

## 논문

비파괴검사학회지  
*Journal of the Korean Society  
for Nondestructive Testing*  
Vol. 17, No. 3 (1997)

### 확률신경회로망에 의한 냉연 강판 표면결함의 분류

송성진,\* 김학준,\*\* 최세호,\*\*\* 이종학\*\*\*

\* 조선대학교 기계설계공학과

\*\* 조선대학교 대학원 기계설계공학과

\*\*\* 포항종합제철주식회사 기술연구소

**요약** 최근 산업 발전에 따라 철강 제품의 수요 증가와 함께 품질의 고급화에 대한 요구도 점차 증가하고 있는데, 이러한 수요자의 요구에 부응하기 위해 철강업체는 냉연 강판 표면결함검출기(surface defect detector; SDD)를 도입 운용하고 있다. 그러나 현재 국내 철강 제조업체들이 보유하고 있는 상용 SDD는 결함의 검출에는 매우 효율적이지만 결함의 분류에는 아직 만족할만한 성능을 보여주지 못하고 있다. 그 이유는 SDD가 결함 분류를 위해 채택한 분류표분류기(classification table; CT)는 시험 표본의 모든 특징값들이 분류표의 범위 내에 있을 때만 결함의 분류를 정확히 수행하기 때문에 결함 분류 정확도가 낮을 뿐 아니라, 분류 법칙의 설정을 작업자의 수작업에 의존하고 있어 현장 적용을 더욱 어렵게 하고 있다. 이러한 단점을 극복하기 위해 본 연구에서 학습 표본으로부터 확률밀도함수를 추정하고 여기에서 분류 법칙을 자동적으로 결정하는 방법을 제시하였고, 강화분류 표분류기(enhanced classification table; ECT)와 확률신경회로망분류기(probabilistic neural network; PNN)를 새롭게 제안하여 이를 분류기를 실제적인 문제에 적용하였다. 그 결과 ECT와 PNN 모두 결함 분류 성능을 획기적으로 높일 수 있는 좋은 방법이며, 특히 PNN은 아주 구별하기 어려운 결함도 구별해내는 능력이 있을 뿐 아니라, 병렬 처리 능력을 가지고 있기 때문에 다량의 데이터를 실시간으로 처리해야 하는 경우에 적용할 수 있는 매우 효율적인 분류기임을 확인하였다.

#### 1. 서론

최근 산업 발전에 따라 철강제품의 수요 증가와 함께 품질의 고급화에 대한 요구도 점차 증가하고 있는데, 특히 가전제품, 자동차 등 최종 소비재의 외장재로 사용되는 냉연 강판의 경우 사소한 표면결함이라 할지라도 수요자의 불만을 초래할 수 있기 때문에 고품질화의 요구가 매우 크다. 이러한 수요자의 요구에 부응하기 위해 철강업체는 냉연 강판의 경우 표면결함의 검출과 제거를 위한 여러가지 노력을 기울이고 있다.

냉연 강판의 표면결함검사는 보통 생산 라인의 맨 끝단에서 실시하고 있는데, 불행히도 이 곳에서는 폭 2m정도의 냉연 강판이 10~15m/sec의 대단히 빠른 속도로 이송되고 있기 때문에, 작업자가 육안검사를 통해 결함을 식별한다는 것은 거의 불가능하다. 따라서 이렇게 고속 이송중에 있는 냉연 강판의 표면결함을 가동중에 검사하기 위해 표면결함검출기(surface defect detector, 이하 SDD)가 개발되어 산업 현장에서 이미 널리 이용되고 있다<sup>1)</sup>. 현재 산업 현장에 보급되어 있는 상용 SDD는 결함을 검출하는 감지 기구에 따

라 카메라 방식과 레이저 방식의 두 종류가 있다. 이 두 종류의 SDD는 모두 감지 기구를 이용하여 결합 신호를 검출하고, 이 결합 신호의 특성을 파악하여 결합의 유무, 종류, 크기를 결정한다. 현재 국내 철강제조업체들이 보유하고 있는 대부분의 상용 SDD는 결합의 검출에는 매우 효율적이지만 결합의 분류에는 아직 만족할만한 성능을 보여주지 못하고 있다. 따라서 지금 까지 SDD를 보유하고 있는 산업체에서는 SDD의 검사 결과 중 표면결합 검출 결과만을 이용하고 있다. 즉, 표면결합이 검출된 냉연 강판은 폐기하거나 고급의 표면 품질이 요구되지 않는 곳에만 사용도록 하는 등의 조치를 취하고 있다. 그러나 이러한 조치는 철강 수요 가에는 만족스러울 수 있겠으나, 결합의 발생 요인을 분석하여 이를 개선해야하는 철강 제조업체의 입장에서는 만족스럽지 못하기 때문에, SDD의 결합 검출 성능 뿐 아니라 결합 분류 성능을 향상시키기 위한 부단한 노력이 경주되고 있다.<sup>2,3)</sup>

이러한 노력의 일환으로, 김경진과 신용태는<sup>2)</sup> 현재 국내 철강 제조업체들이 보유하고 있는 SDD의 결합 분류 알고리즘을 분석하고 그 전 과정을 모의(simulation)한 연구를 수행한 바 있다. 이 연구에서 그들은 SDD가 결합 분류를 위해 법칙근거분류표(rule-based classification table)를 사용하였으며, 이 분류표 방식의 분류기를 사용하기 위해서는 시험 표본으로부터 경험적으로 결정하는 법칙의 설정이 무엇보다도 중요하며 사실상 이 과정이 분류 성능을 좌우하고 핵심이 됨을 밝혔다. 그리고 그들은 실제 냉연 공정에서 수집한 결합 신호를 분석하여 분류 법칙을 설정하고 이를 이용하여 결합 분류를 수행한 결과 결합 분류 성능이 매우 낮은 수준임을 확인한 바 있다. 이 연구 결과를 바탕으로 최세호 등은<sup>3)</sup> SDD의 결합 분류 성능 개선을 위한 연구를 수행한 바 있는데, 그들은 결합 신호 수집 및 분석을 위한 전용 분석 시스템을 개발하여 실험실 내에 설치한 후 체계적인 결합 신호의 특성 분석 연구를 수행한 바 있다.

이들 연구의 결과를 살펴보면 실제 산업 현장에 SDD를 적용할 때 그 결합 분류 성능을 담보하는 핵심 과제를 다음과 같은 두 가지로 요약할 수 있다. 첫째는 결합 신호로부터 추출한 특징값(features)을 이용하여 결합 분류에 가장 효율적인 분류 법칙을 설정하는 문제이다. 이때 가장 중요한 것은 시험 표본으로부터 결합 종류별 특징값의 분포 특성을 파악하고 이를 가장 적절히 표현하는 분포 범위의 상하한값(이를 "descriptor entries"라 함)를 결정하는 것인데, 실제

산업 현장에서 이 과정이 작업자의 수작업에 전적으로 의존하기 때문에 최적 범위 설정에 어려움이 많다. 둘째는 결합 분류를 위해 사용하는 분류 알고리즘의 문제이다. 현재 SDD는 결합 분류를 위해 법칙 근거 분류표를 사용하고 있는데, 이 방법은 분류 대상 결함으로부터 추출한 모든 특징값("가")을 분류표 상에 미리 설정해 놓은 특정 결합(예를 들어 scratch)에 대한 특징값들의 분포 범위("나")와 비교한 후, "가"의 모든 특징값들이 "나"의 특징값들의 범주내에 속하면 이 분류 대상 결함을 "나"에 해당하는 결합으로 분류하는 "형상 일치(pattern matching)" 기법의 하나이다. 이 분류 기법은 특징값의 분포가 선형 분리(linearly separable)의 특성을 가지는 문제만에 효율적으로 적용할 수 있을 뿐 아니라 첫 번째 문제에서 언급한 분류표 상의 분포 범위에 대단히 민감하다는 단점을 지니고 있다. 따라서 SDD의 결합 분류 성능의 향상을 위해서는 이 두 가지 문제에 대한 적절한 해결책이 제시되어야 한다.

SDD에 의한 냉연 강판 표면결합의 분류는 결합 감지 기구에 의해 결합 신호를 검출하여 그 결합 신호의 특징을 추출하고 이를 기반으로 결합의 종류를 판단하는 것으로서 형상 인식 문제의 범주에 속한다. 형상 인식 기법을 구현하는 여러 가지 실용적인 대안중에서 가장 널리 사용되고 있는 방법이 신경회로망 기법이다.<sup>4)</sup> 신경회로망은 인간 뇌의 구조와 작동원리를 모형화 할 수 있다는 점과 함께, 학습 표본을 통해 필요한 지식을 배울 수 있으며, 또한 학습 표본에서 경험하지 못하였을지라도 배운 지식을 일반화하여 필요한 결론을 자동적으로 내려준다는 독특한 장점때문에 1980년 후반부터 그 활용이 급속히 증가하고 있다. 20여 가지의 신경회로망 구조중 패턴 분류, 자동체어, 회귀분석 등에 가장 널리 사용되는 것은 역전파신경회로망(back-propagation neural network: BPNN)<sup>5)</sup>이다. 그러나 BPNN은 입력과 출력사이의 관계가 사용자에 대하여 불투명하고, 학습 시간이 어떤 경우에는 너무 길다는 등의 단점을 가지고 있다. Specht은 이러한 BPNN의 단점을 극복하면서도 동시에 신경회로망이 보편적으로 지니고 있는 장점을 두루 갖춘 확률신경회로망(probabilistic neural network: PNN)<sup>6~8)</sup>이라는 새로운 신경회로망을 제안한 바 있다. PNN은 병렬처리 능력 등 신경회로망이 가지고 있는 장점을 지니고 있을 뿐 아니라 시험 표본으로부터 특징값의 분포 특성을 확률밀도함수(probability density function: PDF)의 형태로 추론하는 등의 독특한 장점을 지니고 있기 때-

문에 특히 형상 인식 문제에 널리 이용되고 있어,<sup>4,10)</sup> SDD의 분류 성능 향상을 위한 효율적인 대안으로 기대되고 있다.

본 연구는 전술한 바와 같은 SDD 적용상의 문제점을 극복하고 결합 분류 성능을 획기적으로 제고시킬 수 있는 강력하고 실용적인 결합 분류기의 개발을 위해 수행하였다. 특히 SDD의 현장 적용상의 애로 요인으로 지적되고 있는 결합 신호 특징값의 분포 특성 분석과 이를 사용한 결합 분류의 문제를 해결하는데 있어 PNN의 적용성에 대해 논의하였으며, 아울러 SDD의 결합 분류 알고리즘을 보완할 수 있는 새로운 분류 기법으로서 제안한 바 있는 강화분류표(enhanced classification table: ECT) 분류기<sup>11)</sup>에 대해서도 논의하였다.

## 2. 냉연 강판 표면결함검출기

현재 국내 철강 제조업체들이 설치 운용중인 SDD의 구성과 결합 검출 및 분류에 대해서는 참고문헌 [2]와 [3]에 상세히 언급되어 있으나, 여기에서는 논의의 연속성을 위해 SDD의 구성, 표면결함 검출 및 분류 원리에 대해 간략히 고찰한다. 그리고 SDD가 결합 분류를 위해 사용하는 분류표분류기와 이 분류표분류기의 단점을 보완하기 위하여 본 연구에서 제안한 강화 분류표에 대하여 논의한다.

### 2.1. SDD의 구성과 결합 검출

현재 국내 철강 제조업체가 보유하고 있는 SDD 시스템은 Photo 1에 나타낸 바와 같이 결합 감지 기구로서 레이저(laser)광을 이용하는 시스템이다. 이 시스템



Photo 1. Surface defect detector with laser scanning system

은 Fig. 1에 나타낸 것처럼 레이저를 냉연 강판 표면에 주사하여 결합 신호를 생성하고 이를 수신하는 레이저 스캐너 시스템(laser scanner system, 이하 광학계)과 수신된 결합 신호를 처리하여 결합에 대한 정보를 결정하는 신호처리부(이하 신호처리계), SDD 시스템에서 필요한 각종 파라미터를 입력하는 작업터미널부, 그리고 결합에 대한 최종적인 정보를 검사자에 제공하는 출력장치부로 구성되어 있다.

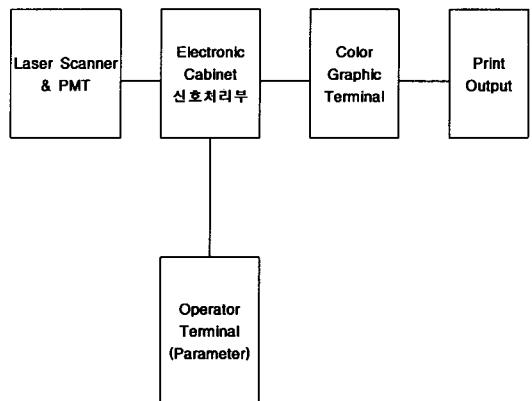


Fig. 1. Schematic diagram of surface defect detector system

Fig. 2에 개략적으로 나타낸 SDD의 광학계는 레이저를 이용하여 냉연 강판의 표면결함을 검사한다. SDD는 He-Ne 레이저를 냉연 강판이 이송되는 방향과 직각인 방향(즉 냉연 강판의 폭 방향)으로 강판 표면에 주사한다. 레이저 스캐너 중심부에 위치한 다면경 휠이 회전함에 따라 다면경에서 반사된 레이저 빔이 강판 표면에 매초 3000회씩 주사된다. 이때 다면경에서 반사한 빔을 강판 표면에 직접 주사시킨다면 강판 중앙에서는 레이저광의 세기가 높고, 강판의 가장자리로 갈수록 레이저광의 세기가 약해진다. 이러한 문제를 없애기 위해 포물면경을 이용한다. 포물면경은 레이저빔이 레이저 선원으로부터 강판까지 도달하는 경로의 거리를 강판 상의 위치에 관계없이 일정하게 유지되도록 함으로써 강판 표면에 입사된 레이저광의 세기를 일정하게 조절한다. 강판 표면에 도달한 레이저빔은 냉연 강판 표면에서 반사되어 집광봉에 도달한다. 집광봉 내에서 내부 반사를 통해 집광봉의 끝단으로 유도된 레이저빔은 광증배관에서 전기적 신호로 변환된다. 만약 결함이 냉연강판 표면에 존재한다면 레이저광의 반사 특성이 변화하고, 이에따라 전기적 신호인 광증배관의 출력 신호가 변화하게 된다. SDD 시스템은 레이저빔 반사 패

터의 변화를 면밀히 관찰하기 위해 반사광의 정반사 위치에 부착된 집광봉 이외에도 정반사 위치로부터 약 18° 떨어진 위치에 또 하나의 집광봉을 부착하여, 정반사한 반사광(이를 bright field라 함)과 함께 결함으로부터 산란된 산란광(이를 dark field라 함)도 수집하여 결합 검출과 분류에 활용하고 있다.

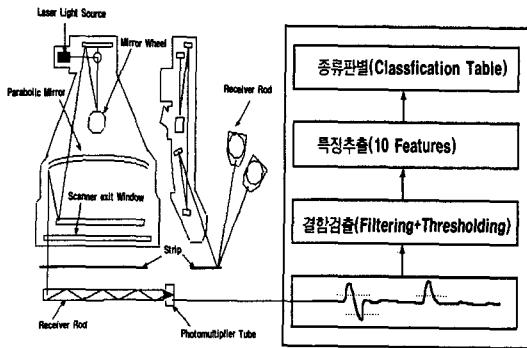


Fig. 2. Laser scanner and receiver system

SDD의 신호처리부는 광증배관의 출력 신호를 입력 받아 결합의 검출과 분류 작업을 수행한다. 신호처리부는 수 개의 신호처리 전용 보드로 구성되어 있는데, bright field와 dark field의 신호로부터 결합 검출과 분류에 필요한 특징(feature)를 추출하기 위해 필터링(low pass filtering, high pass filtering, recursive filtering)을 하고, 필터링된 신호에 미리 설정된 문턱값(threshold) 수준에 따라 thresholding을 실시한다. 냉연 강판의 표면에 결함이 존재하면 반사되는 반사광(혹은 산란광)의 세기는 결함이 없은 경우에 비해 증가할 수도 있으며, 감소할 수도 있다. 증가하는 경우의 반사광(혹은 산란광)의 세기를 양의 진폭(positive amplitude)으로 표시하고, 감소하는 경우의 세기를 음의 진폭(negative amplitude)으로 표시한다. 이렇듯 SDD에는 수광부의 수가 2개(bright field와 dark field)이며, 필터링의 종류가 3가지(low pass filtering, high pass filtering, recursive filtering), 그리고 반사광의 진폭이 2가지(positive amplitude, negative amplitude)가 있기 때문에, SDD 신호처리부에는 수광부-filter-진폭의 조합에 따라 총 12가지의 신호가 도달된다. 신호처리부는 입력된 12가지의 결합 신호에 대한 thresholding을 수행하는데, 이때 필요한 적절한 문턱값은 작업자가 미리 설정하여 입력해야 한다. SDD는 결합의 검출을 이 thresholding 작업을 통해 수행한다. 즉 결함에 의해 변화된 반사광(혹은 산란광)의 세기가 설정한 문턱

값을 넘으면 SDD는 결함이 존재하는 것으로 인식한다. 따라서 SDD의 결합 검출 성패는 이 문턱값의 설정에 의해 좌우 되는데, 불행히도 현재까지 이 문턱값 설정에 대한 명확한 지침(CODE)이 마련되어 있지 않기 때문에 작업자가 자신의 경험에 의존하여 임의로 설정해야 하는 어려움이 있다.

## 2.2. SDD의 결합 분류 - 분류표분류기

신호처리부는 입력된 결합 신호에 대해 thresholding 작업을 수행하고, 각 신호별 문턱값 초과 여부를 테이터화하여 신호처리부의 CPU 보드로 넘겨준다. CPU 보드는 문턱값을 넘은 결합 신호로부터 결합 분류를 위해 Table. 1에 나타낸 바와 같이 amplitude, amplitude ratio, defect area, length/width ratio, direction, bit mask 등의 특징을 추출하는데, 이 특징들은 다음과 같이 정의된다.

- (1) amplitude: 문턱값을 초과하는 진폭을 갖는 결합 신호의 진폭값에서 문턱값을 뺀 값이다. 앞에서 언급한 바와 같이 결합 신호는 수광부-필터-진폭의 조합에 따라 모두 12가지의 결합 신호가 있으나, SDD는 recursive filter(혹은 low pass filter)를 통과한 신호의 positive amplitude와 negative amplitude만을 추출한다.
- (2) amplitude ratio: bright field(Channel 1)와 dark field(Channel 2)간의 결합 신호의 진폭비를 말한다.
- (3) defect area: 결합의 면적을 말하며 CPU에서 문턱값을 넘은 결합 신호로부터 산출한다.
- (4) length/width ratio: 결합의 폭과 길이의 비를 말하며 CPU에서 산정한다.
- (5) direction: 결합의 방향을 말하는데, 냉연 강판의 진행 방향을 기준으로 결합의 기울어진 각도로 정의한다.
- (6) bit Mask: 문턱값을 넘는 결합 신호가 수광부-필터-진폭 조합의 어느 조합에서 발생했는지를 나타내는 값으로서, 문턱값을 넘으면 1, 넘지 않으면 0으로 정의한다.

이상에서 언급한 특징 추출이 끝나면, SDD의 CPU는 결합 분류 작업을 수행한다. 이때 SDD는 검출된 결합에 대한 종류 판별을 위해 분류표(classification table: CT)를 사용한다. 분류표란 모든 종류의 결함에 대해 Table. 1에 나타낸 특징값의 분포 범위를 각 결

함 종류별로 미리 설정해놓은 표를 말한다.

Table 1. Features extracted from PMT output signals for classification

① +A1 : Channel 1의 Maximum Positive Amplitude
② -A1 : Channel 1의 Maximum Negative Amplitude
③ +A2 : Channel 2의 Maximum Positive Amplitude
④ -A2 : Channel 2의 Maximum Negative Amplitude
⑤ +A-Ra : +A1/+A2
⑥ -A-Ra : -A1/-A2
⑦ Surf : 결합면적
⑧ Ratio : 결합의 길이 대폭비
⑨ Dir : 결합의 방향
⑩ Bit Mask : H/W 파라미터에 의해 결함이 검출된 Signal Path Bit

SDD는 어떤 결함(X)이 검출되면, 그 결함의 신호로부터 추출한 모든 특징값들( $X_i, i=1,n$ )이 분류표상의 어떤 종류의 분포 범위(descriptor entries:  $\alpha_i, \beta_i, i=1, \dots, n$ )내에 속하는지를 판단하고 이를 IF~THEN 법칙으로 연결하여, 모든 특징값들이 포함되는 분포 범위를 갖는 결함 종류(Class A)로 검출 결함(X)을 분류한다. 예를 들어 Class A에 대해 특징  $F_i$ 의 descriptor entries값이  $\alpha_i, \beta_i$ 라 주어져 있을 때 검출 결함 X에 대해 다음과 같은 법칙을 이용하여 결함 분류를 실시한다.

IF( $(\alpha_1 \leq X_1 \leq \beta_1)$  AND  $(\alpha_2 \leq X_2 \leq \beta_2)$  AND

⋮

AND  $(\alpha_n \leq X_n \leq \beta_n)$ ) THEN

Classify X to Class A

이 방법을 적용하기 위해서는 결함 종류별로 descriptor entries  $\alpha_i$  와  $\beta_i$  값을 미리 설정해야 한다. 이러한 값을 적절히 설정하기 위해서는 모든 결함 종류별 특징값의 분포에 대한 통계적 분석이 필요한데, 현재 산업 현장에서는 이 과정이 작업자의 수작업에 의해 이루어지고 있어 매우 많은 인력과 시간이 소요되고 있다. 뿐만 아니라 descriptor entries를 힘들여 설정한 후에도 실제적인 결함 분류 작업시 그 정확도

가 매우 낮은 실정이다. 따라서 현재 산업 현장에서 운용중인 SDD의 효율적인 사용을 위해서는 descriptor entries 설정 작업을 자동으로 수행할 수 있는 기법을 개발하는 것이 시급한 실정이다.

### 2.3. 강화분류표분류기

현재 SDD가 사용하고 있는 분류표 분류기는 검출한 결함(X)으로부터 추출한 특징  $X_i$ 에 대해 IF~THEN 법칙의 논리곱(AND 결합)으로 되어 있어, 결합 특징의 분포가 분산되어 있는 경우에는 그 성능이 급격히 저하될 우려가 있다. 이러한 단점을 보안하기 위해 본 연구에서 새로운 “강화분류표분류기(enhanced classification table: ECT)”를 새롭게 제안하였다. 이 분류기는 시험 표본(X)로부터 n개의 특징값  $X_i(i = 1, n)$ 을 추출하고 이 특징값들이 모든 결함 종류(m개)의 분포 범위 내에 속하는지를 확인한다. 그리고 분포 범위 내에 속한 특징의 수를 계수하여 m개의 결함 종류에 대한 m개의  $W_j(j = 1, m)$  값을 결정하고, 최대의  $W_j$ 를 갖는 결함 종류로 검출 결함을 분류하는 기법이다. 강화분류표의 분류 알고리즘은 다음과 같다.

For  $J = 1$  To  $m$

$$W_j = 0$$

IF( $\alpha_1 \leq X_1 \leq \beta_1$ ) THEN  $W_j = W_j + 1$

IF( $\alpha_2 \leq X_2 \leq \beta_2$ ) THEN  $W_j = W_j + 1$

⋮

IF( $\alpha_n \leq X_n \leq \beta_n$ ) THEN  $W_j = W_j + 1$

Next

If  $W_k$  is the Maximum of  $W_j$  ( $j = 1, m$ ) Then  
Classify X to Class K

이 강화분류표분류기도 역시 결함 종류별 descriptor entries  $\alpha_i, \beta_i$ 가 필요한데, 이 값들은 분류표분류기에서와 동일한 방법으로 결정한다.

### 3. 화률신경회로망

이 절에서는 본 연구에서 냉연 강판 표면결함 분류를 위해 이용한 PNN의 구조, 학습 과정, 결함 분류 등의 중요한 특성에 대해 간단히 언급코자 한다.

### 3.1. 구조

Fig. 3에 PNN의 기본적인 구조를 나타내었다.

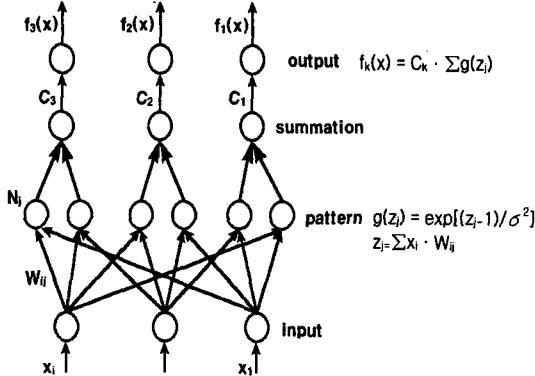


Fig. 3. Probabilistic neural network architecture

PNN은 4개의 층(layer)으로 구성되어 있다. 첫째 층은 입력층으로서 여기를 통해 각 표본의 특징 벡터( $X_i$ )가 PNN에 공급된다. 두번째 층은 패턴층으로서 입력층에 공급된 표본의 특징값  $X_i$ 에 가중치  $W_{ij}$ 를 곱한 결과들의 합을 받아들여, 그 값에 지수함수를 적용한 값을 출력시킨다. 세번째 층은 합산층으로서, 합산층의 각 노드(node)들은 패턴층의 노드들 중 자신과 같은 범주에 속한 노드들에만 연결되어있는데, 연결된 패턴층의 노드들의 출력의 합을 입력으로 받아들인 후 여기에 사용자가 정의한 파라메터인  $C_i$ 를 곱하여 그 결과를 출력시킨다. 마지막으로 네번째 층은 출력층으로서 최종적인 출력이 결합 분류 과정에 사용된다. 다른 종류의 신경회로망과는 달리, PNN의 구조는 주어진 문제 가 가지고 있는 결합 종류의 수와 학습 과정에서 사용된 학습 표본의 수에 의해 결정된다. 즉 출력층과 합산층의 노드의 수는 결합 종류(즉 범주)의 수와 같고, 패턴층의 노드수는 학습 표본의 수와 일치하며, 입력층의 노드수는 특징 벡터의 특징수와 동일하다. 그리고, PNN에는 세가지 종류의 가중치가 존재한다. Fig. 3의  $W_{ij}$ 는 학습 표본의 특징벡터들의 특징값을 그대로 사용하기 때문에 학습 표본으로부터 직접 결정된다. 실제로 PNN내에서 조절 가능한 파라메터는 사용자가 정의하는 파라메터인  $C_i$ 와 전달함수내의 평활화계수  $\sigma$ 가 있는데 이들에 대해서는 다음에 간략히 설명코자 한다.

### 3.2. PNN의 학습

PNN의 학습 과정은 매우 간단한 다음의 3과정으로

이루어져 있다. (1) 학습 표본이 주어지면 패턴층에 이에 해당하는 j번째 노드  $N_j$ 를 설정한다. (2) 만약에  $X_j (i=1,2,3 \dots, M, j=1,2, \dots, N)$ 를 주어진 j번째 학습 표본의 i번째 특징이라고 하면, 패턴층의 j번째 node와 입력층의 i번째 노드를 잇는 연결선의 가중치  $W_{ij}$ 를  $X_{ij}$ 와 같게 한다. (3) 그리고 마지막으로 패턴층의 j번째 노드를 주어진 학습 표본이 속해있는 범주에 상당하는 합산층과 연결한다.

학습 과정에서 특징적인 것은 가중치  $W_{ij}$ 가 반복 과정이 없이 “순간적”으로 결정된다는 것이며, 따라서 학습도 “순간적”으로 완료된다는 점이다. 또한 이 학습 과정에서 PNN은 학습 표본으로부터 Parzen window 방법<sup>[2]</sup>으로 각 범주별 조건부 확률 밀도함수  $p(\xi | w_j)$ 를 계산한다는 점이다.

Parzen window 기법은 주어진 개개의 학습 표본에 대해 특정한 성질을 갖는 window(주로 Gaussian 분포 함수를 사용)를 이용하여 연속적인 분포를 갖는 확률밀도함수를 만들고, 각각의 학습 표본으로부터 구한 개별밀도함수를 합하여 최종적인 확률밀도함수를 추론하는 방법이다. 즉 j번째 범주  $w_j$ 에 속하는 n개의 학습표본에 대한 n개의 특징벡터  $\xi_i (i=1, \dots, n)$ 가 있다고 할 때 d-차원 공간상의 임의의 점  $\xi$ 에서 Parzen window기법에 의해 추정할 수 있는 조건부확률밀도함수  $p(\xi | w_j)$ 는 다음과 같이 주어진다.

$$p(\xi | w_j) = \frac{1}{n} \sum_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma} \exp \left[ -\frac{1}{2} \frac{(\xi - \xi_i)^t (\xi - \xi_i)}{\sigma^2} \right] \quad (1)$$

여기서  $\sigma$ 는 각 학습 표본으로부터  $p(\xi | w_j)$ 를 추정할 때 각 학습 표본의 개별적인 중요도를 조절하는 평활화계수이다.

### 3.3. 회로망 파라메터의 선택

일단 회로망의 훈련이 끝나면 사용자 정의 파라메터인  $C_i (i=1,2,3)$ 와 평활화 계수  $\sigma$ 를 선택해야한다.  $C_i$ 는

$$C_i = \frac{h_i l_i}{n_i} \quad (2)$$

로 정의된다. 여기에서  $h_i$ 는 i번째 범주의 사전 확률,  $l_i$ 는 손실계수,  $n_i$ 는 i번째 범주내의 학습 표본의 수이다. 따라서 사용자가 균열과 같은 어떤 특정 범주에 더 큰 비중을 두고 싶을 때에는 손실계수  $l_i$ 에 큰 값을 지정할 수 있다.

평활화계수  $\sigma$ 는 패턴층내에 있는 각 패턴들의 개

별적인 중요도를 조절하는 계수로서  $\sigma$  값을 작게하면 개개의 패턴에 대한 중요성을 강조하게 되고,  $\sigma$  값을 크게 하면 많은 패턴들의 평균적인 거동을 강조하게 된다. 실제로 평활화계수  $\sigma$ 는 개개의 학습 표본으로부터 범주별 확률밀도함수를 추론할 때 사용되는 계수로서, 어떤 이론적 근거로부터 결정된다기 보다는 다분히 실용적 관점에서 비교적 “양호한” 결합 분류 성능을 얻을 수 있는  $\sigma$  값을 찾아 사용하고 있다.

### 3.4. 결합 분류

PNN의 학습과 회로망 파라메터에 대한 선택이 끝나면, 이 PNN을 이용하여 시험 표본에 대한 결합 분류를 수행할 수 있다. PNN의 결합 분석 알고리즘은 “주어진 시험 표본에 대한 출력층의 노드중 최대값(이 값은 곧 최대 예상 손실을 의미함)을 갖는 범주를 그 시험 표본의 범주로 결정한다”라고 할 수 있다. 이것은 곧 PNN이 Bayes법칙에 따라 결합 분류를 수행함을 말한다.

Bayesian 분류기는 패턴 분류시 통계적 접근 방법인 Bayes 결정 이론에 기초를 두고 있다. 이 방법은 모든 의사 결정 문제가 확률적인 개념들을 사용할 때 적절하게 풀릴 수 있다고 가정하며, 또한 의사 결정에 필요한 확률적 내용들이 알려져 있거나 혹은 학습 표본으로부터 추정이 가능할 때 주로 적용되고 있다. 실제 패턴 분류 과정에서 분류자가 궁극적으로 관심을 갖게 되는 것은 오분류때문에 입게되는 손해 즉, 기대 손실이다. 따라서 이러한 점을 중시한 Bayes 결정법칙의 분류 알고리즘은 다음과 같이 말할 수 있다. 즉 “특정벡터  $\xi$ 를 갖는 실험 표본에 대해  $R(\alpha_i | \xi)$ 를 최소로하는 범주  $w_i$ 로  $\xi$ 를 분류하라.” 여기에서  $R(\alpha_i | \xi)$ 는 조건부 위험이라고 부르는데, 이는 다음과 같이 계산된다.

$$R(\alpha_i | \xi) = \sum_{j=1}^m \lambda(\alpha_i | W_j) P(W_j | \xi) \quad \dots \dots \dots (3)$$

여기에서  $\alpha_i (i=1, 2, \dots, a)$ 는 a개의 행동(action)을 나타내며,  $\lambda(\alpha_i | W_j)$ 는 범주  $W_j$ 인 시험 표본에 대해  $\alpha_i$ 의 행동을 취했을 때 입게 되는 손실이며,  $P(W_j | \xi)$ 는 j번째 범주의 사후 확률이다. Bayesian 분류 알고리즘은 여러가지 패턴 분류 문제를 다루는데 있어, 실제적 상황을 가장 잘 반영하는 분류기이다.

그러나, 이 Bayes 분류기를 적용하는데 있어서 가장 큰 문제점은 사후 확률  $P(W_j | \xi)$ 를 알아야 한다는 것이다. j번째 범주에 대한 사후 확률  $P(W_j | \xi)$ 는 식 (4)으로 정의된다.

$$P(W_j | \xi) = \frac{p(\xi | W_j)P(W_j)}{p(\xi)} \quad \dots \dots \dots (4)$$

여기에서  $P(W_j)$ 는 j번째 범주의 사전 확률이며,  $p(\xi | W_j)$ 는 j번째 범주의 조건부 확률밀도함수이고,  $p(\xi)$ 는 식(5)로 정의되는 혼합밀도함수이다.

$$p(\xi) = \sum_{j=1}^m p(\xi | W_j)P(W_j) \quad \dots \dots \dots (5)$$

전술한 바와 같이 PNN은 학습 표본으로부터 확률밀도함수  $p(\xi | W_j)$ 를 Parzen window 방법으로 추정할 수 있는 능력을 갖추고 있기 때문에, 주어진 분류 대상 결합에 대해 Bayes 분류 법칙을 적용하는데 필요한 사후확률  $P(w_j | \xi)$ 를 자동적으로 계산할 수 있다.

## 4. 냉연강판 표면결함의 분류

냉연 생산 공정에서 냉연강판 표면위에 발생하는 실제적인 결함들 중 Fig. 4에 나타낸 (scab(딱지흠), hole(구멍), blow hole(부푼흠), scratch(긁인흠) 와 line scab) 5종류 결함에 대해 앞에서 언급한 3 가지 분류기(CT, ECT, PNN)을 적용하여 결합 분류하고 각 분류기별 성능을 비교하였다.

### 4.1. 표면결함 Data 수집

분류기의 성능 평가를 위해서는 충분한 양의 냉연 결합 신호를 수집하는 것이 무엇보다도 중요하다. 현재 SDD를 사용하고 있는 철강 제조업체에서는 결합 신호의 수집을 위해 많은 인력과 시간을 투자하고 있으나, 냉연 강판의 이송 속도가 빠르고 냉연 코일의 길이가 매우 길기 때문에 결합 신호 수집과 분석에 어려움을 겪고 있다. 이러한 문제를 해결하기 위해 포항종합제철주식회사는 Fig. 5와 같이 냉연 결합 신호 수집 및 분석을 위한 실험 시스템을 구축하였다.

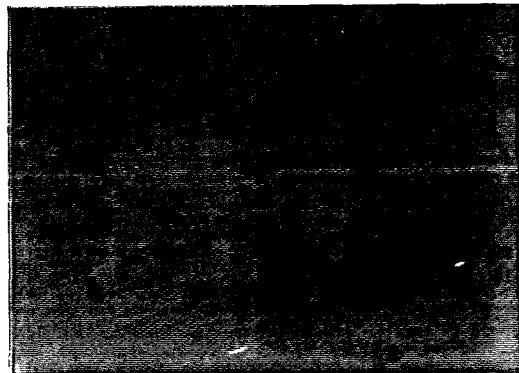
이 시스템은 냉연 강판의 이송 운동을 모의(simulation)하기 위해 최고 99m/min로 움직일 수 있는 시험대를 제작하고, 생산 공정에서 발생한 실제적인 표면 결함을 가지고 있는 결합 시편을 이 시험대 위에 장착시킬 수 있도록 하였다. 그리고 결합 시편을 전후로 이송시키면서 시험대 상부에 위치한 레이저 주사장치로부터 레이저빔을 시편 위에 주사시켜 그 반사광을 수집하였다. 광증배관을 통해 전기적 신호로 변환된 결합 신호로부터 신호처리부는 Table. 1에 나타낸



(a) Scab (딱지흠)



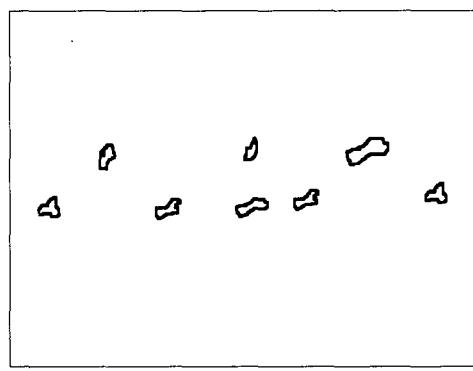
(b) Hole (구멍)



(c) Scratch (긁힌흠)



(d) Blow hole(부푼흠)



(e) Line scab

Fig. 4 Surface defects on cold rolled strips

특징들을 추출하고, 이를 PC에 전송도록 하였다.

본 연구에서는 특징 분석을 위해 냉연 강판 생산 라인에서 채취한 시편 상에 존재하는 5가지 종류의 냉연 표면결함으로부터 모두 230개의 결합 신호를 수집하였다. 이를 결합 종류로 살펴보면 scab(type a)에서 30개, hole(type b)에서 50개, line scab(type c)에서 30개,

blow hole(type d)에서 90개, scratch(type e)에서 30개 쪽이다. 실험실 내에서 채취한 230개의 결합 신호에 대해 Table. 1에 나타낸 특징들을 모두 추출하고, 결합 신호 분류를 위해 personal computer로 전송하였다. 그러나 전송된 특징값중 어떤 특징들은 신뢰성이 극히 의심스러운 데이터가 가끔 발견되어, 본 연구에서는

데이터의 신뢰성을 확신할 수 있는 5개의 특징(+A1, -A1, +A2, -A2, Area)만을 결합 분류에 사용하였다. 이렇게 PC로 전송된 230개의 결합 신호중 115개는 분류기의 학습용으로 나머지 115개는 성능 평가용으로 사용하였다.

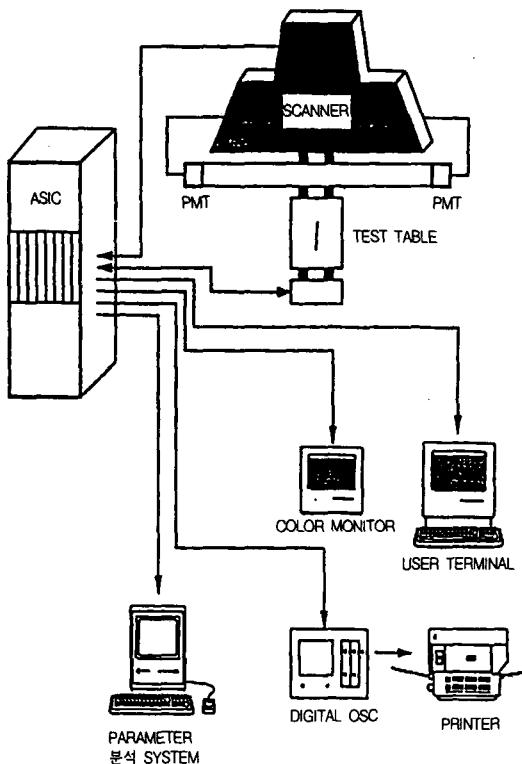


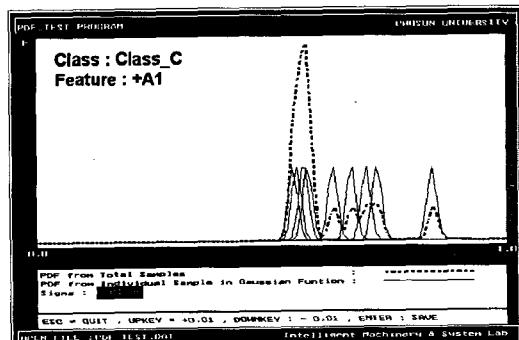
Fig. 5. Schematic diagram of data acquisition and analysis system

#### 4.2. 분류표분류기와 강화분류표분류기의 설정

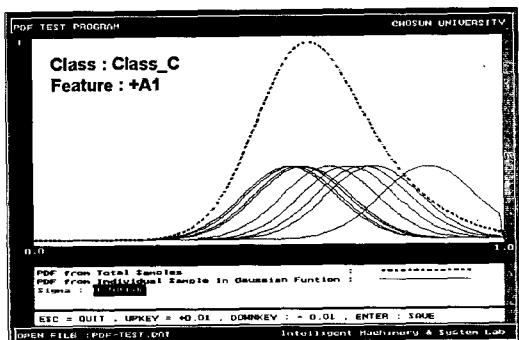
분류표분류기와 강화분류표분류기를 이용하여 결합 분류를 수행하기 위해서는 분류 법칙을 설정해야 한다. 분류 법칙의 설정이란 곧 2.2절과 2.3절에 나타낸 분류 알고리즘 상의 결합 종류별 특징값의 분포 범위를 나타내는 descriptor entries  $\alpha_i$ ,  $\beta_i$ 를 결정해야 함을 말한다. descriptor entries를 설정하기 위해서는 결합 종류별 특징값의 분포 특성을 파악해야 하며 이는 곧 결합 종류별 특징값의 분포 특성을 기술하는 통계 값인 결합 종류별 조건부 확률밀도함수(probability density function : 이하 PDF)를 추정해야 함을 의미한다. 이를 위해 현재 산업 현장에서는 분포도(histogram)를 이용하고 있으나 이 방법으로 PDF를 원만히 추정하

기 위해서는 매우 많은 양의 학습 표본이 필요하다.

제한된 양의 학습 표본을 가지고 PDF를 효율적으로 추정하는 방법중의 하나가 바로 3.2절에서 언급한 Parzen window 기법이다. 이 방법은 주어진 개개의 학습 표본에 Gaussian window를 적용시켜 연속적인 분포를 갖는 함수를 만들고, 모든 학습 표본에 대한 분포 함수를 모두 합하여 최종적인 PDF를 추정하는 방법으로서, 구하고자 하는 조건부 확률밀도함수는 식(1)에 의해 구해진다. 식(1)를 적용하는데 있어 평활화계수  $\sigma$ 는 임의로 선택할 수 있는데, 이 평활화계수의 선택에 따라 달라지는 추정된 PDF의 변화를 Fig. 6에 나타내었다. Fig. 6.(a)는  $\sigma=0.01$ 인 경우에 대한 type c 결합의 +A1 특징에 대한 PDF를 30개의 학습 표본으로부터 추정한 것으로서, 평활화계수가 작으면 개개의 학습 표본을 중요시하는 확률밀도함수가 얻어짐을 알 수 있으며, Fig. 6.(b)는  $\sigma=0.1$ 인 경우로서, 평활화계수가 커지면 학습 표본들의 평균적 거동을 중시하는 확률밀도함수가 얻어짐을 알 수 있다.



(a)  $\sigma = 0.01$



(b)  $\sigma = 0.1$

Fig. 6. Class conditional probability density function estimated from training samples by parzen window approach(defect type : C, feature : +A1)

위와 같은 방법으로 모든 결합 종류별, 특징별 조건부 확률밀도함수를 추정할 수 있다. 이렇게 확률밀도함수가 구해지면, 특징값의 분포 범위의 상하한값을 나타내는 descriptor entries를 설정할 수 있다. Fig. 7에 +A1 특징에 대한 descriptor entries의 설정 예를 나타내었다. 이 그림에 보인 바와 같이 먼저 Parzen window 방법으로 추정한 결합 종류별 PDF들을 구하고, 추정된 PDF 최대값의 25%(실용적인 관점에서 임의로 취한 값)에 해당하는 직선(문턱직선)을 그어, 이 직선과 PDF 곡선이 만나는 점의 값을 descriptor entries로 설정하였다.

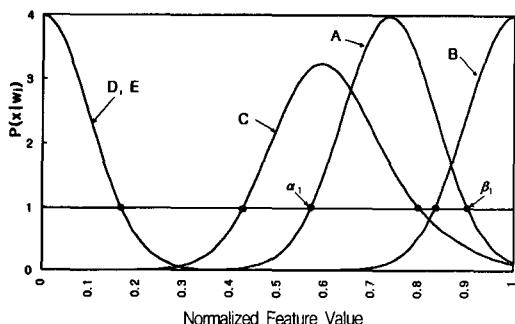


Fig. 7. Determination of descriptor entries from estimated probability density functions

이상의 방법으로 모든 특징에 대한 descriptor entries값을 설정할 수 있다. 전술한 바와 같이 descriptor entries값은 PDF로부터 설정되는데, PDF값이 평활화계수에 의해 좌우되므로, descriptor entries값도 역시 평활화계수에 의해 변화한다. 이 descriptor entries값을 2.2절과 2.3절의 분류 알고리즘에 대입하면, 결합 분류를 위한 분류표분류기(CT)와 강화분류표분류기(ECT)가 모두 구성된다.

#### 4.3. 확률신경회로망의 학습

주어진 결합 신호에 대한 5개의 특징값을 입력으로 제공하면 5종류의 결합중 가장 적합한 종류의 결합으로 분류하는 확률신경회로망을 구성하였다. 이 PNN은 5개의 입력층 노드, 115개의 패턴층 노드, 5개의 합산층 노드, 그리고 5개의 출력층 노드를 가지고 있으며, 앞에서 언급한 115개의 학습 표본을 이용하여 학습시켰다. 그리고 확률신경회로망 변수중 사용자가 임의로 선택할 수 있는 파라메터인 평활화 계수는 분류표 분류기와 같이 0.01과 0.1의 두 값으로 취하였다. 또한 결합의 오분류에 따른 기대손실은 결합 종류별로 차이가 없는 것으로 간주하여 식 (2)의 손실계수는 모두 같은 값을 사용하였다.

#### 4.4. 분류기의 성능 평가

CT, ECT, PNN 등 세가지 분류기를 구성한 다음, 이를 분류기의 성능을 비교 분석하기 위하여 성능 평가용 결합 신호 115개에 대한 결합 분류를 수행하였다. Fig. 8은 평활화계수를 0.01로 취한 경우에 대한 결합 분류 결과인데, 이 결과에서 알 수 있는 바와 같이 CT는 약 50% 정도의 정확도를 나타내고 있으나, ECT와 PNN은 각각 85%, 77%의 높은 정확도를 나타내고 있어 매우 효율적인 분류기임을 알 수 있다. 그러나, CT와 ECT는 type e의 결합을 type d의 결합과 전혀 구별하지 못하는 반면, PNN은 type E와 type d를 어느 정도 구별해내고 있어, PNN이 가장 효율적인 분류기임을 알 수 있다. 이러한 결과는 CT와 ECT가 결합 분류에 특징값의 분포 범위만을 사용하지만, PNN은 특징값으로부터 추정한 사후 확률을 사용하기 때문에 이렇게 뛰어난 분류 성능을 나타내는 것으로 판단된다.

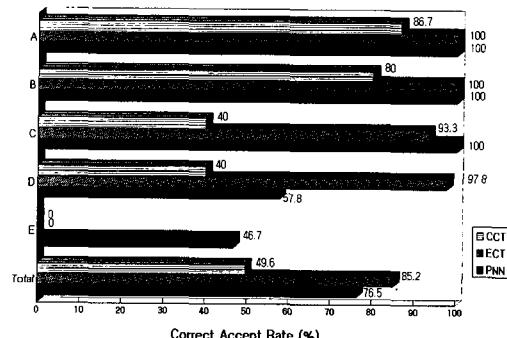


Fig. 8. Performance of classifiers ( $\sigma=0.01$ )

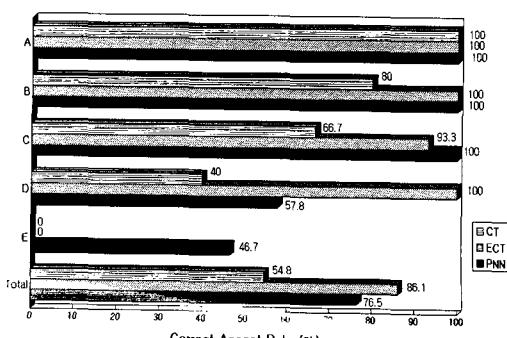


Fig. 9. Performance of classifiers ( $\sigma=0.1$ )

Fig. 9는 평활화계수가 0.1인 경우에 대한 결과인데, Fig. 8과 비슷한 결과를 보여주고 있다. 따라서 이 문제의 경우 평활화 계수  $\sigma$ 가 분류 성능에 그다지 큰 영향을 미치지 않은 것으로 나타났다. 그러나 초음파 결합 분류에 대한 저자의 최근 연구에서 평활화계수의 변화가 PNN에는 큰 영향을 미치지 않으나 CT와 ECT에는 큰 영향을 미치는 것으로 밝혀졌다<sup>13)</sup>. 따라서 이상의 결과를 종합해 볼 때 ECT는 CT의 분류 성능을 향상시킬 수 있는 매우 훌륭한 대안이 될 수 있으나, 역시 PNN이 CT와 ECT의 단점을 보완할 수 있는 가장 우수한 분류기임을 알 수 있다.

## 5. 결 론

본 연구에서는 냉연 강판 표면결함 분류기의 성능을 향상시킬 수 있는 효율적인 분류기의 개발에 관한 연구를 수행하였다. 현재 SDD가 채택하고 있는 분류 표분류기(CT)는 결합 분류 정확도가 낮을 뿐 아니라, descriptor entries의 설정을 작업자의 수작업에 의존하고 있어 현장 적용을 더욱 어렵게하고 있다. 이러한 단점을 극복하기 위해 본 연구에서 학습 표본으로부터 확률밀도함수를 추정하고 여기에서 descriptor entries를 자동적으로 결정하는 방법을 제시하였고, 강화분류 표분류기(ECT)와 확률신경회로망 분류기(PNN)를 새롭게 제안하고 이들 분류기를 실제적인 문제에 적용하였다. 본 연구 결과 ECT와 PNN 모두 결합 분류 성능을 획기적으로 높일 수 있는 좋은 방법이나, 특히 PNN은 아주 구별하기 어려운 결함도 어느 정도 구별해내는 능력이 있을 뿐 아니라, 병렬 처리 능력을 가지고 있기 때문에 다량의 데이터를 실시간으로 처리해야 하는 경우에 적용할 수 있는 매우 효율적인 분류기임을 확인하였다.

## 후 기

이 논문은 한국과학재단 지정 지역협력 연구센터인 조선대학교 수송기계부품 공장자동화 연구센터의 연구비 지원에 의해 연구되었음.

## 참고문헌

1. F. Treiber, "On-line Automatic Defect Detection and Surface Roughness Measurement of Steel Strip", Iron and Steel Engineer, (1989), pp. 26-33
2. 김경진, 신용태, "냉연 코일 결함 검출기의 결합 분석 시뮬레이션", RIST 연구논문, Vol. 6(1992), pp. 609-623
3. 최세호, 이종학 외, "냉연 SDD On-Line 신호처리 시스템 개발(I)", 포스코기술연구소 연구 결과 보고서, (1994)
4. D. E. Lippmann, "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, (1987), pp. 4-22
5. D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Internal Representations by Error Propagation", in Parallel Distributed Processing, Vol. 1, eds. D. E. Rumelhart, J. L. McClelland and the PDP Research Group, MIT Press Cambridge (1986), pp. 318-362
6. D. E. Specht, "Probabilistic Neural Networks for Classification, Mapping or Associative Memory", Proceedings of the IEEE International Conference on Neural Networks, Vol. 1 (1988), pp. 525-532
7. D. F. Specht, "Probabilistic Neural Networks", Neural Networks, Vol. 3 (1990), pp. 109-118
8. D. F. Specht, "Enhancements to Probabilistic Neural Networks", Proceeding of the IEEE International Joint Conference on Neural Networks, Vol. 1(1992), pp. 761-768
9. S. J. Song and L. W. Schmerr, "Ultrasonic Flaw Classification in Weldments using Probabilistic Neural Networks", Journal of Nondestructive Evaluation, Vol. 11(1992), pp. 69-77
10. 송성진, "용접 결합 분류를 위한 초음파 형상인식 기법", 한국비파괴검사학회지, Vol. 15(1995), No. 2, pp. 395-405
11. 송성진, 김학준, 오치환, 최세호, 이종학, "냉연 강판 표면결함의 분류 기법에 관한 연구", 한국비파괴검사학회 '96년 춘계학술발표회 논문집, (1996), pp. 156-161
12. R. O. Duda and P. E. Hart, Pattern Classification and Scene Analysis, New York, John Wiley & Sons, (1973)
13. 김학준, "형상인식기법을 이용한 지능형 결합 분류기에 관한 연구", 석사학위 논문, 조선대학교, (1997)

## **Classification of Surface Defects on Cold Rolled Strips by Probabilistic Neural Networks**

S. J. Song,\* H. J. Kim\* S. H. Choi\*\*\* and J. H. Lee\*\*\*

\* Dept. of Mechanical Design Eng., Chosun Univ., Kwangju 501-759

\*\* Dept. of Mechanical Design Eng., Graduate School, Chosun Univ., Kwangju 501-759

\*\*\* Technical Research Laboratories, Pohang Iron & Steel Co. Ltd, Pohang 790-785

**Abstract** Automatic on-line surface inspection systems have been applied for monitoring a quality of steel strip surfaces. One of the important issues in this application is the performance of on-line defect classifiers. Rule-based classification table methods which are conventionally used for this purpose have been suffered from their low performances. In this work, probabilistic neural networks and the enhanced classification tables which are newly proposed here are applied as alternative on-line classifiers to identify types of surface defects on cold rolled strips. Probabilistic neural networks have shown very excellent performance for classification of surface defects.