

연주공정에서 신경망의 분류 알고리즘을 이용한 횡방향 표면크랙 예측

노용훈¹ · 조동혁² · 김동현³ · 서석⁴ · 이주동⁵ · 이영석[#]

Prediction of Transverse Surface Crack using Classification Algorithm of Neural Network in Continuous Casting Process

Y. H. Roh, D. H. Cho, D. H. Kim, S. Seo, J.D. Lee, Y.S. Lee

(Received December 4, 2017 / Revised March 7, 2018 / Accepted March 9, 2018)

Abstract

In the continuous casting process, the incidence of transverse surface cracks on the piece may occur by multiple and diverse variables. It is noted that mathematical models may predict only the occurrence of the transverse surface cracks, but can require a lot of time (more than three days) to produce a result with this process. This study applied neural networks to predict whether the cracks on the piece surface occurs or does not occur. The computation time was shortened to three minutes, making it applicable to an on-line program, which predicts the non-cracks or cracks of the piece surface in the actual continuous casting process. In addition, the operating conditions to prevent the occurrence of the transverse surface cracks, using decision boundaries were also suggested.

Key Words: Continuous casting, Transverse surface crack, Neural networks, Classification, Decision boundary

1. 서론

연속주조(Continuous casting)는 고로 혹은 전기로에서 생성된 용융 금속(1500℃ 이상)을 순차적으로 냉각·응고시켜서 주편(piece)을 생산하는 공정이다. 본 논문에서는 편의상 연속주조를 연주로 부른다.

주편의 내부/표면크랙은 대부분 연주공정에서 발생한다. 내부/표면크랙이 발생한 주편은 후가공(Post-processing), 즉 압연될 때 많은 문제점(표면흠 등)을 일으키게 된다. 하지만 연주공정 과정에서 내부/표면크랙을 실시간으로 측정 및 제어하는 것은 어렵다. 그 이유는 내부/표면크랙을 제어하기 위해서는 센싱(sensing)을 해야하는데 응고되는 용강(molten

steel)의 온도범위가 약 1000~1500℃이기 때문에 연주공정설비에 센서를 부착하기 어렵다. 따라서 수학적모델을 사용하여 내부/표면크랙을 예측해야한다.

이전 연구에서는 용강이 몰드를 빠져 나온 이후 냉각과정에서 대부분의 내부/표면크랙이 발생한다고 판단하여 연구를 진행하였다.

Cheung 등[1]과 Hancock 등[2]은 냉각과정에서 발생하는 내부/표면크랙 발생을 예측하기 위해서 2차원 열전달 모델을 사용하였다. 이처럼 연주공정에서 열전달 모델에 대한 연구는 지속되어 왔다. 하지만 횡방향 표면크랙에 관해서는 연구가 되지 않았다.

Kim 등[3]은 주로 금융분야에서 사용되던 데이터

1. 중앙대학교 기계공학부

2. 중앙대학교 기계공학부

3. 중앙대학교 기계공학부

4. (주) 익스프레스랩

5. (주) 익스프레스랩

Corresponding Author : School of Mechanical Engineering, Chung-Ang Univ, E-mail: ysl@cau.ac.kr

마이닝(Data mining)을 연주공정에 적용하였다. 데이터마이닝은 빅데이터(Big data)에 숨겨진 유용한 상관관계를 찾아내어 의사 결정에 적용하는 과정을 말한다. 즉 데이터간에 숨겨진 패턴 및 관계를 찾아내는 것이다. 그들은 연주공정을 실시간으로 제어하기 위해 데이터마이닝 기법 중 하나인 의사결정나무(Decision tree)를 사용하였다. 의사결정나무를 이용하여 기포함, 선형함, 크랙 등을 분류하고 예측하는 모형을 생성하였다. 그들은 주편이 스트랜드(Strand) 구간에서 물과 공기에 의해 냉각될 때 유량을 고려하였다. 하지만 몰드(Mold) 내부의 테이퍼 형상이나 최초 열에 의한 변형에 의해서는 고려하지 않았다. 횡방향 표면크랙은 냉각구간에서의 물과 공기의 유량뿐만 아니라 몰드 형상이나 몰드 내부에서 용강의 열변형에 의해 초기크랙이 발생될 수 있다. 따라서 횡방향 표면크랙을 예측하기 위해 몰드에 관한 조업조건이 포함된 연구가 필요하다.

Lee 등[4]은 Mold와 Strand부에서 횡방향 표면크랙(transverse surface crack)에 영향력있는 요인을 파악하는 지수형식모형을 만들었다. 그들은 이 모형을 사용하여 횡방향 표면크랙 발생 유무를 예측하였다. 하지만 지수형식의 모델은 정확도(Accuracy)가 약76% 정도로 미흡하였다. 또한 지수형식모델에 있는 상수 값들은 연구자의 경험에 의해서 결정되었다. 따라서 수학적모델을 이용한 횡방향 표면크랙예측은 상당한 시간이 요구된다. 실시간으로 주편의 내부/표면크랙을 예측하고 제어하기 위해서는 3가지(MCI, SCI, GI)지수의 상수값 계산에 소요되는 시간을 단축시키는 연구가 필요하다. 이 3가지는 조업조건과 밀접한 관련이 있다.

횡방향 표면크랙은 다양한 조업조건과 관련이 있기 때문에 관계, 패턴, 규칙을 하나의 수학적 모델로 정의하여 발생 유무를 예측하는 것은 매우 어렵다. 따라서 본 연구에서는 관계, 패턴, 규칙을 찾는 데 탁월한 능력이 있는 신경망(Neural Network)기법을 사용하였다. 입력값은 횡방향 표면크랙에 영향력이 있는 3가지(MCI, SCI, GI)를 사용하였다. 출력값은 표면크랙 발생 유무이다. MCI, SCI, GI에 대한 설명은 2.3절에 설명되어있다. 계산된 Crack/Non-crack의 결정 경계(Decision boundary)를 이용하여 횡방향 표면크랙발생을 예방하는 조업조건을 제안할 수 있다. 나아가 신경망을 이용한 계산 시간은 지수형식의 모델보다 약95%이상 단축되었다.

2. 연주공정에서의 표면크랙

Fig. 1은 연주공정 도식도이다. 공정 순서는 용강을 담아두는 래들(Ladle), 몰드로 보내는 용강의 공급을 제어하는 턴디쉬(Tundish), 용강을 성형하는 몰드(Mold), 소재를 지지 하는 스트랜드(Strand) 순이다.

2.1 표면 및 내부크랙 위치 및 종류

연주공정 중에서 여러가지 조업조건에 의해 주편 내부 또는 표면에 크랙이 발생한다. Fig. 2는 내부 및 외부크랙의 위치 및 종류를 보여주고, Table 1은 상기 크랙번호의 해당하는 내부 및 외부크랙의 명칭을 설명한다. 본연구에서는 횡방향 표면크랙에 한정해서 연구를 수행하였다.




Fig. 1 Continuous casting process




Fig. 2 Location of the cracks

Table 1 Types of cracks

No.	Internal Crack	No.	Surface Crack
1	Midway	7	Longitudinal, mid-face
2	Triple-point	8	Longitudinal, mid-corner
3	Centerline	9	Transverse, mid-face
4	Diagonal	10	Transverse, corner
5	Straightening/Bending	11	Transverse, narrow face
6	Pinch Roll	12	Star

2.2 횡방향 표면크랙 검출

횡방향 표면크랙은 대부분 현장 조업자의 눈(naked eyes)에 의해 관측된다. 하지만 조업자가 신경써서 자세히 보아야만 검출이 가능하다. 이 과정에서 조업자가 횡방향 표면크랙을 놓치는 경우가 종종 발생할 수 있다. 조업자가 횡방향 표면크랙을 검출하려면 많은 시간이 필요하고 따라서 생산비용이 증가하는 문제점이 있다.

한편 횡방향 표면크랙 검출을 위해서 센서(sensor)가 부착된 자동화된 검출시스템 개발 및 설치를 고려할 수 있다. 하지만 주변은 고온(약 1000℃)이기 때문에 표면크랙 측정센서를 사용하기 어렵다.

따라서 횡방향 표면크랙을 검출하는 것은 순전히 조업자에 노력과 눈에 의존하여야 한다. 이런 이유로 가상 모델을 만들어 횡방향 표면크랙생성에 가장 많이 영향을 주는 지수(index)를 산출하고 그 값을 계산하여 횡방향 표면크랙 예측에 사용해야 한다. 여기서 말하는 가상 모델은 횡방향 표면크랙 측정 센서의 역할을 대신한다고 볼 수 있다.

2.3 크랙 지수

본 연구에서는 대부분의 횡방향 표면크랙은 Mold와 Strand에서 발생한다고 가정하였다. Lee 등[4]등은 연주공정에서 주변의 횡방향 면크랙발생에 영향을 주는 기본 개념(몰드 내부의 균열 경향성, 주조 속도에 영향을 받는 오실레이션 마크 깊이, 온도에 의한 표면 연성, 취성 온도 범위에서의 열에 의한 변형률, 마찰에 의한 외부 변형, 외부의 정적 크리프 변형)을 분석하였다. 그리고 Lee등은 이러한 기본개념, 열전달 및 고상화(solidification)유한요소해석을 수행 하여 몰드내 외부의 횡방향 표면크랙을 평가하였고 현장 데이터와 비교하였다. 나아가 횡방향 표면크랙발생에 영향력있는 요인을 파악할 수 있는 모델을 만들었고 크랙 발생 유무를 예측 할 수 있는 지수형식의 모델을 개발하였다. 아래에서 표면크랙발생에 가장 많은 영향을 주는 지수 3개를 설명한다.

(a) MCI(Mold Crack Index)는 몰드와 용강 사이에 윤활작용을 위해 파우더를 뿌리는데 그 때 파우더가 윤활 작용을 원활히 하지 못해 발생하는 마찰과 열전달에 의한 변형률을 지수화 하였다.

(b) GI(Gap Index)는 몰드 내부의 테이퍼가 너무 크면 용강이 몰드에 끼는 현상이 발생 할 수 있다. 따

라서 몰드의 사이드에서 수직방향으로 몰드 두께와




Fig. 3 Crack index explanation (a) MCI (b) GI (c) SCI

테이퍼의 두께의 길이 비(比)를 지수화 하였다.

(c) SCI(Strand Crack Index)는 Strand구간에서 발생할 수 있는 크랙을 지수화 하였다. 소재가 (-x)방향에서 (+z)방향으로 꺾이는 구간에서 굽힘 인장(Bending tensile)이 발생한다. 이때 크랙이 발생하여 후에 더 큰 크랙으로 진전될 가능성이 있다.

Fig. 3은 각각의 지수를 도식화한 그림이다.

3. 신경망 모형

신경망은 빅데이터에 대한 비선형적인 규칙과 패턴을 찾아내어 최적의 해답을 도출하는 것이 장점이다[5]. 본 연구자는 연주공정에서의 횡방향 표면크랙을 예측하고 새로운 조업 조건을 제시하기 위해 신경망에서 분류 알고리즘(Classification algorithm)을 사용하였다.

3.1 구조

신경망을 구성하는 요소는 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer), 노드(Node), 활성화함수(Transfer function: $f(\sigma)$), 가중치(Weight)로 크게 6가지로 구성된다. Fig. 4는 신경망의 구조를 나타낸다.




Fig. 4 Structure of Neural Networks




Fig. 5 Logistic sigmoid function curve

각층의 노드는 가중치(연결 강도: w)에 의해 연결된다. 가중치(w)에서 i 는 Input node의 수를 의미하고, j 는 Hidden node의 수를 의미한다. 예를 들어 w_{21} 은 두번째 입력 값인 SCI와 은닉층의 첫 번째 노드를 연결하는 가중치이다.

활성함수($f(\sigma)$)는 미분이 가능하고 일반적으로 수렴성이 좋은 시그모이드 함수(Logistic sigmoid function)를 사용하였다. 식1과 Fig .5은 각각 시그모이드 함수의 식과 그래프를 나타낸다

$$f(\sigma) = \frac{1}{1 + e^{-\sigma}} \quad (1)$$

3.2 순전파

입력노드(Input node)를 시그모이드 함수로 출력하기 위해서 0~1사이의 수로 정규화(Normalization)한다. 정규화 된 각각의 입력노드들은 가중치와 곱한 후 합하여(식2) 은닉층의 노드로 출력된다. i 는 입력노드의 서수(Ordinal number)이고, j 는 은닉층의 노드의 서수이다.

$$\sigma = \sum_{i=1}^n w_{ij} * x_i \quad (2)$$

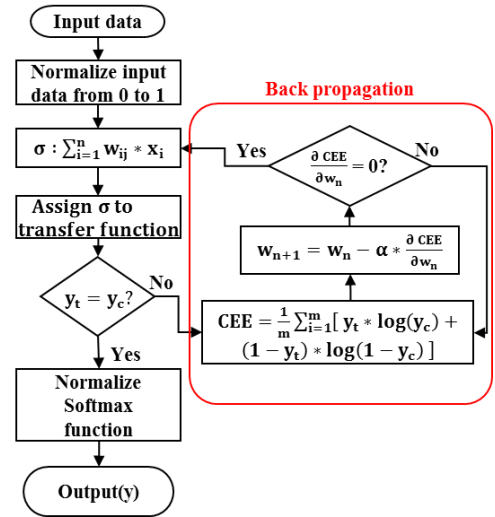


Fig. 6 Training process - flow chart

은닉층의 노드로 출력된 값들은 활성 함수를 통해(식1) 전환된다. 그 다음 마지막으로 소프트맥스함수(Softmax function)로 정규화(식3)하고 출력층의 노드로 값을 출력한다. y 는 출력값이고, k 는 Output node의 수를 의미한다. 이 과정을 신경망의 순전파(Feed forward)라 한다.

$$\exp^{y_k} / \sum_{k=1}^z \exp^{y_k} \quad (3)$$

3.3 역전파

계산된 출력 값(Calculated output: y_c)과 입력한 출력 값(Target output: y_t)는 가중치에 의해 오차가 생긴다. 따라서 오차(Cross Entropy Error: CEE)(식4)를 0에 근사하게 만들어 최적화된 모델을 만들기 위해서는 가중치를 갱신해야한다. 이 때 가중치를 최적화시키는 방법으로 미분을 기반으로 한 최적화 방법 중 하나인 경사하강법(Gradient Descent Method)(식5)을 사용한다. m 은 데이터의 수이다. α 는 학습률(Learning rate)로 0~1사이의 값을 가지며 학습률에 의해 학습(Training)의 속도를 정해진다. 하지만 학습률이 너무 크면 수렴하지 못하는 경우가 발생할 수 있으므로 본연구에서는 0.01로 두었다. 이 과정을 역전파(Back propagation)이라 한다.

$$-\frac{1}{m} \sum_{i=1}^m [y_i * \log(y_c) + (1 - y_i) * \log(1 - y_c)] \quad (4)$$

$$w_{n+1} = w_n - \alpha * \frac{\partial CEE}{\partial w_n} \quad (5)$$

3.4 학습

본 연구에서 학습은 입력 값과 출력 값을 예측하는 최적화된 근사화 모델을 만드는 과정을 말한다. 즉 신경망에서 최적화된 가중치를 찾기 위해 순전파와 역전파를 반복하는 과정을 학습이라 한다. Fig. 6은 신경망이 데이터를 학습하는 과정을 순서도로 나타내었다.

4. 검증

4.1 파라미터

본 연구에서 신경망에 사용된 파라미터는 Table 2에 명시되어있다. 본 연구자의 경험적인 부분으로 은닉층의 수는 2층을 적용하였다. 또한 은닉층의 노드 수는 각층마다 5개를 적용하였다. 은닉층의 수와 은닉노드의 수는 정확도가 가장 높고 과적합이 비교적 덜 발생하는 개수를 사용하였다. 학습시킨 데이터의 수는 326개 이고, 사용된 코드는 Matlab R2017a이다 [6].

Table 2 Detail of the neural network parameters

Topology	3 inputs and 2 hidden layers with 5 hidden nodes in each layer, 2 outputs (3-5-5-2)
Training algorithm	Scaled Conjugated Gradient
Transfer function	Logistic sigmoid, Softmax
Loss function criteria	Minimum Cross Entropy Error
Stopping criteria	When the validation error increases
Number of data	326

4.2 분류행렬표

본 연구에서는 신경망 모형의 적절성을 확인하기 위해서 분류행렬표(Fig. 7)를 사용하였다. 분류행렬표란 예측 모델이 올바르게 분류를 했는지 잘못 분류를 했는지에 관한 정보를 보여주기 위한 표이다.

Fig. 7에서 ①은 True positive(TP)이며, 입력했던 결과가 'Non-crack'일 때 계산결과가 'Non-crack'으로 올바르게 분류가 된 데이터 수를 의미한다. ②는 False Positive(FP)이며, 입력했던 결과가 'Crack'일 때 계산결과가 'Non-crack'으로 분류가 제대로 안된 데이터 수를 의미한다. ③은 False Negative(FN)이며, 입력했던 결과가 'Non-crack'일 때 계산결과가 'Crack'으로 분류가 제대로 안된 데이터 수를 의미한다. ④는

Calculated Class (y _c)	1 (Non Crack)	① (TP) 152 46.6%	② (FP) 38 11.7%	80.0% 20.0%
	2 (Crack)	③ (FN) 21 6.4%	④ (TN) 115 35.3%	84.6% 15.4%
		87.9% 12.1%	75.2% 24.8%	81.9% 18.1%
		1 (Non Crack)	2 (Crack)	
		Target Class (y _t)		

Fig. 7 Classification matrix table

True Negative(TN)이며, 입력했던 결과가 'Crack'일 때 계산결과가 'Crack'으로 올바르게 분류가 된 데이터 수를 의미한다. 분류행렬표의 검증은 정확도, 민감도(True Positive Rate), 특이도(True Negative Rate)로 검증된다. 정확도는 신경망 모형이 횡방향 표면 크랙을 정확하게 분류한 비율을 의미하며 식.6.1로 계산된다. 민감도는 입력했던 결과가 'Non-crack'중에서 신경망 모형으로 계산된 결과가 'Non-crack'으로 분류된 비율을 의미하며 식.6.2로 계산된다. 특이도는 입력했던 결과가 'Crack'중에서 신경망 모형으로 계산된 결과가 'Crack'으로 분류된 비율을 의미하며 식.6.3으로 계산된다.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} = 0.819 \quad (6.1)$$

$$TPR = \frac{TP}{TP + FN} = \frac{\textcircled{1}}{\textcircled{1} + \textcircled{3}} = 0.879 \quad (6.2)$$

$$TNR = \frac{TN}{FP + TN} = \frac{\textcircled{4}}{\textcircled{2} + \textcircled{4}} = 0.752 \quad (6.3)$$

4.3 Receiver Operating Characteristic

ROC curve (Fig. 8)는 신경망을 이용한 이진(binary) 분류 모형의 성능을 검증하기 위한 그래프이다.[7] ROC curve는 326개 데이터 각각의 민감도와 특이도가 어떤 관계가 있는지를 표현한다. x축은 326개 데이터 각각의 False positive Rate(FPR)이며 식.6.4로 계

산된다. y축은 326개 데이터 각각의 민감도(TPR)이다. Area Under Curve(AUC)는 ROC curve 아래면적이다. ROC가 왼쪽 상단에 가까울 수록, 즉 AUC면적이 1에 가까울 수록 신경망 모형의 정확도가 높음을 의미한다.

$$FPR : \frac{FP}{FN + FP} = \frac{\textcircled{2}}{\textcircled{2} + \textcircled{4}} \quad (6.4)$$

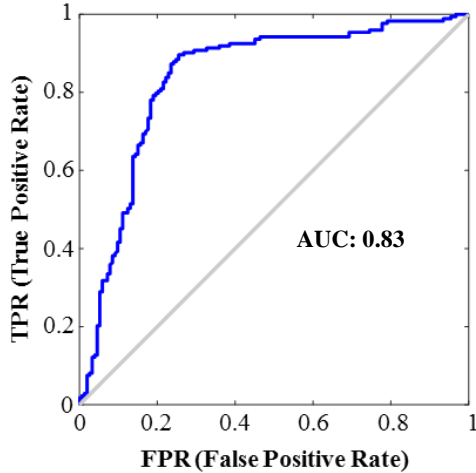


Fig.8 ROC curve

본 연구에서 검증된 AUC는 0.83이다. 일반적으로 AUC가 0.8이상 이면 신뢰성 있는 분류 모형이라고 판단한다. 따라서 본 연구에서 사용된 신경망을 이용한 횡방향 표면크랙 분류 모형이 타당하다고 판단하였다.

5. 결과 및 토론

5.1 계산 시간

신경망 모형을 사용하면 계산 시간이 약 3분 정도 소요된다. 하지만 Lee등이 제안한 예측 모형의 상수를 결정하는 방법은 약3일의 시간이 소요되었다. 즉 약95%의 계산 시간이 단축 되었다. 계산 시간이 단축 되면서 온라인 상용화 프로그램에 개발에 큰 기여를 할 것으로 판단된다.

5.2 결정 경계

신경망모형이 입력한 데이터를 학습하면 결정 경계(Decision boundary)가 생성된다. 이 결정 경계를 통해 현장관리자는 연주공정에서의 횡방향 표면크

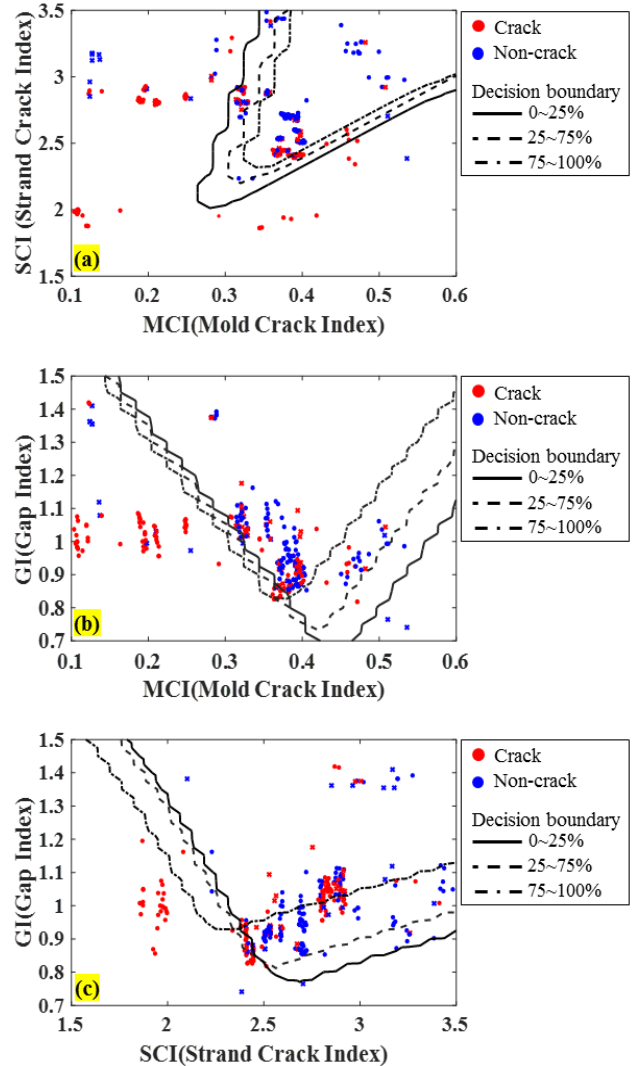


Fig. 9 Decision boundary by data ratio

랙을 예측 할 수 있다. 본 연구에서는 크랙지수들을 신경망 모형으로 학습한 뒤 입력 데이터를 3가지 경우(상위25%, 25~75%, 75~100%)로 나누어 결정 경계를 제시하였다. 이 결정 경계는 횡방향 표면크랙의 발생을 방지하는 기준이 될 수 있다. 예를 들어 Fig. 9.(a)는 신경망을 이용한 분류 결과를 x축이 MCI, y축이 SCI인 방향으로 투영한 그림이다. 현장의 관리자는 이 그림으로 횡방향 표면크랙 예방을 위해 GI가 어느 범위 내에 있어야 하는지 판단 할 수 있다.

6. 결론

본 논문에서는 연주공정에서의 횡방향 표면크랙

을 신경망으로 예측하였다. 본 연구자는 연주공정에서 횡방향 표면크랙에 영향을 미치는 대표 요인들을 지수화하여 입력데이터를 구축하였다. 지수화된 입력데이터를 신경망에 학습 시켜 다음과 같은 결론을 도출하였다.

(1) 신경망이 데이터를 학습하는 시간이 약 3분 이내 이기 때문에 현장 데이터를 실시간으로 업데이트 하는 온라인 상용화 프로그램에 적용 가능하다고 판단하였다.

(2) 분류 정확성이 약 6%향상 되었다. 실제 조업 현장에서 빅데이터가 추가로 주어진다면 좀더 높은 정확성과 횡방향 표면크랙을 예방하는 조업 조건을 제시할 수 있을 것으로 판단된다.

후 기

이 논문은 미래창조과학부의 재원으로 연구성과 실용화진흥원 기초연구성과활용지원사업(제2017-177호)의 지원을 받아 수행된 연구이며, 지원에 대해 진심으로 감사드립니다.

REFERENCES

- [1] N. Cheung, C.A. Santos, J.A Spim, A. Garcia, 2006, Application of a heuristic search technique for the improvement of spray zones cooling conditions in continuously cast steel billets., Appl. Math. Modell, Vol.30, No.1, pp. 104-115.
- [2] Hancock, Walton M., Jae-Wook Yoon, and Roger Plont., 1996, Use of Ridge Regression in the Improved Control of Casting Processes, Int.J. Metrol. Qual. Eng., Vol.8, No.3, pp. 395-403.
- [3] J.K. Kim, H.K. Kim, I.Y. Kim, T.S. Kuwn, K.M. Ha, 2010, A study on performance process quality tracking using data mining, J. kor. Intell. Inf , pp.153-157.
- [4] Joodong Lee, Seok Seo, Sihyun Kwon, Youseung Kim, Donghwan Ryu, Sangjin Kim., 2017, A new way to predict transverse surface corner cracks in continuous casting., Symp. Adv. Steel Technol, jeju, pp75-84
- [5] J.S. Lee., 2016, Development process and understanding of in-depth neural network, J. Commun. Networks, Vol.33, No.10 , pp. 40-48.
- [6] Mathworks, 2017, Classification, <https://kr.mathworks.com/help/stats/examples/classification.html>

- [7] Park, S. H., Goo, J. M., & Jo, C. H., 2004, Receiver operating characteristic (ROC) curve: practical review for radiologists., kor. J. Radiol., Vol. 5, No.1, pp. 11-18.