

신경망을 이용한 냉연 압하력 예측

조용중* · 조성준**

Rolling Force Prediction in Cold Rolling Mill using Neural Networks

Yongjung Cho · Sungzoon Cho

〈Abstract〉

Cold rolling mill process in steel works uses stands of rolls to flatten a strip to a desired thickness. Most of rolling processes use mathematical models to predict rolling force which is very important to decide the resultant thickness of a coil. In general, these mathematical models are not flexible for variant coil types and cannot handle various elements which is practically important to decide accurate rolling force. A corrective neural network is proposed to improve the accuracy of rolling force prediction. Additional variables - composition of the coil, coiling temperature and working roll parameters - are fed to the network. The model uses an MLP with BP to predict a corrective coefficient. The test results using 1,586 process data collected at POSCO in early 1995 show that the proposed model reduced the prediction error by 30% on average.

1. 서론

냉간 압연 공정은 각종 금속 제품의 원자재로 사용되는 냉연 코일을 생산하는 공정으로서, 공정에 투입된 열연 코일을 압연하여 코일의 기계적 성질을 강화하고 코일 두께를 목표 두께로 줄이는 것을 목적으로 한다. 이 때 공정을 거친 코일의 두께가 허용 오차를 넘는 것을 오프 게이지라고 하는데, 이 오프 게이지의 발생을 줄여 공정의 생산성을 높이는 것이 냉연 공정 제어의 목적 가운데 하나이다.

일반적으로 냉연 공정에서는 금속학적 기반의 수식 모델을 이용하여 제어를 수행하고 있는데, 이 모델은 공정에 영향을 주는 다양한 인자들을 충분히 고려하

지 못하고, 코일 강종과 조업 환경의 변화에 대해 유연하지 못한 단점이 있다.

논문에서는 기존 수식 모델의 문제점을 분석하고 그에 따른 대안으로서 보정 신경망 모델을 제안한다. 제 2 절에서는 공정의 구조와 제어 방식을 소개하고, 기존 모델의 문제점을 분석한다. 그리고 해외 각 철사에서 압연 하중의 예측 성능을 향상시키기 위한 연구 개발 사례들을 조사한다. 제 3 절에서는 제 2 절에서 분석, 조사한 결과를 토대로 신경망 보정 모델을 제안하고, 제안 모델을 이용한 실험 결과와 분석을 보인다.

* 포항공과대학교 정보통신대학원 정보통신학과

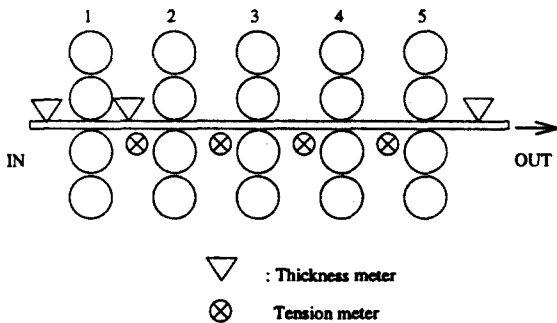
** 포항공과대학교 산업공학과/전자계산학과

2. 냉연 공정과 셋업 모델

2.1 공정의 구조와 제어

〈그림 1〉은 전형적인 냉연 공정의 구조이다. 공정은 대개 5개 내외의 스탠드로 이루어지고, 각 스탠드는 코일을 압연하기 위한 작업 롤로 구성되어 있다. 그리고 실시간 제어에 사용되는 실측치 두께와 장력 검지를 위한 센서(Thickness meter와 Tension meter)가 설치되어 있다.

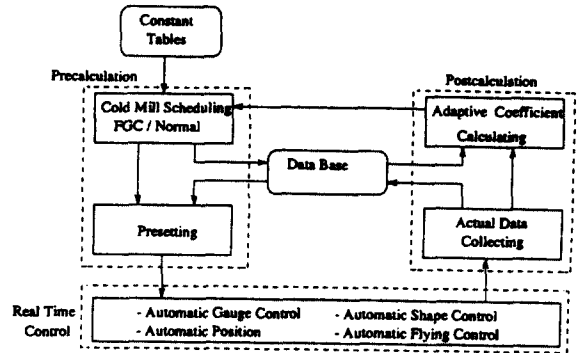
공정에 투입된 코일은 입측으로부터 각 스탠드를 거치면서 압연이 이루어져 최종 스탠드를 거치면 코일에 대한 압연이 끝나게 된다.



〈그림 1〉 냉연 스탠드 구조

〈그림 2〉는 공정의 제어 모델 구조로서 3단계로 구성된다. 사전 계산부(Precalculation Part)는 코일의 압연을 개시하기 전에 공정 제어에 필요한 파라미터들을 사전 계산(Presetting)한다. 사전 계산부의 입력은 작업 코일의 두께(초기치, 목표치), 폭과 강종이며 출력은 작업 롤 속도와 롤 간격등이 있다. 공정에 투입된 코일이 1번 스탠드를 거치면서 압연이 시작되면 실시간 제어(Real Time Control)가 수행된다. 실시간 제어부는 4 종류의 제어 장치로 구성되는데, 이 제어 장치들은 사전 계산부에서 계산한 예측치와 센서들의 실측치를 사용하여 연속적으로 제어 명령을 갱신한다. 실시간 제어 장치중, AGC(Automatic Gauge Controller)는 코일의 두께 제어를 수행한다. 이 때, 사전 계산부의 예측치가 실제값과 큰 오차를 내면, 실시간 제어 장치에 의한 보상이 불가능하거나 정상 상태에 이르

는 시간이 길어지게 되어, 오프 게이지 발생과 같은 문제점이 생길 수 있다. 사후 계산부(Postcalculation)는 압연을 마친 후 다음 코일의 압연을 위해 공정 파라미터에 대한 보정을 수행하며 시스템의 동적인 특성을 반영한다.



〈그림 2〉 공정의 제어 구조

2.2 롤 간격과 압연 하중

두께 제어에 직접적으로 영향을 미치는 파라미터는 각 스탠드의 롤 간격이다. 롤 간격은 각 스탠드를 구성하는 두개의 작업 롤 사이의 간격으로 그 사이를 코일이 통과하면서 압연이 이루어지게 된다. 롤 간격의 값은 사전 계산부에서 식 (1)과 같이 결정된다 [3]

$$S = f(h, P, \vec{k}) \tag{1}$$

여기서, S : 롤 간격

h : 출측 두께

P : 압연 하중

\vec{k} : 압연 조건별 계수 벡터

여기서 출측 두께와 계수들은 압연 사양에 따라 주어진 값들이다. 그리고 압연 하중은 압연시 작업 조건과 코일의 기계적 성질에 의해 결정되는 값인데, 사전 계산부에서는 실제 압연시의 조건을 알수 없으므로 압연 하중을 단지 예측하게 된다. 이 때, 압연 하중은 예측에 영향을 미치는 인자의 종류가 많고, 그 인자들을 모두 고려하는 정확한 예측식이 존재하지

않으므로, 이 압연 하중을 얼마나 정확하게 예측하는가에 따라 롤 간격 예측의 정확성이 결정적으로 영향 받는다.

압연 하중의 예측에는 스탠드별 압연 조건과 관련된 인자들 이외에도 작업 롤과 코일의 기계적 성질에 따른 다양한 인자들이 영향을 미치는 것으로 알려져 있으며 다음과 같이 구분할 수 있다 [7].

- 압연 사양에 따른 스탠드별 인자들 \bar{X} : 코일 폭, 두께(입측, 출측), 장력(전방, 후방), 작업 롤 직경
- 작업 롤과 관련된 인자들 \bar{X}' : 누적 압연량, 압연유량 및 점성, 표면 상태 등
- 코일의 성분과 관련된 인자들 \bar{Q} : 탄소, 규소, 망간, 붕소, 티타늄 등
- 열연 공정 관련 인자들 \bar{S} : 열연 온도, 권취 온도, 재로 시간 등

기존 수식 모델은 위의 압연 하중 예측에 영향을 주는 각 인자들 중에서 \bar{X} 만을 고려하고 있다 [3].

2.3 압연 하중 계산

포항제철 제 1 냉연공장에서는 수식 모델을 이용하여 공정 제어 파라미터들을 계산하고 있다. 수식 모델의 압연 하중 예측식은 (2)와 같다 [3].

$$P_{cal} = g(H, h, \dots, \mu, t_b, t_f) \quad (2)$$

여기서, P_{cal} : 압연 하중 예측치

H, h : 입출측 두께

k : 변형 저항

μ : 마찰 계수

t_b, t_f : 후방 장력, 전방 장력

여기서 장력과 두께는 압연 조건에 따라 고정적인 값을 가지므로 예측의 정확성에 미치는 영향은 작다. 그러나 변형 저항과 마찰 계수는 코일과 작업 롤의 기계적 성질에 의해 결정되는 인자들로서 실측이 불가능하고 정확한 예측식도 존재하지 않는다. 따라서 압연 하중 예측 정도에 결정적인 영향을 미치는 인자는 변형 저항과 마찰 계수이다. 이 중 변형 저항은 주로 코일의 성분이나 열연 공정 관련 온도 인자와 같은 코

일의 기계적 성질에 의해 결정되는 인자이고, 마찰 계수는 압연 속도와 작업 롤의 표면 상태 등에 의해 결정되는 인자이다 [8]

수식 모델의 압연 하중 예측식의 문제점으로서 다음과 같은 것들이 있다.

- 압연 하중 예측에 영향을 주는 인자들을 충분히 반영하지 않는다 [5].
- 변형 저항의 예측에 11개로 구분된 강종군별 상수 테이블에만 의존하고 있다. 강종군별 상수 테이블은 코일의 기계적 성질을 나타내는 항복 강도에 따른 구분인데, 11개로 구분은 되어 있지만 실제로 변형 저항의 계산에는 4가지로만 구분되어 사용되고 있다. 따라서 코일의 성분과 열연 조건에 따른 다양한 기계적 성질을 반영하지 못하고, 강종의 다양화에 따른 유연한 대응을 할 수가 없다. 강종을 구분짓는 것은 성분과 열연 관련 인자들이기 때문이다.
- 마찰 계수의 예측에 단지 압연 속도만을 고려하고 롤 관련 인자들을 고려하지 않는다.
- 수식 모델은 선형 시스템 이론에 근거하므로 공정의 복잡한 비선형성을 반영하지 못하여, 압연 하중 예측의 정확성에 한계가 있다.
- 수식 모델의 입력으로 사용되고 있는 입출측 두께와 장력 등은 실측치가 아닌 압연 개시전의 예측치로서 실제의 값과는 차이가 있다. 따라서 모델이 정확하다고 하더라도 예측에 사용한 입력의 정확도가 떨어지면 전체적인 압연 하중 예측 성능은 떨어질 것이다.

2.4 기존 연구

위에서 기술한 문제들을 해결하여 압연 하중 예측 성능을 향상시키기 위한 연구 개발이 이루어졌다.

먼저, 일본 KSC 제철소에서는 기존 수식 모델에 대해 코일의 성분 관련 변수 3종(탄소, 망간, 규소)과 열연 관련 온도 변수 2종(권취 온도, 열연 온도)을 추가로 고려하여 냉연 공정의 압연 하중 예측 성능을 향상시켰다 [8]. 이것은 기존의 수식 모델에 대한 보완이므로 수식 모델 자체가 갖고 있는 한계를 여전히 가

지고 있다는 점과 강종 다양화에 따른 추가의 성분이나 온도 관련 변수에 대한 대응이 용이하지 않다는 단점이 있다. 그러나 이 사례는 냉연 공정의 압연 하중 예측에 성분과 온도 관련 변수가 중요한 영향을 미친다는 사실을 보여준다.

독일 Westfalen 제철소에서는 열연 공정의 압연 하중 예측 성능을 향상시키기 위하여 신경망을 이용하였다. 신경망의 입력으로는 기존의 수식 모델이 고려하지 않았던 코일 성분 관련 변수와 온도 변수를 추가로 고려하였고, 신경망은 기존 수식 모델의 예측치에 대한 보정치를 출력하도록 하는 보정 모델을 채용하였다. 보정 모델은 신경망이 기존 모델과 함께 사용되므로 모델의 성능 비교가 용이하고, 현장 조업자들에 대한 적응성을 높이는 장점이 있다. 1993년 12월의 조업 데이터 3,601개에 대한 적용 결과 기존 모델에 비해 압연 하중 예측 오차를 약 12.5% 향상시키는 결과를 보였다 [7].

프랑스 Sollac 제철소에서는 Work-hardening 공정에 신경망을 적용하여 압연 하중 예측 성능을 향상시켰다. 신경망의 입력으로는 온도 변수와 마찰 계수와 관련된 롤 표면 상태, 압연류의 점성등을 고려하였다 [6]. 한편 사례에서는 신경망에 의한 예측 성능이 기존 수식 모델보다 낮은 Aberrant 영역을 정의하고, Aberrant 영역에 해당하는 코일 데이터에 대해서는 기존의 수식 모델에 의해 압연 하중을 예측하도록 하여, 전체 모델의 예측 성능을 향상시켰다. Aberrant 영역은 신경망 입력 변수들의 범위에 의해 명시적으로 결정하였다.

위의 사례 조사 결과를 다음과 같이 정리할 수 있다.

- 압연 하중의 예측에 신경망을 적용하여, 기존 수식 모델보다 우수한 압연 하중 예측 성능을 얻었다.
- 신경망을 이용하여 직접 압연 하중을 계산하여 기존 수식 모델의 기능을 대체하는 대체 모델과 기존 수식 모델의 압연 하중 예측치에 대한 보정치를 계산하는 보정 모델을 사용할 수 있다. 보정 모델은 수식 모델을 사용해 오던 현장에서 적응성이 좋은 장점이 있다.
- 압연 하중 예측 성능을 높이기 위해서는 코일의 성분 관련 변수, 온도 관련 변수와 작업 롤의 표면 상

태와 관련된 변수를 고려하여야 한다.

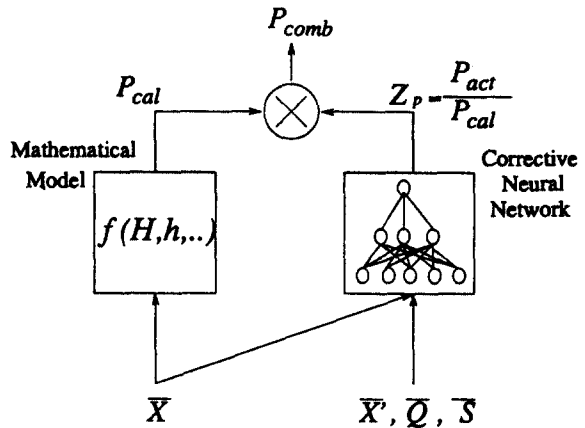
- Aberrant 영역의 데이터에 대해서는 기존의 수식 모델의 값을 사용하도록 함으로써 전체 보정 모델의 예측 성능을 향상시킬 수 있다.

논문에서는 위의 내용을 고려하여 압연 하중 예측 신경망 모델을 구현할 것이다.

3. 신경망 보정 모델과 실험 결과

3.1 제안 모델

〈그림 3〉은 논문에서 제안한 신경망 보정 모델(스탠드별)이다.

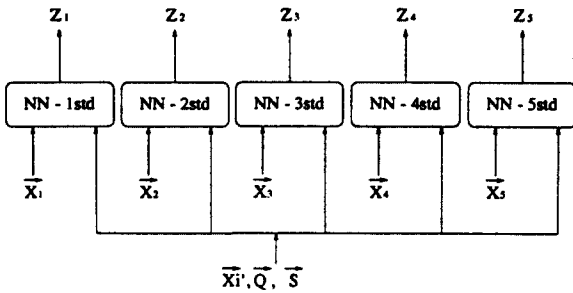


〈그림 3〉 제안 모델-신경망 보정 모델

신경망의 입력으로는 기존의 수식 모델이 고려하지 않던 \bar{X} (작업 롤 관련 변수), \bar{Q} (코일 성분 관련 변수)와 \bar{S} (열연 온도 관련 변수)가 기존 스탠드별 변수와 함께 사용된다. 신경망의 출력은 수식 모델에 대한 보정치인 $Z_p = P_{act} / P_{cal}$ 이다. 여기서 P_{act} 는 압연 개시후 AGC(Automatic Gauge Controller)에 의한 실시간 제어가 이루어진 후의 정상 상태의 값이다. 따라서 제어 모델에 의한 압연 하중 예측치 P_{cal} 이 P_{act} 에 근사할 수록 모델의 예측 성능이 좋은 것이다.

Aberrant 영역의 데이터에 대해서는 $Z_p = 1$ 을 출력함으로써 기존 수식 모델의 값을 사용할 수 있을 것이다. 일반적으로 냉연 공정은 여러개의 스탠드로 구성되어 있으므로 〈그림 3〉과 같은 모델이 스탠드마다 마

련된다. <그림 4>는 공정 전체에 대한 모델을 나타낸다.




<그림 4> 전체 모델

3.2 네트워크와 입출력

<그림 5>는 실험에 사용된 네트워크이다. 은닉층의 노드 수가 20개인 1-은닉층 다층 퍼셉트론이며 학습에 사용된 알고리즘은 역전파 알고리즘이다 [1,4,2].

<표 1>은 네트워크의 입력을 보여주는데, 기존의 수식 모델이 고려하고 있는 입력 변수 이외에 온도 및 성분 관련 변수 4종과 롤 관련 변수 2종을 추가로 고려하였다.



<그림 5> 사용된 네트워크

3.3 학습 및 테스트

학습과 테스트에 필요한 데이터는 포항제철 제 1 냉연 공장의 조업 데이터를 이용하였다. 학습 패턴은 1995년도 조업 데이터 4,944개이고 각 변수에 대하여 식 (3)의 전처리를 하였다.

<표 1> 신경망 입력
(종류는 변수가 연속값을 갖는 경우(C)와 이산값을 갖는 경우(D)를 나타낸다)

구분	이름	종류	설명
\bar{X}	width	C	코일 폭
	H	C	입측 두께
	h	C	출측 두께
	T_f	C	전방 장력
	T_b	C	후방 장력
	DRW	C	롤 직경
\bar{X}	roll	D	롤 종류(브라이트 롤=1, 덜 롤=0)
	len	C	작업 롤 누적 압연량
\bar{Q}	C	C	탄소 함량
	Mn	C	망간 함량
	Si	C	규소 함량
\bar{S}	CT_{avg}	C	평균 권취 온도

$$\hat{x} = \frac{x - \mu_x}{\sigma_x} \tag{3}$$

여기서 μ_x, σ_x 는 각각 변수별 평균값과 표준편차이다.

학습 상수 $\eta = 0.5$ 과 모멘텀 $\mu = 0.5$ 의 값을 사용하였으며 학습 기간은 200 epoch으로 SUN-Sparc 20 워크스테이션에서 각 스탠드마다 약 30분이 소요되었다.

<표 2>는 1996년 조업 데이터 1,586개를 사용한 테스트 결과이다. 성능 측정 기준은 압연 하중 예측에 대한 모델별 절대 오차 및 상대 오차이다(식 (4),(5)).

<표 2> 보정신경망 모델 성능
(감소율(%)은 수식 모델의 오차에 대한 보정 모델의 오차의 비율로서 4번 스탠드는 수식 모델의 예측 성능이 우수하여 상대적으로 오차 감소율이 작다)

스탠드	절대 오차			상대 오차		
	수식	보정	감소율	수식	보정	감소율
1	88.3	67.3	23.7	0.125	0.099	20.8
2	84.1	37.8	55.1	0.102	0.047	53.9
3	68.1	40.4	40.7	0.087	0.055	36.8
4	34.6	31.0	3.6	0.053	0.049	7.5
5	42.1	24.9	41.0	0.091	0.055	39.6
평균	63.5	40.3	32.8	0.092	0.061	31.7

$$\text{절대 오차} = |P_{act} - P| \text{ (톤)} \quad (4)$$

$$\text{상대 오차} = \frac{|P_{act} - P|}{P_{act}} \quad (5)$$

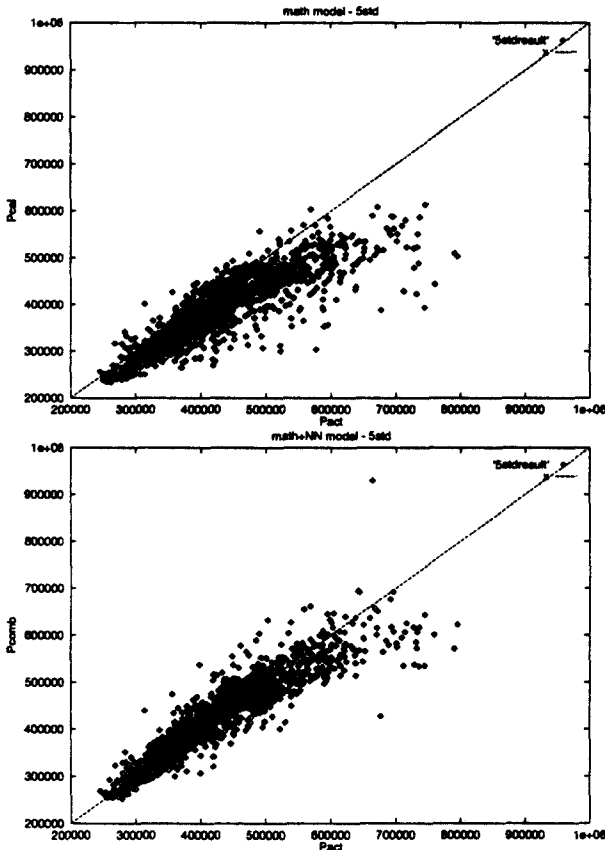
여기서, P_{act} : 압연 하중 실측치
 P : 압연 하중 예측치

표의 결과는 신경망에 의해 압연 하중 예측 오차가 평균 30% 이상 감소하였음을 보여준다. <그림 6>과 7은 5번 스탠드에 대한 모델간 절대 오차 및 상대 오차 분포를 보여준다. <그림 6>에서는 각 점들이 $y=x$ 에 가까울수록 성능이 우수한 것이고, <그림 7>에서는 각 점들이 $y=0$ 에 가까울수록 예측 성능이 뛰어난

것이므로 신경망이 전반적으로 수식 모델보다 예측 성능이 우수함을 보여준다.

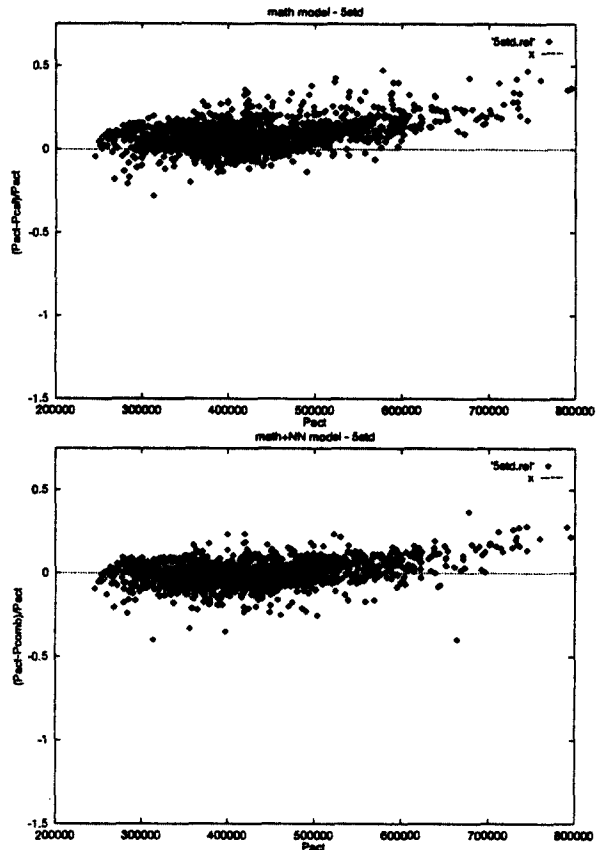
제철 공장에서는 매년 새로운 강종의 개발과 고객 요구 사양의 변화로 생산 강종이 변하게 된다. 따라서 1995년도 조업 데이터를 학습 데이터로 하고, 1996년의 조업 데이터를 테스트로 한 위의 실험은 Out of Sample Test라고 할 수 있다. 그러나 실험의 결과는 제안 모델이 이러한 강종의 변화에 대하여 일반화 성능을 가지고 있음을 보여준다.

한편, 현재 수식 모델에서는 압연 하중 예측의 중요한 인자인 마찰 계수와 변형 저항을 계산하기 위하여 전체 코일을 11개의 강종군으로 구분하여 마련한



<그림 6> 절대오차 분포

—위의 그림이 수식 모델의 오차 분포이고 아래 그림은 신경망 모델의 오차 분포이다



<그림 7> 상대 오차 분포

—위의 그림이 수식 모델의 오차 분포이고 아래 그림은 신경망 모델의 오차 분포이다

상수 테이블을 사용하고 있다. 강중군은 코일의 기계적 성질을 나타내는 항복 강도에 의해 구분된다. 실험에서는 이러한 강중 구분 없이 모든 코일 데이터에 대해 학습 및 테스트를 하였다. 따라서 위의 결과는 압연 하중 예측에 추가로 고려한 성분 변수가 코일의 기계적 성질을 잘 반영하고 있음을 보여준다.

3.4 Aberrant 영역에 대한 처리

Aberrant 영역은 신경망의 예측 성능이 수식 모델보다 안 좋은 데이터 영역이다. 따라서 Aberrant 영역의 데이터에 대해서는 보정 모델의 출력값인 보정 계수 $Z_p=1$ 로 하여 수식 모델의 예측치를 그대로 사용하게 된다면 전체 모델의 성능을 향상시킬 수 있을 것이다.

실험에서는 각 입력 변수의 분포 분석에 의한 방법과 경쟁 학습 클러스터링에 의한 방법을 이용하여 Aberrant 영역을 결정하고자 하였다. 입력 변수의 분포에 의한 방법은 전체 학습 패턴중에서 신경망의 예측 성능이 우수한 패턴 셋과 수식 모델이 우수한 패턴 셋을 구분한 후, 두 패턴 셋의 입력 분포를 단순 비교하여 Aberrant 영역을 결정하는 방법이고, 클러스터링에 의한 방법은 각 클러스터별 중심 벡터와 소속 데이터의 위치 벡터의 분석을 통해 데이터의 분포가 희박하다고 판단되는 영역을 Aberrant 영역으로 결정하는 것이다.

실험에서는 위의 두가지 방법이 모두 전체 모델의 성능 향상에 도움이 되지 않음이 확인되었다. 이는 출력 변수와의 상관 관계를 고려하지 않는 입력 변수들만의 분포 분석만으로는 Aberrant 영역을 구분해낼 수 없다는 것과, 분포가 희박한 데이터에 대해서는 수식 모델도 예측 성능이 떨어짐을 의미한다.

3.5 대치 모델

대치 모델은 신경망으로 직접 압연 하중을 계산하도록 하여, 기존 수식 모델의 압연 하중 예측식을 대치한다. 본 연구에서는 압연 하중을 계산하기 위한 두 가지 모델인 대치 모델과 보정 모델중에서 현장 적용성을 고려하여 보정 모델을 구현하였다. 여기서는 두

모델간의 성능을 비교하기 위하여 대치 모델을 구현하였다. 대치 신경망은 보정 신경망과 같은 학습 조건과 네트워크 구조를 사용하였다. <표 3>에서, 대치 모델의 예측 성능을 보여주고 있다.

<표 3> 대치 모델과 가산/승산 절대 오차 성능

스탠드	수식 모델	대치 모델		가산 모델		승산 모델	
		오차	감소율 (%)	오차	감소율 (%)	오차	감소율 (%)
1	88.3	44.5	49.6	82.9	6.8	105.9	-19.2
2	84.1	33.9	59.7	39.6	52.9	44.5	47.1
3	68.1	39.3	42.3	64.1	5.9	54.0	20.8
4	34.6	40.6	-17.4	40.4	-16.8	35.2	1.8
5	42.1	28.3	32.8	34.7	17.7	34.6	17.9
평균	63.5	37.3	33.4	52.3	13.3	54.8	13.7

<표 2>와 비교할 때, 스탠드별로 차이는 나지만 전반적으로 대치 모델은 보정 모델과 유사한 성능을 보임을 알 수 있다.

3.6 가산 모델과 승산 모델

학습 데이터의 분석을 통하여 수식 모델은 전반적으로 실측치 압연 하중에 대하여 작은 값의 예측치 압연 하중을 출력하는 것으로 판명되었다. 가산 모델은 수식 모델의 예측치에 일정한 상수값을 가산한 값을 압연 하중 예측치로 한다. 그리고 승산 모델은 일정한 상수값을 수식 모델의 예측치에 승산하여 압연 하중 예측치를 구한다.이 때 가산값은 학습 패턴의 $(P_{acr} - P_{cal})$ 의 평균값을 사용하였고, 승산값은 학습 패턴의 $Z(=P_{acr}/P_{cal})$ 의 평균값으로 하였다.

<표 4>는 스탠드별 가산/승산을 위한 상수값이고,

<표 4> 스탠드별 가산/승산값

스탠드	1	2	3	4	5
가산값	135	96	115	-7	45
승산값	1.25	1.13	1.18	0.99	1.12

〈표 3〉에서 가산/승산 모델의 실험 결과를 보여준다. 〈표 3〉의 결과는 가산/승산 모델을 이용한 압연 하중 예측 향상 정도는 보정 모델에 비해 크게 떨어짐을 보여준다. 따라서 수식 모델의 예측값에 대한 단위 가산/승산만으로는 충분한 예측 성능을 가질 수 없다.

4. 결론

냉간 압연 공정에서 압연 하중 예측 성능을 향상시키기 위하여 보정 신경망 모델을 이용하였다. 신경망의 입력으로는 기존의 수식 모델이 고려하지 않던 코일 성분, 열연 온도 관련 변수와 작업 롤 관련 변수를 추가하였다. 그리고 신경망이 수식 모델의 예측치에 대한 보정 계수를 출력하도록 하는 보정 모델의 형태를 취함으로써, 현장 조업자의 적응성을 높이고자 하였다.

사용된 네트워크는 역전파 알고리즘을 이용한 다층 퍼셉트론이며, 포항제철 제 1 냉연 공장의 조업 데이터를 이용한 Out of Sample Test에서 보정 모델은 압연 하중 예측 오차를 기존 수식 모델에 비해 30% 이상 감소시키는 결과를 보였다.

본 연구를 통하여, 제철소내에서 수식 모델에 의해 제어가 이루어지는 공정에 신경망을 적용하여 제어 성능을 향상시킬 수 있을 것이다. 향후, 냉연 공정 외에도 열연등의 다른 제어 공정에서도 신경망을 적용하여 공정의 생산성을 향상시킬 수 있을 것이다.

【참 고 문 헌】

- [1] S. Haykin. Neural Networks: A Comprehensive Foundation. Macmillan College Pub. Co., USA 1994.
- [2] D. Rumelhart, G. Hinton and R. Williams. Learning Internal Representation by Error Propagation. In D. Rumelhart, J. McClelland, and PDP Research Group, editors, Parallel Distributed Processing, Vol 1: Foundations, pages 318-362, MIT Press, Cambridge, MA, 1986.
- [3] Pohang Iron and Steel Company. Technical Report of 2nd Cold Mill Control Equipment(PCM part), Korea, 1989
- [4] A. Krogh, J. Hertz and R. Palmer. Introduction to the Theory of Neural Computation. Addison Wesley, Pub. Co., CA, USA, 1991
- [5] W. Lee. Improvement of Set-up Model for Tandem Cold Rolling Mill. Technical Report, RIST, Korea
- [6] N. Pican and F. Alexandre. Artificial Neural Networks for the Presetting of a Steel Temper Mill, IEEE Expert, pages 22-27, 1996
- [7] N. Portmann. Application of Neural Networks in Rolling Mill Automation. Iron and Steel Engineer, pages 33-36, 1995
- [8] M. Yamashita, I. Yarita, H. Abe, T. Mikuriya and F. Yanagishima. Technologies of Flying Gauge Change in Fully Continuous Cold Rolling Mill for Thin Gauge Steel Strips. IRSID Rolling Conference, 2(1), 1987



조용중

현재 포항공과대학교 정보통신대학원 정보통신학과 석사과정에 재학중이다. 서울대학교 전기공학부에서 학사학위를 취득하였고 현대중공업 중앙연구소에서 연구원으로 재직중이다.

조성준

제 9권 3호 P.100참조