

On-line 학습 신경회로망을 이용한 열간 압연하중 예측

손준식*, 이덕만[†], 김일수⁺⁺, 최승갑[†]

(논문접수일 2004. 04. 21, 심사완료일 2004. 10. 26)

Prediction for Rolling Force in Hot-rolling Mill Using On-line learning Neural Network

Joon-Sik Son*, Duk-Man Lee[†], Ill-Soo Kim⁺⁺, Seung-Gap Choi[†]

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. Indeed, one of the keys to achieve this goal is the automation of the steel-making process using AI(Artificial Intelligence) techniques. The automation of hot rolling process requires the developments of several mathematical models for simulation and quantitative description of the industrial operations involved. In this paper, an on-line training neural network for both long-term learning and short-term learning was developed in order to improve the prediction of rolling force in hot rolling mill. This analysis shows that the predicted rolling force is very closed to the actual rolling force, and the thickness error of the strip is considerably reduced.

Key Words : Neural network, On-line learning, Rolling force, Hot rolling process AI

1. 서 론

열간사상 압연공정을 위한 시스템은 6-7개의 압연스탠드로 구성되며, 압연작업 공정은 전계산(pre-calculation)단계, 제어(control)단계, 후계산(post-calculation)단계의 반복작업으로 구성된다. 전계산 단계는 강종, 온도 등을 기본으로 압연이론에 기초한 수학적 모델식에 의해 률속도, 률갭, 압연하중 등과 같은 설정값(preset-value)을 결정한다.

설정값은 피드백(feedback) 제어하는 제어단계까지 개루프(open-loop)제어 명령값으로 사용되므로 이 설정의 정도에 따라 판 선단부(head-end)의 두께정도를 결정하게 되고 품질에 상당한 영향을 미친다. 후계산 단계는 하나의 코일 제어 후에 전계산 단계의 오차를 줄이기 위해 수식모델 변수(parameter)를 조정하는 일련의 작업을 수행한다⁽¹⁾. 제철소 공정제어의 주요 작업중의 하나는 mill 안으로 스트립이 들어오기 전 정확한 mill 설정값(setting value)을

* 목포대학교 기계공학과 (sonjoonsik@naver.com)

주소: 534-730 전남 무안군 청계면 도림리 61

+ 포항제철 기술연구소

++ 목포대학교 기계·해양시스템공학부

결정하기 위하여 빠르고 정확하게 압연하중과 토크를 예측할 수 있는 공정모델을 개발하는 것이다^(2,3). 이러한 목표는 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 가능하다.

신경회로망의 압연에 이용은 1990년대 초에 Larkiola⁽⁴⁾의 냉간압연 스텝트의 평면도(flatness)와 윤곽(profile)제어에 신경회로망을 적용한 연구결과가 발표된 이후 압연에 신경회로망의 적용은 평평도 제어에서부터 압연재의 기계적 성질의 예측까지 적용범위가 점점 확대되어가고 있다. 1996년 호주의 Yao⁽⁵⁾는 열간압연에서 선단과 선미의 폭 제어를 위해 신경회로망을 이용하여 BHP Steel Co.에 적용하였다. BP(Backpropagation) 신경회로망은 선단과 선미의 폭형상을 기본적인 형상으로 분류하기 위하여 이용하였다. 학습에 사용된 형상은 실제 형상으로 45개의 기본적인 형상을 학습데이터로 사용하였으며, 입력변수로 형상의 20개의 포인트를 사용하였다. 독일의 Siemens AG의 IBSG(The Industrial and Building System Group)는 기초산업에서 2차 공정 자동화를 위해 신경회로망을 사용하여 왔으며, 현재 하나의 플랜트를 운용하는데 20가지 이상의 신경회로망을 적용하고 있다^(6~8). 특히, 제철소에서는 EAF(Electric Arc Furnace)와 열간 압연공정에서 압연하중, 압연재온도, 자연 확산 및 short-stroke 또는 electrode position과 같은 요인을 예측하기 위해 신경회로망을 적용하였다고 발표하였다.

최근에는 열간사상 압연공정에서도 기존의 수식모델과 신경회로망을 결합하여 압연하중 예측 및 두께 적중률을 향상시키고 있다^(8~10). 하지만 사용된 신경회로망은 수장 및 수십장의 같은 성분 및 규격으로 구성되는 lot의 첫 장에만 적용되는 장기학습 압연하중 예측모델에 사용되고 있다. 특히, 동종의 재료를 연속압연시 단기학습에는 신경회로망이 적용되지 않으며, off-line 학습방식으로 학습하기 때문에 사상압연 중에 입력되는 새로운 데이터를 가지고 학습할 수 없는 단점을 가지고 있다.

본 연구에서는 열간 사상압연에서 장기학습 뿐만 아니라 단기학습까지 신경회로망을 적용하여 사상압연 중에 입력되는 새로운 데이터를 가지고 학습하는 on-line 학습법을 적용하고자 하였으며, 이를 통하여 열간사상 압연에서 압연하중 예측 및 두께 적중률을 향상시키고자 하였다.

2. 기존방식에 대한 통계분석

열간 사상압연에서 압연하중을 예측하는 모델에 신경회로망을 적용하기 전에 기존의 압연하중 예측모델에 대한 통계적 분석을 하였다. 분석을 위해서 사용된 데이터는 99년 5월에 압연한 데이터 11983 coil을 사용하였다. 분석은 신경회로망을 적용하는 4번, 5번, 6번 스텠드에 한하여 분석하였다. 압연하중을 비교하기 위하여 아래의 식과 같이 Poliak⁽¹⁾이 정의한 PAM(Predictive Ability of Model)을 이용하여 적중률을 평가하였다.

$$PAM = \frac{N_{PAM}}{N_{total}} \times 100 \quad (1)$$

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

PAM은 Poliak의 논문에 기초하여 오차범위 10% 이내에 예측을 정확한 예측으로 간주하여 모델의 정확도를 나타내었으며, 표준편차는 모델의 분포를 확인함으로써 측정치 압연하중에 얼마나 근접하게 예측하는지를 나타낸다.

Fig. 1은 6번 스텠드에서 압연하중 모델자체의 정밀도를 나타내는 그림이다. 모델자체에서 예측한 압연하중은 측정치 압연하중의 10% 오차범위를 많이 벗어나 있다. 전체적으로 압연하중모델 예측치가 압연하중 측정치보다 높게 나타나며, 그 분포가 넓게 나타나고 있어 오차가 큰 것을 알 수 있다.

Fig. 2는 6번 스텠드에서 압연하중 측정치와 압연재의 압연이 종료된 후에 압연하중 측정치와 압연실적치를 이용하여 계산된 압연하중모델 계산치를 비교한 결과로 모델의 정확도를 나타낸다. 보는 바와 같이 재계산된 압연하중이 측정치 10% 오차범위를 많이 벗어나 있는 것을 알 수 있다.

Table 1은 4번, 5번, 6번 스텠드별로 first coils와 non-first coils의 PAM을 비교하여 나타낸 것으로 각각의 스텠드에서 first coils가 non-first coils보다 PAM이 모두 낮음을 알 수 있는데, 이는 first coils가 non-first coils보다 두께 적중률이 떨어짐을 나타낸다. 그리고 최종 스텠드로 갈수록 PAM이 떨어지는데 이는 6번 스텠드로 갈수록 박판이 되어 압연하중을 예측능력이 떨어지기 때문이다. 특히, 최종 스텠드의 경우 first coils가 non-first coils보다 PAM의 경우 대략 11.5%정도 낮다.

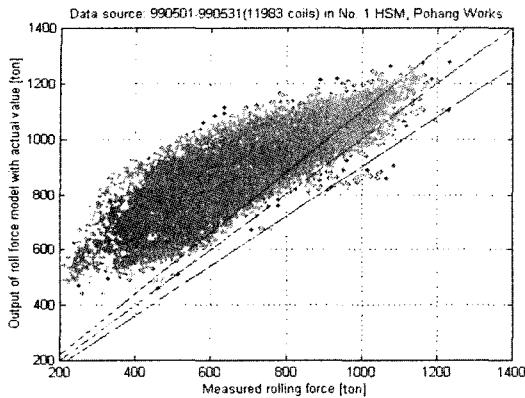


Fig. 1 Comparison of measured rolling force and calculated rolling force using model

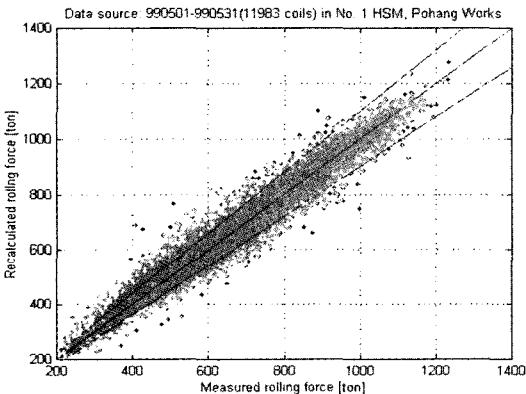


Fig. 2 Comparison of measured rolling force and recalculated rolling force

Table 1 Comparison of first coils PAM and Non-first coils PAM

No. of stand	First coils	Non_first coils
Stand #4	97.2671	99.0827
Stand #5	94.0870	98.6052
Stand #6	82.5342	94.1066

3. Off-line 학습 적용

신경회로망을 이용한 압연하중 예측모델과 기존의 압연하중 예측모델의 성능을 비교함으로써 신경회로망을 이용한 압연하중 예측모델의 성능을 확인하고, on-line 학습을

하기 전 적응시간을 줄이기 위하여 off-line 학습을 실시하였다. Off-line 학습은 lot간 변경이 없는 non-first coils 데이터를 이용하였으며, 테스트는 장기학습인 lot간 변경이 있을 경우에만 제한적으로 사용하였다. 학습에 사용된 데이터는 1999년 5월 11983 coils의 데이터를 이용하였으며, 학습된 신경회로망을 테스트하기 위하여 1999년 6월 1745 coils의 데이터를 사용하였다. Off-line 학습에 사용된 신경회로망은 유전자 알고리즘을 이용하여 선정한 최적 구조의 신경회로망을 이용하여 학습을 하였다. 익닉층은 1개로 하였으며, 선정된 신경회로망 구조는 Table 2에 나타내었다.

신경회로망 학습에 사용된 입력변수는 학습률, 변형, 변형률, C_{eq} , 온도 등 총 5개를 사용하였으며, 4번, 5번, 6번 스탠드에 대하여 신경회로망을 적용하여 학습하였다. 비선형 함수는 tangential sigmoid 함수를 사용하였으며, 학습 알고리즘은 학습속도가 빠른 Levenberg-Marquardt BP 알고리즘⁽¹¹⁾을 사용하였고 목표오차는 0.000001로 하였다.

Fig. 3은 기존 모델에 의한 압연하중 예측결과와 신경회로망을 이용한 압연하중 예측결과를 비교한 것이다. 그림에서 보는 바와 같이 기존 모델에 의해 예측된 압연하중은 분포가 넓고 10% 오차범위를 많이 벗어나 있으나, 신경회로

Table 2 Training condition for each stand

No. of stand	No. of neurons	epoch
Stand #4	10	150
Stand #5	11	100
Stand #6	6	170

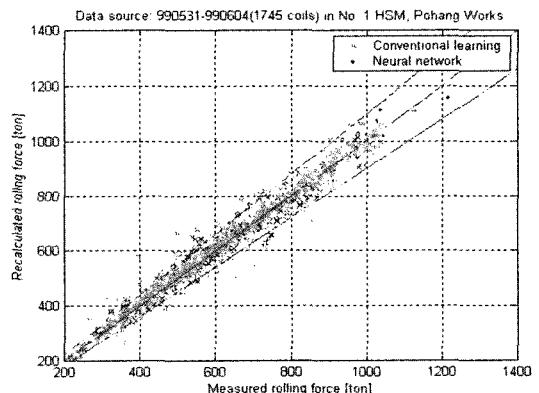


Fig. 3 Comparison of predicted rolling force using neural network and conventional model

망을 이용한 압연하중 예측결과는 측정치 압연하중에 근접한 예측결과를 보여주고 있으며, 오차의 분포가 좁게 나타나 신경회로망을 이용한 압연하중 예측모델이 우수하다는 것을 알 수 있었다.

4. On-line 학습 적용

기존의 off-line 학습을 통한 신경회로망은 lot 교체 후 첫 장에 대해서만 적용되는 장기학습 부분에만 이용되고 있다. 하지만 단기학습은 두 번째 장부터는 기존의 학습방식에 의한 출력력을 이용하여 압연하중을 예측하고 있다. 이와 같은 이유로 모든 부분에 신경회로망이 그 성능을 발휘하지 못하고 있을 뿐만 아니라 다양한 데이터를 가지고 일괄학습을 수행한 관계로 학습시간이 길어지므로 실시간(real-time) 학습이 불가능하였다. 그래서 일정한 간격으로 매번 학습이 요구되며, 이 때문에 그 상황에 맞는 최적의 압연하중을 예측하지 못한다. 따라서 본 연구에서는 기존의 일괄학습(batch learning) 대신에 점증식 학습(incremental learning)을 이용하여 on-line 학습법을 적용하였다.

적용한 on-line 학습법은 먼저 기존의 일괄학습법을 통하여 off-line 학습을 수행하여 적응시간을 최소화시킨 후 점증식 학습법을 통하여 매 coil마다 데이터를 수집하여 실시간 학습이 되도록 신경회로망을 구성하였다. 적용된 신경회로망의 내부구조는 Fig. 4와 같으며, 먼저 입력된 데이터는 정규화되고 신경회로망에서 학습된 후 비정규화 과정을 통해 최종 출력값을 얻도록 구성되었다. Fig. 5는 on-line 학습 신경회로망의 적용 구성을 나타낸다. 기존의 off-line 학습 신경회로망의 적용 구성을 보면 기존의 신경회로망은 장기학습만 이루어지도록 구성되어 있었지만 적용된 신경회로망은 실시간 단기학습이 가능한 구조로 구성되어 있다.

On-line 학습을 위하여 먼저 1999년 5월 11983 coils의 데이터를 가지고 off-line 학습을 수행함으로써 적응시간을 최소화 시켰으며, on-line 학습은 1999년 6월 1745 coils의 데이터를 가지고 학습을 수행하였다.

On-line 학습의 성능을 비교하기 위하여 기존 학습방법 및 off-line 학습방법에 의한 압연하중 예측결과와 성능비교를 하였다. Off-line 학습에서는 lot간 변동이 있는 경우인 first coils 데이터를 가지고 신경회로망의 성능평균을 실시했지만, on-line 학습의 성능평가는 매 coil마다 수집된 데이터를 가지고 학습하는 신경회로망을 평가해야 하기 때문에 first coils 데이터와 non-first coils 데이터 모두를 가지고 신경회로망의 성능을 비교하였다.

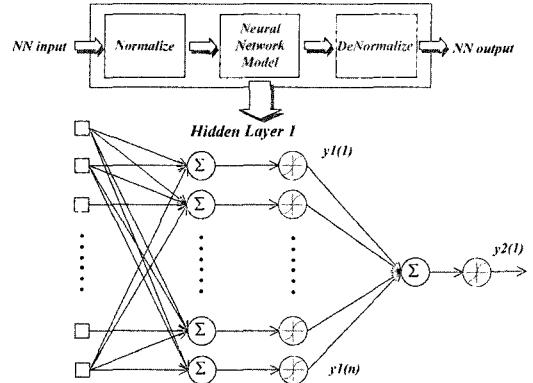


Fig. 4 Block diagram of neural network

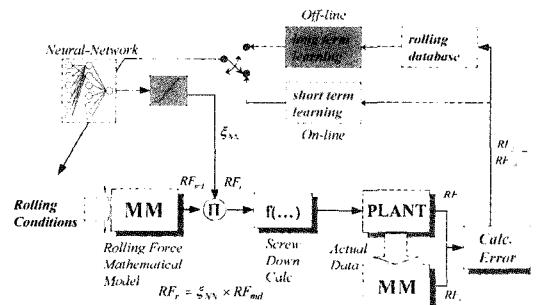


Fig. 5 Block diagram of neural network application

Fig. 6은 기존 학습방법에 의한 압연하중 예측결과와 on-line 학습방법을 이용한 신경회로망에 의한 압연하중 예측결과를 비교한 결과를 나타낸다. Fig. 6에서 보는 바와 같이 기존의 학습방법은 on-line 학습에 비하여 분포가 넓은 것을 알 수 있다. 하지만, on-line 학습에 의한 신경회로망의 경우는 분포도 좁으면서 측정치 압연하중에 상당히 근접하게 예측됨을 볼 수 있다. 이를 통하여 기존 학습방법보다 성능이 우수함을 알 수 있다. Fig. 7은 off-line 학습에 의한 신경회로망의 압연하중 예측결과와 on-line 학습에 의한 신경회로망의 압연하중 예측결과를 비교한 것이다. Off-line 학습이나 on-line 학습 모두 측정치 압연하중에 근접하게 압연하중을 예측했지만, on-line 학습의 경우 측정치 압연하중에 근접하게 압연하중을 예측하였다.

Fig. 8은 off-line 학습방법과 on-line 학습에 의한 압연하중 예측결과의 오차를 나타내는 그림으로 x축은 오차를 나타내며, y축은 각 오차가 나타난 빈도를 나타내고 있다. 기존학습 방법에 비하여 off-line 학습에 의한 압연하중 예측결과도 측정치 압연하중에 근접하게 예측하였지만, 미소하

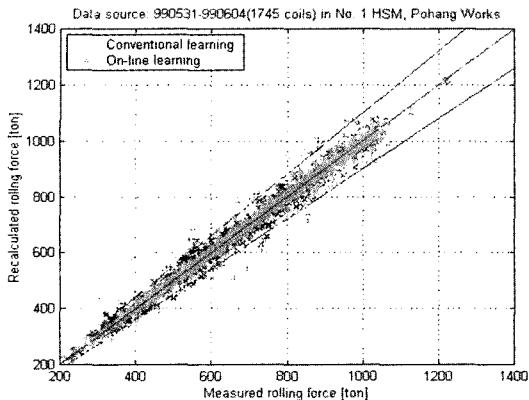


Fig. 6 Comparison of predicted rolling force using on-line learning and conventional model

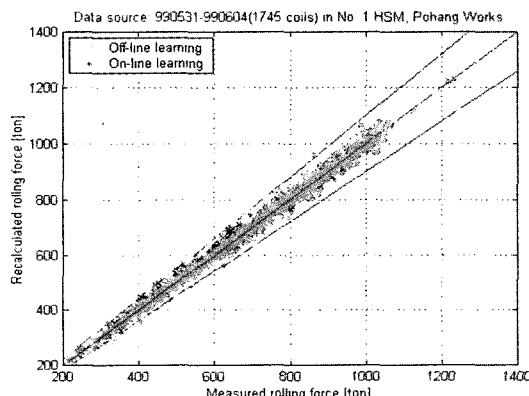


Fig. 7 Comparison of predicted rolling force using on-line learning and off-line learning

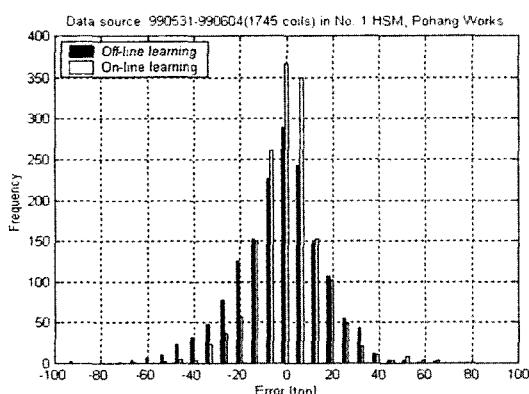


Fig. 8 Comparison of rolling force error using neural network and conventional model

Table 3 Comparison between neural network and conventional model

No. of stand	Conventional learning	Off-line learning	On-line learning
Stand #4	PAM	98.9784	99.3990
	Standard deviation	32.2789	33.3416
Stand #5	PAM	97.8966	98.4976
	Standard deviation	38.9290	33.8484
Stand #6	PAM	92.1274	99.2788
	Standard deviation	33.3793	18.6670
			99.8197
			28.7398
			15.2144

지만 조금은 낮은 쪽을 중심으로 분포하고 있다. 하지만, on-line 학습은 off-line 학습에 비하여 측정치 암연하중을 중심으로 집중 분포하고 있을 것을 볼 수 있다. 보다 정확한 평가를 위하여 세 개의 학습방법에 대하여 PAM과 표준편차를 가지고 Table 3에서 비교해 보았다. 세 개의 학습방법 모두 PAM이 최소 90% 이상으로 상당히 정확한 예측을 하였지만, 세 개의 방법 중 on-line 학습이 가장 정확하게 예측하였으며, on-line 학습의 경우는 4번 스탠드에서 PAM이 100%로 가 나왔을 정도로 정확하게 예측하였다. 또한 표준편차를 비교해 보았을 때도 on-line 학습에 의한 암연하중 예측결과가 가장 집중된 분포를 나타내었다. 결론적으로 on-line 학습법이 off-line 학습보다 우수한 암연하중을 예측능력을 가지고 있었다.

5. 결 론

본 논문에서는 lot간 변경이 있는 장기학습과 lot간 변경이 없는 단기학습 모두에 적용하고, 사상암연 중에 입력되는 새로운 데이터를 가지고 학습할 수 있는 on-line 학습법을 열간사상 암연에서 암연하중 예측에 적용하고, 기존의 학습방법 및 off-line 학습방법과 비교·분석하였다.

적용된 on-line 학습 신경회로망을 이용한 암연하중 예측 모델은 PAM의 경우 최대 100%까지 나타났으며 표준편차에서도 측정치 암연하중에 집중 분포하는 등 기존방법이나 off-line 학습법에 비하여 좋은 예측결과를 보였다.

후 기

이 논문은 2003년도 두뇌한국 21사업에 의하여 지원되었습니다.

참 고 문 헌

- (1) Poliak, E. I., Shim, M. K., Kim, G. S., and Choo, W. Y., 1998, "Application of linear regression analysis in accuracy assessment of rolling force calculations," *Metals and Materials*, Vol. 4, No. 5, pp. 1047~1056.
- (2) Jeon, E. C., and Kim, S. K., 2000, "A Study on the Texturing of Work Roll for Temper Rolling," *Journal of the Korean Society of Machine Tool Engineers*, Vol. 9, No. 4, pp. 7~16.
- (3) Son, J. S., Kim, I. S., Kwon, Q. H., Choi, S. G., Park, C. J., and Lee, D. M., 2001, "A study on development of setup model for thickness control in tandem cold rolling mill," *Journal of the Korean Society of Machine Tool Engineers*, Vol. 10, No. 5, pp. 96~103.
- (4) Larkiola, J., Myllyoski, P., Korhonen A. S., and Cser, L., 1998, "The role of neural networks in the optimization of rolling processes," *Journal of Materials Processing Technology*, Vol. 80, No. 81, pp. 16~23.
- (5) Yao, X., 1996, "Application of artificial intelligence for quality control at hot strip mills," *Ph.D. Thesis, The University of Wollongong*.
- (6) Poppe, T., Obradovic D., and Schlang, M., 1995, "Neural networks : Reducing energy and raw materials requirements," *Siemens Review-R&D Special*, pp. 24~27.
- (7) Schlang, M., Lang, B., Poppe, T., Runkler T., and Weinzierl, K., 2001, "Current and future development in neural computation in steel processing," *Control Engineering Practice*, Vol. 9, pp. 975~986.
- (8) Portmann, N. F., 1995 "Application of neural networks in rolling mill automation," *Iron and Steel Engineer*, Vol. 72, No. 2, pp. 33~36.
- (9) Pican, N., and Alexander, F., 1996, "Artificial Neural Networks for the Presetting of a Steel Temper Mill," *IEEE Expert*, pp. 22~27.
- (10) Lee, J. Y., Cho, H. S., Shim, M. S., Cho, S. J., Jang, M., Cho, Y. J. and Yoon, S. C., 1996, "Improvement of Roll Force Precalculation Accuracy in cold Mill using a Corrective Neural Network," *Proceeding of the 11th KACC*, October, pp. 1083~1086.
- (11) Hagan, M. T., and Menhaj, M. B., 1994, "Training feed-forward networks with marquardt algorithm," *IEEE Transaction on Neural Networks*, Vol. 5, No. 6, pp. 989~993.