

신경회로망을 이용한 원유정제공정에서의 조성식별방법에 관한 연구

A Study on a Neural Network-Based Feed Identification Method in Crude Distillation Unit

이인수 · 이현철* · 박상진** · 이의수***

In Soo Lee, Hyun Cheol Lee*, Sang Jin Park** and Euy Soo Lee***

상주대학교 전자전기공학부, * 서울대학교 제어계측기술연구원

** 동국대학교 화학공학과, *** 동국대학교 화학공학과

요 약

본 논문에서는 원유정제공정에서의 조성을 효율적으로 예측하기 위한 신경회로망을 이용한 조성식별방법을 제시한다. 제시한 신경회로망을 이용한 조성식별기(FINN)는 학습모드와 예측모드로 구성된다. 또한 Borland C++(3.0) 빌드로 신경회로망 원료자동분석 소프트웨어 시스템을 구현하였다. 그리고 시뮬레이션을 통해 제안한 신경회로망을 이용한 조성식별방법의 유용성을 확인하였다.

ABSTRACT

In this paper, we propose a feed identification method using neural network to predict feed in crude distillation unit. The proposed FINN(feed identifier by neural network) is functionally composed of two modes-training mode and prediction mode. Also, we implement a neural network-based soft sensor system using Borland C++(3.0) Builder. The effectiveness of the proposed neural network-based feed identification method is shown by simulation results.

1. 서 론

에너지를 다량 소모하는 정유, 석유화학, 화학공장 과 같은 장치산업에서 공장 운전시 에너지 절약과 비용절감을 위해서는 공정에서의 에너지 관련 변수 및 에너지 효율을 항상 감시할 수 있어야 한다. 이를 위해서는 에너지와 관련된 변수를 공장 운전과 동시에 정확히 측정하고, 설비의 에너지 효율을 실시간대에 능동적으로 분석할 수 있어야 한다. 원료의 분석방법으로는 먼저 하드웨어적인 방법을 들 수 있으나 조성을 실시간으로 측정하기 위한 장치는 고가일 뿐만 아니라 분석시간이 너무 많이 소요되므로 하드웨어적 장치에 의한 실시간 원료 분석은 쉽지 않다. 이에 반해서 소프트센서(soft sensor)는 제품조성과 밀접한 연관이 있는 다른 공정변수들로부터 간접적으로 제품조성을 추정하는 추정기이다. 그러므로 이를 이용하여 실시간에 생산되는 제품의 규격을 예측하여 운전조건을 조절한다면 제품품질의 손실을 막고 과잉 에너지 소비를 줄임과 동시에 하드웨어 센서의 투자 및 유지보수에 따른 비용을 크게 절감할 수 있다.

소프트센서는 대상공정에서 조성을 가장 근사하게

추정할 수 있는 측정 가능한 공정 변수의 종류와 개수를 선정하고, 대상공정에 가장 적절한 방법을 이용하여 선정된 공정 변수와 조성간의 관계를 표현함으로써 설계가 가능하다. 증류공정에서 조성추정을 위해 가장 널리 사용되고 있는 방법은 단(tray)의 온도를 이용하는 것이다[1-3]. 선정된 공정변수와 조성간의 관계를 표현하는 방법은 크게 이론적 모델표현법과 경험적 모델표현법으로 나눌 수 있다. 먼저, 이론적 모델표현법은 공정의 거동을 물질 및 에너지 방정식 등에 근거한 수학적 모델로 표현하는 것으로서 다성분 증류공정과 같이 공정이 복잡하고 파라미터가 많은 경우에는 모델 설계가 쉽지 않다. 이에 반해서 경험적 모델표현법은 실제공정 또는 모사기(simulator)로부터 획득한 데이터를 이용하여 공정변수와 조성간의 관계를 설정하는 방법으로서, 이론적 모델표현법과 비교할 때 비교적 간단하다는 장점이 있다. 근래에 와서 컴퓨터 활용기술이 보편화되면서 막대한 양의 데이터 저장뿐만 아니라 데이터를 실시간으로 받아들이고 처리하는 것이 가능해짐에 따라 데이터를 기반으로 한 경험적 모델링에 의한 증류공정의 소프트센서 설계에 관한 연구가 더욱 활발해지고 있다. 1990년대부터 PCR(principal component regression), PLS(partial least

square)등과 같은 다변량 통계 분석방법이 증류공정의 소프트웨어기술에 도입되었으나[4,5], 이 방법들은 선형모델링 기법이기 때문에 복잡하고 비선형성이 강한 증류공정의 경우에는 추정성능이 좋지 못하다.

최근 신경회로망의 이론 및 학습방법의 발전으로 기존의 이론으로는 풀기 어려운 많은 문제에 신경회로망을 이용하려는 연구가 활발히 진행 중이다. 신경회로망은 병렬처리가 가능하므로 처리속도면에서 이점이 있으며 입력이 다소 불완전하고 잡음을 포함한 경우라도 큰 효과를 발휘할 뿐만 아니라 학습의 기능도 있다. 특히 입출력 데이터로부터 비선형함수 표현이 가능하다. 이러한 장점으로 인해 신경회로망은 패턴인식, 신호처리 및 영상처리, 패턴분류 문제 및 고장진단분야 등에 성공적으로 적용되고 있을 뿐만 아니라 비선형성이 강한 많은 공정 분야에 신경회로망이 적용되어 좋은 성과를 보여왔다[6-11].

본 논문에서는 공정운전중에 측정되어지는 공정의 각종 실시간 데이터들인 온도, 압력, 유량 등과 같은 공정의 제어 값들과 온라인 분석기로부터 얻어지는 제품규격(product specification), 산출데이터(yield data) 등으로부터 원유의 조성을 단시간 내에 효율적으로 식별(identification)하기 위한 신경회로망을 이용한 소프트웨어를 설계한다. 즉, 조성과 관련된 공정변수가 매우 많고 복잡할 뿐만 아니라 공정운전중에 얻어지는 각종 공정 제어 값들과 조성과의 관계는 매우 비선형적이어서 이들의 함수관계를 수식화하는 것은 쉽지 않다. 그러므로 신경회로망의 장점을 이용하여 공정제어 값들과 조성과의 관계를 신경회로망으로 학습한 뒤 원유의 조성을 식별하였다. 또한 신경회로망 조성식별기의 조성예측성능을 향상시키기 위한 적절한 데이터 전처리 방법을 제시한다. 그리고, 현재 상업적으로 운용 중인 원유 정제용 상업증류탑을 대상으로한 공정모사기로부터 획득한 데이터를 이용하여 신경회로망 조성식별기(FINN : feed identifier by neural network)의 성능을 확인하였다.

2. 원유정제공정의 공정모사

본 논문에서는 현재 상업적으로 운용 중인 원유 정제용 상업증류탑을 대상으로 원유의 조성식별 모델 개발을 위한 공정자료의 수집과 상용 공정 모사기를 이용한 증류공정 모사를 수행하였으며, 이로부터 획득한 운전데이터를 가지고 제한한 조성식별기의 조성예측 성능을 확인하였다. 본 논문에서 개발대상으로 하는 증류공정도는 그림 1과 같다.

공정모사의 과정에서 실제 운전데이터에 근접하는

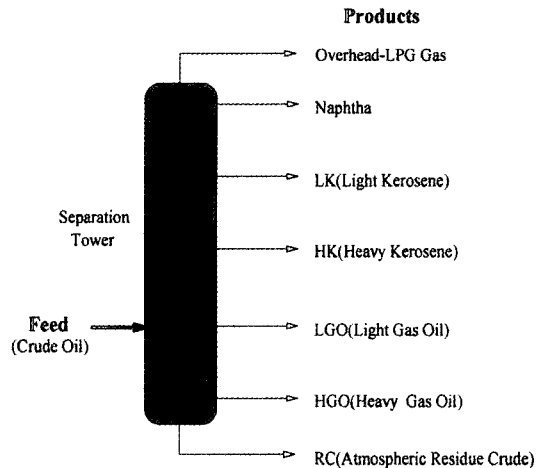


그림 1. 개발대상 증류공정도
Fig. 1. Diagram of the distillation unit

결과와 구현을 위하여 노(furnace)를 column stage의 히터(heater)로 해석하고 모델링하여 효율적인 에너지 수지를 계산하고, 효과적인 조성 분석(feed characterization)을 위하여 내삽 및 외삽기법, 분별(fractionization)기법들을 활용하였으며, 다양한 열역학 방법들의 선정을 통한 여러 가지 형태의 물성 예측식 적용, 고정변수선정(specification and vary variables) 등을 통하여 신뢰성 있고 표준화된 공정모사기법을 확립하였다. 원유의 성상 해석을 위해서는 공정운전데이터와 기준조성(reference feed)과의 상관관계를 규명하기 위해 세 가지 다른 종류의 증류데이터(assay data), 즉 제품으로부터 역혼합(backmixing)한 TBP(true boiling point) 데이터, slice TBP 데이터 및 다양한 원유의 배합 비율에 따라 blending한 TBP 데이터를 이용하여 비선형 회귀기법을 통한 제품의 성상 및 공정운전 변수에 대한 모델링 개발용 기초데이터를 구축하였다.

그리고 Shortcut Method를 사용하여 공정모사에 필요한 이론단수를 구하였으며, 공정모사결과와 실 공정을 비교 분석하기 위해서는 기준이 되는 고정변수가 있어야 하는데 일반적으로 열량, 유량보다는 온도와 압력계기가 정확하기 때문에 이를 고정 변수로 정하였다.

본 공정의 모사는 Simulation Science사의 PRO/II with PROVISION을 사용하였으며, 공정모사 결과 Light gas영역에서는 다소 차이가 있었으나 실 공정과 근사한 공정모사 결과를 얻을 수 있었다. 따라서 전술한 방법을 통해 실 공정의 여러 가지 경우를 공정모사하여 분석함으로써 원유의 조건변화에 따른 공정의 변화를 예측할 수 있으며, 최적의 운전조건을 예측할 수 있다. 다음 장에서는 모사기로부터 획득한 데이터

로부터 원유의 조성을 예측하는 방법에 대해서 서술한다.

3. 신경회로망 조성식별기 (FINN) 를 이용한 소프트센서

소프트센서는 그림 2와 같이 FINN과 입력데이터의 전처리부(data preprocessing)로 구성이 된다. 전처리부는 FINN의 구축시 신경회로망 모델의 정확성을 높이기 위해서 학습데이터를 조절(data scaling)하는 부분으로서, 본 연구에서는 신경회로망의 학습효과를 높이기 위해서 입출력 데이터의 크기를 조절했다. 그리고, 조성을 예측하는 부분인 FINN은 학습모드(training mode)와 조성예측모드(prediction mode)로 동작한다. 먼저, 학습모드는 실험을 통해 획득한 입출력 데이터로부터 FINN을 구축하는 과정으로서 세단계로 구성된다. 첫 번째는 신경회로망의 노드(입력노드, 은닉노드 및 출력노드)수 및 층(layer)수, 학습률등을 포함한 신경회로망의 구조를 선택하는 단계이다. 두 번째는 입출력 데이터로부터 신경회로망을 학습하는 단계이다. 마지막으로 세 번째는 학습된 신경회로망을 테스트하는 단계이다. 다음으로 조성예측모드는 학습된 신경회로망의 가중치를 고정하고 입력정보들로부터 원유의 조성을 예측하는 단계이다.

3.1 데이터의 전처리 (data preprocessing)

본 논문에서는 FINN의 학습 및 조성예측성능을 향상시키기 위해 다양한 크기를 갖는 여러 가지 입력데

이터를 FINN의 입력으로 사용하기 전에 크기를 조절하는 전처리과정을 수행한다. 학습데이터쌍은 FINN의 입력노드에 입력되는 값과 FINN이 예측하고자 하는 원하는 출력값으로 구성된다. 먼저, FINN 입력노드로의 입력값에 대한 크기조절은 모든 학습데이터쌍들의 입력값들 중에서 최대값을 조절인자(scaling factor)로 사용하여 입력값들의 정규화를 행하였으며 이를 식으로 표현하면 아래와 같다.

$$x_i = \frac{x_i}{X_{\max}} \triangleq \frac{x_i}{\max_{i,p} \{x_{ip}\}} \quad (1)$$

여기서 x_i 는 FINN의 i 번째 입력노드의 입력값이며, x_{ip} 는 신경회로망의 학습을 위한 입출력데이터쌍 중에서 p 번째 학습데이터쌍에서 i 번째 입력노드의 입력값을 의미하며, X_{\max} 는 x_{ip} 중에서 최대값이다. 학습을 완료한 후 조성예측모드로 동작할 때에도 입력값들은 식 (1)에 의해 전처리 된 뒤에 FINN에 입력된다.

다음으로 각 학습데이터를 구성하는 요소 중에서 FINN이 예측하고자 하는 원하는 출력값은 학습 및 예측의 정확도를 높이기 위해 세 가지의 데이터 크기 조절방법을 사용하였다. 먼저, 하나의 크기조절인자를 사용하여 FINN의 각 출력노드값을 조절하는 방법으로서 다음과 같다.

$$d_k = \frac{d_k}{D_{\max}}$$

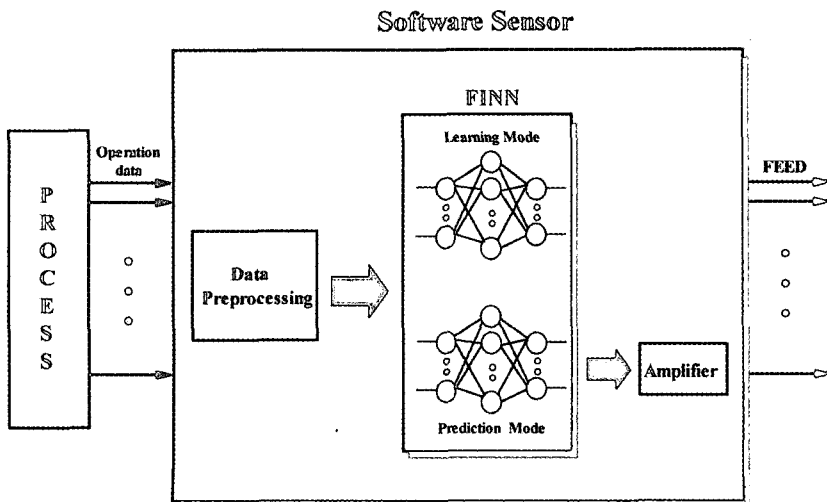


그림 2. 신경회로망 조성식별기를 이용한 소프트센서의 구조
Fig. 2. Structure of the soft sensor using FINN

$$\triangleq \frac{d_k}{\max_{k,p} \{d_{kp}\}} \quad (2)$$

여기서 d_k 는 FINN의 k 번째 출력노드의 값이며, d 는 신경회로망의 학습을 위한 p 번째 입력력 데이터쌍에서 FINN의 k 번째 출력노드의 값이고, D_{\max} 는 d_{kp} 중에서 최대값이다. 즉 식 (2)는 FINN의 학습시 하나의 조절인자를 사용하여 FINN이 추정하고자 하는 출력값을 정규화시킴을 의미한다.

두 번째는 여러 개의 크기조절인자를 사용하여 출력값을 조절하는 방법으로서 각 출력노드에 대한 값이 아래와 같이 조절된다.

$$d_k = \frac{d_k}{\max_p \{d_{kp}\}}, k=1, 2, \dots, K \quad (3)$$

여기서 K 는 FINN의 출력노드의 수이며, 식 (3)은 각 출력노드별로 서로 다른 크기조절인자를 사용하여 출력값을 정규화시킴을 의미한다. 마지막으로 식 (3)의 수정된 형태로서 다음과 같은 방법을 사용한다.

$$d_k = \frac{d_k}{1.1 \times \max_p \{d_{kp}\}}, k=1, 2, \dots, K \quad (4)$$

즉, 식 (3)의 분모인 조절인자에 1.1의 가중치를 부여 하므로서 원하는 FINN의 원하는 출력값을 대략 -0.9에서 0.9사이의 값으로 분포시킨다.

식 (2)의 방법은 각 출력노드에서의 출력값의 차이가 크지 않고 고른 분포를 보이는 경우는 간단하게 적용할 수 있으나 각 출력노드의 값의 차이가 큰 경우는 상대적으로 작은 값은 정규화 시 매우 작은 값으로 조절되므로 상대적으로 학습에 대한 기여도가 낮아 예측성능을 저하시킬 수 있다. 반면 식 (3)과 (4)는 각 출력노드별로 조절인자를 가지므로 각 출력노드의 값의 차이가 큰 경우도 이를 충분히 고려할 수 있다. 특히 식 (4)의 경우는 조절인자에 1.1의 가중치를 부여하므로서 원하는 출력값을 대략 -0.9에서 0.9 사이의 값으로 분포시켜서 학습 시 포화(saturation)로 인한 학습성능 저하를 막을 수 있다. 그러므로 학습데이터들의 성질 및 분포를 고려하여 세 가지 방법 중에서 적절한 방법을 선택하는 것이 효과적이다.

학습이 완료된 후 학습된 신경회로망의 가중치를 고정하고 실제 현장에 적용하여, 입력정보들로부터 원유의 조성을 예측하게 되는데 이 과정은 다음과 같다. 입력값이 식 (1)의 전처리 과정을 거쳐서 신경회로망에 입력되고 신경회로망은 예측값을 출력하며 이

는 전처리과정에서 사용한 크기조절인자와 곱해져서 최종적으로 조성예측값을 내게된다. 즉, 식 (2)의 전처리과정을 이용한 경우의 최종 조성예측값은 아래와 같으며,

$$\hat{d}_k = D_{\max} \times O_k \quad (5)$$

식 (3) 및 (4)를 이용한 경우의 최종 조성예측값은 각각 다음과 같이 계산된다.

$$\hat{d}_k = \max_p \{d_{kp}\} \times O_k \quad (6)$$

$$\hat{d}_k = 1.1 \times \max_p \{d_{kp}\} \times O_k \quad (7)$$

여기서 O_k 는 FINN의 k 번째 출력노드에서의 출력값이며, \hat{d}_k 는 k 번째 최종 조성예측값이다.

3.2 FINN의 학습알고리즘

FINN을 구성하는 다층 신경회로망(multilayer neural network)의 구조는 그림 3과 같이 입력층, 은닉층과 출력층으로 이루어져 있으며 각 층은 다수의 뉴런(노드)과 각 뉴런을 연결하는 가중치(weight)로 구성된다.

그림 3과 같은 다층 신경회로망의 출력값을 계산하는 순방향(feed-forward) 모델식은 은닉층에서의 입력력 관계식과 출력층에서의 입력력 관계식으로 구성된다. 먼저, 은닉층에서의 입력력 관계식은 다음과 같다.

$$net_j = \sum_{i=1}^I w_{ji} \cdot O_i \quad (8)$$

$$O_j = f_j(net_j) \quad (9)$$




그림 3. 다층 신경회로망의 구조도
Fig. 3. Architecture of the multilayer neural network

여기서 net_j 는 j 번째 은닉노드의 입력, w_{ij} 는 i 번째 입력노드와 j 번째 은닉노드 사이의 가중치, I_i 는 입력노드의 수이고, O_j 는 j 번째 은닉노드에서의 출력값으로서 입력층에서는 선형대응이므로 O_j 는 신경회로망의 입력이다. 그리고 O_j 는 j 번째 은닉노드에서의 출력값으로서 활성화함수인 아래와 같은 시그모이드함수 $f(\cdot)$ 을 통과시킨 값이다.

$$f_j(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (10)$$

다음으로 출력층에서의 입출력 관계식은 다음과 같다.

$$net_k = \sum_{j=1}^J w_{kj} \cdot O_j \quad (11)$$

$$O_k = f_k(net_k) \quad (12)$$

여기서 net_k 는 k 번째 출력노드의 입력, w_{kj} 는 j 번째 은닉노드와 k 번째 출력노드사이의 가중치이고 O_k 는 k 번째 출력노드에서의 출력값이다. 또한 J 는 은닉노드의 수이고 $f_k(\cdot)$ 는 시그모이드함수이다.

그림 3의 다층 신경회로망으로부터 원하는 입출력 특성을 얻기 위해서는 학습을 행하여야 한다. 다층 신경회로망의 학습은 최대경사법(steepest descent method)의 일종인 오차 역전파 학습알고리즘(back-propagation algorithm)[12]을 이용하여 가중치를 변화 시킴으로써 이루어지며, 신경회로망을 학습시키기 위한 성능함수는 다음과 같이 정의한다.

$$E = \frac{1}{2} \sum_{k=1}^N (d_k(t) - O_k(t))^2 \quad (13)$$

여기서 N 은 출력노드의 수이며, $d_k(t)$ 와 $O_k(t)$ 는 각각 k 번째 출력노드의 목표값과 실제 신경회로망의 k 번째 출력노드에서의 출력값이다. 신경회로망의 k 번째 출력노드에서 역방향으로 전달되는 오차신호는 아래와 같다.

$$\begin{aligned} \delta_k &= -\frac{\partial E}{\partial net_k} \quad (14) \\ &= (d_k(t) - O_k(t)) \cdot f'_k(net_k) \end{aligned}$$

여기서 $f'_k(\cdot)$ 는 시그모이드함수의 미분을 의미한다. 은닉층과 출력층사이의 가중치(w_{kj})에 대한 오차함수의 기울기와 가중치는 각각

$$\begin{aligned} \Delta w_{kj} &= -\eta \cdot \frac{\partial E}{\partial w_{kj}} \quad (15) \\ &= \eta \cdot \delta_k \cdot O_j \end{aligned}$$

$$w_{kj}(t+1) = w_{kj}(t) + \Delta w_{kj} + \alpha \cdot (w_{kj}(t) - w_{kj}(t-1)) \quad (16)$$

로 개선이 된다. 여기서 Δw_{kj} 는 j 번째 은닉노드와 k 번째 출력노드사이의 가중치 개선량, η 는 학습률, α 는 학습속도 개선을 위한 모멘텀 항이다. 또한, j 번째 은닉노드에서의 오차신호 및 입력층과 은닉층사이의 가중치의 조정은 각각 다음과 같다.

$$\begin{aligned} \delta_j &= -\frac{\partial E}{\partial O_j} \cdot \frac{\partial O_j}{\partial net_j} \quad (17) \\ &= \sum_{k=1}^N \delta_k \cdot w_{kj} \cdot f'_k(net_j) \end{aligned}$$

$$\begin{aligned} \Delta w_{ji} &= -\eta \cdot \frac{\partial E}{\partial w_{ji}} \quad (18) \\ &= \eta \cdot \delta_j \cdot O_i \end{aligned}$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji} + \alpha \cdot (w_{ji}(t) - w_{ji}(t-1)) \quad (19)$$

여기서 Δw_{ji} 는 i 번째 입력노드와 j 번째 은닉노드사이의 가중치 개선량이며, δ_j 는 은닉층에서 입력층으로 역전달되는 오차이다.

3.3 FINN의 학습데이터 성분

FINN의 학습데이터 성분은 표 1에 나타난 바와 같이 원유의 조성과 관련된 공정운전변수중에서 가장

표 1. 신경회로망 조성식별기의 학습데이터 성분
Table 1. Composition of training data for FINN

FINN		학습데이터 성분				
	FEED		FEED			
	LPG		LPG			
	NAPH		NAPH			
	LK		LK			
입력층 (입력노드 22개)	LGO	Temperature	LGO	Total Std. Liq. Rate		
	HK		HK			
	HGO		HGO			
	RC		RC			
	TOP		TOP			
	RECYCLE		RECYCLE			
	O-F		O-F			
			Total Std. API		TBP at 760 MM Hg(LV):	50%
	출력층 (출력노드 10개)		TBP at 760 MM Hg(LV):		1%	70%
					5%	90%
		10%	95%			
		30%	98%			

연관성이 있는 것으로 선정하였다. 즉, 입력값은 공정 운영중에 얻어지는 플랜트의 온도와 유량성분으로서 총 22개이며, 예측하고자 FINN의 출력값은 total API 와 TBP(1%, 5%, 10%, 30%, 50%, 70%, 90%, 95%, 98%)로서 10개이다.

4. 시뮬레이션결과 및 고찰

현재 상업적으로 운용중인 원유 정제용 상압증류탑을 대상으로한 공정모사기로부터 획득한 데이터를 이용하여 본 논문에서 제시한 FINN의 성능을 평가하였으며, 세 가지 전처리과정을 사용하여 조성예측성능을 비교하였다. 즉, 식 (2)에 의한 하나의 크기조절인자를 사용하는 방법 1, 식 (3)에 의한 여러 개의 크기조절인자를 사용하는 방법 2 및 식 (4)에 의한 1.1의 가중치를 부여한 여러 개의 크기조절인자를 사용하는 방법 3을 비교하였다.

예측기로 사용한 신경회로망은 한 개의 은닉층을 갖는 3단의 구조로 설계하였으며, 입력층의 노드수는 22개, 출력층의 노드수는 10개이며 각각의 데이터 성분은 3.3절에서 기술한 바와 같다. 특히 은닉층의 노드수가 예측성능에 미치는 영향을 알아보기 위해 은닉노드수를 30개 및 37개인 경우에 대해 시뮬레이션을 하였으며, 시뮬레이션은 그림 4와 같이 본 연구에서 개발한 “신경회로망 원료자동분석 소프트웨어 패키지”를 이용하여 수행하였다. 신경회로망 원료자동분석 소프트웨어 패키지 는 Borland C++(3.0) 빌드로 구현하였고, 크게 File, Neural Network, About의 3개의 메뉴로 구성되는데 “File” 메뉴는 입출력 데이터를 관리하는 부분이며, “Neural Network” 메뉴는 신경회로망 조성식별기의 학습과 예측기능을 선택하기 위한 부분으로서 학습

을 위한 “Training Mode”와 조성예측을 위한 “Prediction Mode”로 구성되어 있다. 즉, FINN은 실험을 통해 획득한 입출력 데이터로부터 FINN을 구축하는 과정인 학습모드와 학습된 신경회로망의 가중치를 고정하고 현장에 적용하여, 공정에서 획득되어지는 입력정보들로부터 조성을 예측하는 단계인 조성예측모드로 이루어져 있다. 또한 FINN의 학습 및 예측성능을 향상을 시키기 위해서 입출력 데이터를 학습 및 예측을 위해 사용하기 전에 데이터의 크기를 조절하는 전처리과정을 수행하는 기능이 포함되어 있다.

사용법을 간단히 요약하면 먼저 학습모드에서는 실제 실험을 통해 획득한 입출력 데이터로부터 FINN을 구축하기 위해 학습 데이터화일을 로드한 뒤 신경회로망의 구조 및 학습데이터 크기의 조절을 위한 데이터 크기조절인자를 설정한다. 다음으로 신경회로망을 학습한 뒤 학습된 신경회로망을 테스트하여 학습상태




그림 4. 신경회로망 원료자동분석 소프트웨어
Fig. 4. Soft sensor using neural network

Data Normalization Factor			
Input	900		
Out #1	800	Out #6	800
Out #2	800	Out #7	800
Out #3	800	Out #8	800
Out #4	800	Out #9	800
Out #5	800	Out #10	800

Data Normalization Factor			
Input	900		
Out #1	47	Out #6	283
Out #2	64	Out #7	390
Out #3	63	Out #8	546
Out #4	92	Out #9	636
Out #5	184	Out #10	802

Data Normalization Factor			
Input	900		
Out #1	51	Out #6	311
Out #2	70	Out #7	428
Out #3	69	Out #8	600
Out #4	101	Out #9	699
Out #5	202	Out #10	882

(a) 방법 1
(a) Method 1

(b) 방법 2
(b) Method 2

(c) 방법 3
(c) Method 3

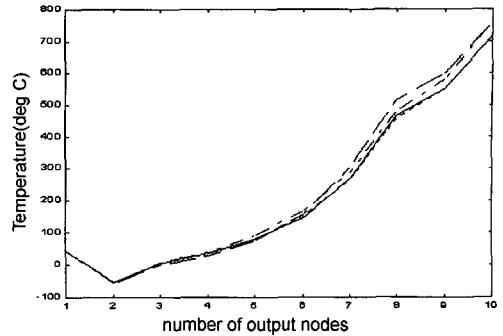
그림 5. 데이터 전처리
Fig. 5. Data preprocessing

가 만족하면 신경회로망을 저장한다. 조성예측모드에서는 학습된 신경회로망의 가중치를 고정하고 입력정보들로부터 조성을 예측한다. 학습 시 학습률 η 는 0.5이며, 22개의 입출력쌍으로 50,000회 학습하였다.


학습 및 예측시 방법 1, 방법 2 및 방법 3에 대한 소프트웨어 패키지에서의 데이터 전처리 화면은 각각 그림 5(a), (b) 및 (c)와 같다.

그리고 예측성능을 알아보기 위한 테스트 패턴의 입력값과 예측하고자 하는 실제 조성값인 출력값은 표 2와 같으며, 입력값이 전처리과정을 거쳐서 FINN에 입력되어서 예측값을 출력하며 이는 전처리과정에서 사용한 크기조절인자와 곱해져서 최종적으로 예측값을 내게된다.

예측기의 은닉노드 수를 37개로 하고 50,000회 학습 후 학습에 이용한 패턴 P23과 학습에 이용하지 않은 새로운 패턴 P24를 입력했을 때의 예측결과는 표 3과 같으며, 이를 도시하면 각각 그림 6(a) 및 7(a)와 같고 실제값과 예측값과의 예측오차는 각각 그림 6(b) 및 7(b)에 나타나있다. 결과들로부터 방법 3의 전처리과정을 사용하여 학습한 FINN이 가장 실제값과 유사하게 조성을 예측해냄을 알 수 있다. 특히 패턴 P23에서 방법 1과 2의 예측성능이 방법3에 비해서 많이 떨어지는 이유는 패턴 P23의 경우에 각 출력노드의 원하는 값의 차이가 크기 때문에 방법 1 보다는 방법 3의 전처리과정이 효과적이다. 이에 반해서 패턴 P24의 경우는 각 출력노드의 값의 차이가 크지 않고 비교적 고른 분포를 보이는 경우로서 방법



(a) 예측결과
(a) Prediction results



(b) 예측오차
(b) Prediction errors

그림 6. P23 패턴에 대한 FINN의 조성예측결과(____: 실제값, -·-·: 방법 1, - - -: 방법 2, - · - ·: 방법 3)
Fig. 6. Results of feed prediction for pattern P23(____: actual value, -·-·: method 1, - - -: method 2, - · - ·: method 3)

표 2. 테스트 패턴
Table 2. Test patterns

패턴	입력값	353.49	41.87	41.87	118.34	194.97	250.49	305.72	341.01	77.69	41.87	335.62
		P23	695.69	51.28	153.4	223.8	29.49	72.33	48.1	118.26	1312.98	600.64
	출력값	45.37	-54.62	5.52	33.53	80.50	144.85	270.15	464.49	548.13	715.31	
P24	입력값	353.64	42.02	42.02	147.84	199.47	260.39	311.17	342.57	116.42	42.02	340.45
	695.69	8.44	153.4	61.189	59.57	117.78	75.086	220.73	841.61	38.24	42.92	
	출력값	37.70	-63.68	54.0	84.0	175.0	276.0	376.0	531.0	603.0	685.0	

표 3. 신경회로망 조성식별기의 조성예측결과(예측기의 은닉노드 수 : 37개)
Table 3. Prediction results of the FINN (number of hidden nodes : 37)

데이터 전처리 방법	테스터 패턴	신경회로망 예측기의 예측결과									
방법 1	P23	46.27	-57.0	8.17	37.12	89.73	166.48	289.09	481.85	580.03	756.48
	P24	38.19	-60.69	55.12	84.84	174.98	276.90	380.75	534.77	615.39	723.16
방법 2	P23	44.75	-58.68	1.29	26.47	73.04	156.37	303.37	513.73	598.53	755.30
	P24	38.09	-60.53	56.09	86.53	177.41	276.92	377.01	532.85	612.68	721.75
방법 3	P23	45.06	-54.62	4.91	32.57	80.28	149.44	267.02	457.63	549.02	715.93
	P24	37.93	-60.09	55.26	85.47	175.66	276.55	377.25	530.34	605.93	700.61

1, 2 및 3 모두 실제값과 유사하게 조성을 예측해낼 수 있다. 그러나 방법 2의 전처리방법은 포화 현상으로 인해 방법 1과 3에 비해서는 성능이 떨어질 수 있다.

예측기의 은닉노드수를 30개로 하고 50,000회 학습한 후 패턴 P23과 P24를 입력했을 때의 예측결과는 표 4와 같으며, 예측결과를 도시하면 각각 그림 8(a) 및 9(a)이고 패턴 P23과 P24에 대한 예측오차는 각

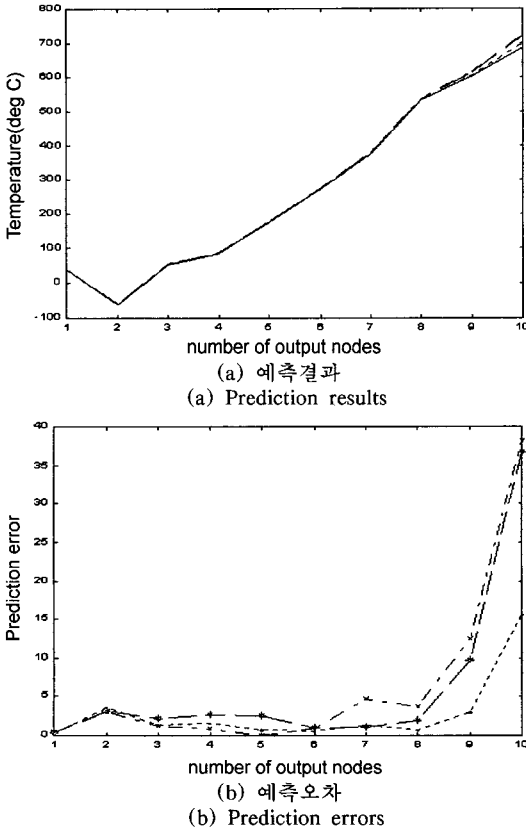


그림 7. P24 패턴에 대한 FINN의 조성예측결과(____: 실제 값, -·-·: 방법 1, - - -: 방법 2, -----: 방법 3)
Fig. 7. Results of feed prediction for pattern P24(____: actual value, -·-·: method 1, - - -: method 2, -----: method 3)

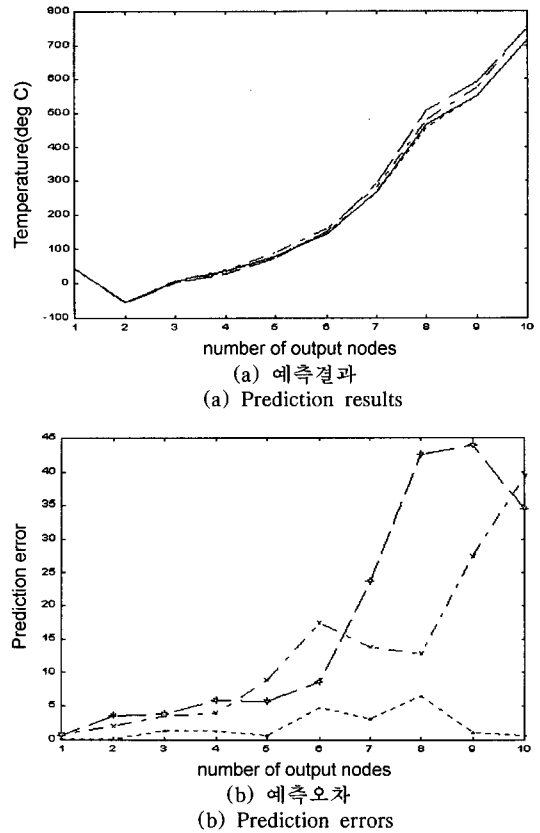


그림 8. P23 패턴에 대한 FINN의 조성예측결과(____: 실제 값, -·-·: 방법 1, - - -: 방법 2, -----: 방법 3)
Fig. 8. Results of feed prediction for pattern P23(____: actual value, -·-·: method 1, - - -: method 2, -----: method 3)

표 4. 신경회로망 조성식별기의 예측결과(예측기의 은닉노드 수 : 30개)
Table 4. Prediction results of the FINN (number of hidden nodes : 30)

데이터 전 처리 방법	테스터 패턴	신경회로망 예측기의 예측결과									
방법 1	P23	46.18	-56.6	8.94	37.55	89.4	162.22	283.87	477.35	575.59	754.65
	P24	38.18	-60.81	55.74	85.53	175.48	276.61	380.26	534.24	614.95	722.38
방법 2	P23	44.65	-58.13	1.66	27.75	74.79	153.44	293.83	506.98	592.17	49.81
	P24	38.10	-60.48	55.48	85.52	176.13	276.83	377.64	532.31	612.12	721.32
방법 3	P23	45.28	-54.69	4.2	32.16	79.85	149.64	267.16	458.07	549.14	715.94
	P24	38.10	-60.33	55.34	85.56	175.82	76.92	378.15	32.06	607.03	700.39




그림 9. P24 패턴에 대한 FINN의 조성예측결과(____: 실제 값, — — : 방법 1, — — — : 방법 2, - - - - : 방법 3)
Fig. 9. Results of feed prediction for pattern P24(____: actual value, — — — : method 1, — — — : method 2, - - - - : method 3)

각 그림 8(b) 및 9(b)에 도시된 바와 같다. 이 경우에도 방법 3의 전처리과정을 사용하여 학습한 FINN이 가장 실제값과 유사하게 조성을 예측해냄을 알 수 있으며 방법 1, 2 및 3을 비교해 보면 방법 2의 경우가 예측성능이 떨어짐을 알 수 있다. 그리고 은닉노드 수를 다양하게 하여 실험한 결과 예측기의 은닉노드 수는 30개~37개 사이가 적절함을 알 수 있었다.

5. 결 론

본 논문에서는 증류과정에서 운전 중에 측정되어지는 공정의 각종 실시간 데이터들인 온도, 압력, 유량 등과 같은 공정의 제어 값들과 온라인 분석기로부터 얻어지는 제품규격, 산출데이터등으로 부터 원유의 조성을 예측하기 위한 FINN을 이용한 소프트웨어를 설계하고, 신경회로망 원료자동분석 소프트웨어를

트웨어 패키지를 구현하였다. 또한 FINN의 조성예측 성능을 향상시키기 위한 적절한 데이터 전처리방법을 제시하였다. 설계한 FINN을 현재 상업적으로 운용중인 원유정제용 상압증류탑을 대상으로한 공정모사기에 적용한 결과 실제값과 거의 같게 조성을 예측함을 확인하였다.

그러므로 제안한 소프트웨어를 사용하여 초기 운전 조건을 통하여 원유의 조성을 예측하므로써 궁극적으로는 새로운 최적의 운전조건을 설정할 수 있을 것이며, 이로 인해 제품품질의 손실을 막고 과잉 에너지 소비를 줄임으로써 에너지와 비용을 절감할 수 있을 것이다. 앞으로 남은 과제는 신경회로망의 구조 및 학습속도 개선책, 학습 및 예측의 정확도를 더욱 향상시키기 위한 전처리과정등에 대한 연구이다.

참고문헌

- [1] T. Mejdell and S. Skogestad, "Estimation of distillation compositions from multiple temperature measurements using partial-least-squares regression", *Industrial and Engineering Chemistry Research*, Vol. 30, No. 12, pp. 2543-2555, 1991.
- [2] T. Mejdell and S. Skogestad, "Composition estimator in a pilot-plant distillation column using multiple temperatures", *Industrial and Engineering Chemistry Research*, Vol. 30, No. 12, pp. 2555-2564, 1991.
- [3] T. Mejdell and S. Skogestad, "Output estimation using multiple secondary measurements: high-purity distillation", *AIChE Journal*, Vol. 39, No. 10, pp. 1641-1653, 1993.
- [4] J. V. Kresta, T. E. Marlin and J. F. Macgregor, "Development of inferential process models using PLS", *Computers & Chemical Engineering*, Vol. 18, No. 7, pp. 597-611, 1994.
- [5] E. C. Malthouse, A. C. Tamhane and R. S. H. Mah, "Nonlinear partial least squares", *Computers & Chemical Engineering*, Vol. 21, No. 8, pp. 875-890, 1997.
- [6] M. J. Willis, G. A. Montague, C. D. Massimo, M. T. Tham and A. J. Morris, "Artificial neural networks in process estimation and control", *Automatica*, Vol. 28, No. 6, pp. 1181-1187, 1992.
- [7] S. Bhamra and H. Singh, "Single layer neural networks for linear system identification using gradient descent technique", *IEEE Trans. Neural Networks*, Vol. 4, No. 5, pp. 890-899, 1993.
- [8] T. Sorsa, H. N. Koivo and H. Koivisto, "Neural networks in process fault diagnosis", *IEEE Trans. Syst., Man and Cybern.*, Vol. 21, No. 4, pp. 815-825, 1991.
- [9] J. C. Hoskins and D. M. Himmelblau, "Artificial neural network models of knowledge representation in chemical engineering", *Computers & Chemical Engineering*, Vol. 12, No. 9, pp. 881-890, 1988.

- [10] V. Venkatasubramanian, R. Vaidyanathan and Y. Yamamoto, "process fault detection and diagnosis using neural networks-steady state processes", *Computers & Chemical Engineering*, Vol. 14, No. 7, pp. 699-712, 1990.
- [11] J. Y. Fan, M. Nikolaou, and R. E. White, "An approach to fault diagnosis of chemical processes via neural networks", *AIChE Journal*, Vol. 39, No. 1, pp. 82-88, 1993.
- [12] D. E. Rumelhart and J. L. McClelland, *Parallel distributed processing: explorations in the microstructure of cognition*. Vol. 1, MIT Press, Reading, MA, 1986.



이인수 (In-Soo Lee)

1986년 : 경북대학교 전자공학(공학사)
1989년 : 동대학원 졸업(공학석사)
1997년 : 동대학원 졸업(공학박사)
1997년~현재 : 상주대학교 전자전기공학부 조교수
관심분야 : 시스템의 고장진단 및 고장 허용제어, 지능제어 및 응용등

이현철 (Hyun Chol Lee)

제7권 5호 참조

박상진 (Sang Jin Park)

1981년 : 동국대학교 화학공학(공학사)
1985년 : Univ. Illinois 화학공학(공학석사)
1989년 : Univ. Illinois 화학공학(공학박사)
1989년~1990년 : Illinois 열역학연구소 연구원
1990년~1993년 : (주)쌍용정유 기술연구소
1993년~현재 : 동국대학교 화학공학과 부교수
관심분야 : 공정설계 및 열역학 등

이의수 (Euy Soo Lee)

1978년 : 서울대학교 화학공학(공학사)
1980년 : 한국과학기술원 화학공학(공학석사)
1988년 : Purdue Univ. 화학공학(공학박사)
1978년~1994년 : (주)제철화학 연구실장
1994년~현재 : 동국대학교 화학공학과 부교수
관심분야 : 공정설계 및 제어 등