

< 논문 >

트리구조 신경망을 이용한 냉연 강판 표면 결함의 분류

문창인* · 최세호** · 주원종† · 김기범**
(2006년 10월 19일 접수, 2007년 5월 15일 심사완료)

Classification of Surface Defects on Cold Rolled Strip by Tree-Structured Neural Networks

Chang In Moon, Se Ho Choi, Won Jong Joo and Gi Bum Kim

Key Words : Neural Network(신경망), Tree Structure(트리구조), Surface Inspection(표면검사), Steel Strip Defect(강 코일 결함), Feature Selection(특징 선정)

Abstract

A new tree-structured neural network classifier is proposed for the automatic real-time inspection of cold-rolled steel strip surface defects. The defects are classified into 3 groups such as area type, disk type, area & line type in the first stage of the tree-structured neural network. The defects are classified in more detail into 11 major defect types which are considered as serious defects in the second stage of neural network. The tree-structured neural network classifier consists of 4 different neural networks and optimum features are selected for each neural network classifier by using SFFS algorithm and correlation test. The developed classifier demonstrates very plausible result which is compatible with commercial products having high world-wide market shares.

1. 서론

현재 국내에 있는 대부분의 철강업체에서는 냉연 강판의 표면결함검사를 Fig. 1 과 같이 생산 라인의 맨 끝단에서 실시하고 있다. 검사자가 빠른 속도(약 150~800m/min)로 지나가는 인라인(in-line)강 코일을 상하면을 비추는 거울 앞에 서서 검사한 후 검사자의 감(feeling)에 의해 등급을 선정하는 시스템으로 되어 있다.^(1,2) 이와 같은 시각에 의한 검사방법은 사람마다 동일 결함에 대한 분석이 다

르기 때문에 부정확할 뿐 아니라 결함에 대한 아무런 정보 데이터를 남겨놓지 않아 품질향상을 위한 feed-back 자료로 사용할 수 없으며 판매를 위한 품질 보증자료로나 손해 보상청구(claim) 소송이 걸렸을 때 제출할 수 있는 대응자료(back-up document)로써 너무 부족하다.^(1,2)




Fig. 1 Coil strip line of Union steel

† 책임저자, 회원, 서울산업대학교 기계설계자동화

E-mail : joo@snut.ac.kr

TEL : (02)970-6340 FAX : (02)974-8270

* 서울산업대학교 산업대학원 메카트로닉스학과

** POSCO 기술연구소, 서울산업대학교

현재 국내에서는 포스코가 유일하게 독일의 Parsytek사와 공동 개발한 강 코일 표면 결함 검사 장비를 포스코 인라인에 설치하여 이용하고 있을 뿐 다른 철강회사들은 이러한 장비를 선뜻 구매를 하든가 자체 개발을 하는데 주저하고 있다. 이러한 상황이 계속되는 주요한 이유는 Parsytek사의 장비가 결함 검출 능력은 우수하지만 결함 분류는 약 85% 수준으로 아직 미흡하다. 또한 결함 분류에 사용하는 알고리즘이 각 현장에 적용되어 친숙화 되기까지 오래 걸리고 새로운 형태의 결함이 발생할 때마다 Parsytek사의 결함분류기인 C-5 rule의 변경작업이 종종 요구되는데 이는 Parsytek사의 전문가만이 할 수 있어 기술 의존상태가 계속되어 유지보수비가 많이 들기 때문이다.⁽²⁻⁴⁾

Parsytek사의 강 코일 표면 결함 검사시스템의 주요 구성 요소는 Fig. 2에서 보는바와 같이 강 코일 생산 공정에서 실시간으로 결함을 검출하는 비전시스템과 획득된 결함을 타입별로 분류하는 분류기(classifier)와 모든 결함정보를 통합하여 통계 처리하고 문서 처리하는 유틸리티 프로그램으로 되어 있다.⁽²⁻⁴⁾

국내의 독자적인 결함검사 장비의 개발을 위해서는 많은 하드웨어, 소프트웨어의 요소 기술이 요구되지만 특히 핵심 소프트웨어인 결함분류기의 개발이 매우 중요하다. 바람직한 결함분류기가 되기 위해서는 사용되는 알고리즘이 매우 보편적이면서 현장의 일반 엔지니어가 기본 알고리즘은 건드리지 않으면서도 주변 파라미터만 수정하면 작동하는 유연한 구조를 가지는 것이다. 이를 위해 지난 10여년 동안 여러 사람들이 패턴인식에 우수한 신경망을 선택하였고 신경망 분류기(neural network classifier)^(1,3) 개발을 시도하여 왔다. 그러나

대부분 경우 한정된 개수의 특징 값과 적은 숫자의 결함 샘플을 가지고 해석을 하였기 때문에 가능성만 얻었지 보다 구체적인 실제적인 결과를 만들지 못했다.⁽³⁾ 본 논문에서는 포스코의 3,241개의 결함 샘플과 781개의 특징 데이터를 이용하여 최적의 특징 값들과 개수를 신경망 분류기의 학습과 테스트를 반복하면서 선정하였다. 1차로 개발한 단일구조 신경망 분류기(single-structured NN classifier)⁽⁴⁾를 이용하여 Parsytek사의 C-5의 성능과 비슷한 약 85%의 성능을 얻었으며, 새롭게 제안한 트리구조 신경망 분류기(tree-structured NN classifier) 개발을 통해 90% 정도의 결함 분류 성능을 얻었다.

2. 결함의 종류와 발생원인

냉연 공정에서 발생하는 결함의 종류는 아주 다양하다. 포스코 광양 제철소에서는 품질에 직접적인 영향을 미치는 11가지 결함 종류를 선정하여 사용한다. 그 결함들은 Hole, Scab, Scale, D-Line, P-Patch, O-Drop, Dirty, P-Tree, B-Hole, L-Scale, P-Oil이며 결함의 형태와 발생원인은 Fig. 3과 같다. 11개의 결함들은 크기와 형태에 따라 아래와 같이 크게 3가지 타입으로 그룹화 하였다.

- a) Area type: Hole, Scab, P-Patch, Dirty, P-Tree
- b) Disk type: O-Drop, P-Oil
- c) Area & Linetype: Scale, D-Line, B-Hole, L-Scale




Fig. 2 Steel strip surface inspection system




Fig. 3 (Continued)

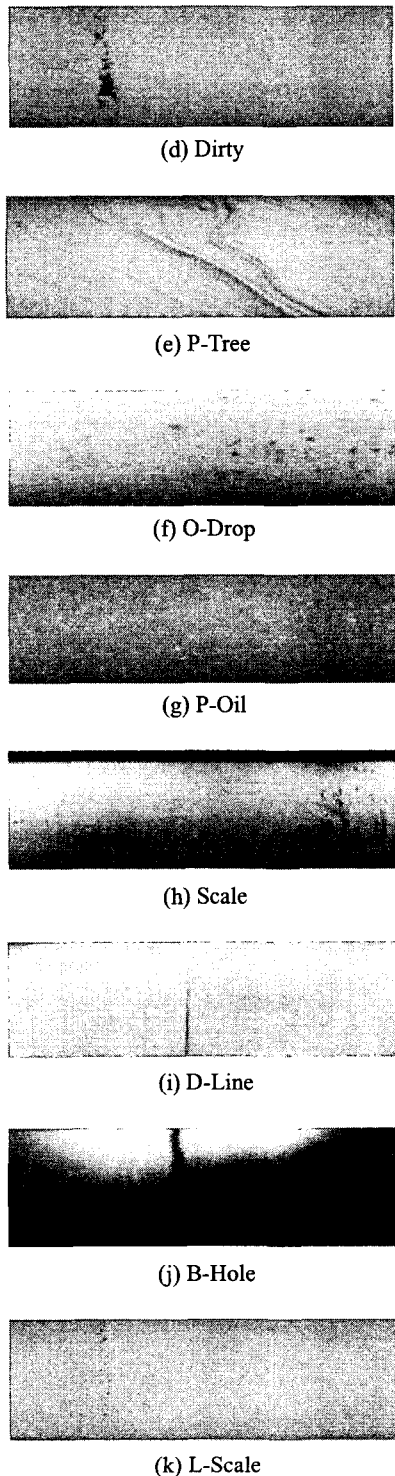


Fig. 3 11 surface defects of cold rolled strip

- (a) Hole: Slab 의 심한 내부 크랙, 이물질 이입
- (b) Scab: Slab 손질 불완전 및 Slab 핸들링 불량
- (c) P-Patch(Pickle patch): Pickling 공정에서 산화물 조합의 불량이 있을 때 주로 생성
- (d) Dirty: 주로 Roll 에 이물질이 있거나 외부에서 이물질 이입으로 인해 주로 발생
- (e) P-Tree(Pinch tree): Roll 의 불안정한 스피드 나 압력에 의해 발생
- (f) O-Drop(Oil drop): Oil 제거 공정 후 표면에 Oil 이 남아 있을 때 주로 발생
- (g) P-Oil(Pickle oil): Pickling 공정에서 산화제 처리 불량으로부터 주로 발생
- (h) Scale: Si 가 강 표면에서 고온 확산되어 냉각 수와 응결되어 산화됨으로 주로 생성
- (i) D-Line(Dark line): Roll 에 끈적거리는 이물질이 이입되었거나 공정 라인에 작은 금속조각 등이 이입되었을 때 생성
- (j) B-Hole(Blow hole): 표면 가까이 있는 기포의 미압착 및 대형 불순물에 기인하여 발생
- (k) L-Scale: Pickling 공정에서 Scale 를 완전히 제거 하지 못하였을 때 주로 발생

3. 특징 선정

신경망 분류기를 실시간 결함 분류에 사용하기 위해서는 입력 노드(input node) 개수가 적을 수록 좋다. 본 논문에서 개발된 신경망 분류기의 입력 값은 결함의 특징 값들이기 때문에 최소한의 개수와 최적의 특징 값들을 결정하는 것이 매우 중요하다.^(3,4,7) 이제까지 포스코와 Parsytek 사가 찾아 사용하는 결함의 특징 종류는 무려 800 여개에 달한다. 실제로 광양 제철소에서는 Parsytek 사의 장비를 이용하여 781 여개의 특징 데이터를 추출하고 있다. 본 논문의 주요한 작업 중에 하나는 이와 같이 많은 특징들로부터 50 개미만의 최적의 특징 데이터를 찾아내는 것이며 이를 위하여 SFFS 알고리즘, K 최근접 이웃(KNN: k-nearest neighborhood) 알고리즘, 상관관계(correlation) 분석 알고리즘을 사용하였다.⁽⁴⁾

SFFS 알고리즘은 Fig. 4 에서 보듯이 작은 특징 값에서 분류 능력이 우수한 특징 값들을 점진적으로 추가하는 방법으로 최고의 변별력을 가진 2 개의 특징 값에서 출발하여 원하는 특징 값들이 충분히 선정되면 중지되는 알고리즘이다.^(2,4)

X_{D-k} : $D - k$ features set, X_k : k features set, $C(X_{D-k})$: X_{D-k} 분류, $C(X_k)$: X_k 분류, x_{best} : X_{D-k} 중 X_k 와 연관되어 최고의 분류능을 갖는 feature, x_{worsi} : $X_k + x_{best}$ 중 최저의 분류능을 갖는 feature 이다.

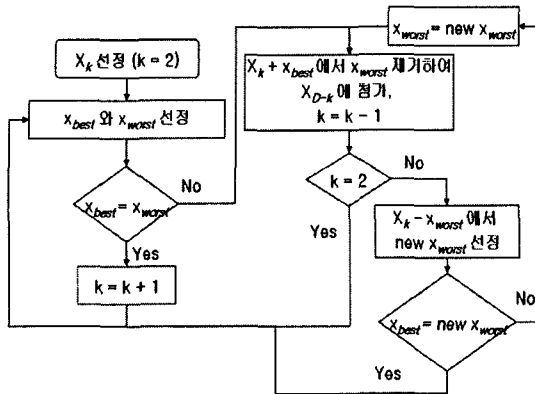


Fig. 4 SFFS algorithm

Table 1 The example of correlation test

상관분석: A, x_sbox, y_sbox, u_sbox, h_sbox, cam_id, R_sbox, A_sbox, U_sbox, A_r

	A	x_sbox	y_sbox	u_sbox
x_sbox	-0.259 0.000			
y_sbox	-0.029 0.000	0.150 0.000		
u_sbox	0.669 0.000	-0.309 0.000	-0.340 0.000	
h_sbox	0.425 0.000	-0.135 0.000	-0.721 0.000	0.675 0.000
cam_id	-0.076 0.069	-0.006 0.000	-0.001 0.000	-0.100 0.400
R_sbox	-0.165 0.000	0.057 0.000	-0.264 0.000	-0.321 0.000
A_sbox	0.710 0.000	-0.343 0.000	-0.356 0.000	0.974 0.000
U_sbox	0.578 0.000	-0.208 0.000	-0.524 0.000	0.947 0.000
A_r	0.282 0.000	0.068 0.000	-0.023 0.000	-0.179 0.000

SFFS 에서 선정된 특징 값들을 KNN 을 이용하여 결함 분류율을 테스트하였다. KNN 기법은 입력패턴이 주어졌을 때 유사도 함수에 기반을 두어 미리 저장되어있는 표준패턴들의 집합에서 입력패턴과 가장 유사한 k 개의 표준패턴들을 선택한다. 선택된 k 개의 표준패턴들의 클래스인 결함 종류들을 확인하여 가장 많이 선택된 표준패턴의 클래스를 입력패턴의 클래스로 결정한다.⁽²⁾

상관관계 분석은 SFFS 를 이용하여 선정된 200 개의 특징 값들에 대하여 상호간의 상관관계를 분석하여 최종적으로 50 개미만의 특징 값들을 선정한다. Table 1 에서 보면 프로그램의 상관관계 분석 결과 값은 -1~1 사이의 값을 출력하며, 0 에 가까울수록 상관관계가 적고, 0 에서 멀어질수록 관계

Table 2 List of selected 37 features

No.	Short Name	Full Name	Comment
1	A	Area	Number of Segmented OD/DD pixels
2	A_r	Area Ratio	Segmented Pixels to Box Ratio
3	h_sbox	Box Height	Height of Bounding Box
4	O	Orientation	Rotation Angle of Principal Coordinates
5	I_max	Max Inertia	Maximum Moment of Inertia
6	I_min	Min Inertia	Minimum Moment of Inertia
7	I_rat	Inertia Ratio	Minimum to Maximum Ratio of Moments
8	e_max	Semi-major	Semi-major Length of Inertia Ellipse
9	e_min	Semi-minor	Semi-minor Length of Inertia Ellipse
10	D_yx	Diameter X+Y	Diameter along 45deg Axis
11	D_xy	Diameter X-Y	Diameter along -45deg Axis
12	D_y	Diameter Y	Vertical Diameter
13	D_min	Min Diameter	Minimum Diameters
14	D_rat	Diameter Ratio	Minimum to Maximum Diameter Ratio
15	CD	Center Distance	Distance Center of Mass to Center of Box
16	SIN_O	Sine Theta	Sine of Orientation
17	a1_A	OD 1 Count	OD Threshold 1 Excess Count
18	a1_Ar	OD 1 Ratio	OD Threshold 1 Excess to Area Ratio
19	a2_A	OD 2 Count	OD Threshold 2 Excess Count
20	a2_Ar	OD 2 Ratio	OD Threshold 2 Excess to Area Ratio
21	a3_A	OD 3 Count	OD Threshold 3 Excess Count
22	a3_Ar	OD 3 Ratio	OD Threshold 3 Excess to Area Ratio
23	merge	OD Merge Flag	OD Merge Flag Data
24	gvr	Contrast	Span of Gray values of Segmented Pixels
25	var	Gray level Variance	Variance of Gray value of Segmented Pixels
26	skew	Histogram Skew	Skew of Gray value Histogram
27	curt	Histogram Kurtosis	Kurtosis of Gray value Histogram
28	mgvgb	Background Gray level	Mean Gray values of Background Pixels
29	mgvdif	Foreground Gray level	Fore to Background Gray value Difference
30	maxgv	Max Gray level	Maximum Gray value of Segmented pixels
31	mingv	Min Gray level	Minimum Gray value of Segmented pixels
32	PERC_DARK	Count Dark	Percentage of Dark Pixels
33	V_DARK	Y Dark	Vertical Position of Dark Area
34	H_DARK	X Dark	Horizontal Position of Dark Area
35	Range_gv	Range gv	Range of Horizontal Gradient
36	Range_gu	Range gu	Range of Vertical Gradient
37	DEV_GV	Deviation Gv	Deviation of Vertical Gradient

가 높은 것으로서 이는 두 특징 값이 비슷한 기능을 가지고 있어 이중 하나가 제외될 수 있다는 것을 의미한다.

이와 같은 분석과정을 거쳐 가장 분류결과가 좋은 최종 특징 값인 형상정보 23 개, 명암정보 14 개인 총 37 개를 선정하여 적용하였으며 그 특징 값들의 종류와 정의는 Table 2 와 같다.

4. 신경망 분류기

철강 표면 결함은 종류가 다양하고 같은 종류의 결함이라도 크기와 명암도가 다양하여 계속적인 튜닝작업이 필요하다. Parsytek 사의 제품은 일종의 전문가 시스템(expert system)인 C-5 를 사용하는데 700 여개의 특징 값으로 구성된 룰 베이스 구조로 Parsytek 사의 전문가가 아니면 수정이 불가능하다. 그러나 본 논문에서 개발한 신경망 분류기는 특징 값들의 기여도에 대한 자세한 내용을 몰라도 손쉽게 특징 값을 추가하거나 제거할 수 있고 가중치(weighting factor)^(5,6,8-10)는 학습을 통해서 자동으로 조정되기 때문에 현장 적용력이 매우 높다. 1 차로 개발한 단일 구조 신경망 분류기에 의한 결함 분류율은 85%에 도달하였고⁽⁴⁾ 본 논문에서는 결함 분류율을 더 향상시키기 위하여 새롭게 트리구조 신경망 분류기를 개발하였다.

단일구조 신경망 분류기는 46 개의 특징 값을 입력받는 입력층(input layer), 18 개의 노드를 가진 은닉층(hidden layer), 11 개의 결함으로 분류하는 출력층(output layer)으로 이루어져 있으며 그 형태는 Fig. 5 와 같다.⁽⁴⁾

제안된 트리구조 신경망은 2 단계의 구조로 되어 있으며 총 4 개의 신경망 구조를 가지고 있다. 1 단계에서는 11 개의 결함을 3 개의 타입별 Area, Line, Disk 로 1 차 분류를 한다. 2 단계에서는 1 차 타입별 분류결과에 대하여 3 가지의 신경망 분류기를 이용하여 최종 결함 분류를 수행한다. 모든 신경망 분류기는 각각의 입력층, 은닉층, 출력층을 가지고 독립적으로 학습되었고 신경망의 구조는 Fig. 6 과 같다.

각 신경망에서의 입력노드, 출력노드 및 히든노드의 개수는 Table 3 과 같다. 각각의 신경망의 히든노드의 수는 신경망의 성능에 아주 큰 영향을 미친다.⁽³⁻⁵⁾ 보통 입력 노드의 절반의 수로 설정을 하지만 본 논문에서는 보다 좋은 분류기의 성능을 높이기 위하여 실험을 통하여 가장 적합한 히든노드의 개수를 찾아내었으며 각 신경망 분류기에서 사용한 특징 값의 종류와 히든 노드의 개수는 Table 4, 5, 6, 7 에 나타나 있다.

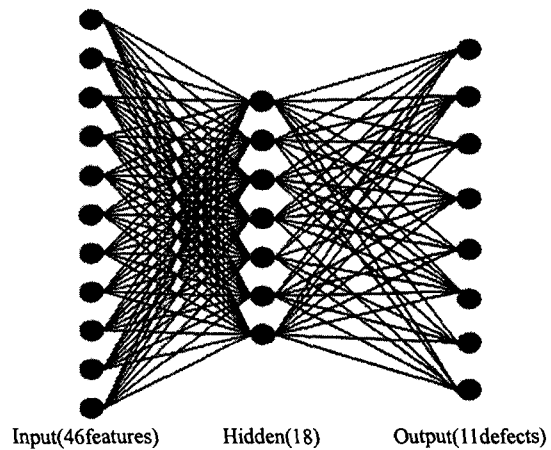


Fig. 5 Diagram of single-structured NN

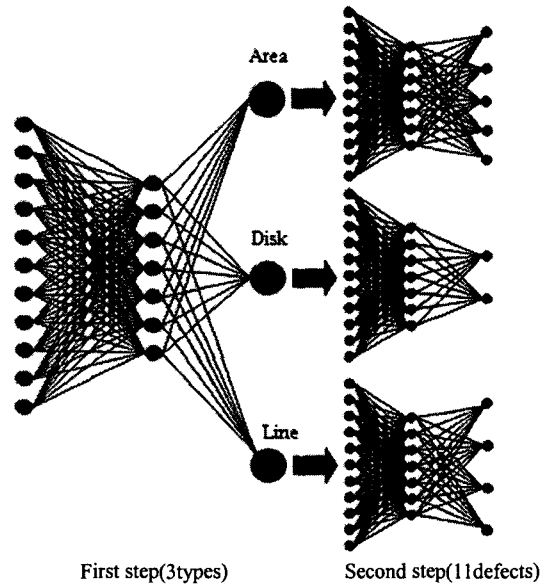


Fig. 6 Diagram of tree-structured NN

Table 3 Node numbers of 4 different NN classifiers

신경망	개수	입력노드	출력노드	히든노드
		(특징 값)	(결함분류)	
1 단계	Type 분류 NN	26	3	18
2 단계	Area 분류 NN	27	5	13
	Disk 분류 NN	9	2	7
	Line 분류 NN	25	4	10

Table 4 The list of features for tree-structured neural networks(1st stage)

Geometry Features		Gray Features
A	D_rat	maxgv
h_sbox	I_min	mingv
A_r	I_rat	gvr
CD	a1_A	var
O	a1_Ar	skew
D_yx	a2_A	curt
D_y	a2_Ar	mgvbg
D_xy	a3_A	mgvdif
D_min	a3_Ar	

Table 5 The list of features for classification of area type defects(2nd stage)

Geometry Features		Gray Features
A	a1_A	gvr
A_r	a1_Ar	var
I_rat	a2_A	skew
O	a2_Ar	curt
Sin_O	a3_A	PERC_DARK
D_yx	a3_Ar	V_DARK
D_xy	merge	H_DARK
D_min	e_max	RANGE_gv
D_rat	e_min	RANGE_gu

Table 6 The list of features for classification of line and area type defects(2nd stage)

Geometry Features		Gray Features
a1_A	I_max	gvr
a1_Ar	I_min	maxgv
a2_A	I_rat	mingv
a2_Ar	h_box	var
a3_A	D_y	skew
a3_Ar	A_r	DEV_GV
A	D_min	PERC_DARK
CD	D_rat	V_DARK
		H_DARK

Table 7 The list of features for classification of disk type defects(2nd stage)

Geometry Features	Gray Features	
A_r	skew	gvr
I_rat	curt	maxgv
e_min	var	mingv

Table 8 Sample data regulation for tree-structured neural network

Defect	Number	Regulated	Train	Test
Hole	148	417	201	216
Scab	584	400	200	200
Scale	12	396	200	196
D_Line	102	408	218	190
P_Patch	199	382	191	191
O_Drop	52	416	201	215
Dirty	253	410	193	217
P_Tree	285	403	218	185
B-Hole	57	396	186	210
L-Scale	11	407	192	215
P-Oil	1538	400	217	183
Total	3241	4435	2217	2218

5. 실험 및 결과

5.1 데이터의 재구성 및 정규화

임의의 결함 샘플 수가 다른 결함 샘플 수보다 많으면 신경망 학습 시 가중치의 값이 샘플수가 많은 결함에 큰 영향을 받는다. 이와 같은 경향을 줄이기 위하여 결함별 샘플 수의 차이가 많은 결함 샘플 데이터의 수를 조절하였다.^(2, 4) 조절 방법은 각 샘플의 수를 200 개 정도로 정하고 샘플의 수가 적은 결함에 대해서는 랜덤함수를 이용하여 노이즈를 추가하는 방법으로 결함 샘플 수를 생성하였으며, 샘플의 수가 많은 결함의 경우에는 랜덤하게 제외시켜서 전체 결함의 수를 Table 8 과 같이 조절하여서 포스코로부터 받은 3,241 개의 샘플 수를 총 4,435 개로 늘렸으며 이중 학습용으로는 2,217 개 그리고 테스트용으로는 2,218 개를 사용하였다.

Table 9 First step error rates of tree-structured

Type	Defect	No. of Fail	Sample	Error rate(%)
Area	Hole	7	216	3.2407
	Scab	10	200	5
	P-Patch	3	191	1.5706
	Dirty	47	217	22.9268
	P-Tree	9	185	4.4664
Total		76	1009	7.5322
Line	Scale	7	196	3.5352
	D-Line	8	190	3.9214
	B-Hole	17	210	8.5858
	L-Scale	29	215	14.2056
Total		61	811	7.5215
Disk	O-Drop	27	215	12.9806
	P-Oil	34	183	18.5792
Total		61	398	15.3266

또한 각 결함들의 특징 값들은 서로 다른 크기의 범위를 가지고 있는데 학습 시 신경망이 이들 중 큰 특징 값 쪽으로 편향되는 것을 방지하기 위하여 각 특징마다 식 (1) 표준편차(standard deviation)를 이용하여 데이터 정규화(normalizing) 작업을 식 (2)로 하였다.^(2,4)

$$s = \sqrt{\frac{1}{N} \sum_{i=1}^n (f_i - m)^2} \quad (1)$$

m: 특징 데이터들의 평균 값
f_i: 특징 데이터(*f₁~f_n*)
N: 전체 특징 데이터 개수

$$f_i' = (f_i - m) / s \quad (2)$$

f_i': 정규화된 특징 데이터(*f'₁~f'_n*)

5.2 트리구조 신경망의 1 단계 분류 결과

트리구조 1 단계는 특징 값 28 개에 대하여 2217 개의 샘플로 학습시킨 후 새로운 2218 개의 샘플로 테스트하였다. Area 타입 1009 개의 샘플에서는 79 개의 에러(7.5%)가, Line 타입 811 개의 샘플에서는 61 개의 에러(7.5%)가, 그리고 Disk 타입 398 개의 샘플에서는 61 개 에러(15.3%)가 발생하였으며 총 에러율은 8.93%이다. 모든 샘플 데이터에서 결함 종류는 미리 알고 있으며 각 결함 별 에러율 결과는 Table 9 와 같다.

Table 10 Second step error rates of tree-structured

Type	Defect	No. of Fail	Sample	Error rate(%)
Area	Hole	1	209	0.4785
	Scab	0	190	0
	P-Patch	2	188	1.0638
	Dirty	5	170	2.9412
	P-Tree	2	176	1.1364
Total		10	933	1.0718
Line	Scale	0	189	0
	D-Line	0	182	0
	B-Hole	5	193	2.5907
	L-Scale	1	184	0.5435
Total		6	748	0.8021
Disk	O-Drop	5	188	2.6596
	P-Oil	0	149	0
Total		5	337	1.4837

Table 11 The classification results of overall tree-structured neural network

Defect	No. of Fail	Sample	Error rate(%)
Hole	8	216	3.7037
Scab	10	200	5
Scale	7	196	3.5714
D-Line	8	190	4.2105
P-Patch	5	191	2.6178
O-Drop	32	215	14.8837
Dirty	52	217	23.9631
P-Tree	11	185	5.9459
B-Hole	22	210	10.4762
L-Scale	30	215	13.9535
P-Oil	34	183	18.5792
Total	219	2218	9.87376

5.3 트리구조 신경망의 2 차 트리분류 결과

트리구조 2 단계에서는 1 단계에서 3 가지 타입 분류에 실패한 샘플들은 제외되고 성공한 샘플만을 가지고 각 타입의 세부 분류작업을 실시한다. Area 타입 933 개의 샘플에서는 10 개의 에러(1.1%)가, Line 타입 784 개의 샘플에서는 6 개의 에러(0.8%)가, 그리고 Disk 타입 337 개의 샘플에서는 5 개의 에러(1.5%)가 발생하였다. 각 결함 별 에러율 결과는 Table 10 에 나타나 있다.

1 단계와 2 단계를 합친 트리구조 신경망 분류기의 결함별 분류 에러율은 Table 11 에 나타나 있으며 총 에러율은 9.9 % 이다. 이는 단일 구조 신

경망 분류기⁽⁴⁾의 15.2%보다 5.3% 향상된 분류결과를 보였다.

선정된 특징값들을 사용하여 신경망에 의해 결합 분류시 분류하고자하는 결합의 종류와 개수가 많을수록 오분류의 확률은 높아진다. 제안된 트리 구조를 적용하여 각 단계별로 분류하고자하는 결합의 종류와 개수를 단순화시켜 신경망을 설계하고 훈련시키면 단일신경망보다 더 좋은 결과를 얻을 수 있음을 실험을 통하여 증명하였다.

6. 결론

본 연구에서는 고속이송 냉연강판의 결합 종류를 분류하는 분류기로 트리구조 신경망 분류기를 제안하였다. 포스코의 광양 제철소에서 중요한 결합으로 판정하는 11 개의 결합 종류에 대하여 해석하였으며 포스코가 제공한 결합 샘플과 추출한 특징데이터를 이용하여 신경망 분류기를 학습하고 테스트하였다. 11 개의 결합 종류가 크게 3 가지 타입으로 나누어질 수 있다는 관찰에 근거하여 1 단계 신경망 분류기에서는 결합을 Area 타입, Line 타입, Disk 타입으로 나누고 2 단계에서는 각 타입에 맞는 개별 신경망 분류기를 만들어 세부적인 결합 분류를 실시하였다. 이를 위해 4 종류의 신경망 분류기가 개발되어 각각에 대해 최적의 특징값들을 추출하였으며 각 은닉층에 필요한 최적의 노드 개수를 실험을 통하여 선정하였다. 새롭게 제안된 트리구조 신경망 분류기의 결합 분류율은 90% 정도로 1 차로 개발된 단일구조 신경망 분류기의 분류율 85%, Parsytek 사의 C-5 분류기의 결합 분류율 85%보다 우수한 성능을 보였다.

후 기

이 논문은 한국산업기술재단(KOTEF)의 지역혁신

인력양성사업 연구비 지원에 의하여 연구되었습니다.

참고문헌

- (1) Song, S. J., Kim, H. J., Choi, S. H. and Lee, J. H., 1997, "Classification of Surface Defects on Cold Rolled Strips by Probabilistic Neural Networks," *The Korean Society for Nondestructive Testing*, Vol. 17, No. 3, pp. 162~173.
- (2) Kim, C. H., Chol, S. H., Joo, W. J. and Kim, G. B., 2006, "Classification of Surface Defect on Steel Strip by KNN Classifier," *Journal of the Korean Society for Precision Engineering*, Vol. 23, No. 8, pp. 80~88.
- (3) Treiber, F., 1989, "On-line Automatic Defect Detection and Surface Roughness Measurement of Steel Strip," *MA: Iron and Steel Engineer*, pp. 26~33.
- (4) Moon, C. I., Choi, S. H., Joo, W. J., Kim, G. B. and Kim, C. H., 2007, "Development of a Neural Network Classifier for the Classification of Surface Defects of Cold Rolled Strips," *Journal of the Korean Society for Precision Engineering*, Vol. 24, No. 4, pp. 76~83.
- (5) Rao, Valluru. and Rao, Hayagriva., 1995, "C++ Neural Networks and Fuzzy Logic Second Edition," *MA: MIS*.
- (6) Bishop, C. M., 1995, "Neural Networks for Pattern Recognition," *Oxford University Press*.
- (7) Haralick, R., Shaumugam, K. and Dinstein, I., 1973, "Textural Features for Image Classification," *IEEE Trans. Systems and Cybernetics*, Vol. 3, No. 6, pp. 53~58.
- (8) Mehrotra, Kishan., Mohan, Chilukuri. K. and Ranka, Sanjay., 1997, "Elements of Artificial Neural Networks," *MA: A Brand Book*, pp. 65~109
- (9) Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, "Learning Internal Representations by Error Propagation," *MIT Press Cambridge*, Vol. 1, pp. 318~362.
- (10) Freeman, J. A. and Skapura, D. M., 1992, "Neural Networks Algorithms, Applications, and Programming Techniques," *MA: Addison-Wesley Publishing Company*.