

## 인공신경회로망을 응용한 고로조업지원 전문가 시스템 연구

최태화 · 윤인섭\*

산업과학기술연구소 제철연구부

\*서울대학교 공과대학 화학공학과

(1990년 10월 17일 접수, 1991년 3월 15일 채택)

## An Expert System to Aid Blast Furnace Operation Using Artificial Neural Network Techniques

Tae Hwa Choi and En Sup Yoon\*

*Ironmaking Department, Research Institute of Industrial Science & Technology*

*\*Dep. of Chem. Eng., College of Engineering, Seoul National University*

(Received 17 October 1990; accepted 15 March 1991)

### 요 약

철을 생산하는 일관제철소의 고로공정을 대상으로 조업지원을 위한 전문가 시스템을 개발하였다. 본 연구에서는 종래의 규칙기반 전문가 시스템이 가지고 있는 자체 학습능력의 미흡이나 지식표현 등의 문제점을 극복하고자 인공신경회로망을 응용한 노황이상진단방법을 제시하였다. 진단의 선명성 향상과 여러 가지 이상상태의 진단에 대처하는 진단의 강건성을 높이기 위해 고로에 설치된 각종 sensor data를 전처리하여 사용하였다. 이상진단을 위해 입력층, 중간층, 출력층이 있는 3층으로 된 back-propagation type의 인공신경회로망을 구성하였다. 진단의 구조는 우선 노황의 이상유무를 판정하고 이상이 있으면 그 종류에 따라 구체적인 진단을 하는 계층구조로 구성하여 신속하고 정확한 진단을 할 수 있게 하였다. 진단결과인 노황이상의 종류와 진행정도에 따라 조업실적 분석결과를 근거로 마련한 action guidance를 CRT화면을 통해 제시하였다. 과거 이상현상이 발생했던 전후의 조업 data를 사용한 본 시스템에 의한 진단결과와 그 당시의 조업정위를 비교해 보았다. 노황의 점진적인 변화로 인해 조업자는 초기의 이상상태를 인식하지 못하고 아무런 조치를 취하지 않은 반면에 본 전문가 시스템은 초기에 이상상태를 잘 파악하여 적절한 action을 제시하였다.

**Abstract**—An expert system has been developed to support blast furnace operations in the integrated iron and steelmaking works. In the present study, a technique to diagnose furnace abnormality, using the artificial neural network, is proposed to overcome problems of the conventional rule-based expert system, such as lack of in-system automatic regulation and the limits of knowledge expression, etc. In order to enhance diagnostic resolution and robustness to counteract various furnace abnormalities, the data acquired by several sensors installed in the blast furnace were pretreated before using them as input sources for diagnosis. For the diagnosis of abnormal conditions, back-propagation type of artificial neural networks were constructed, which consist of input, hidden and output layers. Diagnostic procedures are structured hierarchically, that is, first the diagnostic network finds the abnormal conditions and then carries out a detailed diagnosis according to the type of abnormality. In this study, an action guidance is suggested through the analysis of actual operation results according to the type and progress of the abnormal conditions. The expert system

was tested using the operation data obtained from the abnormalities in a real blast furnace. Without the expert system, the operator could not recognize the initial irregularity due to the gradual change of furnace conditions. On the other hand the expert system could find the initial furnace abnormality and suggested appropriate counteractions.

## 1. 서 론

근래에 인공지능기술의 발달과 함께 지식기반 전문가 시스템에 의한 공정공학상의 여러 가지 어려운 문제들을 해결하려는 많은 연구가 활발히 진행되어 왔다. 우선 plant 운전지원을 위한 전문가 시스템의 한 예로서 adipic acid convertor를 대상으로 한 전문가 시스템(FALCON)은 on-line상에서 plant를 상시 감시하여 그 상황을 판단하고 필요에 따라 이상진단이나 대책을 지원하는 목적으로 개발되었다. 또한 cement kiln제어 전문가 시스템(LINKman)이나 jacket형 batch식 반응기의 지적 온도제어 전문가 시스템은 fuzzy제어나 PID parameter의 자동수정 및 plant의 상황에 따라 제어방식을 결정하는 plant의 지적 제어방식으로 개발된 바 있다. 그 밖에 plant의 운전계획이나 plant설계 및 제어제 설계 지원을 위한 여러 가지 전문가 시스템이 소개된 바 있다 [2].

공정문제를 다루는 전문가 시스템은 다른 응용분야의 영역(domain)에 비해 매우 크고 복잡하다. 특히 공정 상태가 동적으로 변화함으로 이상상태를 진단하는 기준을 마련하는 것이 어려운 문제가 된다. 그리고 지식의 양이 방대하여지고 on-line상에서 운용이 되어야 하는 경우에는 추론시간의 제약도 받게 된다.

공정의 이상진단을 위한 전문가 시스템은 대부분은 경험적 지식접근법(experiential knowledge approach)이나 모델기반 접근법(model-based approach)에 의해 문제를 해결하고자 하였다. 또한 지식표현을 위해 규칙(rule), 프레임(frame), 객체 지향 프로그래밍(object oriented programming) 등을 이용하여 실제 전문가 시스템의 구현에 관련된 문제들을 해결하고자 하였다[8, 10, 13, 15].

그러나 종래의 지식기반 전문가 시스템은 수행능력의 증대를 위한 자체의 학습이나 동적 변화에 대응하기 위한 능력이 아직 미흡하다. 그리고 크고 복잡한 시스템에서는 정확한 수학적인 모델을 구하기가 어렵고 지식수집이나 표현이 용이하지 않다. 특히 규칙기반 전문가 시스템의 경우 근본적으로 명시적인 규칙(explicit rule)을 필요로 한다. 그러나 대부분의 인간지식은 암시적(implicit)인 것이 많다. 전문지식인 경우에는 더욱 그러하다. 일반적으로 암시적인 지식은 쉽게 말이나

글로써 표현될 수 없고 명시적인 방법으로 형식화하기가 어렵다. 즉, 이는 지식이 암시적인 문제의 영역(domain)에서는 판단 rule의 정확하고 구체적인 표현이 어렵다는 것을 의미한다. 더욱이 지식의 습득단계에서 암시적인 지식을 명시적인 rule형태로 변환할 때 결정적인 정보를 유실할 수 있다. 그러므로 이러한 rule-based 전문가 시스템에서 지식공학자(knowledge engineer)는 문제 영역 전문가의 사고과정을 철저히 이해하여 지식 base를 구축해야 한다. 그러나 이들 전문가는 그들 자신의 정보가공에서 사용된 암시적인 구조를 말이나 글로 표현하지 못하고 지식공학자에게 개인적인 관점에서 이해되길 원하는 경우가 있다. 이러한 방식으로 지식 base를 구축하는 경우에는 많은 시간과 노력이 요구된다.

본 연구의 대상공정인 철을 생산하는 제철소의 고로 공정은 복잡한 노내의 상황으로 인해 수학적 모델의 한계성이 있기 때문에 수치해석에 의한 제어방식보다는 아직까지 대부분 경험에 의존한 조업이 이루어지고 있다. 그러나 최근 인공지능 기술의 발전으로 지식공학(knowledge engineering) 방법에 의한 고로 조업지원 전문가 시스템의 연구가 활발히 진행되고 있으며 실제 공정에 응용되는 사례가 있다[20]. 종래의 지식기반 방식에 의한 이들 전문가 시스템이 실제 조업에서 유용하게 사용되기 위해서는 앞에서 언급한 여러 가지 문제점들이 해소되어야 한다.

본 연구에서는 지식공학적 방법에 의한 공정의 이상 진단에서 이러한 문제들을 극복하기 위한 방안으로 인공신경회로망을 응용하였다. 인공신경회로망은 예제의 입력과 출력의 상관관계를 학습하여 이들의 관계를 일반화한다. 이러한 학습후에 인공신경회로망은 새로운 입력에 대해 적절한 출력을 발생시킨다. 인공신경회로망에 의한 공정이상 진단방법은 최근에 화학공장을 대상으로 off-line상태에서만 일부 시도가 되고 있으나 본 연구에서는 고로노화 이상진단(diagnosis of blast furnace abnormality)을 위한 on-line상의 실제 공정에 응용하여 그 타당성을 검토하였다.

## 2. 인공신경회로망

### 2-1. 인공신경회로망의 개요

인공신경회로망은 패턴들의 유사성을 인식함으로써 학습과정을 단순화하기 위해 패턴들을 부분적인 군으로 분리할 수 있다. 이러한 data의 압축능력은 많은 훈련 샘플이 요구될 때 중요하다. 각 군은 unique하며 각 군들은 전체적으로 동등하게 받아들여진다. 이것은 사용자가 결과의 질을 절충하거나 타협함이 없이 보다 넓은 공정범위를 받아들일 수 있게 한다. 또한 인공신경회로망은 불완전한 입력을 완전한 패턴으로 재구성하는데도 사용될 수 있다. 예를 들어 인공신경회로망은 화상분석을 통해 부분적으로 오염된 부분을 밝혀 낼 수 있다. 공정제어, 진단, 의사결정 등은 이러한 능력이 탁월하게 잘 적용될 수 있는 분야이다. 제어에 응용되는 인공신경회로망은 적응제어(adaptive control)와 같이 시스템모델을 배운다. 진단에 응용되는 인공신경회로망은 증상과 그 원인과의 관계를 밝혀내고 상관분석한다. 즉 인공신경회로망은 주어진 상황의 인과관계를 학습하여 문제를 해결한다. 인공신경회로망은 알려진 입력값을 출력값으로 변경시키는 수학적인 사상을 계산하여 문제를 학습한다. 이러한 반복적인 학습은 입력과 출력의 사상이 허용오차 범위내에 도달될 때까지 계속한다. 일단 인공신경회로망이 훈련이 되면 문제를 해결하기 위한 준비가 된다. 새로운 입력값이 제시되면 적절한 출력값을 발생시킨다.

화학공정의 이상진단을 위해 인공신경회로망을 응용한 연구가 최근에 활발히 연구되고 있다. Hoskins와 Himmelblau는 직렬로 연결된 3개의 CSTR(Continuous Stirred Tank Reactor) 이상진단문제를 통해서 화학공정분야에서 인공신경회로망의 적용 가능성을 보여 주었다[12]. Watanabe 등은 촉매를 사용하여 heptane으로부터 toluene을 생산하는 제조공정에서 인공신경회로망을 써서 결함을 진단하였다[19]. Venkatasubramanian과 Chan은 FCCU(Fluidized Catalytic Cracking Unit)에서 back-propagation 인공신경회로망에 의한 다중결함진단의 가능성을 보여 주었다[18].

## 2-2. 인공신경회로망의 학습방법

인공신경회로망은 학습방법에 따라 지도학습(supervised learning)과 자율학습(unsupervised learning)으로 나눌 수 있다. 지도학습은 입력과 출력이 학습쌍을 이루어, 그 입력에 대한 원하는 출력과 실제 출력값의 차이가 오차로 작용하여 다음 학습에서는 이 오차를 줄이는 방향으로 가중치(weight)를 수정한다. 자율학습은 입력값만으로 학습이 이루어지며 그 입력값에 대한 출력이 있기 전에는 출력을 예측할 수 없다. 따라서 어떠한 입력이 주어질 때마다 그에 상응하는 출력값을 나타내도록 자율구성(self organize)한다. 이 방식은




Fig. 1. A schematic depiction of a feedforward connectionist network.

Cart-Pole시스템처럼 원하는 출력값을 모를 때 매우 유용하다[1, 13, 16].

본 연구에서 사용한 인공신경회로망은 Fig. 1과 같이 입력층(input layer), 중간층(hidden layer) 그리고 출력층(output layer)이 있는 3층의 feed-forward 구조로 되어 있다. 만약 목표출력이 입력변수들 ( $I_1, I_2, \dots, I_n$ )의 함수로써 한 변수만을 예측한다면 출력량은 단일변수가 된다. 이들의 관련성은 다음과 같은 관계식으로 전개될 수 있다.

$$O = C_0 + \sum_{i=1}^N C_i \phi_i(I_1, I_2, \dots, I_n) \quad (1)$$

여기서  $\phi_i$ 는 비선형 다항식이다.

인공신경회로망의 한 node를 생각해 보자. Node는 입력값과 연결 weight와의 곱을 합하여 얻은 값을 비선형 경계치 함수에 대입시킨다. k층의 j번째 node의 출력은 다음과 같이 주어진다.

$$X_j^k = f\left(\sum_i W_{ji}^k X_i^{k-1} + \theta_j^k\right) \quad (2)$$

여기서  $\theta_j^k$ 는 k층의 j번째 node에 관련된 bias이며, 함수 f는 활성화 함수이다.

Node의 출력계산은 출력값이 경계치의 level에 도달하면 node의 출력이 발생되는 활성화 함수를 경계치 함수로 취한다. 본 연구에서는 연속적인 비선형 함수인 다음과 같은 sigmoid logistic 함수를 사용하였다.

$$f(X_j^k) = \frac{1}{1 + \exp(-R X_j^k)} \quad (3)$$

여기서  $r$ 은 함수  $f$ 의 shaping ratio이며 sigmoid함수의 모양을 변형시킨다. 이 값을 조정하여 학습의 수렴성을 높일 수 있다.

각 층의 node들을 서로 연결하는 weight의 할당은 어느 특정 결합이나 이상조건을 나타내는 출력 pattern과 입력 pattern을 연관시키는 학습을 통해 이루어지게 된다. 이 연결 weight를 할당하는 방법은 인공신경회로망의 학습특성에 따라 여러 가지가 있다. 본 연구에서는 지도학습을 하는 back-propagation 방법을 사용하였다. Rumelhart와 McClelland에 의해 제시된 Generalized Delta Rule(GDR)이라고 불리는 back-propagation 학습의 기본개념은 다음과 같은 출력오차의 자승합(sum of squared error)을 최소화하기 위해 weight를 변경시킨다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (4)$$

여기서  $t_{pj}$ 와  $o_{pj}$ 는 각각 어떤 임의의 pattern  $p$ 에 대한  $j$ 번째 출력 node의 목표 출력값과 실제 출력값을 나타낸다. 즉 출력층의 오차는 목표 출력값과 실제 출력값의 차로 쉽게 계산될 수 있다. 그러나 hidden layer에 대한 목표 출력값은 알 수 없기 때문에 직접 계산될 수 없다. Delta rule은 출력층으로부터 back-propagation을 사용하여 어느 layer에 있는 node의 오차를 계산할 수 있다. 이를 위해 신경회로내의 임의의 weight에 대해 오차함수의 미분값을 구해 weight를 변경시킨다. 일반적으로 어떤 임의의 pattern  $p$ 에 대한  $i$ 번째 node와  $j$ 번째 node간의 weight( $W_{ij}$ )를 구하기 위한 GDR은 학습하는 동안에 진동(oscillation)을 방지하기 위하여 momentum항을 포함시킨 다음과 같은 계산방식을 많이 사용한다.

$$\Delta p W_{ji}(n+1) = \eta \delta p_j O_{pj} + \alpha \Delta p W_{ji}(n) \quad (5)$$

여기서  $\eta$ 는 학습율(learning rate),  $\delta p_j$ 는 입력값에 대한 오차( $E_p$ )의 미분값,  $O_{pj}$ 는 출력값,  $\alpha$ 는 momentum계수이다. 0과 1사이의 값을 갖는 학습율은 weight공간내에서 결과값이 진동하는 것이 없이 수렴할 수 있도록 충분히 커야 한다. 일반적으로 학습율이 클수록 가중치의 변화량이 크게 된다. 학습율이 크면 빨리 학습은 마칠 수 있지만 한편으로는 문제의 해답을 찾지 못하고 진동(oscillation)을 하는 경우가 생긴다. Momentum 계수는 진동을 막으면서 학습율을 크게 해주기 위해 도입된 것으로 바로 전번의 가중치 변화량을 얼마만큼 적용시킬 것인가를 나타낸다. 그러므로 학습의 수렴성을 좋게 하기 위해서는 인공신경회로망의 node 구성과 학습 data에 따라 학습율과 momentum계수를




Fig. 2. Configuration of blast furnace process.

적절히 선정하여야 한다.

### 2-3. 학습 알고리즘

본 연구에서 사용한 back-propagation에 의한 학습 알고리즘은 다음과 같다.

- (1) 회로망을 구성하고 모든 node에 연결 weight  $W_{ji}$ , bias  $\theta_{pj}$ , 학습율( $\eta$ ), momentum계수( $\alpha$ )를 할당한다.
- (2) 정규화된 입력패턴(normalized input pattern)을 input layer에 입력하고 다음식을 사용하여 output layer로 전파시킨다.

$$O_{pj} = \frac{1}{1 + \exp(-\text{net } p_j)} \quad (6)$$

- (3) Output layer의 local error를 계산한다.
- (4) Hidden layer의 local error를 계산한다.
- (5) 모든 연결 weight의 bias를 계산하여 보정한다.
- (6) 다음 식들을 사용하여 연결 weight( $W_{ji}$ )와 bias( $\theta_{ji}$ )를 update시킨다.

$$\Delta p W_{ji}(n+1) = \eta \delta p_j O_{pi} + \alpha \Delta p W_{ji}(n) \quad (7)$$

$$\Delta p \theta_{ji}(n+1) = \eta \delta p_j + \alpha \Delta p \theta_{ji}(n) \quad (8)$$

- (7) 목표하는 output값과 계산된 output값의 차가 허용오차 범위안에 들어오지 않으면 (2)에서 (7)까지의 반복계산을 계속한다. 그렇지 않으면 계산을 끝내고 최종 weight값들을 저장한다.

## 3. 고로 노환이상진단 전문가 시스템의 구현

### 3-1. 고로공정의 특성과 이상현상

고로설비는 Fig. 2와 같이 고로본체 및 부대설비로

나눌 수 있다. 고로본체는 내화면으로 축조되어 있다. 내부는 장입물이 채워질 수 있도록 텅 비어 있으며, 외부는 철판으로 둘러 쌓여있고 연와보호용 냉각판이 설치되어 있다. 하부에는 용선(molten iron)과 용재(slag)를 배출하는 출선구가 있고 그 위에 열풍을 노내로 불어넣는 원주방향으로 일정한 간격의 풍구가 설치되어 있다. 부대설비로는 철광석이나 coke 등의 장입물을 저장, 평량, 절출하는 원료 저장절출설비와 conveyer belt와 같은 수송설비, 노내로 원료를 장입하는 장입설비가 있다. 또한 노내로 공기를 이송하기 위해 고온(1,000-1,300℃)으로 공기를 가열하는 열풍로, 고로하부로 배출되는 용선과 slag를 처리하는 주상, 노정으로 배출되는 고로가스를 여과하는 가스청정설비와 배출되는 가스압력을 이용하여 전기를 생산하는 노정압 발전기 등이 있다[3].

고로내에서 장입물은 상부로부터 장시간의 traveling time을 가지고 하부로 강하하면서 환원과 용융을 하는 반면에 풍구를 통해 노내로 공급된 1,150℃의 공기는 열교환과 노내반응에 관여하면서 100℃정도로 노정으로 빠져 나간다. 즉 고로는 향류의 흐름을 가진 연속식 반응기이며 3차원적으로 각 부분마다 온도나 압력 그리고 가스조성분포 등이 각각 다르게 나타난다. 그리고 이상발생시 취한 action에 대한 응답시간을 살펴보면 철광석과 코크스 등의 장입비율 변경이나 성분변동의 응답시간은 긴 반면에 송풍온도나 송풍량 등 송풍관련 인자들의 응답시간은 짧다.

노환의 이상현상은 일반적인 화학공정에 비하면 그 변화가 순간적이기 보다는 점진적으로 일어나며 국부적이기 보다는 전반적으로 나타나는 경우가 많다. 그러므로 노환의 이상을 진단할 때는 장시간의 추이를 파악하고 종합적인 판단이 필요하다. 또한 고로는 건설이 되어 일단 가동을 하게 되면 12-15년간 계속 조업을 한다. 따라서 조업자는 매일 3회로 나누어 교대근무를 하므로 개인적인 능력차, 주관적 판단 등이 조업에 큰 영향을 미친다. 그러므로 교대근무로 인한 정보의 유실을 막고 조업자가 인식하고 있는 이상진단의 정신적 모델(mental model)을 표준화하고 체계화하는 것이 필요하다.

고로조업시 주요 이상현상으로서 노하부에 노벽쪽의 열원인 coke가 연소되지 않는 부분이 생기는 불활성현상과 노내의 가스흐름방향이 일정하지 않는 불안정현상이 있다. 이들이 발생될 때 조업실적 data와 조업경험을 분석한 결과로 그 상황을 요약하면 다음과 같다.

노하부 불활성화현상은 초기에 노상부 온도가 점진적으로 상승하면서 노내의 통기성은 양호하여 노환은 안정된 상태를 유지한다. 그러나 계속 진전이 되면 노

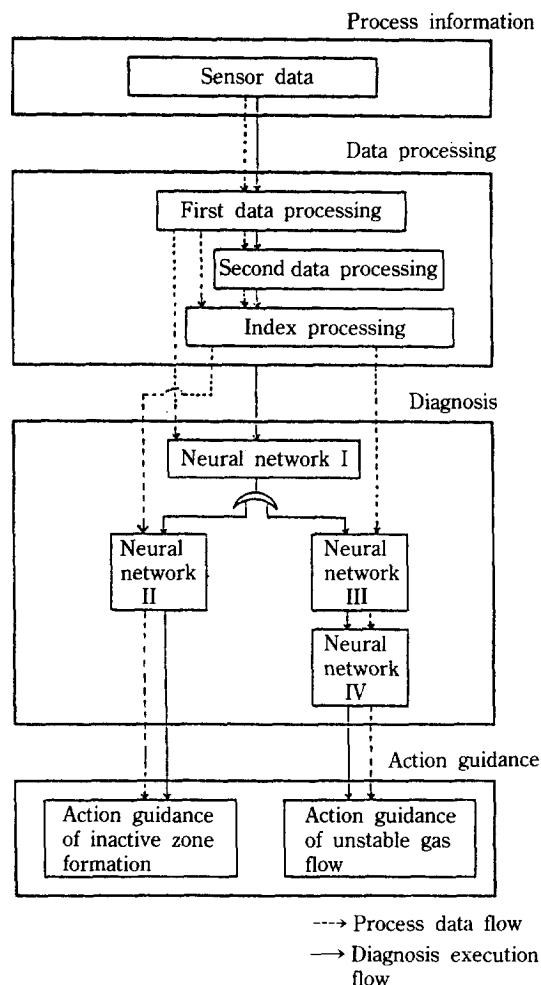


Fig. 3. Overall procedure of abnormality diagnosis.

하부 온도가 저하하면서 노상부 온도는 계속 상승한다. 그리고 노내의 통기성이 악화되고 노내의 CO가스 이용율이 저하되면서 노열도 저하하여 최종적으로는 노하부에 정체하는 장입물이 형성된다. 이 현상은 일상조업시 자주 발생하는 현상은 아니지만 일단 심화되면 복구하는데 많은 노력과 시간을 소요하는 경우가 많다. 이 현상은 10-30일간에 걸쳐 점진적으로 진행되므로 순간적인 판단으로는 쉽게 밝혀내기 어렵다.

노내 가스류 불안정현상은 일상조업시 종종 일어나는 이상현상으로 앞에서 언급한 노하부 불활성화현상에 비해 그 진행속도도 빠르고 변동도 다양하다. 이 현상은 고로 하부의 노벽온도가 상승하고 상부온도가 저하하는 경향을 보여 노하부 불활성화 현상과 상반된다. 그러나 통기저항지수가 증가하고 노정의 가스이용율이 감소하




Fig. 4. Configuration of sensors in a blast furnace.

는 경향은 일치한다. 또한 이 현상이 발생하면 고로에 설치된 여러 가지 검출단의 data변동이 노하부 불활성 화시 보다 심하게 나타난다.

### 3-2. 노황이상진단의 전체적인 구성

노황이상진단을 위한 개략적인 수행절차는 Fig. 3과 같다. 우선 고로에 설치되어 있는 각종 sensor들 중 고로 노황의 변동에 민감한 반응을 나타내는 것들을 노황이상시의 사례분석을 통해 선정하였다. 이들 sensor data는 각각의 종류와 설치위치에 따라 변동량이나 응답시간이 달라서 노황이상시 이들의 특성이 잘 나타날 수 있도록 여러 가지 형태로 data를 가공하여 이상진단의 입력원으로 사용하였다.

이상진단방법은 학습능력이 있어서 진단을 위한 지식의 보완이 용이한 인공신경회로망을 이용하였다. 노황이상진단을 위한 인공신경회로망은 학습시간이 오래 걸려 off-line상태에서 이상사례의 분석결과를 근거로 마련한 학습 data로 학습을 시킨 다음 이를 on-line상으로 copy하여 사용하였다. 이상진단은 우선 노황의 이상상태 여부를 분류하고 이상이 있을 경우 이상의 종류에 따라 상세한 진단을 하는 hierarchy구조를 취하여 빠르고 정확한 진단을 할 수 있게 하였다.

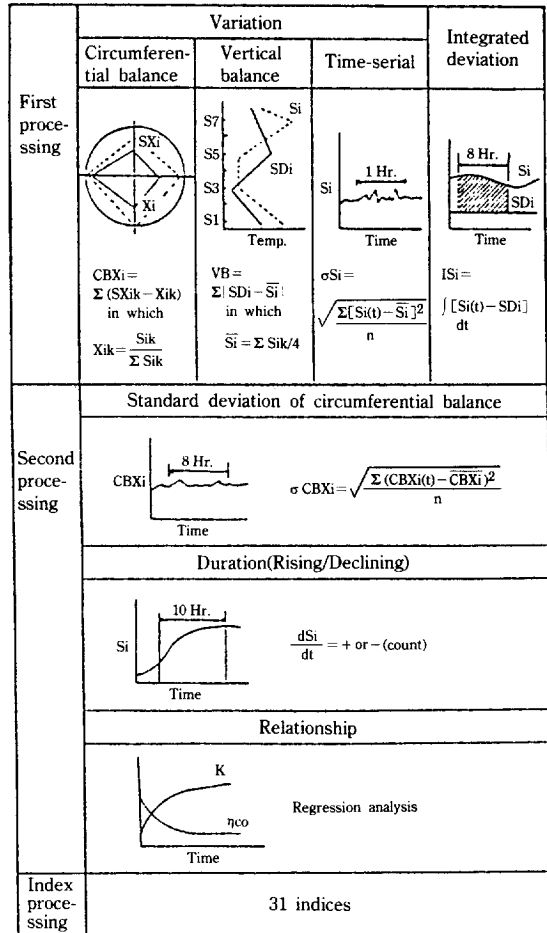


Fig. 5. Sensor data processing.

이상진단의 결과인 이상의 종류와 그 심화정도에 따라 조업경험과 조업실적 분석결과를 근거로 마련한 action guidance를 진단결과와 함께 CRT(Cathode Ray Tube)화면을 통해 나타냈다.

### 3-3. 지식의 수집과 공정 Data 가공

본 전문가 시스템을 구축함에 있어서 고로노황 이상진단과 action guidance에 관한 지식은 다음과 같은 방법에 의해 수집하였다. 우선 조업경험에 관한 지식을 숙련된 조업자와 interview 및 설문조사를 통해 경험적인 이상진단 지식을 수집하고 과거 이상이 발생했던 시계열적 조업 data의 통계분석을 행하여 노황 이상시의 각 인자별 변동형태, 응답(지연)시간, 상호관련성 등을 정량적으로 분석하였다. 그리고 조업시 취한 action의 종류와 양을 각 경우별로 수집하였다. 또한 기술표준서, 기술(조업)검토서, 노황 이상 실적보고서, 외국 조업자

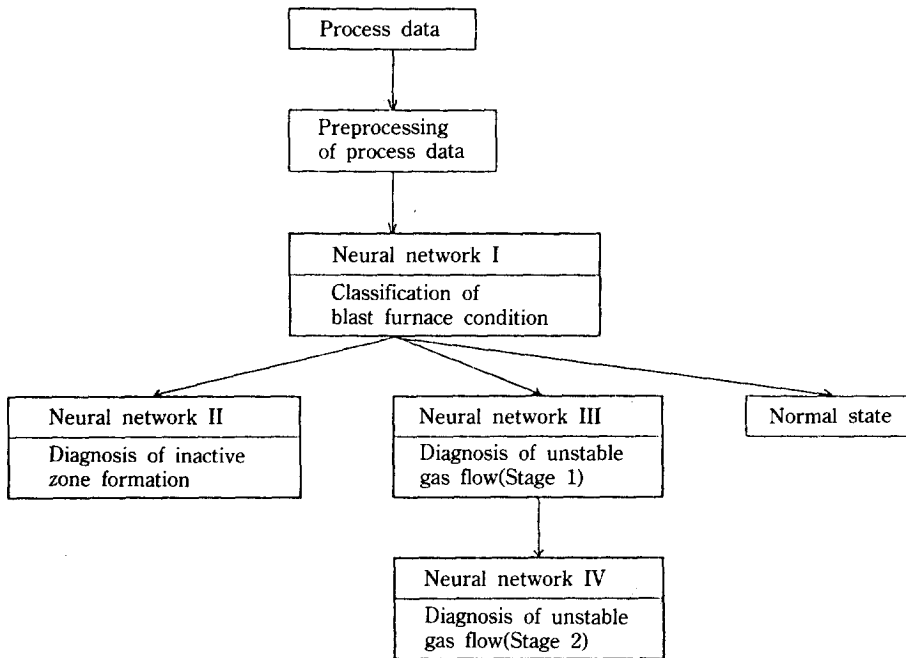


Fig. 6. Overall structure of abnormal state diagnosis in a blast furnace.

료 등도 검토하여 이상진단의 지식원으로 활용하였다. 이들을 토대로 노황 이상의 종류별로 입력변수, 진단의 구조 등을 설정하였다.

Fig. 4와 같이 고로에 설치된 700여 point에 달하는 각 검출단은 data level이나 변동의 크기, 응답시간들이 각각 다르다. 이들 data가 노황 이상진단에 유용한 정보가 되기 위해서는 일관성있고 함축성있는 처리가 요구된다. 그리고 이상현상을 잘 나타내는 완전하고 정확한 형태의 외적인 묘사가 필요하다. 본 연구에서는 Fig. 5와 같이 공정 data의 1, 2차 가공과 지수화를 하였다. 1차 가공에서는 노내의 원주나 수직 balance변동, 시계열변동, 기준조업시와 편차 비교를 위해 여러 가지 형태로 가공하였다. 2차 가공에서는 1차 가공 data의 변동상태, 변동의 지속성, 다른 data와의 상호관련성 등을 살펴 노황 이상시의 특성파악을 용이하게 하였다.

고로조업 전문가가 노황상태를 진단할 때 미세한 부분이나 순간적인 변동상태를 검토하기 보다는 부분적이고 중장기적인 변동의 추이나 level을 파악하여 이상을 진단한다. 즉 노체온도 변화의 경우 어느 한 sensor의 순간적인 변동보다는 상부나 하부온도로 구분하여 3-4 일간의 지속적인 변동상태를 검토한다. 이와 같은 조업전문가의 개념과 일치할 수 있도록 각 sensor별 data가공 결과를 노황 이상시 변동의 특성별로 묶어 지수화하여 이상진단의 입력원으로 사용하였다.

### 3-4. 노황 이상진단방법과 Action Guidance

본 연구에서는 일단 학습이 되면 신속한 결과를 얻을 수 있으며 고로노황 이상진단과 같이 여러 변수들이 서로 작용을 하는 다변수적인 특성을 가진 공정의 이상진단에 적합한 인공신경회로망기법을 사용하여 새로운 노황이상 진단방법을 시도하였다. 진단의 구조는 Fig. 6에서 보인 바와 같이 4개의 인공신경회로망으로 이루어진 계층구조이다.

우선 고로노황상태를 노하부 불활성화, 노내 가스류 불안정 그리고 정상상태 등으로 노황상태를 크게 3가지로 분류한다. 이 노황상태의 분류는 이미 3가지 노황상태의 특징을 인식할 수 있도록 학습이 되어 있는 인공신경회로망 I에 의해 이루어진다. 만약 여기서 노황의 이상이 밝혀지면 이상의 종류에 따라 다음 단계에서 노하부 불활성화 진단이나 노내 가스류 불안정 진단을 하게 된다. 노황상태를 분류하는 인공신경회로망 I는 가스이용율과 통기저항지수 그리고 노하부 불활성화와 노내 가스류 불안정시 상반되게 나타나는 하부온도(ST1, 2단)와 상부온도(ST8, 9단)를 입력원으로 하였다.

노하부 불활성화현상은 앞에서 언급한 것처럼 비교적 장시간에 걸쳐 발전하므로 인공신경회로망 II를 써서 그 진행단계를 초기단계, 중기단계, 말기단계로 구분하였다. 이렇게 이상의 진행과정을 분류해 냄으로써 시기

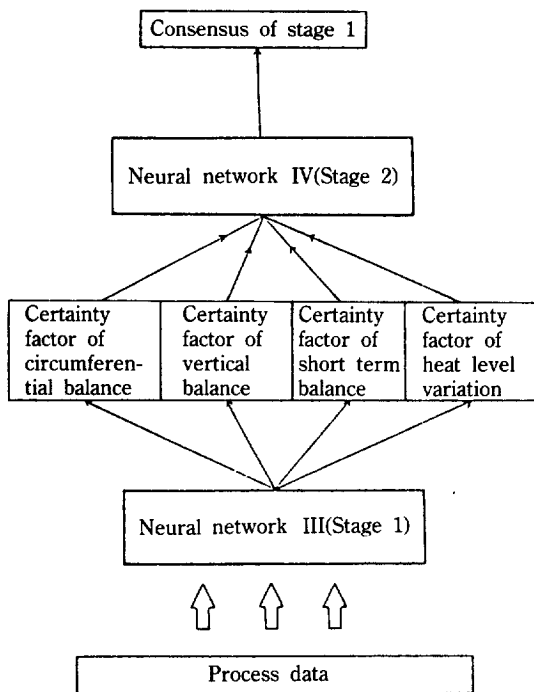


Fig. 7. Two-stage diagnostic process of unstable gas flow.

Table 1. Number of nodes, learning rate and momentum rate in each neural network

	Neural network I	Neural network II	Neural network III	Neural network IV
Number of nodes				
Input layer	8	8	31	4
Hidden layer	11	11	35	5
Output layer	3	3	4	1
Learning rate	0.7	0.7	0.7	0.7
Momentum rate	0.9	0.9	0.9	0.9

적절한 action을 취할 수 있는 근거를 마련하고 조기에 이상현상을 정확히 밝혀 내는 것이 가능하도록 하였다. 또한 노하부 불활성화시 특징적으로 변동하는 8개의 지수화된 인자들을 인공신경회로망 II의 입력원으로 하였다.

노내 가스류 불안정 진단은 Fig. 7과 같이 2단계의 구조로 되어 있다. 1단계 진단을 위한 인공신경회로망 III은 지수화된 31개의 인자들을 입력원으로 하여 원주 balance 불균형, 수직 balance 불균형, 단기변동, 노열 변동 등 각 부문별 진단을 하였다. 노내 가스류 불안정현상이 발생할 때는 여러 가지 요인들이 동시에 다발적으로 변동함으로 2단계 진단을 위한 인공신경회로망 IV는 1단계의 각 부문별 진단결과를 입력원으로 하여




Photo 1. CRT display-I.



Photo 2. CRT display-II.

이들을 종합하는 network으로 구성하였다.

본 연구에서 사용한 각 인공신경회로망의 node수, 학습율, momentum계수값은 Table 1과 같다.

조업실적을 분석한 결과를 근거로 노황 이상의 종류와 심화정도에 따라 시기 적절한 조치를 취할 수 있는 기준을 마련하여 이상진단의 결과와 함께 action guidance로 제시하였다. Action guidance를 위한 지식표현은 규칙(rule)으로 표현하였다.

### 3-5. 사용자 환경

본 연구에서는 고로조업에 유용한 정보를 제공하여 주고 사용자가 쉽게 친숙하는 전문가 시스템이 될 수 있도록 조작을 간편하게 하고 여러 가지 display화면을 개발하였다. 이상진단에 필요한 표준조업 data는 사용자가 단말기를 통해 임의로 설정할 수 있도록 하여 조업인자들의 관리기준을 설정하기 위한 simulation이 가능하게 하였다. 그리고 Photo 1과 같이 이상진단 결과 및 action guidance를 나타내는 화면, Photo 2와 같이 진단결과와 보다 세부적인 사항을 나타내는 화면 등을



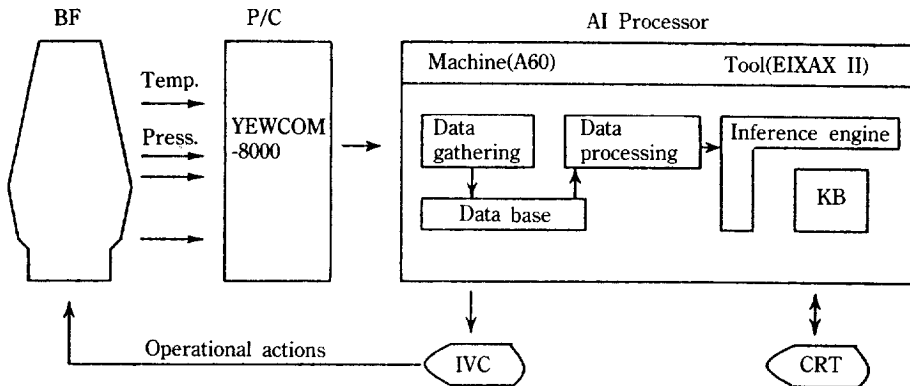


Fig. 8. Overall structure of the expert system.

만들어 노황상태를 쉽게 파악할 수 있게 하였다. 또한 진단결과와 비교를 위해 실제 sensor data나 조업지수 등의 시계열적인 변동을 나타내는 여러 가지 화면을 만들었다.

#### 4. 시스템의 구조

Fig. 8은 본 시스템의 전반적인 구조를 나타내고 있다. 이는 기존의 process computer(YEWCOM-8000)와 전문가 시스템의 동작환경(EIXAX-II)이 내장된 AI(Artificial Intelligence)전용 processor(Fuji A-60)로 이루어져 있다. 12 Mb의 기억용량을 가진 AI전용 processor는 fixed disk unit나 cartridge magnetic tape 그리고 floppy disk unit 등의 여러 가지 보조기억장치와 연결되어 있다. 또한 주변기기들로 개발계에서 사용하는 CRT(Cathode Ray Tube)와 진단결과를 보여주는 공업용 display 화면을 가진 CRT 그리고 진단결과와 장표 출력력을 위한 printer 등을 설치하였다.

AI전용 processor는 기존의 공정전산기로부터 노황 이상진단에 필요한 공정 data를 직접받아 data가공처리를 한 후 이상진단을 위한 인공신경회로망과 action guidance를 위한 지식형 rule이 내장된 추론기구(inference engine)에서 진단결과와 action guidance를 display화면을 통해서 제시한다. 본 AI전용 시스템은 offline계의 지식 base구축시 지원을 담당하는 개발계와 on-line계의 실행을 담당하는 운용계로 완전 분리하여 운영하였다. 따라서 지식 base의 구축과 test가 용이하고 on-line상의 실제공정에서 신속한 추론이 가능하게 하였다[9].

본 시스템의 지식 base구성은 global변수부, frame부, 수식 base부, rule module부, 추론제어부 등으로 이루어져 있다. Global변수부에서 production rule이나 수식

base 그리고 frame 등 전 지식 base에서 사용하는 변수들의 정보를 공통으로 관리하였다. Frame을 사용하여 지식 base에서 사용하는 계층적인 data를 관리하고 frame data끼리의 정보의 계승을 할 수 있게 하였다. 수식 base부에서 rule의 조건부(if부)나 실행부(then부)의 내용을 global변수나 frame변수를 사용한 수식으로 기술하고 필요한 함수의 호출이나 계산을 하며 인공신경회로망에 의한 이상진단을 행하였다. Rule module부는 조건부의 판단명이나 실행부의 action명을 조합시켜 구성한 production rule을 관리하였다. 추론제어부에서 추론의 순서를 제어하고 rule들이 서로 경합할 경우 이를 해소시키기 위해 맨 처음 성립(hit)된 rule에 우선하는 first hit방법을 설정하였다.

#### 5. 사례연구 및 결과 검토

##### 5-1. 노황 이상종류의 분류

노황 이상의 종류를 분류하기 위한 인공신경회로망 I의 학습 data는 Table 2와 같다. 입력층의 입력변수값은 그 변동상태의 유무에 따라 1과 0으로 정하였다. 그리고 노하부 불활성과 가스류 불안정 그리고 정상상태의 3가지 경우를 구분지을 수 있도록 할당된 출력층의 각 node에 대한 목표값(target value)은 계산상 수렴성을 좋게 하기 위하여 1과 0대신 0.9와 0.1로 설정하였다. 만약 목표값을 1과 0을 사용하면 가중치를 구하는 반복계산에서 가중치가 변하지 않아서 수렴을 하지 않을 경우가 있다.

학습단계에서 인공신경회로망의 각 node간의 가중치 계산은 (4)식에 의해 정의된 목적함수값(Ep)이 허용 오차범위를 만족할 때까지 반복계산을 하게 된다. 인공신경회로망 I이 학습과정에서 진동을 하지 않고 수렴을 하는지를 살펴 보았다. Fig. 9에서 보는 것처럼

Table 2. Training data of classification of abnormal types

K	$\eta$ co	Input layer								Output layer		
		ST 1		ST 2		ST 8		ST 9		Inactive zone formation	Unstable gas flow	Normal state
Up	Down	Up	Down	Up	Down	Up	Down	Up	Down			
1	1	1	0	0	0	1	0	0	0	0.9	0.1	0.1
1	1	1	0	0	0	0	0	1	0	0.9	0.1	0.1
1	1	1	0	1	0	0	0	0	0	0.9	0.1	0.1
1	1	1	0	1	0	1	0	0	0	0.9	0.1	0.1
1	1	1	0	1	0	1	0	1	0	0.9	0.1	0.1
1	1	0	0	1	0	1	0	0	0	0.9	0.1	0.1
1	1	0	0	1	0	0	0	1	0	0.9	0.1	0.1
1	1	0	0	0	0	1	0	1	0	0.9	0.1	0.1
1	1	0	0	1	0	0	0	1	0	0.9	0.1	0.1
0	0	1	0	0	0	0	0	0	0	0.1	0.1	0.9
0	0	0	0	1	0	0	0	0	0	0.1	0.1	0.9
0	0	0	0	0	0	1	0	0	0	0.1	0.1	0.9
0	0	0	0	0	0	0	0	1	0	0.1	0.1	0.9
1	1	0	0	1	0	1	0	1	0	0.9	0.1	0.1
1	1	1	0	0	0	1	0	1	0	0.9	0.1	0.1
1	1	1	0	1	0	0	0	1	0	0.9	0.1	0.1
1	1	0	1	0	0	0	1	0	0	0.1	0.9	0.1
1	1	0	1	0	0	0	0	0	1	0.1	0.9	0.1
1	1	0	1	0	1	0	0	0	0	0.1	0.9	0.1
1	1	0	1	0	1	0	1	0	0	0.1	0.9	0.1
1	1	0	1	0	1	0	1	0	1	0.1	0.9	0.1
1	1	0	0	0	1	0	0	1	0	0.1	0.9	0.1
1	1	0	0	0	1	0	0	0	1	0.1	0.9	0.1
1	1	0	0	0	1	0	0	0	1	0.1	0.9	0.1
0	0	0	1	0	0	0	0	0	0	0.1	0.1	0.9
0	0	0	0	0	1	0	0	0	0	0.1	0.1	0.9
0	0	0	0	0	0	0	1	0	0	0.1	0.1	0.9
0	0	0	0	0	0	0	0	0	1	0.1	0.1	0.9
1	1	0	0	0	1	0	1	0	1	0.1	0.9	0.1
1	1	0	1	0	0	0	1	0	1	0.1	0.9	0.1
1	1	0	1	0	1	0	0	0	1	0.1	0.9	0.1

반복계산의 횟수가 증가할수록 목적함수(Ep)가 기하급수적으로 감소함을 나타낸다.

Table 2의 학습 data에 의해 학습이 된 인공신경회로망 I에 노화 이상이 발생했던 미학습된 실제 공정 data를 적용한 출력층의 각 node별 activation level은 평균 0.95이상으로 분리를 잘 해 냈다. Activation level은 V. Venkatasubramanian 등[18]에 의해 다음과 같이 정의한 것을 사용하였다.

$$\text{Activation level} = 1 - |tpj - opj| \quad (9)$$

여기서 tpj는 p패턴의 목표 출력값이며 opj는 계산에 의한 실제 출력값을 나타낸다.

## 5-2. 노하부 불활성화 진단

노하부 불활성화 진단을 위한 인공신경회로망 II의 학습은 Table 3과 같은 data를 사용하였다. 불활성화의 진행단계별로 심화정도에 따라 4가지 level을 고려하여 학습 data를 구성하였다. 학습된 인공신경회로망 II에 미학습된 공정 data를 적용한 결과는 출력층의 activation level이 평균 0.98 이상으로 각 진행단계를 잘 구분하였다.

노하부 불활성화가 발생했던 여러 가지 경우의 조업 실적 data를 이용하여 진단결과와 과거의 실제 조업정위를 비교하였다. Fig. 10은 그 한 예로써 불활성화현상이 발생했던 전후의 조업 data의 경향과 본 연구에




Fig. 9. Convergence of the objective function (Ep) in case of neural network I learning.

의한 진단결과 및 action guidance를 나타내고 있다. 우선 진단결과를 살펴 보면 노하부 불활성화의 진행단계인 초기, 중기 및 말기단계를 시계열적으로 거의 겹침이 없이 확실히 구분하여 판단하고 있다. 이는 종래의 규칙기반 전문가 시스템에서 지식 base가 방대하여 질 경우 진단의 선명성(resolution) 문제를 인공신경회로 망방법을 통해 극복할 수 있음을 나타내고 있다. 이 조업기간 동안 작업일지에 의한 조업자의 노황판단을 살펴보면 중반까지 노내 가스이용율이나 통기저항지수 그리고 노체온도가 점차 변화하는 것을 간과하였으며 노황 이상을 못 느꼈다가 후반에서 노체온도나 노체압력 그리고 노정가스온도 심한 변동을 인식하고 감광의 action을 취하였다. 그러나 본 연구에 의한 진단결과는 조업자가 노황 이상을 인식하기 1일 전부터 노하부 불

활성화의 초기단계임을 판단하여 action guidance를 제시하고 있다.

### 5-3. 노내 가스류 불안정진단

노내 가스류 불안정현상은 노하부 불활성화에 비해 다양한 형태로 나타나며 여러 가지 검출단이 변동을 하게 된다. 그리고 변동의 진행도 일시적이고 갑작스러운 변동을 하는 경우가 많아서 사례분석에 의한 72 가지 경우를 고려하여 1단계 진단을 위한 인공신경회로망 III을 학습시켰다. 또한 1단계의 진단결과인 4가지 부분을 종합화하는 2단계 인공신경회로망 IV의 학습은 노황판단의 경험에 의한 각 부문별 가중을 고려하여 학습 data를 작성하였다.

노내 가스류 불안정진단의 검증을 위해 노하부 불활성화의 경우와 마찬가지로 여러 가지 사례의 조업 data를 이용한 진단결과와 실제 조업경위를 비교하였다. Fig. 11은 한 예로 노내 가스류 불안정현상이 발생했던 전후의 조업경향과 이상진단결과를 나타내고 있다. 노내 가스류 불안정에서도 조업자가 이상상태임을 판정하여 action을 취하기 이전에 이상상태를 잘 진단하고 있다. 특히 조업자가 확실한 이상상태임을 직감하는 slip이 발생하기 이전에 이미 노내 가스류 불안정상태임을 나타내고 있다.

## 6. 결론 및 제언사항

### 6-1. 결론

본 연구를 통해 다음과 같은 결론을 얻었다.

(1) 고로노황 이상진단을 위해 자체 학습이 가능하고 구현이 용이한 인공신경회로망을 응용함으로써 신속한 진단과 선명성이 높은 진단을 할 수 있었다.

(2) 조업자의 노황판단의 개념과 일치할 수 있도록

Table 3. Training data of diagnosis of inactive zone formation

Input layer								Output layer		
Node 1	Node 2	Node 3	Node 4	Node 5	Node 6	Node 7	Node 8	Node 1	Node 2	Node 3
0.3	0.2	0.2	0.2	0.2	0.1	0.1	0.0	0.3	0.01	0.01
0.5	0.3	0.3	0.3	0.3	0.1	0.1	0.0	0.5	0.01	0.01
0.7	0.4	0.4	0.4	0.4	0.15	0.15	0.0	0.7	0.01	0.01
0.9	0.5	0.5	0.5	0.5	0.2	0.2	0.0	0.9	0.01	0.01
0.0	0.55	0.55	0.55	0.55	0.4	0.4	0.3	0.01	0.3	0.01
0.0	0.6	0.6	0.6	0.6	0.5	0.5	0.4	0.01	0.5	0.01
0.0	0.65	0.65	0.65	0.65	0.6	0.6	0.5	0.01	0.7	0.01
0.0	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.01	0.9	0.01
0.0	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.01	0.01	0.3
0.0	0.8	0.8	0.8	0.8	0.8	0.8	0.8	0.01	0.01	0.5
0.0	0.85	0.85	0.85	0.85	0.85	0.85	0.85	0.01	0.01	0.7
0.0	0.9	0.9	0.9	0.99	0.9	0.9	0.9	0.01	0.01	0.9




Fig. 10. Operation trend and diagnosis results with action guidances in case of inactive zone formation(Pohang 3BF ; '88. 4-5).




Fig. 11. Operation trend and diagnosis results in case of unstable gas flow(Pohang 3BF ; '90. 2).

수많은 sensor정보를 가공, 지수화하여 사용함으로써 여러 가지의 이상변동에 대처할 수 있는 시스템을 구현하였다.

(3) 이상의 종류별로 그 특성에 적합한 인공신경회로망을 구성함으로써 진단의 효율성과 강건성을 증대시켰다.

(4) 실제 조업 data를 적용한 본 시스템의 진단결과와 분석을 통해서 본 시스템이 장기적인 노화의 이상을 초기에 대처할 수 있음을 확인하였다.

(5) 본 연구를 통해서 조업자의 개개의 능력차를 해소하는 노황판단지식의 표준화와 조업기술을 축적하였다.

## 6-2. 제안사항

규칙기반 전문가 시스템은 각 rule들의 분명한 결정기준이 있어서 쉽게 그 추론과정을 설명할 수 있다. 그러나 본 연구에서 응용한 인공신경회로망에 의한 지식은 weight나 activation value형태로 전 network에 걸쳐 분산되어 있다. 그러므로 많은 node들에 의해 결론에 도달되는 path를 추적하거나 설명하기가 어렵다. 그러나 각 node를 연결하는 weight나 output layer의 activation value를 비교 분석하면 진단결과에 대한 설명이 가능할 것으로 기대되어 이에 관한 연구가 필요하다고 본다.

또한 실제 조업에서 전체적인 노황관리를 위해서는 노열제어나 장입물 분포제어 그리고 송휴풍시의 전문가 시스템을 개발하는 연구를 더욱 확대시켜 보다 복합적인 진단과 action guidance가 제시되어야 할 것이다.

그리고 긴급한 이상 발생시 현장 조업자에게 음성이나 경보로 전달하여 줄 수 있는 시스템의 보완이 요구된다.

## NOMENCLATURE

$C_i$	: constant
$CBX_i$	: circumferential variation ratio of the k th layer sensor
$\overline{CBX_i}$	: mean value of $CBX_i$
$E_p$	: sum of squared error
$I_i$	: input value of artificial neural network
$IS_i$	: integrated value in data processing
$K$	: gas permeability index in blast furnace
$net\ p_j$	: input value of artificial neural network
$O, Op$	: Output value in artificial neural network
$r$	: shaping ratio of sigmoid function
$Si, ST_i$	: measured stove temperature of blast furnace

$\overline{S_i}$	: mean value of $S_i$
$SD_i, SX_i$	: standard value of ith sensor
$tp$	: target value of artificial neural network
$VB$	: amount of vertical variation in sensor data processing
$W_{ij}$	: weight in artificial neural network
$X_i$	: actual value of circumferential deviation fraction
$X_j^k$	: output value of jth node in kth layer

## Greek Letters

$\alpha$	: momentum rate in back propagation type network
$\eta$	: learning rate in back propagation type network
$\eta_{CO}$	: CO gas utilization ratio of blast furnace gas
$\theta$	: bias term in artificial neural network
$\phi$	: polynomial function
$\sigma$	: standard deviation
$\delta_{pj}$	: variation ratio of error( $E_p$ ) in artificial neural network

## REFERENCES

- 오세영 : 전기학회지, **38**(2), 17(1989).
- 일본화학공학회편 : "화학공학에 있어서 Expert System", 화학공업사, **13**(1988).
- 포항제철(주) : "기술표준서(고로공정)", (1987).
- Aharonian, G.: *J. of Neural Network Computing*, **53** (Summer, 1989).
- Dietz, W. E., Kiech, E. L. and Ali, M.: *J. of Neural Network Computing*, **5**(Summer, 1989).
- Dogherty, E. R. and Giardina, C. R.: "Mathematical Methods for Artificial Intelligence and Autonomous Systems", Prentice-Hall, London, **59**(1988).
- Eberlein, S.: *J. of Neural Network Computing*, **5** (Fall, 1989).
- Finch, F. E. and Kramer, M. A.: 10th World Congress on Automatic Control, **6**, 298(1987).
- Fuji-Facom Control Co.: "EIXAX Manual", Fuji-Facom Co., 5(1989).
- Himmelbrau, D. M.: "Fault Detection and Diagnosis in Chemical and Petrochemical Process", Elsevier, (1978).
- Hirata, T., Yamamura, K., Morimoto, S. and Takada, H.: 전기학회 산업응용부문 전국대회 발표집 (일본), 807(1989).

12. Hoskins, J. C. and Himmelblau, D. M.: *Compt. Chem. Engng.*, **12**(9), 881(1988).
13. LISPE: "Knowledge-based Expert Systems in Process Engineering", Dep. of Chem. Eng., MIT, U. S. A., (Summer, 1990).
14. McClelland, D. E., Rumelhart and PDP Research Group: "Parallel Distributed Processing", 6th, MIT Press, Cambridge, Ma., (1987).
15. Oh, J. K.: Ph. D. Dissertation, Seoul National Univ., Seoul, Korea(1990).
16. Pao, Y. H.: "Adaptive Pattern Recognition and Neural Networks", Addison-Wesley Publishing Co., 113(1989).
17. VerDuin, W. H.: *J. of Neural Network Computing*, **46**(Winter, 1990).
18. Venkatasubramanian, V. and Chan, K.: *AIChE J.*, **35**(12), 1993(1989).
19. Watanabe, K., Matsuura, I., Abe, M., Kubota, M. and Himmelblau, D. M.: *AIChE J.*, **35**(11), 1803 (1989).
20. Yagi, J. I.: *CAMP-ISIJ*, **2**, 2(1989).