

論文99-36S-8-5

온라인 재학습 가능한 RBF네트워크를 이용한 열연 권취 온도 제어 모델 개발

(Development of a Temperature Control Model for a Hot Coil Strip using on-line Retrainable RBF Network)

鄭韶永*, 李敏鎬**, 李壽永*

(So-Young Jeong, Minho Lee, and Soo-Young Lee)

요약

본 논문에서는 포항제철의 열연 권취 온도 공정을 제어하기 위한 방법으로 온라인 재학습 가능한 RBF 네트워크(Radial Basis Function network)를 제안한다. 새로 제안된 신경회로망 모델을 이용해 권취 온도 제어 시스템의 열전달 계수를 생성해주는 기존의 규칙 기반 계수표를 대체할 수 있다. 열연 공정 작업의 시간에 따른 변화를 고려하도록 기존의 RBF 네트워크에 부가적인 온라인 재학습용 시냅스 가중치를 도입한다. 부가적인 가중치들로 인해 이미 학습된 전체 데이터들의 특성 정보를 유지하면서 새로 들어오는 데이터들에 대해 온라인 재학습이 이루어진다. 따라서, 제안된 RBF 네트워크는 파국적 간섭(catastrophic interference) 효과를 상당히 감소시킬 수 있다. 그리고 거부 네트워크를 도입하여 제어기의 신뢰도를 높일 수 있었고, 실제 현장에 적용한 실험 결과는 기존의 방법보다 평균 2.2퍼센트 이상 향상된 성능을 보였다.

Abstract

This paper describes on-line retrainable RBF network in order to control the coiling temperature for a hot coil strip at Pohang Iron & Steel Company(POSCO). The proposed neural network can be used for improving conventional rule-based lookup table, which generates a heat transmission coefficient. To cope with time-varying characteristics of hot coil process, additional synaptic weights for on-line retraining purposes are introduced to hidden-to-output weights of conventional RBF network. Those weights are locally adjusted to newly incoming test data while preserving old information trained with off-line past data. Hence the effect of catastrophic interference can be greatly alleviated with the proposed network. In addition, rejection scheme is introduced for reliability concerns. From the experimental results applied to the actual process, it is noticed that overall control performance represents about 2.2 % increase compared to the conventional one.

I. 서론

* 正會員, 韓國科學技術院 電氣 및 電子工學科
(Department of Electrical Engineering, Korea Advanced Institute of Science and Technology)

** 正會員, 慶北大學校 感應工程系
(Department of Sensor Engineering, Kyungpook National University)

接受日字: 1999年5月3日, 수정완료일: 1999年7月15日

제철 공정에서 신경회로망에 기반한 제어 방법은 냉연의 압연력 예측^[1]이나, 이동 테이블(moving table)의 정밀제어^[2], 압연 공정 제어^[3]과 같은 여러 분야에 적용되어 왔다. 현재 열연 공정에는 기존의 PID형태의 제어기나 근사화한 수식을 이용한 모델 기반 제어기가 주로 쓰이고 있다. 이러한 방법들은 부정확한 수식 모델과 변화하는 환경에 대한 적응성이

떨어지고 잡음에 민감하게 반응하여 성능에 많은 한계가 있다. 제어 시스템에 대한 엄밀한 수학적 모델링이 거의 불가능하고 시간에 따른 시스템의 변화가 심한 온도 제어 공정에서는 충분한 입출력 데이터가 확보된다면 신경회로망을 통한 제어기 모델링이 좋은 성능을 보일 수 있다.

열연 공정에서 생산되는 강의 품질을 결정하는 여러 요인들 중에서 최종 권취부에서의 권취 온도(coiling temperature) 제어 성능은 매우 중요하다. 왜냐하면, 생산되는 강의 인장 강도(tensile strength), 항복 강도(yield strength) 및 연신률 등과 같은 기계적 특성은 강의 냉각 이력 과정 및 최종 냉각 온도에 의해 주로 결정되기 때문이다. 강의 두께와 폭을 원하는 크기로 맞추기 위한 다듬질 공정이 끝난 강의 온도는 약 1200도가 넘는다. 따라서 공냉만으로는 보통 권취부의 목표 온도인 약 600도로 냉각할 수 없으므로 수냉 과정이 필요하게 된다.

포항제철의 열연 공정에서 현재 쓰이는 권취 온도 제어는 전방향 제어기, 궤환 제어기, 그리고 간단한 학습 제어기로 이루어진다. 전방향 제어기는 열 용량을 계산하여 주수 맹크의 최적 패턴을 결정하는 수식 모델과 강의 종류 및 작업 조건에 따른 열 전달 계수를 결정하기 위해 경험에 기반한 규칙들로 만들어진 계수표로 구성된다. 궤환 제어기는 전방향 제어기의 제어 오차를 보상하기 위해 PI제어기로 구성되고 마지막 맹크의 주수 패턴을 결정한다. 마지막으로 변화하는 환경에 적응하기 위해 열 전달 계수표를갱신하기 위한 간단한 학습 제어기가 있다.

열연 공정에서는 같은 종류 두께, 폭, 성분등의 코일을 여러 장 연속해서 생산하는 데 이것을 한 세트(set)라 한다. 동일한 세트내의 코일 첫장의 제어는 궤환 제어기와 학습 제어기를 이용할 수 없으므로 일반적으로 코일의 다른 장들에 비해 성능이 떨어져 전체적인 제어 성능이 나빠지는 원인이 된다. 그러므로, 코일 첫 장의 제어 성능을 높이기 위해서는 전방향 제어기의 성능이 향상되어야 한다. 현재 전방향 제어기에 이용되는 열 전달 계수표는 세 가지 제어 변수만으로 구성되어 있고 양자화 오차로 인해 정확도가 떨어져 전방향 제어기의 성능을 떨어뜨리는 원인이 된다.

한편, 다층 구조 신경회로망은 주어진 입출력 데이터에 대해 충분한 뉴런을 가진 네트워크로 임의의 비선형 함수를 근사화할 수 있다고 알려져 있다.^[4] 따

라서, 학습 데이터가 충분하다면 열연 공정에서 얻어진 실제 데이터를 이용하여 열 전달 계수표를 신경회로망으로 대체시킬 수 있다. 신경회로망은 연속 함수를 근사화 하기 때문에 계수표의 양자화 오차를 줄일 수 있고, 계수표에 비해 다양한 제어 변수를 입력으로 줄 수 있으므로 좀 더 정확한 열 전달 계수를 계산할 수 있다.

시간에 따른 주위 환경의 변화가 심한 열연 공정의 권취 온도를 제어하기 위해서는 주변의 변화하는 공정 조건들을 반영할 수 있는 신경회로망 모델이 개발되어야 한다. 즉, 이미 학습한 네트워크를 온라인으로 재학습(테스트 과정을 일컫는다)이 가능하도록 해야하다. 하지만, 기존의 신경회로망 모델은 과거 데이터를 가지고 학습한 네트워크에 대해 새로운 데이터를 입력으로 주고 재학습을 시키면, 이미 학습한 정보는 크게 손상당하게 된다. 이것은 “안정성-유연성 딜레마(stability-plasticity dilemma)” 문제로 잘 알려져 있다. 즉, 잡음으로 간주되는 데이터들에 대해서는 네트워크가 이미 가지고 있는 정보를 손상당하지 않도록 안정성을 유지하면서 동시에 새로운 정보를 가진 데이터가 들어왔을 때는 네트워크의 정보를 부분적으로 갱신할 수 있게 유연하게 대처할 수 있어야 한다.^[5] 신경회로망 모델의 학습 관점에서 보면 파국적 망각(catastrophic forgetting), 또는 파국적 간섭(catastrophic interference) 현상으로 볼 수 있다. 예를 들어, 여러 개의 집합으로 이루어진 학습 데이터가 있을 때 전체 데이터를 한꺼번에 학습을 시키지 않고, 한 개의 집합 내에 있는 데이터들을 완전히 학습시키고 나서 다음 집합의 데이터들을 학습시킨다고 보자. 그러면, 이미 학습된 데이터 집합의 정보는 새로운 집합의 데이터들을 학습하는 과정에서 손상당하게 되어 바람직하게 않게 된다. 따라서, 기존 데이터로 학습된 네트워크의 정보를 유지하면서 새로운 들어오는 데이터에 대해서도 적절하게 학습할 수 있는 신경회로망 모델과 학습 알고리즘 필요하다. 파국적 간섭 효과를 줄이기 위한 다양한 방법들에 대한 연구^[6, 7, 8]가 있지만, 포항 제철의 열연 공정 제어를 위한 컴퓨터들의 메모리와 계산 능력의 한계 때문에 바로 적용하기는 쉽지 않다.

본 논문에서는 이미 학습한 네트워크의 전체 정보를 어느 정도 유지하면서 공정 환경의 변화를 고려하기 위해 네트워크를 국부적으로 학습할 수 있는 새로

운 신경회로망 모델과 학습 방법을 제안한다. 제안된 모델은 온라인 재학습 기능을 갖는 RBF네트워크이고 실제 현장 적용에서의 제어 모델 신뢰도를 높이기 위해 거부 네트워크를 도입한다. 공정 현장에 적용하여 제안된 모델의 성능을 기존의 계수표 방법을 이용한 경우와 비교한다.

논문의 구성은 다음과 같다.

2장에서는 현재 열연 공정에 쓰이는 온도 제어 시스템을 설명하고, 현 시스템의 문제점들에 관해 논의 한다. 3장의 초반부에서는 새로 제안된 RBF 네트워크 모델에 대해 설명하고, 모의 실험과 실제 현장에 적용한 실험 결과를 후반부에 제시한다. 마지막으로 4장에서 결론을 내린다.

II. 열연 공정의 온도 제어 시스템

1. 열연 공정 개요

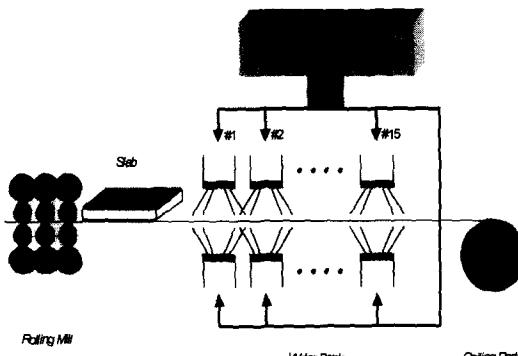


그림 1. 포항 제철의 열연 공정 개요

Fig. 1. Overview of hot coil strip process at Pohang Iron & Steel Company.

다듬질 공정이 끝난 고온의 코일은 냉각 과정을 거치기 위해 그림 1에서 보는 것처럼 수냉 지역으로 들어온다. 포항제철의 열연 공정에는 압연 공정 종료 지점부터 권취부까지 15개의 주수 맹크가 있고 각 맹크는 위, 아래 6개씩의 밸브를 가지고 있다. 코일의 기계적 특성들은 냉각 과정에서 주로 결정되고, 최종 권취부의 온도가 이를 나타내는 지표가 되기 때문에 냉각 온도 제어 성능이 코일의 품질을 결정하는 중요한 요소가 된다. 온도제어 시스템은 수냉 영역으로 들어오는 코일의 속도, 목표 권취 온도(이하, 간단히 TCT라 한다)와 코일의 특성 두께, 폭, 코일의 구성 성분 등을 읽어들여 주수 맹크 제어기에 제어 신호로 보내어

밸브의 개폐 패턴을 결정한다. 수냉이 끝나 목표 권취 온도로 냉각된 코일은 제품의 마지막 단계로 권취되어 보관된다.

최종 권취부에서는 코일의 길이가 매 11.52m마다 온도를 측정하는데, 목표 온도와 ±15도 이내로 차이가 나면 제어 오차가 없다고 보고 권취부에서 온도 측정 횟수중에 제어 오차가 없는 횟수의 비율을 제어 적중률이라고 한다. 예를 들어, 코일의 길이가 1.1km일 때 100번 정도 온도를 측정할 수 있고 측정 횟수중에 90번이 제어 오차가 없다고 보면 제어 적중률은 90%가 된다. 제어 적중률이 코일의 품질을 결정하기 때문에 이러한 적중률을 높이는 것이 온도 제어 시스템 설계의 목표가 된다.

2. 기존의 열연 온도 제어 시스템

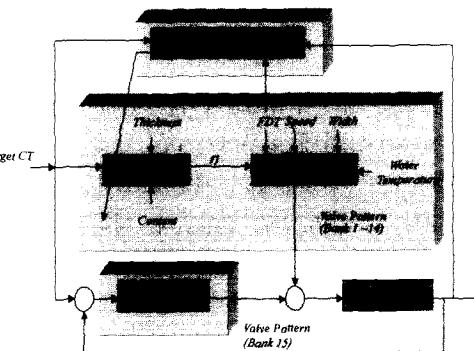


그림 2. 열연 공정을 위한 권취 온도 제어 시스템

Fig. 2. Block diagram of temperature control system for hot coil strips.

그림 2에서 보는 바와 같이 열연 공정의 온도 제어 시스템은 최적의 주수 패턴을 결정하기 위해 3종류의 제어기로 구성된다. 전방향 제어기는 각 맹크당 온도 강하량을 계산하여 개폐할 밸브의 수를 결정하기 위해 규칙 기반 계수표와 수식 모델로 이루어져 있다. 제어기의 앞 부분에는 코일의 두께, 성분, 목표 권취 온도로부터 열 전달 계수(이하, 간단히 f_1 이라 한다)를 결정하는 계수표가 있다. 코일의 성분은 탄소, 망간 실리콘으로 구성되는데 아래 수식 (1)과 같이 한 개의 변수로 전환하여 이용한다.

$$C_{eq} = C_c + \frac{C_{Mn}}{6} + \frac{C_{Si}}{12} \quad (1)$$

여기서 C_c , C_{Mn} , C_{Si} 는 각각 코일을 구성하는 탄소, 망간과 실리콘의 양을 나타내고, 수식의 계수는 각

성분이 f_1 에 미치는 상대적인 영향 정도를 나타낸다.

수식 모델은 계수표로부터 얻어진 f_1 과 코일의 폭, 수냉 지역으로의 진입 속도, 암연 종료 후 온도(이하, 간단히 FDT라 한다)와 수온등을 이용하여 밸브의 개폐 패턴을 계산하는 모델이다.

전방향 제어기의 제어 오차를 보상하기 위해 PI제어기로 이루어진 궤환 제어기는 15번째 뱅크의 주수 패턴으로 제어한다. 마지막으로 변화하는 공정 조건들을 반영하기 위해 계수표의 f_1 을 갱신하여 주는 간단한 학습 제어기가 있다. 수식(2)와 같이 f_1 의 값을 갱신한다.

$$f_{1_new} = f_{1_old} \left(\frac{FDT - CT - FBT}{FDT - TCT} \cdot G + (1 - G) \right) \quad (2)$$

여기서 FBT , CT , G 는 각각 궤환 제어기에 의한 마지막 뱅크의 온도 강하량, 권취되는 순가의 온도, 그리고 휴리스틱 방법에 의해 결정되는 이득 상수 값을 나타낸다.

현재 열연 공정의 온도 제어는 위에서 언급한 3종류의 제어기로 함께 이루어지지만, 냉각 영역의 중간 지점에는 온도 센서가 없기 때문에 코일 첫 장의 성능은 전방향 제어기만으로 결정된다. 따라서 궤환 제어를 이용하지 못하므로 제어 적중률이 일반적으로 그리 좋지 않고 코일 전체의 제어 성능도 떨어지므로 전방향 제어기 자체의 성능을 향상시켜야 한다. 전방향 제어기의 성능에 영향을 미치는 여러 변수들 가운데 f_1 은 다른 센서로부터 측정된 변수들과는 달리 계수표로부터 계산되고 수식 모델에도 이용되기 때문에 가장 중요한 매개 변수로 볼 수 있다. 즉, 전방향 제어기의 전체 성능은 적절한 f_1 을 선택하는가에 달려 있다고 볼 수 있다.

계수표를 이용하여 f_1 을 결정하는 방법에는 양자화 과정에서 발생하는 오차와 다양한 변수들이 이용되지 못하고 단지 세 개의 변수 코일의 진입 속도, FDT 및 수온 - 만으로 구성된다는 단점이 있다. 신경회로망을 통한 시스템 모델링은 이러한 단점을 극복할 수 있다. 임의의 연속 함수를 근사화 할 수 있는 신경회로망의 특성으로 인해 입력 변수들의 양자화 오차를 줄일 수 있고, 세 가지 변수 외에 다른 변수들을 고려하여 보다 정확한 f_1 을 계산할 수 있다. 그리고, 포항 제철의 열연 공정에서는 한 달에 9000개 이상의 코일을 생산하고 그 기록을 보관하고 있으므로 충분한 데이터를 확보할 수 있어 신경회로망을 통한 접근법이

유용하게 쓰일 수 있다.

III. 신경회로망을 통한 계수표 모델링

1. 온라인 재학습 가능한 RBF네트워크의 필요성

신경회로망의 대표적 근사화 모델에는 MLP네트워크(multi-layer perceptron network)와 RBF네트워크(radial-basis function network)가 있다. MLP는 학습하려는 데이터의 전체 특성을 쉽게 배울 수 있는 반면, RBF는 데이터를 국부적으로 학습한다. 그런데, 열연 공정 데이터는 비슷한 입력에 대해서도 시간이 지남에 따라 목표 출력이 크게 변하고 제어 모델의 신뢰도가 매우 중요하다. 즉, 기존에 학습된 네트워크의 정보를 유지하면서, 새로 들어오는 데이터에 대해서도 국부적으로 학습하고 전혀 학습하지 않은 데이터는 거부할 수 있는 네트워크 모델이 필요하다. 따라서, 열연 공정의 신경회로망 모델링 관점에서는 MLP 네트워크보다는 RBF네트워크가 더 적합하다.

서론에서 언급한 파국적 망각 현상을 방지하는 방법에는 두 가지가 있다. 하나는 네트워크를 재학습할 때 기존에 학습한 데이터와 새로 학습한 데이터를 함께 이용하는 것이다. 그러나, 기존 데이터들을 재학습에 이용할 수 없을 때는 이 방법을 쓸 수 없기 때문에 이미 학습된 네트워크를 이용해 가상의 학습 데이터들을 만들어 재학습 시키는 의사리허설 방법이 있다^[8]. 하지만, 열연 공정에는 온라인으로 재학습이 이루어져야 하므로 기존의 데이터들과 새로운 데이터들을 함께 재학습 시킬 수 없고, 제어 컴퓨터의 성능 때문에 위에서 언급한 의사리허설 방법도 이용할 수 없다. 본 논문에서는 파국적 망각 현상을 줄이기 위해 온라인 재학습 시냅스 가중치를 부가적으로 갖는 새로운 RBF네트워크를 제안한다.

2. 제어 모델의 신뢰도를 고려하기 위한 거부 네트워크

실제 열연 공정에서는 외부의 환경 변화에 의해 작업 조건들이 달라지는 현상들이 자주 일어난다. 제어 모델의 신뢰도 관점에서 보면, 이미 학습한 데이터들과 재학습하려는 데이터들이 환경적 요인에 의해 크게 달라졌다면, 신경회로망을 통해서는 원하는 출력값을 줄 수 없다. 따라서, 이 경우에는 기존의 열 전달 계수표를 이용하도록 신경회로망으로 데이터가 들어오기 전에 거부할 수 있는 네트워크가 필요하다. 거부 네트

워크를 이용하지 않고 만약 전혀 새로운 데이터가 들어왔을 때 자동 은닉 뉴런 생성(automatic hidden-unit recruitment)과 같이 이 데이터에 대해 새로운 RBF를 세워주는 RBF 학습 방법이 있지만, 제한된 컴퓨터 성능과 안정적이고 온라인으로 작동해야 하는 재학습 과정에는 이용할 수 없다.^[9]

RBF네트워크의 첫번째 층을 이용하여 학습 데이터와 재학습 데이터의 유사성을 계산하여 거부 네트워크를 쉽게 구성할 수 있다. 즉, 재학습 데이터가 RBF네트워크의 입력으로 들어왔을 때 은닉층 뉴런값은 이미 학습한 데이터와의 유사 정도를 나타낸다. 은닉층 뉴런값이 낮은 테스트 데이터는 네트워크의 신뢰도를 유지하기 위해 거부되어야 한다. 실제 적용에서는 신경회로망으로 들어오는 데이터들은 거부 네트워크를 통해 기존의 열 전달 계수표를 이용할 것인지 온라인 재학습 RBF 네트워크를 이용하여 f_1 을 결정할지를 판단하게 된다. 재학습 데이터의 은닉층의 활성값이 일정한 임계값을 넘지 않으면 거부되어 계수표를 통해 f_1 을 주게 된다. 따라서, 거부 네트워크를 통해 거부된 데이터들은 기존의 계수표를 통해 출력을 주고, 거부되지 않은 데이터들은 RBF로 출력을 주기 때문에 거부 네트워크의 도입으로 신경회로망 모델의 신뢰도를 높일 수 있고 전체적인 제어 성능도 최소한 열 전달 계수표보다는 좋아질 수 있다.

3. 온라인 재학습 RBF 네트워크

그림 3은 제안된 RBF네트워크의 구조를 나타낸 것이다.

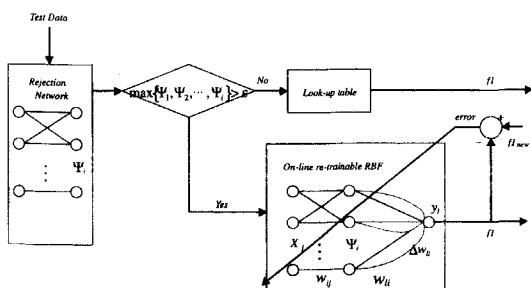


그림 3. 제안된 온라인 재학습 가능한 RBF네트워크
Fig. 3. Proposed re-trainable RBF network controller.

우선, 실제 현장에서 얻어진 데이터들을 몇 개의 영역으로 분할한다. 다양한 클러스터링 방법들이 가능하지만, 전문가의 지식에 의해 학습하려는 데이터를 클러스터링한다. 그림 4에 나타난 바와 같이 대표적인

입력 변수인 코일의 두께는 입력 공간상에서 거의 연속적으로 분포되어 있어 퍼지 클러스터링(fuzzy clustering)^[10]이나 코호넨의 특징 맵(Kohonen's feature map)^[11] 등과 같은 자동 클러스터링 방법^[12]으로는 클러스터들이 대체적으로 고르게 선택된다. 현장 전문가에 의하면 특정 영역의 두께를 갖는 코일들은 비슷한 특성 동일한 수온하의 냉각 정도나 코일의 이동 속도등을 갖는다고 경험적으로 알려져 있어, 선형적 지식(prior knowledge)을 이용한 클러스터링 방법이 필요하고, FDT(finishing delivery temperature)의 경우 대략 800~900도 사이의 이산 레벨 값(discrete-level value)들만 취하기 때문에 자동 클러스터링 방법을 굳이 사용할 필요가 없다.

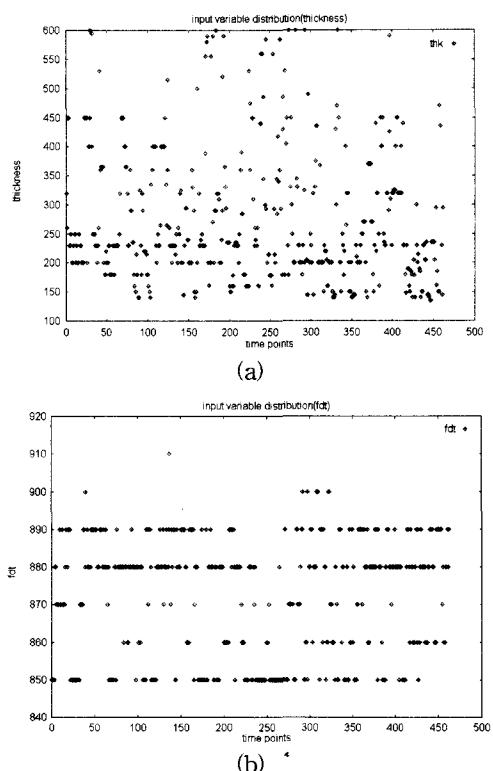


그림 4. 입력 변수값들의 분포 모양 (a) 코일의 두께 분포 (b) 압연 종료후 코일의 온도 분포

Fig. 4. Distribution of input variables (a) thickness of a slab (b) target coiling temperature.

한편, 입력 변수들에 따라 데이터들도 작게는 수십에서 크게는 수백까지 변하므로 자동 클러스터링 방법을 이용하려면 미리 데이터를 규준화(normalization)해야 하지만, 오프라인 학습이 끝난 다음, 제어 모델을 온라인으로 재 학습하는 데는 적합하지 않다. 따라

서, 초기 RBF의 매개 변수들을 설정하는 데 있어 전문가 지식에 의한 휴리스틱 클러스터링이 기존의 자동 클러스터링 방법들보다 의미있는 클러스터를 보다 효과적으로 찾을 수 있다.

입력 데이터들에 대한 클러스터링이 끝나면, 각 영역에 한 개씩의 RBF가 할당된다. 각 영역에 속한 데이터들의 평균과 표준편차로 RBF의 초기 매개변수들이 결정되고 평균제곱 오차(mean-squared error)로 출력층에서 정의된 오차 합수를 최소화하는 방향으로 RBF네트워크의 매개변수들과 은닉층과 출력층 사이의 시냅스 가중치들이 학습된다. 이때 출력층의 목표 값은 동일한 세트에 속하는 코일들 중에서 가장 좋은 성능을 내는 코일의 f_1 으로 둔다. RBF네트워크가 이런 f_1 을 학습하고 테스트 과정에서 코일의 첫장에 적용되는 f_1 을 준다면 코일의 제어 성능이 크게 향상될 것이다.

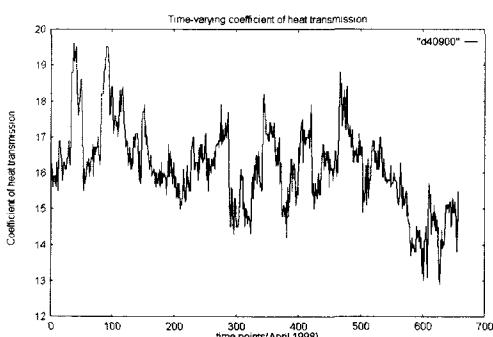


그림 5. 비슷한 입력 값을 갖는 데이터들의 f_1 의 시변 특성

Fig. 5. Time-varying fluctuations of f_1 with similar input values.

그림 5는 클러스터링된 입력 데이터 영역에서 비슷한 입력값을 가지는 데이터들의 목표 f_1 을 나타낸 것으로, 시간에 따라 f_1 이 크게 변함을 알 수 있다. 공정 데이터의 시변 특성을 고려하기 위해 온라인으로 재학습이 가능한 RBF네트워크를 새로 제안한다. 기존의 RBF네트워크의 은닉층과 출력층에 온라인 재학습용 시냅스 가중치를 추가로 도입한다. 재학습용 가중치들은 과거에 학습한 데이터와 입력값이 비슷한데도 목표 f_1 이 달라져 있는 데이터가 들어왔을 경우에 이를 보상하도록 학습된다. 즉, 입력값들은 비슷한데 다른 목표 출력 f_1 을 갖는 테스트 데이터에 대해 가장 큰 활성화값을 갖는 은닉층 뉴런과 출력층 뉴런에 연결된 재학습용 가중치가 생성된다. 이 가중치들은 보통 때에

는 RBF네트워크의 출력값을 계산하는데 기여를 하지 않는다. 대신 과거에 학습한 데이터와의 유사성을 RBF네트워크의 은닉층 활성화 값을 통해 계산하여 재학습용 가중치들을 학습시킬지를 결정한다.

온라인 재학습 가능한 RBF네트워크의 학습 과정은 기존의 RBF네트워크의 학습 알고리즘과 동일하고 재학습 방법은 위에서 설명한 것처럼 이루어진다. 학습과 재학습 알고리즘을 정리하면 다음과 같다.

온라인 학습 과정:

- 전문가 지식을 이용한 클러스터링 방법으로 RBF 평균과 표준편차를 구한다.
- 네트워크의 출력값을 계산하기 위해 전방향으로 신호를 전파한다.

$$\Psi_i = \Psi(\mathbf{x}, \mathbf{m}^i, \mathbf{K}^i)$$

$$= \exp \left[-\frac{(\mathbf{x} - \mathbf{m}^i)^T \mathbf{K}^i (\mathbf{x} - \mathbf{m}^i)}{2} \right]$$

$$y_l = \sum_i w_{ik} \Psi_i$$

$$= \sum_i w_{ik} \exp \left[-\sum_j \sum_k \frac{k^i j_k (x_j - m_j^i)(x_j - m_k^i)}{2} \right] \quad (3)$$

여기서, x_j , m_j^i , w_{ik} 는 각각 입력 패턴 \mathbf{x} 의 j 번째 요소, 평균 벡터 \mathbf{m}^i 의 j 번째 요소, 은닉층의 i 번째 뉴런과 출력층의 k 번째 뉴런에 연결된 시냅스 가중치를 나타낸다.^[9] 그리고, $k^i j_k$ 는 RBF 모양을 결정하는 형태 벡터 \mathbf{K}^i 의 (j,k) 번째 요소이고, RBF의 표준 편

차 σ 와는 $K_{jk}^i = \begin{cases} \frac{1}{(\sigma_j^i)^2} & \text{if } j = k \\ 0 & \text{otherwise} \end{cases}$ 의 관계로 정의된다.

- 매개변수 학습을 위해 역방향으로 신호를 전파한다.

$$w_{ik}[n] = w_{ik}[n-1] + \eta(t_l - y_l) \Psi_i \quad (4)$$

$$m_j^i[n] = m_j^i[n-1] + \eta_\mu \frac{(x_j - m_j^i)}{(\sigma_j^i)^2} \Psi_i \sum_{l=1}^M (t_l - y_l) w_{ik}$$

$$\sigma_j^i[n] = \sigma_j^i[n-1] + \eta_\sigma \frac{(x_j - m_j^i)^2}{\sigma_j^i} \Psi_i \sum_{l=1}^M (t_l - y_l) w_{ik}$$

여기서, η , η_μ , η_σ 는 각각 시냅스 가중치의 학습률, RBF 평균과 표준편차의 학습률을 나타낸다.^[9] t_l 는 동일한 세트의 코일중에서 가장 좋은 성능을 내는 코일의 목표 출력값 f_1 이다.

온라인 재학습 알고리즘(테스트 과정):

- 재학습용 시냅스 가중치들을 제로로 초기화한다.
- 이미 학습된 네트워크에 테스트 데이터들을 입력으로 준다.
- 네트워크의 출력값을 계산하기 위해 다음과 같이 전방향으로 신호를 전파한다.

$$\Psi_i = \Psi(\mathbf{x}, \mathbf{m}^i, \mathbf{K}^i) = \exp\left(-\frac{(\mathbf{x} - \mathbf{m}^i)^T \mathbf{K}^i (\mathbf{x} - \mathbf{m}^i)}{2}\right)$$

$$y_i = \sum_i w_{ii} \Psi_i + \Delta y_i = \sum_i w_{ii} \Psi_i + \Delta w_{ii} \Psi_i \quad (5)$$

여기서 Δw_{ii} 는 은닉층의 i 번쨰 뉴런과 출력층의 i 번쨰 뉴런사이의 재학습용 시냅스 가중치를 나타낸다.

- RBF네트워크의 은닉층 활성화 값이 가장 큰 은닉 뉴런을 찾는다.
- 출력층에서의 오차를 계산한다.
- (4)번에서 찾은 은닉 뉴런과 출력층에 연결된 재학습용 시냅스 가중치를 다음과 같이 갱신한다.

$$\Delta w_{ii} = \frac{f1_{new} - y_i}{\max_i \{\Psi_i\}} \quad (6)$$

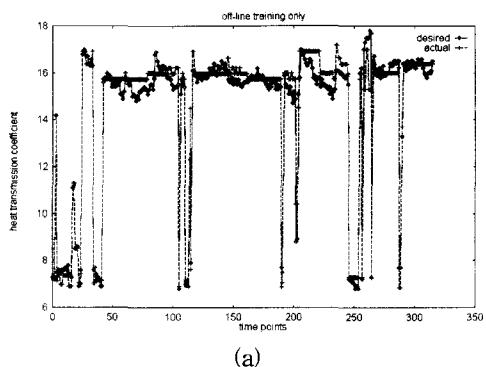
여기서 $f1_{new}$ 는 현재 입력으로 들어오는 테스트 데이터에 대해 수식 2를 통해 갱신된 $f1$ 값이다. 그리고 수식2의 $f1_{old}$ 는 네트워크의 출력값으로 y_i 와 동일하다.

4. 열연 공정에 적용된 실험 결과

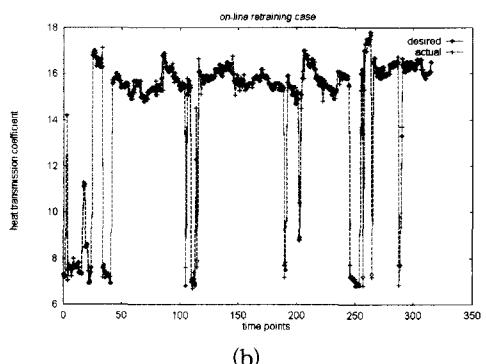
모의 실험에는 1998년 4월부터 5월까지 포항제철의 열연 공정에서 얻은 실제 데이터를 이용하였다. 입력 변수로 코일의 두께, 성분, 목표 권취 온도, 수온과 FDT를 준다. 학습에 이용한 데이터는 90%이상의 성능을 나타내는 데이터로 선택하고, 목표 출력값 $f1$ 은 동일한 세트의 코일들 중에서 가장 좋은 성능을 내는 코일의 $f1$ 값으로 준다. 학습에는 463개의 데이터와 188개의 RBF가 이용되었고, 출력 오차가 0.3이하로 충분히 학습시켰다.

그림 6에서 보면, 온라인 재학습 과정 없이 오프라인 학습만 했을 때는 적절한 $f1$ 을 얻을 수 없음을 알 수 있다. 그림 7은 온라인 재학습과 오프라인 학습 시 거부 네트워크를 이용했을 때와 이용하지 않았을 때의 제어 성능을 나타낸다. 그림 7에서 X축은 네트워크의 출력값과 목표 출력값과의 차이를 나타내고, 히스토그램의 가장 안쪽 막대는 온도 제어 오차가 제로인 비율을 나타낸다. 즉, 평균 제어 적중률을 나타낸다. 그림

7(a)와 (b)를 비교하면, 거부 네트워크를 이용하면 온라인 재학습의 제어 성능이 약 60%에서 90%이상으로 증가함을 볼 수 있다. 그리고 온라인 재학습을 적용한 경우에는 오프라인 학습만 했을 때에 비해 전반적으로 약 20%이상의 성능 향상을 보인다. 이 결과로부터 공정 조건들이 시간에 따라 크게 달라져 있으므로 온라인 재학습이 반드시 이루어져야 함을 알 수 있다.



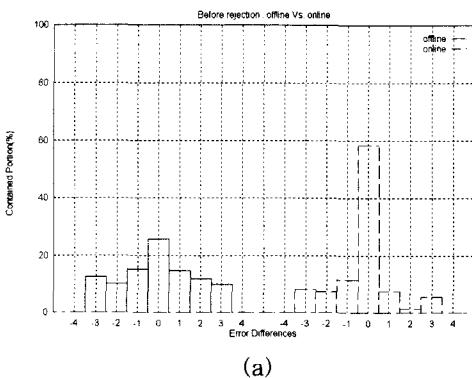
(a)



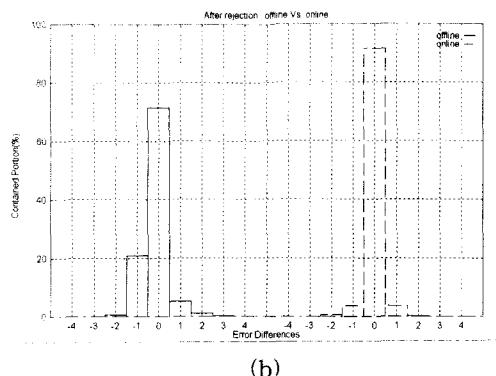
(b)

그림 6. 일반화 성능 결과 (a) 오프라인 학습만 이용했을 경우 (b) 온라인 재학습이 이루어진 경우

Fig. 6. Generalization results (a) when only off-line training is used (b) when on-line retraining is used.



(a)



(b)

그림 7. 오프라인 학습과 온라인 학습시의 제어 오차에 따른 성능비교 (a) 거부 네트워크를 이용하지 않은 경우 (b) 거부 네트워크를 이용했을 경우

Fig. 7. Off-line and on-line test results according to error differences (a) without rejection scheme (b) with rejection scheme.

본 논문에서 제시된 신경회로망을 통한 제어 모델을 포항제철의 실제 열연 공정에 적용한 결과를 표1에 보인다. 학습에는 1998년 5월 8일부터 6월 8일까지의 1달 데이터를 이용하였다. 1998년 6월 12일부터 7월 12일까지의 열연 공정에 온라인 재 학습 과정인 테스트를 한 결과 기존의 계수표 방법에 비해 평균 2.2% 이상의 제어 성능 향상을 얻을 수 있었다. 여기서 평균 제어 성능은 목표 온도와 제어 온도와의 차이가 도내인 코일의 수를 전체 작업 코일의 수로 나누어 폐센트를 구한 것이다. 현재 본 논문에서 제안된 제어 모델은 현장에 설치되어 베타 테스트 중에 있다.

표 1. 온라인 재학습 RBF네트워크 모델을 포항 제철의 열연 공정에 직접 적용한 경우 기존의 계수표 방법과의 성능 비교

Table 1. Average performance comparison between the conventional look-up table modeling and the proposed on-line re-trainable RBF network.

Range	540< TCT <=640
Average performance(%)	
Look-up table	95.16
Neural Network	97.39

IV. 결 론

본 논문에서는 시간에 따른 주위 환경의 변화가 심

한 포항 제철의 열연 공정에 온라인 재학습 가능한 RBF네트워크를 도입하여 기존의 열연 온도 제어 시스템을 보완/개선하는 방법을 제안하였다. 열연 공정의 데이터를 이용한 모의 실험으로 기존의 계수표 모델을 신경회로망에 기반한 모델로 대체할 수 있었고 간단한 거부 네트워크를 도입하여 제어 모델의 신뢰도를 높일 수 있었다. 또한 1달간 실제 현장에 적용한 결과 기존의 방법에 비해 평균 2.2% 이상의 제어 성능 향상을 볼 수 있었다.

참 고 문 헌

- [1] S. Cho, Y. Cho, and S. Yoon, "Reliable Roll force prediction in cold mill using multiple neural networks", *IEEE Transactions on Neural Networks*, Vol. 8, No. 4, 1997, pp. 874-882.
- [2] Q. Wang, J. Z. Zhang, et al., "Multi-layered mathematical model system for hot continuous rolling process control and its application in real process", *Proceedings Of the 1997 IEEE International conference on intelligent processing systems*, Vol. 2, No.1, 1997, pp. 754-758.
- [3] J. Kato, et al, "Measure and control of rolling of a precision moving table", *Proceedings Of the 1997 IEEE International conference on intelligent processing systems*, Vol. 1, No.1, 1990, pp. 70-74.
- [4] K. Hornik, "Approximation capabilities of multilayer feedforward networks", *Neural Networks*, Vol. 4, No. 2, 1991, pp. 251-257.
- [5] S. Grossberg, "Competitive learning : From interactive activation to adaptive resonance", *Cognitive Science*, Vol. 11, 1987, pp. 23 -63.
- [6] R. M. French, "Pseudo-recurrent connectionist networks: An approach to the "sensitivity-stability" dilemma", *Connection Science*, Vol. 9, No. 4, 1997, pp. 353-379.
- [7] S. Weaver, L. Baird, and M. M.

- Polycarpou, "An analytic framework for local feedforward networks", *IEEE Transactions on Neural Networks*, Vol. 9, No. 3, 1998, pp. 473-482.
- [8] A. Robins, "Catastrophic forgetting, rehearsal, and pseudorehearsal", *Connection Science*, Vol. 7, 1995, pp. 123-146.
- [9] S. Lee and R. M. Kil, "A gaussian potential function network with hierarchically self-organizing learning", *Neural Networks*, Vol. 4, 1991, pp. 207-224.
- [10] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks", *IEEE Transactions on Neural Networks*, Vol. 9, No. 4, 1998, pp. 601-612.
- [11] T. Kohonen, "The self-organizing map", *Proceedings of IEEE*, Vol. 78, 1990, pp. 1464-1480.

저자소개



鄭 韶 永(正會員)

1975년 6월 8일생. 1996년 2월 한국
과학기술원 전기및전자공학과 졸업
(공학사). 1998년 2월 한국과학기술
원 전기및전자공학과 졸업(공학석
사). 1998년 ~ 현재 한국과학기술
원 전기및전자공학과 박사과정 재학
중. 주관심 분야는 시계열 예측, 신경회로망 학습 알고리
즘 개발 및 모델링등

李 敏 鎬(正會員) 第34卷 C編 第6號 參照

李 壽 永(正會員) 第34卷 C編 第6號 參照