

신경회로망과 유전자 알고리즘을 이용한 열연두께 정도 향상

Improvement of Thickness Accuracy in Hot-Rolling Mill

Using Neural Network and Genetic Algorithm

손준식*, 김일수**, 최승갑***, 이덕만***

* 목포대학교 대학원 기계공학과

** 목포대학교 기계선박해양공학부

*** 포항제철 기술연구소 계측제어연구그룹

Abstract

In the face of global competition, the requirements for the continuously increasing productivity, flexibility and quality (dimensional accuracy, mechanical properties and surface properties) have imposed a major change on steel manufacturing industries. The automation of hot rolling process requires the developments of several mathematical models for simulation and quantitative description of the industrial operations involved. To achieve this objectives, a new learning method with neural network to improve the accuracy of rolling force prediction in hot rolling mill is developed. Also, Genetic Algorithm(GA) is applied to select the optimal structure of the neural network and compared with that of engineers experience. It is shown from this research that both structure selection methods can lead to similar results.

1. 서 론

철강제품은 자동차, 가전제품 등 광범위한 산업현장에서 이용되고 있으며, 이러한 철강제품의 90%이상은 압연공정을 통하여 생산되고 있다. 최근의 시장경쟁 체제에서 압연제품의 품질에 대한 요구는 더욱 엄격해지고 있으며, 압연공정 중에서 열간사상 압연공정은 가장 기본적인 공정으

로 열간사상 압연공정의 두께제어기술은 제품의 품질향상과 생산효율의 향상이라는 관점에서 매우 중요한 문제이다.

열간사상 압연공정 제어 시스템은 기본적으로 측정데이터를 얻는 부분(acquisition)과, 미리 계산(예측)하는 부분(pre-calculation), 모델식(model equation), 마지막으로 공정 후 보정을 위한 계산부분(post-calculation) 등으로 구성되어 있다. 열간 압연과 같은 공정에서는 가장 중요한 부분이 미리 계산(예측)하여, 설정(setting)하는 것이다. 즉, 압연과정에서는 철판이 롤에 들어오기 전에 정확한 설정값(setting value)을 결정하기 위하여 빠르고 정확하게 압연하중과 토크를 예측하여야 한다. 이를 위해서는 충분한 양의 공정 데이터를 기초로 실시간(real-time) 공정에 수학적 모델에 의한 전계산(pre-calculation) 오차에 대한 보정을 의미하는 후계산(post-calculation) 작업에 신경회로망을 이용함으로써 가능하며¹⁻²⁾, 최근 몇 년 동안, 이에 대한 많은 연구가 활발히 진행되고 있다. 독일의 Siemens AG의 IBSG(The Industrial and Building System Group)는 EAF(Electric Arc Furnace)와 열간사상 압연하중, 압연재온도, 자연 확산 및 short-stroke 또는 electrode position과 같은 요인을 예측하기 위해 신경회로망을 적용하였다³⁻⁵⁾. 또한, 1998년 중국 상하이에 소재한 Baoshan Iron and Steel Corp.은 열간압연의 압연하중을 예측하기 위하여 BP(Backpropagation) 알고리즘을 이용한 신경회로망

을 수학적 모델에 결합하였다⁶⁾.

신경회로망은 구조가 복잡해지면, 뉴런의 수가 증가함에 따라 학습시간이 증가하며, 학습시초기값에 따라 전역 최소점에 도달하지 않는 단점이 있다. 따라서 실제 시스템을 효과적으로 표현할 수 있는 최소 뉴런수와 그에 따른 연결구조, 그리고 원하는 출력과 학습된 신경회로망 출력사이의 오차가 최소가 되며, 응답시간 역시 최소가 되는 최적 구조의 신경회로망 설계가 필요하다. 하지만 대부분의 열간사상 압연공정 제어에서 신경회로망을 적용한 연구들은 압연하중 예측에 중점을 두고 있으며, 최적의 압연하중을 예측할 수 있는 신경회로망의 구조에 관한 연구는 미비한 실정이다.

따라서 본 연구에서는 신경회로망의 구조를 유전자 알고리즘(Genetic Algorithm : GA)의 유전자로 이진 코딩하여 최적 구조 신경회로망을 탐색하고, 이 최적 구조의 신경회로망을 이용하여 열간사상 압연의 압연하중을 예측할 수 있는 모델을 개발하였다.

2. 신경회로망 구조 최적화

유전자 알고리즘을 이용하여 신경회로망의 구조에 은닉층 뉴런수와 반복횟수를 염색체로 표현하여 적합도 함수에 의해 최적의 구조를 신경회로망에 전달하여 신경회로망의 구조를 최적화하는 것이다. 유전자 알고리즘은 신경회로망 구조요소를 전역 탐색함으로써 최적의 뉴런수와 반복횟수를 신경회로망으로 전달하여 응답시간과 오차가 최소가 되는 최적의 신경회로망 구조를 찾게 된다.

2.1 신경회로망의 구조

최적의 신경회로망 구조를 선정하기 위해 학습에 사용된 데이터는 1999년 5월 11983 coils에 대한 데이터를 가지고 학습하였다. 신경회로망 구조에서 은닉층의 수는 기준의 대부분 압연하중 예측모델에 대한 연구에서 은닉층의 수를 1개로 고정하였고, Tarun Khannam⁷⁾는 최적화 문제에서 은닉층의 수가 1개만으로도 충분하다고 하였으므로 신경회로망의 은닉층 뉴런의 수와 반복

(iteration) 횟수를 결정하여 최적의 신경회로망의 구조를 선정하고자 하였다. 학습에 사용된 알고리즘은 Levenberg-Marquardt BP 알고리즘을 이용하였으며, 객관적 평가를 위하여 신경회로망의 가중치 초기값은 0.01로 고정하였으며, 바이어스(bias)는 0.1로 고정하였다. 입력변수는 5개로 하였으며, 입력변수는 학습률($RF_a/RF_{ma} - 1$), 변형, 변형률, 온도, Ceq로 선정하였다.

2.2 신경회로망 구조의 부호화 및 적합도

유전자 알고리즘을 이용하여 문제를 해결하고자 할 때, 해결하고자 하는 문제에 대한 가능한 해들을 염색체(chromosome)로 표현하고 이를 점차 변형해 나감으로써 점점 더 좋은 성능의 해를 구한다. 본 연구에서는 신경회로망의 구조를 염색체로 표현하여 최적 구조 신경회로망을 구하기 위하여, 다음과 같은 방법으로 신경회로망의 구조를 코드화 하였다. 신경회로망의 구조에서 은닉층 뉴런개수와 반복횟수를 유전자 알고리즘의 이진코딩(binary encoding)을 사용하여 코딩한 후 유전자 알고리즘의 연산과정을 통해 최적의 신경회로망 구조를 탐색하였다. 각 진화 단계에서 유전자 알고리즘은 신경회로망의 구조를 결정하게 되고, 이 구조를 바탕으로 신경회로망의 학습방법에 의해 학습을 하게 된다. 학습 후 실제 출력과 신경회로망 출력사이의 오차와 신경회로망의 구조가 가지는 응답시간을 산출하며 이것을 적합도 함수값으로 산출하여 유전자 알고리즘의 개체를 진화하는데 사용한다.

Table 1 Limits of search

Bit	Min value	Max value
1 ~ 3	000	Iteration : 100
	:	:
	111	Iteration : 100
4 ~ 6	000	No. of neuron in hidden layer : 4
	:	:
	111	No. of neuron in hidden layer : 4

은닉층 뉴런수와 반복횟수를 염색체로 표현하기 위해, 본 연구에서는 Table 1과 같은 탐색범

위를 설정하였다. 염색체를 전체 6 bit로 이진 코딩하였으며, 염색체의 처음 3 bit는 반복횟수이고, 다음 3 bit는 은닉층 뉴런수를 나타낸다. Fig. 1은 본 연구에서 사용된 이진 코딩의 예를 나타낸 것이다.

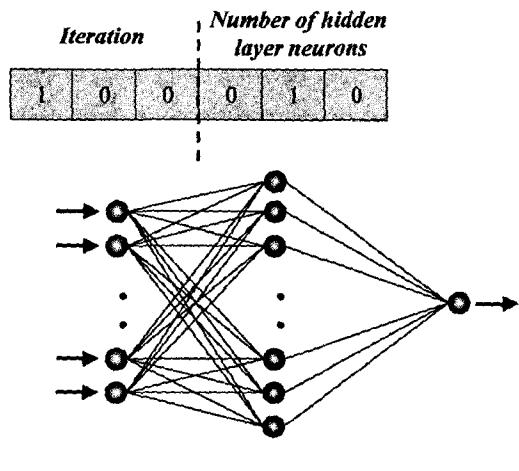


Fig. 1 Binary Coding of neural network structure

본 연구에서 제안한 최적 신경회로망 구조 탐색은 크게 두 가지의 조정기구에 의하여 구한다. 우선 유전자 알고리즘을 이용하여 은닉층 뉴런수와 반복횟수 같은 신경회로망 구조를 최적화하는 과정을 거치게 되며, 다음으로 각 구조에 대해서 뉴런간의 연결강도는 신경회로망 학습 방법인 Levenberg-Marquardt BP 알고리즘⁸⁾에 의해 결정되어 진다. 최적의 신경회로망 구조를 얻기 위해서는 평가기준이 요구되며, 본 연구에서는 식(1)과 같은 적합도 함수를 설정하며, 이 적합도 함수가 최소가 되도록 조정하여 최적 구조 신경회로망을 탐색한다. 식(1)에서 $f_e(\hat{e})$ 는 실제 출력과 신경회로망 출력 사이의 오차이고, $f_t(\hat{t})$ 는 신경회로망 구조가 가지는 응답시간이며, W_1 , W_2 는 적절한 가중치 값이다.

$$fit_{GA} = W_1 \cdot f_e(\hat{e}) + W_2 \cdot f_t(\hat{t}) \quad (1)$$

2.3 신경회로망 최적화의 구조 및 연산과정

은닉층 뉴런수와 반복횟수는 유전자 알고리즘의 이진 코딩을 이용하여 염색체로 표현하였으며, 각 탐색 단계에서 염색체의 값을 신경회로망 구조로 변환하여 신경회로망으로 전달하게 된다. 신경회로망은 전달된 구조를 가지고 동일한 조건 하에서 학습하게 되며, 학습이 끝난 후 오차와 응답시간을 산출하여 저장하게 된다. 산출된 오차와 응답 시간의 값을 적합도 함수를 이용하여 적합도를 산출하고, 재생산, 교배 연산, 돌연변이 연산과정을 거쳐 진화하게 된다. 진화 후 개체들은 최적 구조의 신경회로망 구조를 가지게 된다.

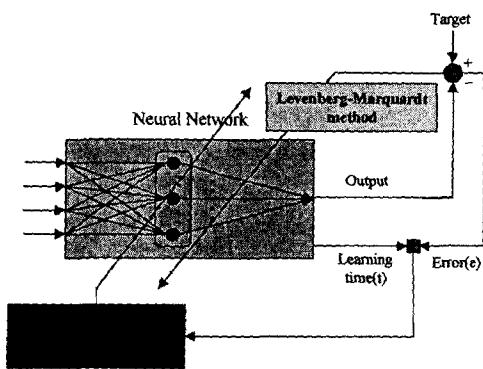


Fig. 2 Structure of optimization using genetic algorithm

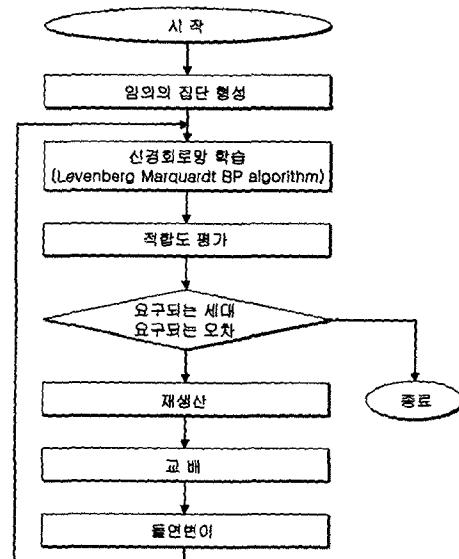


Fig. 3 Operation structure of genetic algorithm

Fig. 2는 제안한 유전자 알고리즘을 이용한 신경회로망 최적화 구조를 나타내며, Fig. 3은 제안한 유전알고리즘을 이용한 신경회로망 최적화의 연산과정을 나타낸 것이다.

2.4 최적의 신경회로망 구조 선정

유전자 알고리즘을 이용하여 최적의 신경회로망 구조를 선정하기 위하여 유전자 알고리즘의 변수(parameter)로 최대 진화수는 40세대, 개체수는 16, 교배확률 0.8, 돌연변이 확률 0.01로 설정하였으며, 적함도 함수의 가중치값은 신경회로망의 출력오차가 더 중요한 영향을 미치도록 W_1 은 6으로 W_2 는 4로 설정하였다.

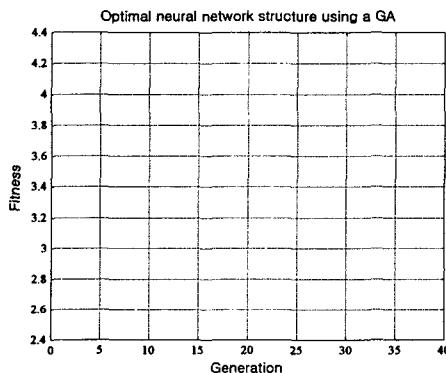


Fig. 4 Search for Optimal neural network structure

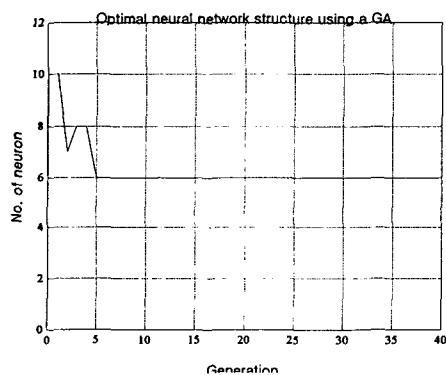


Fig. 5 Optimal number of neuron in hidden layer

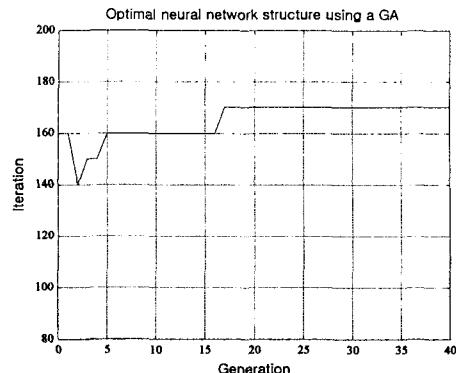


Fig. 6 Optimal iteration

Fig. 4는 최적의 신경회로망을 탐색한 결과를 나타내며 17세대에서 최적의 신경회로망 구조를 탐색하였다. Fig. 5와 Fig. 6은 탐색된 신경회로망의 구조를 나타낸다. 탐색된 결과에 따르면 신경회로망 구조는 은닉층 뉴런수가 6개이고, 반복횟수가 170회였을 때 최적의 신경회로망 구조를 갖는다.

3. 열간사상 압연에 신경회로망 적용

최적 구조의 신경회로망을 이용한 압연하중 예측모델을 열간사상 압연의 압연하중 예측에 적용하여 기존의 압연하중 예측모델과 성능을 비교함으로써 신경회로망을 이용한 압연하중 예측모델의 성능을 확인하였다. 학습에 사용된 데이터는 1999년 5월 11983 coils의 데이터를 이용하였으며, 학습된 신경회로망을 테스트하기 위하여 1999년 6월 1745 coils의 데이터를 사용하였다. 신경회로망 학습에 사용된 입력변수는 학습률($RF_a/RF_{ma} - 1$), 변형, 변형률, Ceq, 온도 등 총 5개를 사용하였으며, 비선형 함수는 tangential sigmoid 함수를 사용하였으며, 학습 알고리즘은 학습속도가 빠른 Levenberg- Marquardt BP 알고리즘을 사용하였다.

Fig. 7은 기존 모델에 의한 압연하중 예측결과와 신경회로망을 이용한 압연하중 예측결과를 비교한 것이다. 그림에서 보는 바와 같이 신경회로망을 이용한 압연하중 예측결과가 보다 정확함을 나타내고 있다.

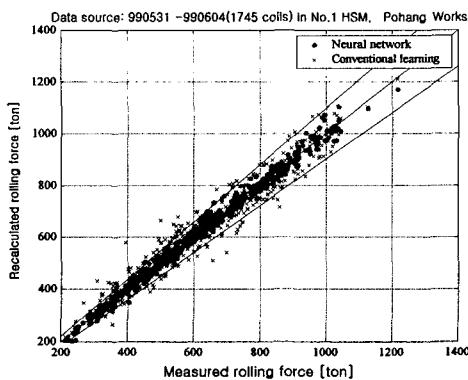


Fig. 7 Comparison of predicted rolling force using neural network and conventional model

Fig. 8은 기존 모델에 의한 압연하중 예측결과와 신경회로망을 이용한 압연하중 예측결과를 실제 측정한 압연하중과 비교하여 나타난 오차를 보여주는 그림으로서 기존 모델에 의한 압연하중 예측결과는 실측치 압연하중에 비하여 낮게 예측하였으며 또한, 오차의 분포가 넓게 나타났다. 하지만 신경회로망을 이용한 압연하중 예측결과는 실측치 압연하중에 근접한 예측결과를 보여주고 있으며, 오차의 분포가 좁게 나타나 신경회로망을 이용한 압연하중 예측모델이 우수하다는 것을 알 수 있었다.

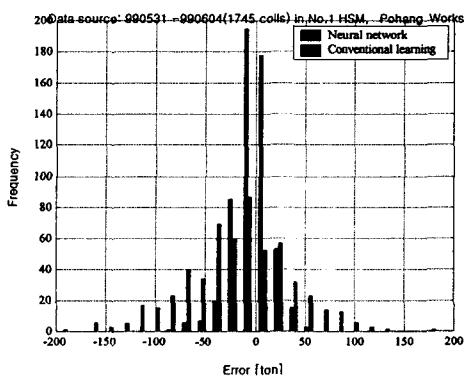


Fig. 8 Comparison of rolling force error using neural network and conventional model

예측한 압연하중을 보다 정확하게 비교하기 위하여 아래의 식과 같이 Poliak⁹⁾이 정의한 PAM (Predictive Ability of model)을 이용하여 정확도를 평가하였다.

$$PAM = \frac{N_{PM}}{N_{total}} \times 100 \quad (2)$$

여기서, N_{PAM} 은 $\left| \frac{RF_a - RF_{ma}}{RF_a} \right| \leq 0.1$ 범위의 예측치의 수를 나타내며, N_{total} 은 전체 예측치 수를 나타낸다. 그리고 RF_a 는 실측치 압연하중이며, RF_{ma} 는 재계산된 압연하중을 의미한다.

PAM는 오차범위 10% 이내에 예측을 정확한 예측으로 간주하여 모델의 정확도를 나타내며, 표준편차는 모델의 분포를 확인함으로써 실측치 압연하중에 얼마나 근접하게 예측하는지를 나타낸다.

Table 2 Comparison between neural network with conventional model

	Standard deviation (%)	Standard error (%)
Conventional model	84.1918	43.8336
Neural network	98.9343	18.6946

Table 2는 PAM과 표준편차를 나타낸다. PAM를 보면 기존 모델에 의한 압연하중 예측결과는 84% 까지 떨어지는 것으로 나타나는데 이는 16%정도가 정확한 예측에 실패했다는 결과가 된다. 하지만 신경회로망을 이용한 압연하중 예측결과는 98%이상으로 보다 정확한 예측결과를 나타냄으로써 기존의 모델보다 월등하게 정확한 예측을 했다는 것을 알 수 있다. 또한 표준편차에서도 기존의 방법보다 상당히 적은 값을 나타냈다. 이는 예측된 결과가 기존의 방법보다 실측치에 근접하게 예측한다는 것을 입증한다. 위의 결과를 분석해 보았을 때 신경회로망을 이용한 압연하중 예측모델이 기존 모델을 이용한 압연하중 예측모델보다 압연하중 예측성능이 뛰어나다는 것을 알 수 있었다.

4. 결 론

본 연구에서는 신경회로망 및 유전자 알고리즘을 이용하여 열간사상 압연에서 압연하중 예측 모델의 성능을 개선하였으며, 기존 모델과 새로운 모델을 비교·분석하였다.

- 1) 최적의 신경회로망 구조를 선정하기 위하여 신경회로망의 구조를 유전자 알고리즘의 유전자로 이진 코딩하여 최적의 신경회로망 구조를 탐색하였다. 탐색 결과에 따르면 신경회로망 구조는 은닉층 뉴런수가 6개이고, 반복횟수가 170회였을 때가 최적이었다.
- 2) 신경회로망을 이용한 압연하중 예측모델의 성능을 확인하기 위하여 기존의 압연하중 예측 모델에 의한 압연하중 예측결과를 비교·분석하였다. 비교결과 PAM의 경우 14%정도 성능이 향상되었으며, 신경회로망을 이용한 압연하중 예측모델의 예측치 압연하중이 실측치에 보다 근접하게 압연하중을 예측하였다.

참고문헌

1. N. F. Portmann, "Application of neural networks in rolling mill automation", Iron and Steel Engineer, pp. 33-36, February, 1995.
2. C. Lu, X. Wang, X. Liu, G. Wang, K. Zhao and J. Yuan, "Application of ANN in combination with mathematical models in prediction of rolling load of the finishing stands in HSM", Proceeding of The International Conference on Steel Rolling, Iron and Steel Institute of Japan, pp. 206-209, 1998.
3. T. Poppe, D. Obradovic and M. Schlang, "Neural networks : Reducing energy and raw materials requirements", Siemens Review-R&D Special, pp. 24-27, 1995.
4. N. F. Portmann, "Application of neural networks in rolling mill automation", Iron and Steel Engineer, Vol. 72, No. 2, pp. 33-36, 1995.
5. M. Schlang, B. Lang, T. Poppe, T. Runkler and K. Weinzierl, "Current and future development in neural computation in steel processing", Control Engineering Practice, Vol. 9, pp. 975-986, 2001.
6. X. Yao, "Application of artificial intelligence for quality control at hot strip mills", Ph.D Thesis, The University of Wollongong, 1996.
7. T. Khanna, "Foundations of Neural Networks", Addison-Wesley, 1990.
8. M.T. Hagan and M. B. Menhaj, "Training feedforward networks with marquardt algorithm", IEEE Transaction on Neural Networks, Vol. 5, No. 6, pp. 989-993, 1994.
9. E. I. Poliak, "Application of linear regression analysis in accuracy assessment of rolling force calculations", Metals and Materials, Vol. 4, No. 5, pp. 1047-1056, 1998.