

신경회로망을 이용한 소결기 팻릿 속도 제어

Pallet speed control in a sintering plant using neural networks

장 민*, 조성준**

jmin@postech.edu, zoon@snu.ac.kr

*포항공과대학교 컴퓨터공학과

**서울대학교 산업공학과

요약

Sintering transforms powdered ore into lumped ore so that the latter can be used in a blast furnace. The powdered ore combined with coke and other materials is loaded into a container and moved along by a pallet while the ignited coke burns. The speed by which the pallet moves determines how much sintering takes place. Since the process is complicated and lacks an accurate mathematical model, human operators manually control the speed by monitoring various factors in the plant. In this paper, we propose a neural network-based pallet speed controller which copies human operator knowledge. Actual process data were collected from a sintering plant for eight months and preprocessed to remove noisy and inconsistent data. A multilayer perceptron was trained using a back-propagation learning algorithm. In on-line testing at the sinter plant, the proposed model reliably controlled pallet speed during normal operation without the help of human operators. Moreover, the quality and productivity was as good as with human operators.

1. 서론

자연계에는 보통 두 가지 형태의 철광석이 존재한다. 하나는 덩어리 형태이고 또 다른 하나는 가루 형태로 존재한다. 덩어리로 된 것은 고로(blast furnace)에서 직접 이용될 수 있는데 반해, 가루로 된 것은 고로의 공기 투과성을 나쁘게 만들기 때문에 직접 이용할 수 없기 때문에 철 가루를 응집시켜 덩어리로 만드는 작업이 필요하다. 이러한 작업을 소결이라 하는데 가루로 된 철을 생석회 등의 고착제를 섞은 후 높은 온도로 가열하여 엉겨 붙게 하여 덩어리로 만드는 작업이다. 소결 공정(sintering process)은 크게 다음과 같은 몇 개의 단계로 나눌 수 있다. 첫째, 소결의 원료들을 잘 섞는다. 여기에는 철가루, 생석회, 석회석 및 코크스 등이 일정 비율로 섞인다. 둘째, 섞인 원료를 천천히 움직이는 소결기 팻릿(sinter pallet) 위에 올린다. 셋째, 코크스를 점화시키고 주 통풍구(main blow)에서 공기를 빨아들이면 코

크스가 천천히 타 들어 가면서 철 가루가 덩어리화된다. 이 단계에서 소결기의 속도를 조절하는 것이 소결광의 품질 및 생산성을 결정하는데 매우 중요하다. 마지막으로 소결이 다 끝난 소결광을 식히고 알맞은 크기로 분쇄한 후에 고로에서 이용하게 된다.

소결기 팻릿(sinter pallet)의 속도는 소결 공정에서 가장 중요한 제어 변수이다. 만약 속도가 너무 낮다면, 소결광의 질과 생산성이 낮아진다. 또한 먼지(dust), 일산화탄소 및 이산화탄소의 배출량과 농도가 높아져 결국 공해의 요인이 된다. 반대로, 속도가 너무 높으면 철 가루가 충분히 소결이 되지 않아서 반광(returned ore)의 비율이 높아져서 생산성이 낮아진다. 또한, 냉각기(cooling plant)에 손상을 줄 경우도 발생한다. 결국 최적의 속도로 소결기를 조정하는 것이 생산성, 품질, 비용 및 환경을 위해서 필수 불가결하다.

그러나, 실제적으로 소결 공정 및 소결기 속도를 제어하는 정확한 수학적 모델들을 만드는 것은 매우 어렵다. 왜냐하면, 공정이 매우 비 선형적(non-linear)이고 돌발적, 연속적이며 재료의 입력과 제품의 출력 사이에 긴 시간적 지연(delay)이 존재하기 때문이다. 이와 같은 이유로 자동화 조업이 불가능하여 전문 조업자에 의한 제어가 수행되고 있는 실정이다. 현재, 포항제철 제 1 소결 공장에는 네 명의 조업자가 일일 3 교대로 경험에 의한 전문적 지식을 바탕으로 소결기의 속도를 제어하고 있다.

소결기 속도 제어 자동화는 다음과 같은 이유때문에 절실히 요구되고 있는 실정이다. 첫째, 조업자가 소결기를 계속 감시(monitoring)하는 단순한 일로부터 자유롭게 하여 좀더 급하고 중요한 일을 하도록 할 수 있다. 둘째, 조업자는 조금씩 다른 방법으로 소결기 속도를 제어하는데 이는 조업의 안정성과 일관성에 영향을 줄 수 있다. 셋째, 궁극적으로 소결기의 속도를 자동화하여 생산성 및 제품의 품질을 높일 수 있게 한다.

실제 소결 조업 데이터, 즉, 조업상황/속도제어의 쌍으로 이루어진 데이터를 1996년 11월부터 1997년 6월까지 모았다. 잡음이 섞이고 일관적이지 않은 데이터를 제거하는 전처리 과정(pre-processing)을 수행한 후, 오류 역전파 알고리즘(error back-propagation)을 이용하여 2층의 다층 퍼셉트론을 학습하였다 [10]. 구축된 속도 제어 시스템을 먼저 실험실에서 오프라인으로 시험하여 안정성 및 성능을 검증하였다. 그 다음 포항제철 제 1 소결기의 제어 컴퓨터에 인스톨하여 실제 소결 조업에 적용하였다. 실제 적용 결과 공정이 안정적이었고 생산된 제품의 품질 및 생산성도 조업자가 제어한 경우와 비슷한 것으로 나타났다.

2. 소결 공정(Sintering Process)

2.1 소결 공정 개요




그림 1: 소결 공정도

그림 1은 소결 공장(sintering plant)의 장치들을 간단히 도식화 한 그림이다. 원료 배합기(material blending bin), 드럼 믹서(drum mixer), 서지 후퍼(surge hooper), 점화로(ignition furnace), 소결기 펠릿(sinter pallet), 배기구(Wind-box 라는 말이 일반적으로 쓰이므로 이 후로는 wind-box 라 함), 주 송풍기(main blow), 냉각기(cooler) 그리고 수분계(acuameter), 압력계(pressire gauge) 등의 다양한 센서로 이루어져 있다. 소결기로 들어가기 전에 원료들은 고르고 균일하게 섞인다. 소결이 끝난 소결광은 냉각되고 알맞은 크기로 분쇄되어 고로로 보내진다. 각 단계에서 일어나는 일들은 다음과 같이 나눌 수 있다.

원료의 배합(blending)과 균일화(granulation) : 소결 공정의 원료는 철 가루, 고착제(binder), 그리고 열원인 코크스로 이루어져 있다. 철 가루는 다양한 화학적 성분과 성질을 가지는 다양한 철 가루를 함께 혼합한다.

장입(feeding)과 소결(sintering) : 서지 후퍼를 통해서 혼합된 원료는 균일하고 연속적으로 소결기 펠릿 위에 올려진다. 일단 점화로에서 점화가 되면, 원료들은 천천히 소결 과정을 거치면서 펠릿에 실려 소결기 후단까지 옮겨지게 된다. 펠릿의 아래쪽에서는 wind-box 를 통하여 주 송풍기에서 공기를 흡입하여 소결의 진행을 돕는다. 소결이 끝난 소결광은 소결

기의 끝단에서 냉각기로 옮겨지게 된다.

냉각(cooling) 및 선별(screening) : 소결광은 냉각되고 적당한 크기로 분쇄되어 선별된다. 선별된 소결광은 고로로 운반되고, 나머지 소결광은 반광으로 분류되어 다시 소결기로 옮겨진 후 소결 공정에 재투입된다.

2.2 소결기 속도 제어 관련 인자

표 1 : 소결기 속도 제어 변수

	분류 (Category)	인자(Factors)
원인 (Causes)	원료(Raw material)	코크스 밀도(Coke granulation ratio) 코크스 수분(Coke moisture) 생석회 비(Quick lime ratio) 반광 비(Return fine ratio) 혼합기 수분(Mixer moisture) 혼합원료 수분 (Blending material granulation ratio)
	장입 상태 (Feeding state)	원료 장입 비(Raw material feeding ratio) 장입 층후(Sinter bed height)
	소결 환경 (Sintering Environment)	점화로 온도(Ignition furnace temperature) 주 송풍기 온도(Main Blower temperature) 목표 생산량(Target production) 날씨 및 계절(Weather & season)
결과 (Effects)	공정 상태 (Process state)	먼지 온도(Dust temperature) wind-box 온도(Windbox temperature profile) 먼지 농도(Dust density) 적열층 성질(Hot zone properties)
	품질 데이터 (Quality data)	분률(Shatter Index ,SI) 환원 지수 (Reduction Degradation Index ,RDI) 회수율(Screening rate)

소결기 속도에 관련된 인자들은 표 1 에서와 보는 바와 같이 크게 다섯 가지로 분류할 수 있다. 첫째 3 개의 종류는 소결 공정에 물리적인 영향을 주는 인자들로서 일종의 원인(cause)이라 할 수 있다. 나머지 두개의 종류는 소결 공장에서 원인의 결과를 반영하는 인자로서 일종의 결과(effect)라고 할 수 있다. 이와 같은 분류는 실제 포항제철의 소결 공장의 조업자들로부터 소결기 펠릿의 속도 제어에 중요

한 변수들에 대한 설문조사를 통하여 얻은 결과이다. 이 인자들에 대한 중요도(significant level), 평균 제어 범위(normal range), 수정 주기에 대한 내용이 표 2 에 나와 있다. 이 중에서 중요한 몇 개에 대하여 자세히 알아보자.

배광부 적열층 성질(Hot zone properties) : 배광부의 적열층(hot zone)이란 소결기의 끝부분에서 볼 수 있는 소결이 완료된 소결광의 가로 방향으로 이루어진 고온의 온도 층을 말한다. 여러 가지 조사를 통하여 적열층의 온도가 가장 중요한 제어 인자이고 소결 공정의 결과를 반영하고 있음을 알 수 있다. 성질에는 적열층의 모양, 적열층의 비율, 높이 및 면적 등이 포함된다. 현재 포항제철 제 1 소결 공장에서는 적열층의 분포를 중심으로 하여 조업자들이 조업을 하고 있으나, 이에 대한 온라인 데이터는 수집되고 있지 않고 있다. 따라서, 적열층에 대한 정보는 본 연구의 신경회로망의 구현에서 사용될 수 없었다.

Wind-box 온도 분포 : Wind-box 들은 소결기 바로 밑 단에 위치하고 있고 주 송풍기에 연결되어 공기를 흡입하고, 이때 14 개의 wind-box 내의 온도들이 측정된다. 그림 2 는 wind-box 의 온도의 분포의 한 예를 나타낸다. 온도가 가장 높은 곳을 BTP(burn through point)라 한다.




그림 2 : wind-box 온도 분포의 예. BTP(burn through point)는 22 번 wind-box 에 형성되고 있다

층후(bed height) : 소결 원료의 두께(층후)는 소결기

펠릿 위에 장입되는 원료의 높이를 나타낸다. 만약 매우 높다면, 공기 투과성이 낮아 되어 소결기의 속도를 낮추어야 한다. 반대로 너무 낮다면, 속도를 증가시킬 수 있다.

생석회 비(quick lime ratio) : 생석회는 알갱이로 존재하는 철광석을 응집시키는 결합제로서 사용되는 동시에 공기 투과성을 제어하는 데에 이용된다. 즉, 이 비율이 높다면, 공기 투과성이 증가된다. 정상 조업 상태에서 이 인자는 잘 변화하지 않기 때문에 신경회로망의 제어 인자로 사용되지 않았다.

그 밖의 인자들 : 그 밖에 중요한 인자들 중에서 wind-box 온도와 관련되어 자주 변화되는 변수들을 신경회로망 속도 제어 시스템에서 고려하였다. Wind-box 온도가 가장 중요한 인자이기 때문에 온도와 상관도가 높은 변수 일수록 중요하기 때문이다. 주 송풍구의 기압과 전력 및 원료의 수분 함유량을 포함시켰다. 표 2의 오른쪽 끝 행에는 신경회로망 제어 시스템의 입력을 정하기 위한 실험에 사용한 변수들을 표시하였다.

표 2: 속도 제어에 관련된 측정 가능한 인자들

중요도 (%)	인자(Factor)	정상 작동 범위 (Normal operation Range)	수정 주기	사용
19.9	적열층 성질	180±5cm	1 분	
12.9	Wind-box 온도 변화	400±20°C	1 분	○
12.4	층후	550-10mm	일정	
8.7	생석회 비	1.5±0.2%	10 일	○
8.2	주 송풍기 기압	1525±25mmH ₂ O	1 분	○
6.3	주 송풍기 전력	2.9MW±0.1MW	1 분	○
6.1	코크스 크기	1.40mm±0.2mm	10 일	
5.9	분률	91±0.5%	4 시간	
5.2	반광 비	13±2 %	10 일	
3.7	선별회수율	17.5±2.5%	10 일	
3.5	혼합 원료 수분	6.0±0.3 %	1 분	○
2.3	코크스 비	3.7±0.1%	10 일	
2.3	장입 밀도	1.955±0.05ton/m ³	2~3 일	
1.2	환원 지수	33.2±2.0%	8 시간	

2.3 소결기 펠릿 속도 제어

소결기 펠릿 속도는 소결 공정에서 가장 중요한 제어 변수이다. 조업자는 wind-box 온도 등 몇 개의 관련된 인자들을 기반으로 속도를 예측한다. 펠릿 속도를 너무 크거나 작게 맞추면 다음과 같은 상황이 발생한다.

속도가 낮을 때:

- 생산량 감소
- 소결광의 경도를 측정하는 분률이 감소
- 주 송풍구와 점화로의 불필요한 에너지 필요
- 환경 오염 지수증가

속도가 높을 때:

- 반광의 회수율이 증가하고 소결의 비용이 증가
- 냉각기 등의 장비에 손상
- 환경 오염 지수증가

단순한 속도 제어는 완전 연소 점(BTP, burn through point)의 위치를 기반으로 한 제어이다. 포항제철 제 1 소결기에서, BTP가 wind-box 23에 위치하고 그 위치에서의 온도가 400±20°C 일 때 가장 좋은 결과를 얻을 수 있다고 알려졌다. 만약 BTP가 23번 wind-box의 앞쪽에 위치한다면, 이것은 소결 과정이 너무 빠르다는 것을 의미하며, 속도를 증가시킨다. 반대로 BTP가 뒤쪽에 위치하면, 소결 과정이 너무 늦게 이루어 진다는 것을 의미하며, 속도를 감소시키게 된다. 정상 상태에서의 속도 제어의 범위는 2.0±0.2m/min 이라고 알려져 있다.

3. 제안된 속도 제어 시스템

3.1. 함수 근사기로서의 신경회로망

신경회로망은 산업 공정의 모델링을 위한 가장 실용적인 방법들 중의 하나이다. 정의 되지 않은 시스템으로부터 생성되는 공정 데이터를 이용하여 학습함으로써 시스템을 모델링 할 수 있다. 또한 시스

템에 내재되어 있는 변수들의 복잡하고 비선형적인 상관관계를 구축할 수 있다.

소결기 속도 제어시스템에서의 신경회로망의 역할은 소결 공정의 상황으로부터 소결기 펠릿의 속도 제어 함수를 근사하는 것으로 간주할 수 있다. 즉, 공정 데이터 집합이 $(x, f(x))$ 로 주어졌을 때, 신경회로망 $G(w, x)$ 를 사용하여 연속 함수 $f(x)$ 를 근사하는 것이다. 여기서 w 는 신경회로망의 가중치이고 x 는 입력 벡터이다. 알지 못하는 함수 f 에 대하여 최적의 근사 함수를 찾아내는 것은 신경회로망의 최적 가중치를 찾아내는 일이 된다. 소위 보편적 근사 이론(universal approximation theorem)에 따르면 충분한 수의 시그모이드 형태의 활성화 함수를 은닉 노드로 가지고 있는 다층 퍼셉트론은 어떤 연속 함수든지 원하는 정도의 정확도로 근사할 수 있다고 알려졌다. 그리고 이 다층 퍼셉트론을 학습 시키는 효과적인 알고리즘이 오류 역전파 알고리즘이다[1,10].

조업자들이 소결기 속도를 조절할 때 고려하는 인자를 신경회로망의 입력으로 정하고, 출력은 조업자들이 그 입력 인자들을 보고 판단하여 제어한 소결기 속도라고 하자. 그러면, 인자/속도 의 쌍을 사용하여 신경회로망 $G(w, x)$ 가 입력 x 에 대하여 최소의 에러를 가지도록 신경회로망의 가중치 w 를 찾을 수 있다. 이때 최적의 가중치를 찾는 것을 학습이라고 한다. 학습이 끝난 후에 새로운 입력 인자가 주어지면, 신경회로망은 일반화된 출력을 낼 수 있게 된다. 즉, 조업자가 현재의 소결 조업 인자를 보고 속도를 설정하듯이, 신경회로망도 새로운 입력에 대하여 최적의 속도를 출력할 수 있다. 이러한 기법을 이용하면 조업자의 제어 패턴을 모방하는 신경회로망 속도 제어기를 만들 수 있다.

3.2 데이터 수집

포항제철 제 1 소결 공장으로부터 1996년 11월부터

1997년 6월까지의 조업 데이터를 수집하였다. 소결 조업이 연속적인 공정이기 때문에, 매 분마다 수집된 데이터이다. 즉, 하루에 최대 1440개의 데이터를 얻게 된다. 표 3은 얻어진 데이터 파일의 일부분을 나타내었다.

표 3: 데이터 파일의 예 (2월 23일 조업 데이터)

시간 (time)	...	생식 회비 (%)	...	Wind-box 22번 온도 (°C)	Wind-box 23번 온도 (°C)	...	속도 (m/min)	...
13:42	...	1.70	...	319.20	384.80	...	1.96	...
13:43	...	1.70	...	323.20	388.50	...	1.96	...
13:44	...	1.70	...	327.20	391.20	...	1.94	...
13:45	...	1.70	...	330.90	392.50	...	1.94	...

공정 데이터 중에는 똑같은 입력에 대하여 다른 출력을 갖는 비함수(non-function) 데이터가 존재한다. 이런 데이터들은 구별되어 학습 데이터 집합에서 제거되어야만 한다. 이와 같은 데이터가 발생하는 원인은, 각 조업자가 약간씩 다른 소결기 속도 제어 방법을 가지고 있기 때문이다. 조업자들은 그들의 조업 방법에 약간씩 차이가 있기 때문에 똑같은 상황에서도 약간 다른 속도 제어 방법을 가지고 있게 된다. 이를 해결하기 위해서 조업 데이터를 조업자들에 보여준 후 가장 조업이 안정적인 한 명의 조업자를 선택하게 하여 그 사람의 조업데이터를 신경회로망의 학습에 이용하였다.




그림 3 : (a) 2월 23일 wind-box 온도 변화 (b) 조업자의 속도 제어. V_{op} 는 조업자의 속도 설정값을 나타낸다.

또 하나의 문제점으로 조업자의 제어 출력이 항상 완벽하지 않다는 것이다. 조업자가 공장에 있는 많

은 시설 및 장비들을 계속 관찰하고 있어야 하기 때문이다. 즉, 보다 시급한 일을 처리하다 보면 wind-box 온도 및 다른 인자들을 놓치게 되는 경우가 발생한다. 그림 3(a)는 wind-box의 온도 변화를 나타내고 그림 3(b)는 조업자의 소결기 펠릿의 속도 제어를 나타낸다. 1997년 2월 23일, 0:30에서 17:10까지 wind-box의 온도는 연속적으로 계속 변화하고 있는데 반해, 조업자는 소결기 펠릿의 속도를 몇 번 바꾸지 않고 있다. 특히 앞쪽 부분에서는 단 한번밖에 소결기 속도에 변화를 주지 않았다. 이 당시의 소결 조업자는 앞쪽 부분에 소결기의 속도를 좀 더 자주 바꾸어 주어야만 했으나 다른 급한 일의 처리 때문에 그렇게 할 수 없었다. 만약 이러한 데이터를 모두 신경회로망의 학습에 이용한다면, 좋은 성능의 속도제어 시스템을 얻을 수 없을 것이다. 따라서, 소결 조업자의 도움을 얻어 이러한 데이터를 골라내고 제어가 제대로 이루어졌던 부분의 조업 데이터만을 선별하여 신경회로망의 학습에 이용하였다.

3.3 신경회로망 모델과 학습

가장 좋은 신경회로망 모델을 찾아내기 위하여 어떤 공정 인자와 변수들을 신경회로망의 입력으로 사용할 것인지에 대하여 고려하였다. 이를 위하여, 검증 데이터(validation data)를 이용하여 다양한 모델에 대하여 여러 번의 실험을 수행하였다. 학습 데이터로는 1996년 11월 부터 1997년 3월까지 수집된 데이터를 이용하였다. 비함수(non-function) 데이터를 전처리(pre-processing)를 통하여 제거하여 총 8146개의 입/출력(I/O) 데이터를 얻었다. 그리고 총 데이터 중에서 6340개를 학습에 이용하였고 1806개를 모델의 검증(validation)에 이용하였다.

최적 모델의 선택을 위하여 wind-box 온도, 생석회비, 주 송풍구(main blow) 기압 및 전력, 배합원료 수분을 고려하였다. 그러나, 적열층 성질에 대한 데

이터는 얻을 수 없었기 때문에 모델 선택 시에 제외되었다.

다양한 변수를 사용하는 여러 모델을 구축한 후, 여러 번의 검증 실험을 통하여 wind-box 18, 20, 22, 23번 온도를 입력으로 사용한 모델이 가장 좋은 성능을 보였다. 또한, 소결 공정이 시간 지연(time delay)을 갖는 연속 공정이기 때문에, 과거와 현재의 변수를 모두 고려해야만 했다. 다양한 과거 변수를 이용한 검증 실험을 통하여, 최종적으로 현재, 5분전, 10분전, 20분전 그리고 30분전의 wind-box 온도로 이루어진 총 20차원의 입력 벡터가 정해졌다. 모델의 출력은 현재의 소결기 펠릿 속도 설정치(set-up speed)이다.

학습에 사용된 오류 역전파 학습 알고리즘은 다음과 같다. 먼저, 이 학습 알고리즘의 학습 규칙은 신경회로망의 가중치 w 를 학습 데이터에 대한 오류 함수를 최소화 하도록 수정된다. 오류 함수는 아래와 같이 정의 된다.

$$E(w) = \frac{1}{2} \sum_k (d_k - y_k)^2. \quad (1)$$

여기서 d_k 와 y_k 는 각각 목표 값(target value)과 신경회로망의 출력 값(neural network output value)이다. Chain rule과 편미분을 이용하면 노드 i 와 j 의 가중치 w_{ij} 는 아래의 식에 의해 수정된다.

$$\Delta w_{ij} = -\eta \left[\sum_k (d_k - y_k) f'_o(net_k) w_{ij} \right] f'_h(net_j) x_i \quad (2)$$

여기서, η 와 net_k 는 각각 학습률(the learning rate)과 노드 k 의 가중 합(weighted sum)이다. f_o 와 f_h 는 미분 가능한 비선형 함수로서, 출력 노드와 은닉 노드에서 $f(net) = 1 / (1 + e^{-net})$ 와 같이 정의된 함수이다. 자세한 내용은 참고문헌 [10]을 참조하자. 실험 결과 두개의 은닉 노드를 갖는 다층 퍼셉트론이 검증 데이터에 대하여 가장 좋은 성능을 보이는

것으로 밝혀졌다(그림 4). 최종 네트워크는 학습률 0.0005, 모멘텀(momentum) 0.2 를 갖고 100 회(epoch) 학습시켜 생성하였다.




그림 4: 속도 제어 시스템에 사용된 다층 퍼셉트론 신경회로망 모델. T-i 는 i 분 전의 온도를 나타내고 Vnn 은 현재의 소결기 펠릿의 설정 속도(set-up speed)를 나타낸다.

4. 성능평가

제안된 신경회로망 제어기의 성능을 오프라인(off-line)과 온라인(on-line)의 두 가지 방법을 이용하여 평가하였다. 오프라인 평가에서는 신경회로망의 학습에 전혀 사용되지 않았던 조업자의 데이터를 가지고 테스트하였다. 온라인 평가에서는 실제 소결 공장에 신경회로망 속도 제어기를 직접 설치하여 성능을 테스트 하였다. 테스트 결과를 기반으로 신경회로망 속도 제어기의 안정성이 인정되고, 소결기 속도 자동화에 이용될 것인지 결정 될 것이다.

4.1 오프라인(off-line) 평가

신경회로망 속도 제어기의 성능을 평가하기 위해, 학습과 검증에서 사용되지 않은 10 일치의 데이터를 무작위로 선택하였다. 적용한 날의 데이터로부터 앞쪽의 1000 분 동안의 데이터를 모아서 총 10000 개의 테스트 데이터를 오프라인 평가에 사용하였다.

표 4는 신경회로망과 조업자의 실제 속도 설정치 사이의 차이를 제곱 평균(root mean square, RMS) 에러로 표현하였다. 학습 에러(training error)와 테스트

에러(test error)는 학습데이터에 대한 에러와 테스트 데이터에 대한 에러를 나타냈다. 테스트 에러의 경우 실제 속도로 표현했을 때의 에러도 함께 나타내고 있다. 실제 조업자들도 $\pm 0.025\text{m/min}$ 의 범위의 오차 허용 범위를 가지고 있다고 알려져 있으므로 결과는 만족할 만한 수준의 오차를 가지고 있다고 할 수 있다.

표 4 : 신경회로망 모델의 학습 에러와 테스트 에러(단위: root mean square error)

	학습(Training) 에러	테스트(Test) 에러
RMS Error (m/min)	0.029	0.042 (0.030)

그림 5는 신경회로망의 출력 속도(V_nn)를 실제 조업자의 속도 설정치(V_op)와 함께 나타내고 있다. 결과에 대한 실제 조업자의 의견은 아래와 같다.

2월 23일 (그림 5a) : 신경회로망과 조업자 모두 올바르게 소결기 속도를 올바르게 제어하고 있다. 10:30 주위에서, wind-box 20 번의 온도가 증가될 때, 신경회로망은 제대로 반응을 하였다. 전반적인 신경회로망 제어 모델의 성능은 만족스럽다.

12월 11일 (그림 5b) : 신경회로망의 출력은 전반적으로 만족스럽지만, 조업자의 제어는 0:30 에서 10:30 분 사이에 좋지 못하다. 이 시간 동안에, 조업자들은 좀 더 자주 소결기의 속도를 바꾸어 주어야 한다.

1월 14일 (그림 5c) : 조업자의 속도 제어는 만족스러우나 신경회로망의 속도는 너무 높다. 1997년 1월에, 1 소결 공장은 기기 이상으로 평균 소결기 속도를 보통 때보다 낮게 설정하였다. 정상 상태의 데이터를 학습한 신경회로망은 이러한 이상 상태일 경우 속도 제어가 제대로 되지 않음을 알 수 있다.

2월 24일 (그림 5d) : 전반부에는 신경회로망의 속도 제어는 좋지 않다. 후반부는 적당한 제어를 하고 있다. 조업자는 15:00 주위에서 소결기의 속도를

낮추어야만 했다.

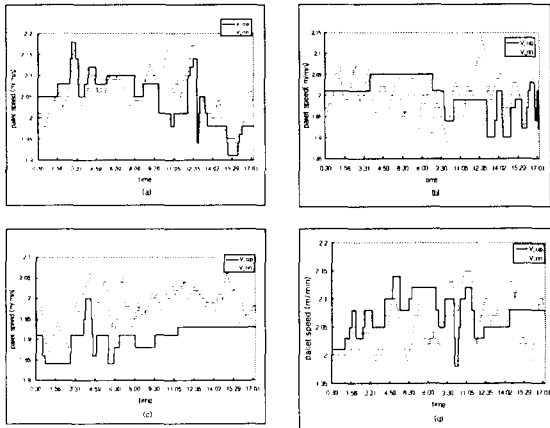


그림 5 : 오프라인 실험 결과. 조업자(V_op)와 신경 회로망 제어 모델(V_nn)의 결과를 비교할 수 있다. (a) 2월 23일, (b) 12월 11일, (c) 1월 14일 (d) 2월 24일

실험 결과를 종합하면, 신경회로망의 제어 성능은 실제 소결 조업자의 성능과 견줄 만하다는 것을 알 수 있다. 또한, 신경회로망의 제어는 조업자의 제어 방식보다 wind-box의 온도 변화에 민감하기 때문에 빠른 속도 제어가 가능하다는 장점이 있다.

4.2 온라인(on-line) 평가

개발된 소결기 속도 제어 시스템을 포항제철 제 1 소결 공장에서 7월 14일부터 16일까지 1일당 최소 6시간씩 온라인 제어로 테스트 하였다. 테스트 과정에는 실제 조업자가 함께 신경회로망을 감시하였다. 신경회로망 제어가 속도를 잘못 제어하고 있다고 판단되면, 조업자는 신경회로망 제어기로부터 제어를 넘겨 받아 제어가 가능하도록 하였다. 신경회로망의 성능은 얼마나 조업자가 만족을 하는가, 조업자가 얼마나 자주 신경회로망의 제어를 넘겨 받은 횟수, 그리고 소결광의 생산량 및 품질 등으로 평가하였다.

그림 6에서 8은 3일 동안의 실제 온라인 적용의

결과이다. 신경회로망 속도 제어 모델이 wind-box의 온도 변화에 민감하게 반응하는 것을 보이기 위하여, 20, 22, 23번 wind-box의 온도 변화도 함께 보이고 있다. 그림 6은 7월 14일의 온라인 적용 결과이다. 조업자가 신경회로망의 제어에 전혀 개입하지 않았고, 신경회로망의 6시간동안 소결기의 속도를 제대로 제어하고 있음을 볼 수 있다.




그림 6: 7월 14일의 온라인 적용의 결과. Wind-box 20, 22, 23번의 온도 변화 (a)와 신경회로망의 펠릿 속도 제어 결과(b)를 나타내고 있다.

그림 7은 7월 15일의 결과이다. 조업자가 15:20에서 한번 제어에 관여를 하였다. 이때는 서지 후퍼 (surge hooper)의 이상이 발견되어 이상 상태였기 때문이었다. 공장의 설비가 이상 작동할 경우에 신경회로망으로부터 속도 제어를 넘겨받아 조업자가 제어를 할 수 있게 설치되었다. 고장이 수리된 후 다시 신경회로망이 제어를 계속하게 된다. 여기서도, 5분간의 수리 후 15:25에 다시 신경회로망이 제어를 수행하고 있다.




그림 7: 7월 15일의 온라인 적용 결과. (a)는 Wind-box 20, 22, 23번의 온도 변화를 (b)는 와 신경회로망(V_nn) 과 조업자(V_op)의 제어를 나타내고 있다.

그림 8은 7월 16일의 신경회로망의 제어 결과를 나타내고 있다. 이 경우 3번 조업자가 신경회로망의 제어를 넘겨 받아서 제어를 하였다. 첫 번째, 서지 후퍼를 청소하기 위하여 10:10에 소결기 속도를 매우 낮게 놓았다. 따라서 wind-box의 온도들이 매우 낮게 떨어졌다. 만약 조업자가 10:30의 주위에서 신경회로망이 그대로 제어하도록 하였다면, 정상 상태가 아니었기 때문에 제대로 제어가 불가능했을 것이다. 두 번째로, 10:40 즈음 10분 동안 같은 이유로 조업자가 신경회로망으로부터 제어를 넘겨받았다. 세 번째는 14:30 즈음 소결기 펠릿이 갑자기 멈추었기 때문에 발생하였다. 세가지 경우 모두 비정상 상태의 경우이고 신경회로망이 제어할 수 없는 매우 예외적인 상황이었다.




그림 8: 7월 16일의 온라인 적용 결과. (a)는 Wind-box 20, 22, 23번의 온도 변화를 (b)는 와 신경회로망(V_nn) 과 조업자(V_op)의 제어를 나타나고 있다.

요약하면, 3일 동안의 실제 온라인 적용을 통해, 신경회로망 속도 제어기는 특별한 오류 없이 소결기의 속도를 자동적으로 제어 할 수 있음을 알 수 있었다. 조업자는 단지 비정상 상태에서 개입하여 발생한 문제를 해결하였고, 문제 해결 후 신경회로망으로 제어를 계속 할 수 있었다. 표 5는 7월 14일부터 16일까지 신경회로망이 소결기 속도를 제어했을 3일 동안의 생산량과 소결광의 품질을 나타내고 있다. 다른 날의 조업자의 의해 생산된 결과 만큼 좋음을 볼 수 있다.

표 5 : 온라인 적용시의 생산량과 소결광의 품질. 신경회로망 속도 제어기의 결과는 두꺼운 글자로 나타나 있다.

날짜 (Date)	생산량 (톤, ton)	소결광 품질 Sintered Ore Quality (%)		
		분률(SI)	환원지수 (RDI)	선별회 수률
7/12	5172	89.8	31.0	19.1
7/13	4479	89.7	27.3	19.0
7/14	4847	89.8	27.7	20.2
7/15	5183	89.9	27.6	18.6
7/16	5033	89.6	30.2	20.0
7/17	5126	89.8	28.6	19.0

5. 결론 및 연구 방향

본 연구에서는 신경회로망 모방 제어 기법을 이용한 소결기 속도 제어 시스템을 제안 하였고, 실제 공정에 직접 적용을 통하여 개발된 자동 제어 시스템의 성능을 평가하였다. 소결 공정의 내재적인 비선형성 및 복잡성, 긴 공정 시간 등 때문에 소결기 속도 제어는 전문 조업자에 의해서만 수행되고 있는 실정이다. 본 연구에서는 현재의 조업 환경이 주어졌을 때, 다층 퍼셉트론 신경회로망을 이용하여 조업자의 제어 방식을 모델링 하도록 자동 제어 시스템을 구현하였다. 현재 조업자들이 가장 중요하게 생각하는 제어 변수인 wind-box 온도가 신경회로망 모델의 입력으로 사용되었다. 또한, 공정이 매우 긴 공정 시간을 가지고 있기 때문에 현재의 wind-box 온도 뿐만 아니라 과거의 온도도 고려한 모델을 개발하였다. 공정 데이터는 포항제철 제 1 소결 공장으로부터 8달 동안 수집하였다. 잡음과 일관되지 않은 데이터를 전처리를 통하여 제거한 후, 오류 역전파 학습 알고리즘을 이용하여 학습하였다. 개발된 모델의 안정성 및 성능을 검증하기 위하여 실험실에서 오프라인으로 충분히 실험하였다. 안정성을 테스트를 충분히 거친 후, 3일 동안 1 소결 공장에서 온라인 적용한 결과 정상상태에서 조업자의 개입이 전혀 없이 소결기 속도 제어가 가능하였고, 신경회로망 모델의 제어로 생산된 소결광의 생산량 및 품질이 조업자가 제어했을 경우와 비슷하였다.

앞으로 개발된 속도 제어기의 성능을 향상시키고 안정적으로 만들기 위해서 적열층의 성질을 제어기의 입력으로 이용하여야 할 것이다. 조업자들을 대상으로 한 설문 조사에서 나타났듯이 적열층은 가장 중요한 인자이기 때문에 신경회로망 제어기에서 이를 이용할 수 있는 설비와 시스템이 필요할 것이다. 또한, 생석회 비 등의 장기 인자를 좀 더 정교하게 제어할 필요가 있다. 이를 위해서 퍼지 제어와 같은 기법이 필요하다. 실제로 조업자들의 제어 지식은 매우 모호하고 표현하기 힘든 경우가 많다. 이런 경우 퍼지 이론(fuzzy theory)은 모호한 조업 정보들을 시스템에서 사용할 수 있게 한다. 신경회로망과 퍼지 이론을 함께 사용한다면 더욱 좋은 성능을 가진 안정된 시스템이 가능할 것이다.

참고문헌

- [1] Bishop, C.M. : Neural Networks for Pattern Recognition, Oxford University Press, Oxford, UK, 1995.
- [2] Bulsari, A.; Saxen, H. : Classification of Blast Furnace Probe Temperatures Using Neural Networks. Steel Research 66 (1995) No. 6, p.231/236.
- [3] Cho, S.; Cho Y.; Yoon, S. : Reliable Roll Force Prediction in Cold Mill Using Multiple Neural Networks. IEEE Transactions on Neural Networks 8 (1997) No. 4, p.874/882.
- [4] Cybenko, G. : Approximation by Superpositions of a Sigmoidal Function. Mathematical Control Signals Systems 2 (1989), p.303/314.
- [5] Di, Y.; Tianzheng, H.; Xiaohui, F. : Adaptive Prediction and Control of Sinter Chemical Composition. In Proceedings of Sixth International Symposium on Agglomeration, p.450/454, Nagoya, Japan, 1993
- [6] Iwamoto, M.; Hashimoto, K.; Inaba, M.; Kobayashi, T.; Hattori, M.; Komatsu, O. : Application of Fuzzy Control for Iron Ore Sintering Process. Transactions ISIJ (1998), p.341/345.
- [7] Loney, D.; Roberts, I.; Watson, J. : Modelling of Hot Strip Mill Runout Table Using Artificial Neural Networks. Ironmaking and Steelmaking 24 (1997) No.1, p.34/39.
- [8] Maki, Y.; Takashima, N.; Obata, H.; Iida, O.; Nakashima, K.; Sawada, T. : Application of Fuzzy Theory to Ironmaking Process Control. Technical report, Kawasaki Steel Giho, Japan, 1991
- [9] Matsuda, K.; Tamura, N.; Nose, K. ; Noda, T.; Okata, T.; Osuzu, K. : Sintering Process Control Using Fuzzy Inference and Neural Network. In Proceedings of Sixth International Symposium on Agglomeration, p. 421/426, Nagoya, Japan, 1993.
- [10] Rumelhart, D.; Hinton, G.E.; Williams, R.J. : Learning Internal Representations by Error Propagation. In D. Rumelhart, J. McClelland, and the PDP Research Group, editors, Parallel Distributed Processing, Vol 1, Foundations, p.319/364. MIT Press, Cambridge, MA, 1986.
- [11] Su, H.T.; Samad, T. : Neuro-Control Design: Optimization Aspects. In O. Omidvar and D. L. Elliott, editors, Neural Systems for Control, p.259/288. Academic Press, San Diego, CA, 1997.
- [12] Vermeulen, W.G.; Morris, P.K.; de Weijer, A.P.; van der Zwaag, S. : Prediction of Martensite Start Temperature Using Artificial Neural Networks. Ironmaking and Steelmaking 23 (1996) No.5, p.433-437
- [13] Wada, T.; Hattori, M.; Fukuyo, H.; Matunaga, Y.; Ona, M. : Development of Uniform and Stable Sintering Technology in Keihin Sintering Plant. In Proceedings of Sixth International Symposium on Agglomeration, p.408/413, Nagoya, Japan, 1993.