 BPN을 사용하여 학습을 실행하였다.

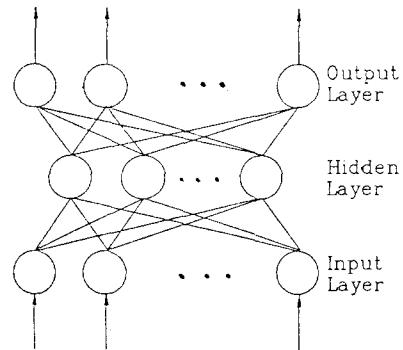


그림 2 3 layer Back-Propagation Network

3. 나프타 분해로 이상진단 시스템 구현

(1) 나프타 분해로(Naphtha Furnace)

나프타 분해로 공정은 물질 흐름상 크게 세부분, 나프타와 회석 스텁(dilution steam)이 섞여 고온에서 열분해되어 에틸렌등의 생산물을 만드는 원료-생성물 흐름부분, 연료가스(fuel gas)를 연소시켜 나프타 분해로의 열원으로 공급하는 부분과 에틸렌등의 생성물을 급냉하기 위해서 BFW(Boiling Feed Water)를 공급하는 부분으로 구성되어 있다. 물질을 공급하는 부분들은 각각의 흐름을 제어하기 위한 DCS(Distributed Control System)이 부착되어 있고 제어 변수와 중요 변수들의 관계를 모델링하여 각 제어기의 setpoint를 내려주는 DMC(Dynamic Matrix Control)가 연결되어 있다. 장치적으로 분해로 공정을 나누어보면 분해로, 나프타 펌프, ID FAN, BFW펌프, 스텁 드럼(steam drum), 제어기등으로 구성되어 있으며, 분해로 자체는 여러개의 열교환기와 같은 역할을 하며 생성물의 열원을 제거하기 위하여 BFW, 스텁 드럼부분이 사용된다. 나프타 분해로 공정 자체가 여러개의 열교환기로 모델링될 수 있고 제어 구조도 DCS와 DMC가 같이 부착되어 있기 때문에 변수들의 관계가 어떤 다른 공정보다 복잡하게 된다.

(2) 시스템의 분할

나프타 분해로에서 발생하는 이상에 의해 나타나는 증상들은 측정기(sensor)로 부터 컴퓨터로 들어오는 정보를 이용하여 표현될 수 있다. 실제 분해로 공정에서 컴퓨터로 입력되는 공정 변수는 75개 인데 이외에 제어기 상에서 계산되는 변수 38개를 합쳐서 총 113개이다. 이 113개의 변수에 대해 높고 낮은 두 상태를 가지므로 모두 226개의 증상이 사용되며 이를 통하여 진단할 수 있는 314개의 원인 후보를 설정하였다. 이와 같은 경우 1개의 인공 신경 회로망으로 시스템

을 구성하여 이상 원인을 찾아내는 것은 매우 어렵다. 따라서 본 연구에서는 314개의 이상원인 후보를 6개의 BPN으로 나누어 진단하는 방법을 이용하였다. 각각의 BPN은 3 layer로 구성되어 있으며 그 구조는 표 1과 같다. Input은 각 증상의 존재를 표시하며 output은 이상의 발생 여부를 나타낸다. 같은 증상이 나타나는 이상이 존재하므로 fault의 숫자가 output보다 많아질 수 있으며 hidden layer의 node수는 여러 번의 학습을 통하여 가장 선명성이 높은 것을 채택하였다.

표 1 시스템의 구성 (No. of nodes)

	input	hidden	output	faults
1st	27	50	18	29
2nd	32	90	28	40
3rd	25	50	18	60
4th	24	35	8	108
5th	50	60	10	10
6th	16	16	16	67

위와 같이 시스템을 분할하여 구성함에 있어서 가능한한 같은 증상들이 빈번되어 사용되지 않도록 하며, 같은 증상 패턴을 나타내는 증상은 1번만 학습하여 그 결과를 반복하여 이용하도록 하므로써 전체구조를 최소화하였다.

(3) 학습데이터의 구성 및 학습

학습데이터의 구성을 위하여 납사 분해로를 대상으로 하여 작성된 FCD를 이용하였다. FCD모델의 특성은 다음과 같이 요약될 수 있다.[10]

- .인과관계를 거시적으로 파악하는 이상전파 모델이다.
- .모델 개발시 미측정 변수가 필요없다.
- .증상패턴이 실질적이며 독특(unique)하므로 진단의 선명성이 증대된다.
- .반대방향의 feedback응답에 대한 실용화된 증상패턴을 표현한다.
- .인과관계가 분명히 표현되어 좋은 설명기능을 제공하고 있다.
- .작성이 용이하고 경험적 지식(experiential knowledge)을 함께 표현하기 쉽다.

그러나 완전한 전파 유향을 모두 이용할 경우 학습이 매우 어려워지므로 FCD의 앞부분에 나타나는 4-7개의 증상만으로 학습데이터를 구성하였다. 즉 f1이라는 이상이 발생하여 초기에 4개의 증상들이 A,B,C,D의 순서를 가지고 진행된다면 학습데이터는 다음과 같이 구성될 수 있다.

case 1

A	B	C	D	f1	f2
1	1	1	1	1	0

위와 같은 방법으로 학습데이터를 구성하는 경우 시스템의 분할에 의하여 발생하는 선명성의 저하를 피할 수 없다는 점과 증상의 발생순서를 고려할 수 없다는 단점을 지니게 된다. 이 경우 증상의 전파순서를 모두 고려하는 방법을 생각해 볼 수 있다. 즉 다음과 같은 학습데이터가 구성된다.

case 2

A	B	C	D	f1	f2
1	0	0	0	1	0
1	1	0	0	1	0
1	1	1	0	1	0
1	1	1	1	1	0

그러나 이 경우에도 선명성의 저하문제는 남게되며, 큰 공정에 적용할 경우 학습데이터의 양이 방대해지므로써 학습이 매우 어려워진다. 따라서 본 연구에서는 다음과 같은 학습데이터를 작성하여 학습하였다.

case 3

A	B	C	D	f1	f2
0.5	0.5	0	0	0.8	0
1	1	1	1	1	0

위와 같이 하나의 이상원인에 대하여 두 단계의 학습데이터를 작성하므로써 얻을 수 있는 효과는

.이상원인을 초기에 진단한다.

.분할된 시스템으로부터 어느정도 일정한 output을

얻으므로써 진단의 선명성을 높힐 수 있다.

.같은 증상이 두 가지 이상원인에 공통으로 나타나는 경우 증상이 먼저 나타나는 이상원인에 가중치가 주어지므로써 증상의 전파순서를 고려할 수 있다.

등이다.

학습 프로그램은 'C' 언어를 이용하여 구현하였으며, 학습은 IBM-PC와 SUN-IV를 사용하여 이루어졌다.

(4) 시스템의 작동

기존의 이상진단 시스템은 대부분 일정한 경계치를 벗어나는 공정 변수를 증상으로 이용하는 추상화(abstraction)를 통하여 공정의 정보를 활용하도록 하므로써 실제 공정에서

경계치를 설정하기가 어려울 뿐만 아니라 많은 정보를 잃어 버릴 위험성이 있다. 인공 신경 회로망을 이용하는 경우 연속적(continuous)인 입력값을 사용할 수 있으므로 그림 3과 같이 sigmoid형태의 함수를 통하여 측정기(sensor)의 정보를 0에서 1 사이의 값으로 표준화(normalize)하여 입력할 수 있다. 측정 변수가 감소하는 증상을 나타내는 경우에도 절대값을 이용하여 그림 3과 같이 나타낼 수 있다.

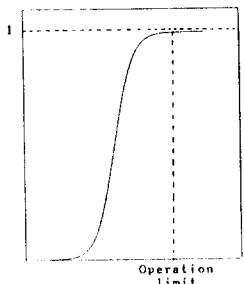


그림 3 Sigmoid 함수

이 방법으로 공정에 약간의 noise가 있어도 안정된 진단 결과를 얻을 수 있으며 operation limit에 가까이 다가감에 따라 가중치가 적용되어 진단의 선명성을 높힐 수 있고, 측정기의 정보를 충분히 활용하므로써 추상화를 통한 공정 정보의 유실을 막을 수 있다.

즉 그림 3과 같은 함수를 통하여 0에서 1사이의 값으로 표준화되어 각 BPN의 입력값으로 사용되며, 출력값은 sorting을 하여 이상 원인 후보의 이름과 함께 표시하게 된다.

4. 결론 및 제안

본 연구에서는 나프타 분해로를 대상공정으로 314개의 이상을 정의하고, 이상원인후보를 대상으로 작성된 FCD를 이용하여 인공신경 회로망을 통한 이상진단 시스템을 구현하였다. 또한 크고 복잡한 공정에의 적용을 위하여 시스템을 분할하여 구성하고 그에 따라 발생할 수 있는 선명성 저하의 문제를 학습데이터의 2단계 구성을 통하여 해결하므로써 대규모 화학공정에도 그 적용이 가능함을 확인하였다. 그 결과 실제 사고사례와 가상 사고사례에 대하여 고장의 발생 초기에 실제 예상되는 이상원인을 신속히 찾아내는데 성공하였다.

이와같이 인공 신경회로망을 이용하여 진단의 고속화, 진단 시스템의 용이한 구성 및 확장, 타 공정에의 손쉬운 확장, 다중 이상의 진단등의 이점을 얻을 수 있는 반면에 다음과 같은 문제점에 대한 연구가 필요하다.

1. 제어에 따른 반대 증상 발생의 표현
2. 인과관계를 이용한 설명기능을 이용할 수 없다는 점
3. 이상 전파에 의해 나타나는 증상을 부분적으로 사용하여야 하는 점

특히 2번과 같은 문제는 인공 신경 회로망이 가지고 있는 근본적인 문제점이므로 기존의 이상 진단 전문가 시스템이 제공하는 기능을 효과적으로 사용할 수 있는 방법이 고려되어야 할 것이다. 따라서 현재 기존의 OASYS의 장점과 인공 신경 회로망을 이용하여 구현된 시스템의 장점을 상호 보완적으로 사용할 수 있도록 하는 연구가 진행중이다.

개발된 이상진단 시스템은 실시간 공정에서 이상의 원인을 신속하고 정확하게 찾아낼 수 있으며, 이에 따라 조업성 향상에 기여할 수 있다.

감사

본 연구의 수행을 위하여 연구비를 지원하여 준 (주)유공에 감사드리며, 공정에 대한 지식과 경험을 제공해 준 NCC (Naphtha Cracking Center) hot section을 담당하는 여러분들과 공정에 대한 자료와 제어 구조에 대한 정보를 제공해 준 제어부 여러분들께 감사드립니다.

참고 문헌

1. D. E. Rumelhart, J. L. McClelland and the PDP Research Group, "Parallel Distributed Processing. vol. 1", MIT Press, 1986
2. D. E. Rumelhart and J. L. McClelland, "Explorations in Parallel Distributed Processing", MIT Press, 1988
3. J. C. Hoskins and D. M. Himmelblau, "Artificial Neural Network Models of Knowledge Representation in chemical Engineering", Comput. Chem. Engng., Vol. 12, No.9, 1988
4. K. Watanabe, I. Matsuura, M. Abe, M. Kubota and D. M. Himmelblau, "Incipient Fault Diagnosis of Chemical Processes via Artificial Neural Network", AIChE J., Vol.35, No.11, 1989
5. M. A. Kramer and B. L. Palowitch, "A rule-based Approach to Fault Diagnosis Using the Signed Directed Graph", AIChE J., Vol.33, No.7, 1987
6. S. K. Shum, J. F. Davis, W. F. Punch and B. Chandrasekaran, "An Expert System Approach to Malfunction Diagnosis in Chemical Plants", Comput. Chem. Engng., Vol.12, No.1, 1988
7. T. F. Petti, J. Klein and P. S. Dhurjati, "Diagnostic Model Processor: Using Deep Knowledge for Process Fault Diagnosis", AIChE J., Vol.36, No.4, 1990
8. V. Venkatasubramanian and K. Chan, "A Neural Network Methodology for Process Fault Diagnosis", AIChE J., Vol.35, No.12, 1989
9. Y. H. Pao, "Adaptive Pattern Recognition and Neural Networks", Addison-Wesley, 1989
10. 오천근, "증상트리와 이상전파유향그래프를 이용한 공정 이상진단 전문가 시스템 연구", 박사학위논문, 서울대학교, 1990