

신경망을 이용한 용해로 최적 SET-UP 예측시스템

한 부 학*

Furnace Set-up Prediction System Using Neural Network

Boo-Hak Han*

요 약

TV 브라운관 유리를 생산하기 위한 용해 공정은 원료의 투입에서 부터 유리물이 생성될 때까지 고온의 화학적 작용을 거친다. 유리물을 생성하기 위한 여러가지 조건 중에서 용해로 내부에서의 유리물의 온도 변화 및 이에 따른 제반 공정변수의 조정 설정치(Set-up)는 불량률에 밀접한 영향을 미친다. 그러나 고온의 밀폐된 환경에서 반응이 진행되므로 공정의 운전 요원들은 그들의 경험을 바탕으로 용해로의 운전 상태를 파악하고 운전해 나간다. 본 연구에서는 이러한 경험적 판단에 따른 위험성을 가능한 한 줄이고 용해로의 안정적인 운영을 통하여 불량률을 감소시키기 위하여 용해로 최적 Set-up 예측 시스템을 개발 하였다. 이 시스템은 일정 기간 동안의 용해로의 운전 상태와 불량률간의 관계를 신경망 기법을 이용하여 학습한 후에, 이를 이용하여 불량률을 유지하기 위한 Set-up 값을 예측하여 준다.

Key Words : 신경망, 다층 퍼셉트론, 용해로, Set-up 예측, 오류역전파

I. 서 론

신경망(Neural network) 분야의 연구는 1950년대 미국에서 시작되었으나 당시에는 컴퓨터 분야의 기술이 발달되지 않은 상태였으며 신경망 이론 또한 완전하게 정립되지 않은 상태였기 때문에 지속적으로 연구가 진행되지 못하였다(Lippman, 1988). 그러나 1980년 대에 들어와서 Caltech의 Hopfield 교수와 PDP(Parallel Distributed Processing) 그룹의 Ru-

melhart등에 의하여 새로운 이론적 발판이 마련되고 또한 기존의 인공지능 연구가 그 한계를 드러내는 상황이 되자 80년대 후반 부터 인기를 얻으며 많은 연구가 시작되었다(Hopfield, 1985와 Rumelhart, 1986).

신경망이란 인간 두뇌의 신경기능을 모방하여 정보처리에 이용하려는 기술이다. 신경망의 응용분야는 크게 패턴인식, 연상기억, 로봇등의 콘트롤, 최적화, 예측문제등이며 이외에도 많은 분야에서 활발한 응용시도가 이루어지고 있다(Kohonen, 1988과 Pao,

* 삼성코닝(주)

1989). 최근에는 국내에서도 신경망을 이용한 각종 응용 프로그램의 개발이 활성화 되고 이를 이용한 전자제품들이 실용화되고 있다.

유리의 용해공정에 있어서는 용해로의 안정적인 운전이 전체의 생산성에 막대한 영향을 미친다. 따라서 용해로와 관련된 공정 데이터를 해석하고 안정적으로 운전하기 위해서는 다각적인 노력이 필요하다. 그러나 용해공정은 일종의 화학 공정으로 복잡한 변화의 과정을 수반하고 고온의 환경적인 요소로 인하여 용해로 내부의 운전 과정을 정확히 알 수 없고, 따라서 이의 분석도 매우 힘들다.

본 연구는 용해로의 조종상태와 온도상태의 변화에 따른 불량률과의 상관관계를 신경망 기법을 이용하여 모델링하고 용해로의 운전상태를 분석한 후에 최적화 알고리즘을 이용하여 적정한 불량률을 유지하기 위한 최적의 운전 조건을 예측하여 제시함으로써 현장의 엔지니어가 불량을 줄여나가는데 도움을 주고자 하는데 그 목적이 있다. 이를 위하여 본 연구에서는 다층 퍼셉트론(Multilayer perceptron) 모델을 이용하였으며 오류역전파(Back-propagation) 모델을 학습 알고리즘으로 이용하였다.

II. 모델링

용해 공정은 수 백개의 변수를 포함하고 있으며, 시스템적으로는 재현성을 찾기가 힘든 비선형 시스템이다. 이로 인하여 기존의 수학적 모델을 이용한 방법으로는 문제를 해결하기가 힘들다. 따라서 특정한 수학적 모델을 필요로 하는 통계적인 방법 보다는 신경망의 훈련을 통하여 용해로의 시스템 방정식을 구하는 방법을 택하였다. 여기에서 시스템 방정식이란 수학적 표현을 의미하는 것이 아니라, 용해 상태의 데이터와 불량률을 함수 관계로 고려했을 경우에 입력을 대입하면 불량률을 알 수 있다는 의미이다.

본 연구에서는 신경망 학습 알고리즘을 이용하여 일정 기간 동안의 용해 공정의 상태와 불량률과의 상관관계를 해석하여 최적의 Set-up 값을 구하고자 하였다. 그리고 엔지니어들이 이를 통하여 공정운전의 기준치를 보다 쉽고 빠르게 결정할 수 있도록 도와주는 것에 주된 목적이 있으며, 또한 특정한 불량률로부터 원하는 값으로 가기 위한 적정한 Set-up 값을 구하고자 하였다. 이를 위하여 현재 용해운전과 관련된 변수의 영역을 설정하고 여기에 신경망을 적용할 수 있도록 모델링 하였다.

2.1 운전 변수의 관계 설정

앞에서 설명한 바와 같이 용해 공정에는 수백개의 변수가 관련되어 있다. 이러한 변수들을 크게 구분하면 원인 변수와 결과 변수로 나누어지는 데, 이들 변수 간의 관계를 과거 수십년 간의 경험을 기반으로 하여 그림 1과 같이 세 부류로 나누었다. 이와같이 변수를 세 부류로 나눈 이유는 공정의 작업자들은 대부분의 경우에 있어서 생산 현장에서 용해로를 제어한 결과와 불량률의 관계를 중요시 하기 때문이며, 또한 불량이 발생할 경우에 용해로에 어떠한 현상이 일어나는지를 파악하여 조치를 취하기 때문이다. 용해로를 공정의 작업자들이 직접 조작할 수 있는 변수를 제어(Control) 변수로 정의 하였고, 이때에 생산되는 유리물의 품질을 불량률로 정의 하

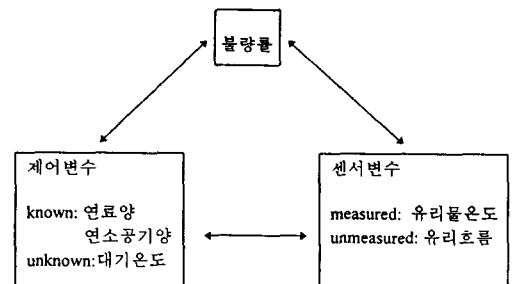


그림 1. 변수 간의 관계

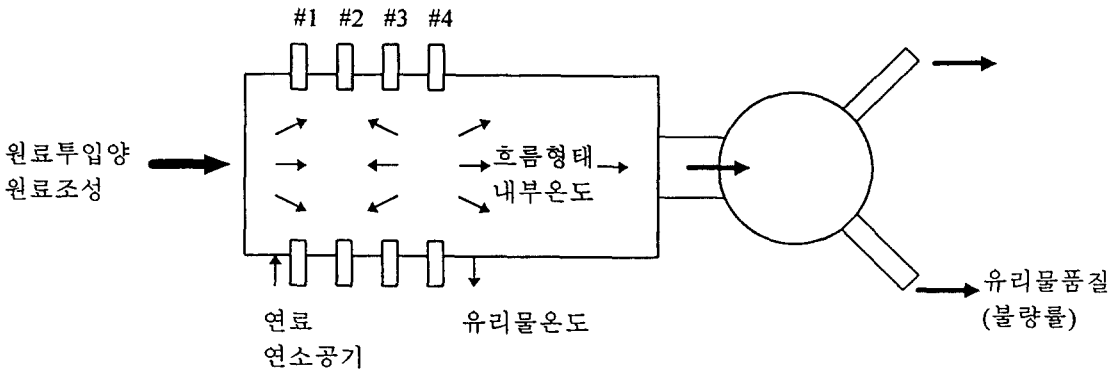


그림 2. 용해로 구조 및 관련 변수

였다. 제어 변수에는 원료의 투입속도, 연료의 양, 연소를 위한 공기의 양과 같이 작업자가 직접 조작할 수 있는 변수도 있지만 대기 온도등 조작이 불가능한 변수도 포함되어 있다. 그리고 용해로의 상태를 나타내는 변수의 그룹을 센서(Sensor) 변수로 정의 하였으며, 이를 불량률과 연계시켰다. 센서 변수에는 용해로의 온도와 같이 상태를 쉽게 감지할 수 있는 변수도 있지만 용해로 내부에서 고온으로 흐르는 유리물의 흐름형태등 상태의 감지가 매우 어려운 변수도 포함되어 있다. 용해로에서 발생하는 중요한 센서 변수와 제어 변수의 종류를 그림 2에 간략하게 표시하였다.

위와 같이 변수를 세가지 유형으로 분류한 이유는, 결국은 공정의 운전자가 변경할 수 있는 변수는 제어 변수이고, 제어 변수의 변경을 통하여 공정을 잘 운전하는 것이 최종 목표이기 때문이다. 위의 목표를 달성하기 위하여 첫째로 생각할 수 있는 방법은 현재의 불량률을 줄이기 위하여 제어 변수와 불량률의 관계를 분석함으로써 직접 제어 변수를 변경하는 방법이다. 이 관계에서 얻어진 해는 데이터의 정확성만 보장된다면 간단한 절차에 의하여 쉽게 구할 수 있겠으나, 현재까지 밝혀지지 않은 제어변수가 존재할 가능성이 많고 또한 이러한 변수의 존재를 알고 있더라도 인위적으로 조정이 매우 어려운 변

수들이 존재하기 때문에 제어 변수만을 가지고 직접 공정을 운전하는 것은 현재의 기술로는 어렵다고 볼 수 있다.

또 하나의 방법은 센서 변수와 제어 변수와의 관계를 파악함으로써 제어 변수를 변경하는 방법이다. 제어 변수의 변경은 센서값에 의하여 측정되므로 센서와 불량률과의 관계를 규명하고, 그 관계에서 불량률을 줄일 수 있도록 센서값을 변경한다. 그러나 이 방법은 용해로의 센서가 정확해야 한다는 전제 조건이 있어야 한다. 따라서, 본 연구에서는 앞에서 설명한 모든 변수를 고려하는 것 보다는 그림 3에 나타난 바와 같이 현장의 전문가들이 중요하게 생각해왔던 변수 중에서 조작이 가능하고 상태의 감지가 용이한 변수 만을 고려의 대상으로 삼았다.




그림 3. 본 연구의 고려 대상

2.2 신경망 모델

오류역전과 알고리즘은 일종의 지도학습(Supervised Learning)방법으로 실제의 출력값과 출력되기를 원하는 값 사이의 오차가 줄도록 가중치를 역방향으로 조정하여 오차의 평균제곱합 (Mean Squared Error)이 최소가 되도록 하는 반복 알고리즘이다. 이 알고리즘에는 미분이 가능한 함수가 필요하며, 본 연구에서는 Sigmoid Function을 이용하였다. 본 연구에서 이용한 학습 알고리즘을 간단히 정리하면 다음과 같다(김대수, 1993).

- (1) 가중치(Weight)와 Bias를 초기화한다.
- (2) 입력패턴과 원하는 결과치를 준다.
- (3) 주어진 입력에 대해 출력값을 계산한다.
- (4) 연결강도를 조정한다.
- (5) 단계 2에서 단계 4를 반복한다.

오류역전과 알고리즘을 이용하여 어떤 상태를 신경망에 학습을 통해 기억시키기 위해서는 입력값과 그에 따른 출력값을 동시에 주어야 한다. 이 시스템의 입력 패턴으로는 주로 용해로를 제어하는데 이용되는 변수들과 용해로의 상태를 알게해 주는 센서 변수의 값이 이용되었으며, 출력으로는 불량률이 이용되었다. 용해 불량은 용해로의 현재의 상태에서 약 8시간 내지 12시간이 경과한 후에 영향이 나타나는 것으로 추정되므로 이 경과 시간을 고려하여 패턴 데이터가 만들어졌다. 또한 선택된 변수들의 단위와 조작 범위가 모두 다르기 때문에 이들을 정규화하여 학습에 이용하였다. 여기에서는 입력층으로는 제어 변수와 센서 변수들을, 그리고 출력층으로 불량률을 패턴으로 하였다. 입력과 출력의 패턴을 이용하여 학습된 결과는 신경망의 연결강도로 표현되며, 이를 앞 장에서 시스템 방정식으로 정했다. 이 시스템 방정식은 데이터를 훈련시킴으로써 얻어지게 되는 데, 학습의

속도는 회로망을 어떻게 구성하느냐에 따라서 결정된다. 회로망을 어떻게 구성하는 것이 최상인가에 대해서는 일반적인 해가 정확히 밝혀지지 않았지만 Kolmogorov에 의하면 일반적으로 3층으로 충분하다는 연구 결과가 나와있다(Lippmann, 1987). 다층 퍼셉트론에서는 중간층의 갯수가 증가할수록 어떤 연결강도가 오차를 유발시키는지 알 수 없기 때문에 학습이 어려워지나 퍼셉트론이 형성하는 결정 구역의 특성은 더욱 고급화된다. 그러나 본 연구에서는 주어진 공정 데이터를 테스트한 결과 2개의 은닉층을 이용했을 경우에는 1개의 은닉층을 사용했을 경우보다 학습 속도와 주어진 오차대로 해가 수렴하는 속도가 다소 빨라졌기 때문에 2개의 은닉층을 그대로 이용했다. 그 이유는 용해 공정의 비 선형적인 특징에 있다고 판단된다. 따라서, 본 연구에서는 그림 4과 그림 5에서와 같이 입력층, 두개의 은닉층(Hidden Layer) 및 출력층의 4개 층으로 이루어진 신경망을 이용하였다. 그리고 신경망의 모델은 다대일(Many to one)로 설정하였는데 그 이유는 앞에서 설명한 것과 같이 제어 변수 또는 센서 변수의 변경된 내용이 모두 불량률로 반영이 되기 때문이며, 공정 운전자의 관심 사항도 제어 변수와 센서 변수값의 변경에 대한

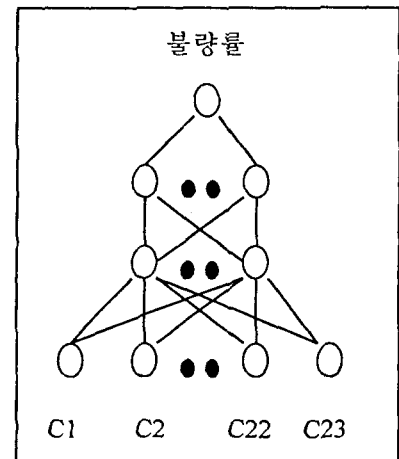


그림 4. 제어변수-불량률관계

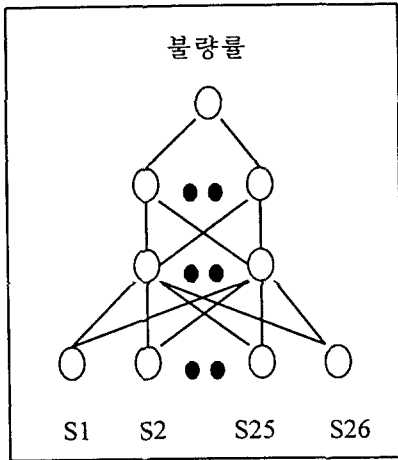


그림 5. 센서변수-불량률관계

불량률의 변화이기 때문이다.

2.3 최적화 과정

앞 장에서 용해 공정의 제어 변수와 센서 변수를 각각 입력으로 하고 용해 불량률을 출력으로 하는 다층 퍼셉트론으로 용해 공정의 입력 및 출력 관계를 형성하였다. 용해 공정 시스템의 제어에서는 용해로 운전 전문가들이 불량률을 제시된 허용치 이하로 낮추도록 운전 조절 변수값을 구하는 것이 가장 중요하다. 이는 학습이 완료된 다층 퍼셉트론의 입력과 출력 관계에서 역값을 계산하는 과정으로써 허용 불량률이 제시되면 그에 해당하는 운전 조절 변수값을 계산해내는 역값 계산 과정이다.

학습이 완료된 신경회로망에서 역방향으로 특정 출력값에 대한 입력값을 계산하는 과정은 신경회로망의 학습 알고리즘에서 특정 입력 패턴이 특정 출력값을 유도하도록 연결강도를 결정하는 과정과 유사하다. 신경회로망에서의 학습은 특정한 출력값을 유도하기 위하여 고정된 입력 패턴에 대하여 연결강도를 조정하는 과정이지만, 본 연구에서의 신경회로망의 역값 추적은 고정된 연결강도가 이미 주어

졌을 때 특정한 출력값을 발생시키는 입력값을 결정하는 과정이다.

이러한 점을 고려하여 입력 패턴과 연결강도 벡터를 뒤바꾼 후에 학습 알고리즘을 적용하면 신경회로망에서의 역값을 근사적으로 구할 수 있다. 그러나 용해 공정을 모형화 한 다층 퍼셉트론 구조에서는 입력 패턴과 연결강도 벡터를 뒤바꾸는 것이 불가능하다. 이는 다층퍼셉트론에서의 입력 패턴과 연결강도 벡터의 각 요소들이 일대일로 대응되지 않기 때문이다. 그러므로 본 연구에서는 역값 추적을 위하여 비선형 시스템에 부분 선형화를 적용하여 근사적으로 신경망의 출력값에 대한 입력값을 구하는 방법을 취하였다.

최적화란 현 상태의 불량률에서 원하는 목표 불량률로 가기 위한 최적의 Set-up 값을 구해내는 과정을 말하며 이 시스템의 최종 목표는 최적의 Set-up 값을 예측하는 것이다. 신경망 모델을 이용할 경우에는 일정 기간 동안의 실제 공정상의 데이터로부터 학습시킨 결과가 신경망의 각 노드의 가중치로 기억되며 이는 일정 기간의 운전상태를 의미한다. 따라서 학습이 완료된 상태에서 제어변수 또는 센서 변수의 값을 신경망의 입력으로 하여 출력값에 해당하는 불량률을 예측할 수 있다. 그러나 주어진 불량률로부터 역 방향으로 제어변수 또는 센서변수의 값을 얻어내는 과정은 비선형 시스템이기 때문에 쉬운 일이 아니다. 앞에서 설명한 것과 같이 다층 퍼셉트론의 다대일 관계로 부터 입력 패턴과 연결강도를 이용하여 다음 기간의 출력값을 예측하는 것은 신경망 모델로 가능하나, 주어진 출력값에(일대다 : one to many) 대한 입력값을 구하는 과정은 신경망을 통하여 직접 계산이 불가능하다. 따라서, 이 값을 구하기 위해서 비선형 시스템에 부분 선형화를 적용하여 근사적으로 신경망의 출력값에 대한 입력값을 구하는 방법을 취하였다. 부분 선형화를 위하여 아래와 같이 제 1차항 까지만 고려한 Taylor

확장 공식을 이용하였다(정강모, 1990).

$$f(X) = f(X_0) + f'(X_0)(X - X_0)$$

위의 공식을 이용하여 주어진 불량률로부터 제어 변수의 값을 구할 경우에 위 공식의 X_0 와 $f(X_0)$ 에 제어 변수와 불량률의 값을 각각 대입하고, 또한 전문가가 제시하는 불량률을 $f(X)$ 에 대입하여 X 를 구한다. 여기에서 $f'(X_0)$ 의 값은 신경망의 연결강도를 이용하여 구할 수 있으며 만족스러운 값을 얻을 때까지 X 를 다시 X_0 에 대입하여 반복적인 방법으로 X 를 구한다.

III. 응용 시스템의 개발

본 연구에서는 용해로의 운전조건에 따른 불량률을 최적으로 유지시키기 위하여 오류역전과 알고리즘을 이용하여 이를 모델링하고 실제공정의 운전 제약조건을 고려하면서 최적화 알고리즘을 이용하여 용해로의 최적 Set-up을 예측하는 일종의 의사 결정 지원 시스템을 개발하였다. 본 시스템은 Unix 운영체제에서 C 언어로 구현하였다. 처음에는 User Interface를 X Window/Motif를 이용하여 개발하고 X-terminal을 사용하였으나, 사용자가 이용하기에 불편하였기 때문에 Power-builder를 이용한 Client/server 구조로 전환하여 PC에서 이용할 수 있도록 하였다. 시스템의 구성도는 그림 6에 표시 하였다. 이 시스템은 일정 기간의 용해로의 상태 변화와 불량률 사이의 관계를 신경망을 이용하여 훈련시킨 뒤에 실제 공정 운영상의 제한 조건을 고려하여 중요한 변수들의 최적 Set-up 값을 예측해 낸다. 또한 Set-up 값의 사전 simulation 기능도 수행한다. 이 시스템은 그림 7에 나타난 것과 같이 데이터의 사전처리, 데이터 학습,

최적화, 시뮬레이션등을 수행할 수 있는 기능들로 이루어져 있다. 이러한 기능들을 이용하여 시스템의 사용자들은 데이터 자동변환, 학습 및 결과 평가, 중요 변수 선택, 최적으로 예측된 Set-up값, Simulation, 운전변수의 추이등을 참조할 수 있으며, 이를 통하여 공정을 효율적으로 운영할 수 있게 된다. 각 기능에 대하여 다음 장에서 간단히 설명하였다.

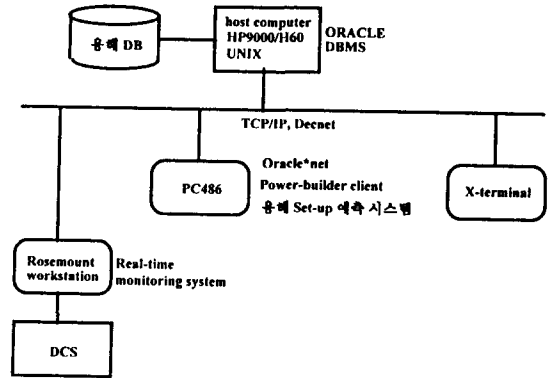


그림 6. 전체 시스템 구성도

3.1 학습 사전 처리

오류역전과 알고리즘을 이용하여 용해로의 상태를 학습시키기 위해서는 입력값과 그에 따른 출력값을 동시에 주어야 한다. 이시스템의 패턴 데이터로 사용되는 입력에는 주로 용해로의 제어에 이용되는 변수들과 용해로의 상태를 알게해 주는 센서값이 이용되며, 출력으로는 불량률이 이용된다. 용해 원료의 투입에서 부터 제품이 형성되는 시간은 대략 8시간에서 12시간이 소요되므로, 이를 반영하여 패턴 데이터를 준비하였다. 센서 변수로는 주로 용해로의 온도 데이터를 이용 하였고, 제어 변수로는 연료의 유량 및 연소공기량, 불량률로는 용해 불량률을 이용하였다. 여기서 사용된 변수의 값은 모두 0과 1사이로 정규화 하였는데 그 이유는 각 변수들의 운전

범위가 상이하고 데이터의 훈련시에 activation function의 계산을 손쉽게 하기 위해서이다.

신경망을 이용하여 용해로의 상태를 학습시키기 위해서는 학습에 필요한 여러가지 조건들을 사전에 설정할 필요가 있다. 학습의 조건에는 신경망의 구성에 필요한 네트워크 노드 갯수, 네트워크 층 수, Target 값, 학습률(Learning rate)등 오류역전파 알고리즘을 적용하기 위한 각종 변수값들이 포함된다. 앞에서 설명한 바와 같이, 본 연구에서는 센서 변수의 입력으로 23개의 노드, 제어 변수의 입력으로는 37개의 노드를 각각 이용하였으며 출력으로는 한 개의 노드를 이용하였다. 그리고 은닉층에는 20개의 노드를 각각 이용하였다. 일정 기간 동안의 용해로 운전 상태를 파악하기 위해서는 이 기간 동안의 공정 데이터가 이용된다. 공정 데이터는 용해로의 각종 센서로 부터 실시간으로 생성되고 있으며 그 중에서 용해로의 상태를 파악하고 운전하는 데 있어서 중요하다라고 생각되는 약 50개의 변수들을 선택하고 이로부터 신경망 학습에 필요한 패턴 데이터를 생

표1. 학습 조건의 설정값

항 목	학습 조건 값
입력층의 데이터 종류	제어 변수, 센서 변수
출력층의 데이터 종류	불량률
각 은닉층의 유니트 갯수	20
Time delay	8시간
Time interval	20분 데이터 1일 1시간 데이터 3일 1일 데이터 1달
학습시의 허용 오차율	0.01
오차 한도	0.003
momentum	0.5
학습률(Learning rate)	0.1
훈련 횟수	최저 50, 최대 1000
데이터 타입	raw data, 가공된 데이터

성하였다. 학습조건은 표 1과 같이 설정하였으며 시스템에서 각각의 값을 변경하여 사용할 수 있도록 하였다.

패턴 데이터는 ORACLE 관계형 데이터베이스에 저장되어 있는 데이터로 부터 그대로 생성할 수 있도록 하였다. 그리고 저장된 데이터 중에서 불필요한 부분은 제거하고, 필요에 따라서 데이터를 가공하여 이용할 수 있도록 하였다. 이를 위하여 각 변수 별로 사전에 정의한 기준범위를 벗어나면서 공정에 영향을 주지 않는 데이터는 육안으로 판단한 후에 시스템에서 자동으로 제거하도록 하였다.

그리고 시스템의 예측 정확도를 높이기 위하여, 현장에서 발생하는 데이터 중에서 일시적인 센서의 고장등으로 인하여 값이 부정확한 데이터들은 재가공하여 이용하였다. 예를 들어서, 온도계에서 읽어들이는 값이 보통은 수백도에서 부터 약 1500도의 범위 내에서 변경되는 데 접촉 불량으로 인하여 가끔 온도계의 접점이 단락이 되어 온도가 짧은 시간 내에 급격히 내려가는 경우가 가끔 발생하였다. 이러한 경우에는 온도의 값이 실제 공정에 아무런 영향을 미치지 못함에도 불구하고 온도 자체에는 매우 많은 영향을 주기 때문에 학습을 제대로 할 수 없었다.

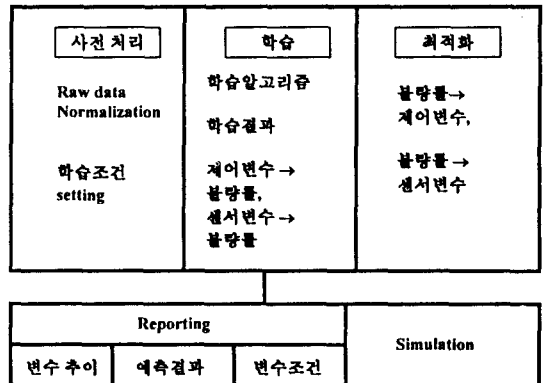


그림 7. 응용 시스템 구조

3.2 학 습

데이터의 사전처리에 의해 생성된 패턴 데이터를 오류역전과 알고리즘을 이용하여 학습시키기 위하여, 일 단위로 집계된 데이터를 주로 이용하였으며 장기적인 분석을 하기 위하여 월별, 분기별 데이터도 이용하였다. 이 시스템에서는 앞 장에서 언급된 바와 같이 두가지의 측면에서 분석이 행하여 지는데 하나는 용해로 제어 변수들과 불량률과의 관계이며, 또 다른 측면은 용해로의 온도 변화와 같은 센서 변수와 불량률과의 관계이다. 첫번째 측면을 위하여 입력층으로 제어 변수들을, 출력층으로는 불량률을 이용하였다. 두번째 측면에서는 입력층으로는 센서 변수들을, 출력층으로는 불량률을 패턴 데이터로 이용하였다.

용해로에서 발생하는 데이터는 공정의 말단인 계측기 또는 센서로 부터 수 초 간격으로 발생하며 공정의 특성상 데이터를 1분, 20분, 1시간, 일별로 집계하여 학습시켰다. 분 단위로 발생된 데이터를 이용하여 학습시켰을 경우에는, 학습이 거의 안되었던 반면에, 일별로 집계된 한달 동안의 데이터를 이용했을 경우에는 공정 운전자가 생각한 방향과 유사하였다. 이것은 용해 공정의 특성이 천천히 변하기 때문인 것으로 추정되며, 이와 같이 용해 운전 데이터는 단기간 내에 변동이 많을 경우에는 학습이 잘 되지 않았으며, 학습 결과치도 부정확하게 나타나는 특성을 가지고 있다.

학습 과정에 있어서 한번에 학습이 되지 않거나 여러번 시도하는 경우가 많았으며, 이를 위하여 공정 데이터의 이상 유무 확인을 하였고, 이상 데이터가 존재할 경우에는 이를 제거 또는 가공한 후에 이용하였다. 학습의 횟수가 적을 경우에는 결과치의 산출까지 시간이 오래 소요되었으며, 또한 적정 학습 횟수 지정이 어려웠다. 이를 위하여 변수의 가중치 조정과 학습조건등을 변경하여 테스트하였으나, 용해

데이터의 성격에 따라 달라져서 일관성을 유지하기가 힘들었다.

용해 부문의 문제는 조치는 보통 8시간 내에 이루어지기 때문에 현장에서는 가능한 짧은 시간 내에 예측결과가 나와야 하며, 또한 이를 적시에 활용할 수 있어야 한다. 그러나, 데이터 학습에는 제어 변수와 센서 변수 각각 약 3시간 정도로 많은 시간이 소요되었기 때문에 현장에서 사용하기에는 불편하였다. 용해 공정의 변동 상황을 가능한 한 많이 공정 데이터로 부터 추적하기 위하여 새로운 데이터를 계속 추가 시키면서 학습 시킴으로써 (dynamic하게 이용) 예측치 계산시에 가장 최근의 정보를 반영하였으나 계산 시간이 오래 소요 되었기 때문에 이미 계산된 한 달간의 연결강도 데이터를 이용하였다(static 하게 이용).

3.3 최적화 과정

앞 장에서 설명한 것과 같이 최적화 과정은 본 연구의 최종 목표라고 할 수 있다. 실제 공정상의 데이터를 이용하여 일정한 기간 동안 학습 시킨 결과는 신경망의 연결강도로 저장되며 이는 일정 기간 동안의 용해로의 운전 상태를 의미한다. 이것은 이미 2.3장에서 설명하였는 데, 이를 쉽게 표현하면 $b=f(a)$ 라고 할 수 있다. 여기서 목표로 하는 불량률을 c 라고 하면, $a=f(b)$ 일 경우에 $c=f(x)$ 를 만족하는 x 의 값을 구하는 것이다. 이 문제를 해결함에 있어서 현재 상태에서 학습을 통하여 시스템 방정식을 알았을 때, 가장 작은 불량률의 값을 구해야 하는 것이 타당하다. 그러나 모든 경우에 있어서 불량률의 최소값을 구하는 것은 또 하나의 다른 문제 영역으로 간주하는 것이 좋다. 그렇기 때문에 본 연구에서는 어떤 특정한 불량률(예를 들면 현재의 불량률이 20%라고 가정하면 10%의 불량률)이 되기위한 입력값을 구하는 방법을 채택하였다.

위에 설명한 최적화 방법의 어려움은 편미분 값이 신경망을 통해서 얻어지기 때문에 주어진 영역 내에서 해를 못 찾는 경우가 종종 발생하였다. 이러한 경우에는 편미분값의 방향에 따라서 이미 정해 놓은 각 변수의 상한값 또는 하한값으로 대치함으로써 문제를 해결하고자 하였다. 용해공정 시스템은 거의 완만한 surface로 표현되므로 위의 방법이 타당한 것으로 생각되었다.

앞에서 설명된 것과 같이 훈련된 데이터와 현재의 공정 데이터를 이용하여 향후 불량률과 관련된 변수의 예측치를 구하는 것이다. 최적화에서 불량률을 특정 목표치로 낮추고자 할 때에, 목표치와 훈련 데이터를 이용하여 목표치에 대응되는 Set-up 값을 구한다. 이 값을 구하기 위하여 2.3장에서 설명한 Taylor expansion을 이용하였다. 신경망을 이용하여 변수와 불량률의 예측치를 구하는 과정은 다음 장에서 자세하게 설명되므로, 이 장에서는 특정한 목표 불량률로 가기 위한 제어 변수의 값을 계산한 예를 들기로 한다. 이에 대한 자료는 표 2에 간단하게 예시하였다. 표 2는 현재의 불량률이 25.9%일 경우에 5.9%를 낮춘 20%의 불량률 목표치로 가기 위하여 그림 2에 나타난 첫번째의 연료양과 공기양을 계산한 값이다. 이 경우에는 연료양을 24.4 l/hr, 공기양을 219.95 cubic meter/hr 만큼 올려야 한다는 것을 제시하고 있다.

표2. 최적값 계산 예

변 수	현재값	최적값	차 이
#1 연료양	520.56	545.0	+24.44
#1 공기양	4655.05	4775.00	+219.95

용해로의 최적 Set-up을 예측하더라도 이를 실제 공정에 모두 적용 시키기는 어렵다. 왜냐하면 50 여 개나 되는 변수들을 조종하여 예측한 Set-up 값과

완전히 일치시키기는 현실적으로 불가능하기 때문이다. 따라서 이들 변수들 중에서 불량에 영향을 많이 주는 변수를 선택한 후에 공정의 전문가가 그들의 경험을 반영하여 제어 변수의 설정값을 결정하도록 하였다.

3.4 시뮬레이션

신경망 방법의 특징은 학습을 통하여 과거의 상황을 신경망이 기억하고 있다면 이와 유사한 상황에 대해서 쉽게 그때의 상황을 판별해 낼 수 있다. 특히 용해로는 시간이 지남에 따라 자체의 특성이 달라진다. 만약에 이러한 용해로의 특성을 장기간 동안 잘 기억시킬 수가 있다면 유사한 경우 쉽게 도움을 받을 수 있다. 또한 용해 공정은 제품의 불량이나 오기까지 시간적인 간격이 있으므로 과거의 운전 상태를 신경망이 잘 기억하고 있다면 향후의 불량률을 쉽게 예측할 수 있다. 시뮬레이션 기능을 이용하여 엔지니어가 Set-up 값을 변경하려고 할 경우에, 사전에 Set-up 값을 시뮬레이션 해보고 그 결과를 참조할 수 있도록 하였다. 용해 담당자가 현재의 공정데이터를 그대로 사용하지 않고 값을 바꾼 후에 불량률의 예측치를 구해 볼 수 있으며, 바꾼 값과 불량률의 예측치가 바람직할 경우에는 이 때의 값을 Set-up치로 적용할 수도 있다.

3.5 기타 지원 도구

현장의 숙련된 운영자들은 불량률의 원인을 파악하기 위하여 많은 데이터를 축적한 후에 이를 수작업으로 가공하여 분석하거나 또는 여러가지 시스템 도구들을 활용하고 있다. 이러한 도구들 중에서 항상 필요로 하는 레포트와 변수들의 추세에 관한 그래프는 시스템에서 제공할 수 있도록 하였다. 이 시스템에서는 각 변수들의 경향성을 볼 수 있도록 데이터베이스와

연결하여 각종 그래프를 제공하였고 쉽게 변수들을 비교해 볼 수 있도록 하였다. 또한 변수들의 최소값, 최대값등 운전조건에 관한 여러가지 필요한 기능을 제공하여 사용자들이 사용하기에편기하게 구성하였다.

공정의 운전자들이 사용하는 도구들이 매우 다양하므로 데이터를 쉽게 입력하고 패턴 데이터등 필요한 데이터를 주어진 조건에 따라서 자동으로 생성할 수 있도록 하였고, 변수 선택등 조건 설정은 보통은 기준값(default)을 이용하도록 하였고 다양한 분석을 위하여 이미 주어진 기준값을 변경하여 여러가지의 선택적인(option) 경우에도 분석을 할 수 있도록 하였다. 따라서, 시스템을 이용할 경우에 변수의 선택에 제한이 없도록 하였다.

데이터의 입력 시에 데이터를 그래프화 하여 눈으로 쉽게 확인할 수 있도록 하였고, 또한 수정 및 편집 후에도 그래프로 데이터를 쉽게 확인한 후에 저장 할 수 있도록 하였다. 그리고 결과 데이터를 그래프화 하고 쉽게 분석하기 위하여 변수의 범위를 다양하게 볼 수 있도록 각 변수값에 대하여 확대 또는 축소하여 볼 수 있도록 하였다.

IV. 실험 결과 분석

본 연구를 위하여 여러가지 종류의 공정 데이터에 신경망 알고리즘을 적용하였다. 실제 공정에서는 수 초 간격으로 변수의 값이 실시간으로 발생하나, 실제 분석을 위해서는 이 데이터를 분, 시간, 일 단위로 집계한 후에 이용하였다. 앞 장에서 설명한 것과 같이 용해 운전 데이터는 단기간에 발생된 데이터를 이용할 경우에는 학습이 잘 되지 않았으며, 학습 결과치도 부정확하게 나타나는 특성을 가지고 있기 때문에 본 연구에서는 주로 일 단위로 집계된 데이터를

이용하였다. 표 2는 과거 한달 간의 센서에 관련된 공정 데이터를 신경망을 이용하여 학습시킨 후에 예측된 센서변수의 예측치를 보여준다. 이 결과치에 관하여 분석해 보면 용해로 각 부분의 온도가 그동안 낮게 운전되었다는 것을 알 수 있다. 따라서, 온도를 전반적으로 상승하라는 방향으로 시스템이 예측하고 있다는 것으로 해석 할 수 있다.

표 2. 센서변수 예측 결과

변 수	실제값	예측값	차 이
S1 (#1 온도)	1130.1	1176.9	46.8
S2 (#2 온도)	1124.2	1134.6	10.4
S3	1111.4	1124.8	13.4
S4	1106.0	1154.8	48.8
S5 (유리물온도)	1238.1	1287.9	49.8
S6	1306.8	1345.2	38.4
S7	1496.3	1511.8	15.5
S8	1555.7	1587.7	32.0
S9	1614.5	1623.7	9.3
S10	1616.9	1662.4	45.5
S11	1575.6	1595.3	19.7
S12	1504.8	1530.3	25.5
S13	1354.4	1397.5	43.1
S14(용해로온도)	843.4	856.9	13.5
S15(용해로온도)	338.2	378.8	40.6

비슷한 방법으로, 표 3은 과거 한달 간의 제어와 관련된 공정 데이터를 신경망을 이용하여 학습시킨 후 예측된 제어변수의 Set-up 예측치를 보여준다. 이 결과치에 관하여 분석해 보면 첫번째 제어변수 C1(그림 2에서 #1의 연료양에 해당함)과 네번째 제어변수 C4(그림 2에서 #4의 연료양에 해당함)의 Set-up 값을 낮추고, 마찬가지로 C2와 C3는 증가시키는 방향의 Set-up치를 제시하고 있다. 이 당시의 용해로의 운전 상태를 분석해 보면 각 센서별로 온도의

표 3. 제어변수 예측 결과

변 수	실제값	예측값	차 이
C1 (연료양)	543.2	537.5	-5.7
C2	593.9	601.3	7.4
C3	624.1	698.6	74.5
C4 (연료양)	336.3	330.8	-5.5
C5	543.3	537.6	-5.7
C6	594.2	601.7	7.5
C7	624.1	698.7	74.6
C8	336.0	330.5	-5.5
C9 (연소공기양)	4791.3	4740.2	-51.1
C10	6144.0	6237.5	93.5
C11	5809.8	6406.0	596.2
C12	3829.5	3821.3	-8.2
C13 (원료투입양)	1648.3	2802.2	1153.9
C14	4786.8	4735.7	-51.1
C15	6141.3	6234.8	93.5

편차가 일정하게 유지되어야 하나 일부 국부적으로 낮게 운영되어온 것을 알 수 있었다. 또한, 시간이 경과됨에 따라 온도가 부위별로 하락 하기도 하여 일부 생산라인에서 불량률이 증가 되었음을 알 수 있었다. 이 당시의 공정 상황과 시스템에서 제공한 예측치를 실제 공정에 적용한 결과를 표 4에 요약 하였다. 실제 조치를 취한 후의 용해로 운전 상태를 표 4를 통하여 보면 전반적으로 센서변수의 값이 증가되었고 용해 불량률이 감소되었음을 알 수 있다. 따라서, 이 당시에 전문가들이 예측하였던 공정의 상황은 신경망 학습에 의한 시스템의 예측 결과와 유사하였다.

V. 결론 및 향후 연구방향

본 연구는 신경망 학습 알고리즘을 이용하여 용해

표 4. 주요 변수와 불량률 경향

변 수	7 월	8 월	차 이
센서변수			
S1 (유리물 온도)	1303.4	1303.7	0.3
S2	1313.9	1315.6	1.7
S3	1325.6	1325.5	-0.1
S4	1294.7	1295.7	1.0
S5	1339.4	1341.5	2.1
S6	1265.2	1267.5	2.3
S7	1274.9	1277.8	2.9
S8	1266.4	1267.7	1.7
S9	1281.9	1284.0	2.1
제어변수			
C1 (연료양)	541.0	542.3	1.3
C2	590.8	592.3	1.5
C3	620.3	620.7	0.4
C4	334.3	334.7	0.4
불량률			
P (용해 불량률)	31.8	30.4	-1.4

공정의 상태와 불량률과의 상관 관계를 파악하고, 여기에서 도출된 용해로의 최적 Set-up을 공정에 적용함으로써 운전을 안정적으로 하며, 또한 용해 불량률을 줄이고자 하는 데 목적이 있다. 본 연구에서는 신경망의 기법을 이용하여 이를 해결하고자 하였다. 신경망을 이용하여 용해로의 시스템 방정식을 구할 수 있었으며, 이를 용해공정에 적용할 수 있었다. 그리고 실제 공정에서는 시스템에서 예측된 Set-up 값과 엔지니어의 경험을 병행하여 판단함으로써 시행착오를 줄일 수 있었다.

현재 이 시스템이 제시한 예측 결과를 분석해 보면, 주어진 변수 및 데이터의 범위 내에서는 신경망을 이용한 방법이 실제 공정의 운전 상태를 유사하게 모델링하는 것으로 분석되고 있다. 그러나, 제어 변수와 불량률과의 관계를 신경망을 통하여 모델화하고

최적화 방법을 이용하여 적절한 불량률을 유지할 수 있도록 변수의 값을 예측하는 과정에서 원하는 출력값이 적절한 값을 가질 수는 있었으나, 모델의 구조가 복잡하고 최적화 과정에서 사용한 가정들로 인하여, 이들의 값이 최적값인지 증명 하기는 어려웠다. 따라서, 신경망 모델을 공정의 현업에 정착 시키기 위해서는 예측결과의 정확도를 향상시키고 신뢰성을 높이는 것이 필요하다. 이를 위하여 향후에 진행해야 할 일은 다음과 같다.

- (1) 본 연구에서 이용한 모델은 제어 변수와 불량률, 센서 변수와 불량률의 두개의 모델을 독립적으로 사용하였기 때문에 제어 변수와 센서 변수와의 관계를 모두 포함한 모델화가 필요하다.
- (2) 여기에서 이용한 알고리즘이 최적의 결과를 가져 오는지에 관한 검증이 필요하며 이를 위하여 신경망의 여러가지 알고리즘에 관하여도 비교할 필요가 있으며, 또한 공정 데이터를 일별, 월별, 분기별등 보다 다양한 데이터를 이용하여 학습함으로써 특정 모델에 적당한 데이터를 찾아내야 할 필요가 있다.
- (3) 모델에서 이용한 데이터의 항목 선정과 데이터 자체의 가공이 과거의 경험에 의존하였기 때문에 이를 검증하기 위해서는 통계적인 방법등을 이용하여 입력 데이터의 선정을 보다 객관화 할 필요가 있으며, 또한 데이터에 잡음(noise)이 섞이지 않도록 공정 데이터의 가공 방법에 관한 연구도 필요하다.

참 고 문 헌

- Hopfield J. J. and D. Tank, "Neural Computation of Decisions in Optimization Problems", *Biological Cybernetics*, Vol.52(1985), 141-152.
- Kohonen T. K., "Self-Organization and Associative Memory", Springer-Verlag, Berlin, 1984.
- Kohonen T. K., "The Neural Phonetic Typewriter", *IEEE Computer*, Vol.21, No.3(1988), 11-22.
- Lippman R. P., "An Introduction to Computing", *Neural Network*, vol.1(1988), 3-16.
- Lippman R. P., "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, April(1987), 4-22.
- Pao Y. H., *Adaptive Pattern Recognition and Neural Networks*, Addition-Wesley, MA, 1989.
- Rumelhart D. E., G. E. Hinton, and R. J. William, "Learning Internal Representation by Error Propagation", in *Parallel Distributed Processing*, The MIT Press, Vol.1(1986), 318-362.
- 김대수, *신경망 이론과 응용(I)*, 하이테크 정보, 1993.
- 정강모, "Process 운영 법칙을 고려한 최적화", *삼성기술원 기술보고서*, TR-007-KMJUNG-NN, 1990.