

다층 퍼셉트론 신경망을 이용한 하드 디스크 결함 분포의 패턴 인식

(Pattern Recognition of Hard Disk Defect Distribution Using Multi-Layer Perceptron Network)

이재두 · 문운철*

(Jae-Du Lee · Un-Chul Moon)

요 약

하드 디스크(Hard Disk) 결함의 표준 패턴 클래스는 6 가지로 분류되며, 이는 하드 디스크 생산 공정의 불량 처리 과정에서 중요한 역할을 수행한다. 본 논문에서는 다층 퍼셉트론(Multi-Layer Perceptron)을 이용한 하드 디스크 결함 분포의 패턴 인식 기법을 제시한다. 결함 분포로부터 5가지의 특징들을 추출하고, 이를 이용하여 퍼셉트론의 입력을 구성하였으며, 미리 분류된 표준 패턴 클래스를 이용하여 퍼셉트론의 출력을 구성하였다. 구성된 입출력 데이터들은 오차 역전파(Error Back-Propagation) 알고리즘을 통하여 다층 퍼셉트론의 학습에 사용되었다. 테스트 결과 제시된 신경망은 하드 디스크의 패턴 분류에 만족할 만한 성능을 나타내었다.

Abstract

In the Hard Disk Drive(HDD) production, the defect pattern of defective HDD set is important information to diagnosis of defective HDD set. This paper proposes a pattern recognition neural network for the defect distribution of HDD. In this paper, 5 characteristics are determined for the classification to six standard defect pattern classes. A multi-layer perceptron is trained for the pattern classification, the inputs of which are 5 characteristic values and the 6 outputs are the nodes of standard patterns. The experiment with proposed neural network shows satisfactory results.

Key Words : Pattern Recognition, Hard Disk Drive, Artificial Neural Network, Perceptron

1. 서 론

패턴 인식(Pattern Recognition)은, 미지의 입력 패턴을 여러 클래스 중 적절한 하나의 클래스로 대응시키는 정보처리 과정으로 정의될 수 있다[1-2]. 이러한 패턴 인식 분야는 인간 능력의 자동화를 실현하기 위한 중요한 기술 요소로 꾸준히 연구되

* 주저자 : 중앙대학교 전자전기공학부 조교수
Tel : 02-820-5286, Fax : 02-825-1584
E-mail : ucmoon@cau.ac.kr
접수일자 : 2007년 4월 18일
1차심사 : 2007년 4월 23일
심사완료 : 2007년 5월 2일

어 왔으며, 과학, 의학, 산업분야 등에서 염색체분석, 음성인식, 문자인식 등의 다양한 문제에 성공적으로 적용되었다[1-3]. 이 때 각 입력 패턴의 클래스가 미리 주어진 경우에는 교사 분류(Supervised Classification) 문제, 그렇지 않은 경우를 비교사 분류(Unsupervised Classification) 문제로 불리운다 [2].

일반적으로 교사분류의 경우, 분류에 적절한 특징 값을 선정하여 추출하고, 이를 기반으로 판정 트리 구조, 최대우도율, 최소에러율 및 확률적 기법 등의 다양한 기법이 적용된다[1]. 따라서 패턴 분류 문제에서는, 적용 분야에 적합한 특징의 추출 및 이를 어떠한 방식으로 이용하여 분류하였는지가 중요한 관점이다.

한편 인공신경망(Artificial Neural Network)의 일종인 다층 퍼셉트론(Multi-Layer Perceptron)은 오차역전파(Error Back-Propagation) 학습 알고리즘의 개발과 더불어, 일반적인 함수의 학습에 효율적으로 적용될 수 있음이 알려졌다[4-6]. 이와 같은 학습 능력을 기반으로 퍼셉트론은 여러 분야의 교사 분류 문제에 성공적으로 적용되었다[7-10].

본 연구에서는 컴퓨터의 기억장치인 HDD(Hard Disk Drive) 결함의 패턴 분류에 다층 퍼셉트론을 적용한 결과를 제시한다. HDD제조 공정에서는 공정의 마지막 단계에서 HDD의 읽기/쓰기/찾기 등의 검사를 수행하여 HDD의 이상 유무를 확인한다[11]. 이 때 정상적인 읽기/쓰기/찾기가 수행되지 않는 섹터는 결함으로 처리되며, 이러한 정보는 HDD 내부에서 소프트웨어적으로 처리되어 데이터의 저장에 사용하지 않도록 한다. 이러한 결함의 개수가 주어진 임계치를 초과하게 되면 그 HDD는 불량품으로 처리된다.

수리공정에서 HDD 결함 분포의 분류는 불량 종류의 종류를 나누는 중요한 정보를 제공한다. 수리사가 인식하는 결함 분포의 표준 패턴 클래스(Standard Pattern Class)는 루프(Loop)형, 분침(Watch)형, 아크(Arc)형, 방사(Radial)형, 찍힘(Spot)형, 전체(Whole)형의 여섯 가지이다. 수리사는 결함 분포가 표준 패턴 클래스에 해당하는지를 구분한 후, 그에 따른 후속 처리과정을 거쳐서 불량 종류의 처방을

완성한다. 실제 불량 섹터의 분포는 여섯 가지 표준 패턴 클래스의 수많은 변형으로 존재하기 때문에, 실제 수리사가 결함 분포를 패턴 클래스별로 분류하는 작업은 시각적 판단과 경험적 지식이 동원되는 복잡한 작업이다.

본 연구에서는, 결함 패턴으로부터 패턴 분류의 근거가 되는 5가지의 특징을 선정하였다. 그 후 퍼셉트론 신경망의 교사 학습(Supervised Learning)을 위하여, 5개의 특징 값을 입력으로, 그리고 수리사에 의해서 미리 분류된 클래스 종류를 출력 값으로 갖는 학습 데이터를 구성하였다. 구성된 학습 데이터들은 다층 퍼셉트론 신경망의 오차 역전파 학습에 사용되었다. 제시된 알고리즘은 실제 제조 공정에서 발생한 불량 HDD의 결함 분포를 대상으로 평가되었고, 만족할 만한 패턴 분류 성능을 확인하였다.

2. 표준 패턴 클래스의 선정

디스크는 표면에 동심원으로 구성된 실린더(Cylinder)와 각 실린더내의 물리적인 최소 저장단위인 섹터(Sector) 들로 구성되어 있다. 고속으로 회전하는 디스크와 디스크의 중심에 수직인 방향으로 왕복운동을 하는 HAS(Head Suspension Assembly)의 제어에 의해 고밀도로 집적된 디스크 섹터에 접근하여 데이터의 입출력이 수행된다 [12-13]. 이러한 회전체로서의 특성 때문에 HDD 결함 분포는 전반적으로 디스크 중심에 대칭적인 형태를 띄고 있다.




그림 1. HDD 결함분포의 예
Fig. 1. Examples of Defect Distribution

불량으로 판정된 HDD는 수리공정으로 이송되고, 수리공정의 작업자들은 해당 HDD의 가장 안쪽의 실린더(Maintenance Cylinder, MC)에 기록된 결함

다중 퍼셉트론 신경망을 이용한 하드 디스크 결함 분포의 패턴 인식

들의 정보에 접속하여 결함 분포를 관찰한다. 그림 1은 HDD 결함 분포의 두 가지 예를 나타낸다. 그림에서 각 디스크상의 진하게 나타난 부분들은 정상적인 읽기/쓰기/찾기가 불가능하여 결함으로 처리된 부분들이다.

수리사와의 인터뷰 결과 수리사들은 결함분포가 루프(Loop)형, 분침(Watch)형, 아크(Arc)형, 방사(Radial)형, 찍힘(Spot)형, 전체(Whole)형의 여섯 가지 표준 패턴으로 분류함을 확인하였다. 그림 2는 전형적인 여섯 가지 표준 패턴 클래스를 나타낸다. 수리사들은 결함분포의 패턴 클래스에 근거하여 후속 테스트를 결정한다. 예를 들면 결함분포가 루프형인 경우에는 불량 헤드(Head)로 인한 불량일 확률이 높기 때문에, 헤드에 추가적으로 읽기/쓰기를 수행한다. 읽기/쓰기 에러 발생횟수가 임계치를 넘어서는 경우에는 헤드 불량으로 판정하여, 해당 HDD는 다시 클린룸으로 투입되어 헤드를 교체한 후, 생산 공정에 다시 투입된다.

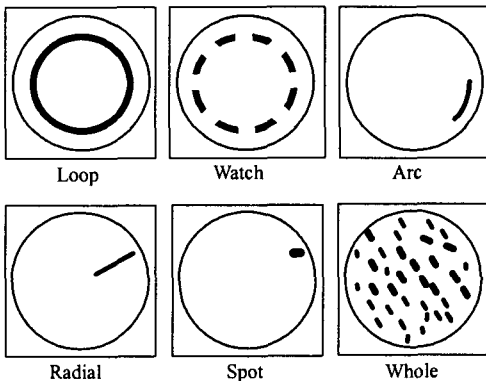


그림 2. HDD 결함분포의 표준 패턴 클래스
Fig. 2. Standard Pattern Classes

3. 패턴 인식을 위한 특징 추출

먼저 결함 분포의 전처리(Pre-processing)를 통하여 결함 분포 데이터 파일을 작성하였다. 디스크를 극좌표(Polar Coordinate)상으로 나타낸 후, 반지름은 150 구간으로, 각도는 1[°]씩 360 구간으로 각각 이산화시켜서 구역화하였다. 각 구역에 기준 이상의 결함들이 존재하는 경우, 그 구역에는 결함이 존재

하는 것으로 처리하였다. 이와 같은 전처리를 통하여, 일반적으로 500개 이하의 결함들로 이산화되며, 이때 각 결함의 위치를 다음과 같은 극 좌표 형태로 표현하였다.

$$d_i = (r_i, \theta_i) \quad (1)$$

여기서

d_i : i 번째 결함,

r_i : 중심으로부터 d_i 까지의 거리

θ_i : 3시 방향에서 d_i 까지의 각도

이 때 θ_i 는 HDD의 3시 방향을 기준으로 설정한 후, 반시계 방향으로 각도가 증가하는 것으로 나타내었다.

표 1. 전처리된 결함 패턴 데이터의 예
Table 1. An example of Defect Pattern Data

결함	위치(r_i, θ_i)
d_1	(45, 30[°])
d_2	(130, 40[°])
d_3	(85, 110[°])
d_4	(90, 320[°])




그림 3. 표 1의 결함 패턴
Fig. 3. Defect Pattern of Table 1

표 1은 전처리된 패턴 데이터의 한 예로서, 총 4개의 결함으로 구성된 패턴을 나타내었다. 각 결함의 위치를 극좌표 형태로 나타내었으며, 거리와 각도는 각각 정수 단위로 이산화되어 있음을 알 수 있다. 그림 3은 표 1의 결함 패턴 데이터의 결함 분포를 나타낸다. 그림 4는 전처리된 표준 패턴의 전형적인 데이

터이다.

그 후 전처리된 입력 패턴이 표준 패턴에 해당하는지를 판단할 수 있는 특징들에 대한 분석을 실시하였다. 분석 결과 다음과 같은 다섯 가지의 특징이 선정되었다.

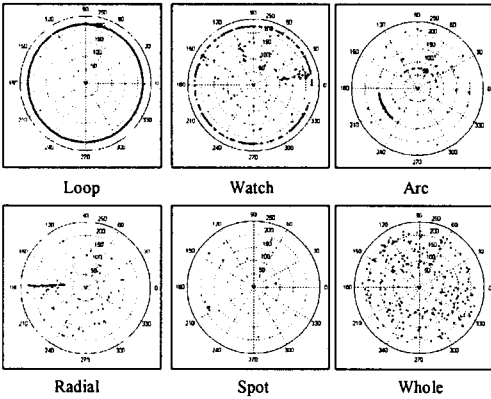


그림 4. 전처리된 패턴 클래스
Fig. 4. Preprocessed Pattern Classes

3.1 필터링(Filtering)후 결함의 개수

본 연구에서는 산발적인 결함들을 제거하기 위하여 극좌표를 직교좌표(Cartesian Coordinates)로 변화하였다. 이 때 횡축은 각도, 종축은 1~150까지의 반지름으로 변형한 후, 반지름 축은 1, 그리고 각도 축은 1[°]씩으로 이산화시켜서 격자 형태로 표현하였다. 그 후, 종축과 횡축이 각각 5칸의 크기를 갖는 5×5 정사각형 형태의 이동창(Moving Window)을 이용하여, 결함 개수가 3개 이하인 이동창의 결함을 제거하는 필터링(filtering) 방식을 사용하였다.

첫 번째 특징은 필터링된 패턴 데이터의 결함 개수 n 이다. 일반적으로 n 은 최대 500정도의 정수로 나타내어진다. 루프형과 분침형은 약 200개 이상의 큰 값을 가지며, 찍힘형은 10개 이하의 값을 갖는 것이 일반적이다.

3.2 필터링 전후의 결함 개수 차이

두 번째 특징으로는 필터링 전후의 결함 개수 차이를 선정하였다. 전체형의 경우 필터링 전후의 개

수 차이가 150개 이상으로 크게 나타나며, 찍힘의 경우에는 차이가 100개 이하로 작게 나타나는 것이 일반적이다.

3.3 r 성분의 표준편차

이는 반지름 성분의 관점에서 결함들이 얼마나 분포되어 있는지를 의미하며, 다음과 같이 일반적인 표준편차로 계산된다.

$$\sigma_r = \sqrt{\sum_{i=1}^n (r_i - m_r)^2 / n} \quad (2)$$

여기서 n 은 필터링 후 결함의 총 개수, m_r 은 r_i 의 평균값이다. 루프형이나 분침형 그리고 아크형의 경우 r 성분 집중도가 높기 때문에 상대적으로 (2)의 값이 40이하의 작은 값으로 나타나게 된다.

3.4 θ 점유도

이는 θ 성분으로 계산한 결함의 점유도이다. 취득된 데이터의 각도는 0~360[°] 사이의 정수 단위로 이산화 되었기 때문에 전체 360[°]에서 결함을 포함한 각도를 다음과 같이 계산하였다.

$$\theta \text{ 점유도} = (\text{결함을 포함한 각도} / 360) \times 100 \quad (3)$$

따라서 루프형의 경우 점유도가 거의 100에 가까운 값으로 나타나게 되며 찍힘이나 방사형은 10 이하의 작은 값을, 그리고 아크형은 중간 정도의 값을 나타내게 된다.

3.5 θ 성분의 분포도

이는 각도의 관점에서 결함들이 얼마나 퍼져있어 있는지를 나타내는 정도이다. 루프형이나 분침형의 경우에 전 각도에 걸쳐서 결함들이 분포되어 있으며, 찍힘형이나 방사형의 경우에는 좁은 각도에 집중되어 있다는 사실에 근거하여 매우 유용한 특징이 될 수 있다.

하지만 결함분포의 θ 성분 분포도로서, (2)와 유

다중 퍼셉트론 신경망을 이용한 하드 디스크 결함 분포의 패턴 인식

사하게 θ 의 표준 편차를 직접 사용할 경우에는 물리적인 특성에 부합하지 않는 문제점이 있다. 즉 극좌표계의 특성상 $0[^\circ]$ 와 $359[^\circ]$ 는 매우 가까운 각도임에도 불구하고 데이터 상에서는 큰 차이를 나타내는 것으로 처리되게 된다.




그림 5. $0[^\circ]$ 근처에 집중된 결함 분포의 예제
Fig. 5. A Defect Distribution Near 0°

그림 5는 이러한 경우의 예로써, 세 개의 결함 d_1, d_2, d_3 가 모두 $0[^\circ]$ 근처에 존재한다고 가정한 경우이다. 즉, (d_1, d_2, d_3) 의 각도가 $(1[^\circ], 3[^\circ], 359[^\circ])$ 인 경우이다.

이 경우 각도 성분의 평균 m_θ 및 표준 편차 σ_θ 를 구하면,

$$m_\theta = (1 + 3 + 359) / 3 = 121^\circ \quad (4)$$

$$\sigma_\theta = \sqrt{\sum_{i=1}^3 (\theta_i - 121^\circ)^2 / 3} = 168.29 \quad (5)$$

로 나타나게 된다. 즉 m_θ 가 $121[^\circ]$ 로 나타나 세 결함의 물리적인 중심 부위인 $1[^\circ]$ 근처에 위치하지 않는 문제점이 발생한다. 또한 m_θ 가 $1[^\circ]$ 근처에 있다고 가정한 경우에도, $359[^\circ]$ 에 있는 결함은 평균과 큰 차이를 나타내는 것으로 계산되어 표준 편차가 크게 나타나게 된다. 따라서 r 성분과는 달리, θ 성분의 분포도를 나타내는 지표로써 단순한 표준편차를 사용하기는 곤란하다는 것을 알 수 있다.

이러한 문제를 해결하기 위해서 결함의 각도를 m_θ 를 기준으로 새롭게 정의하여 σ_θ 를 구하였다. 즉, 물리적으로 m_θ 로부터 가장 멀리 떨어진 각도는 대칭방향인 $(m_\theta \pm 180[^\circ])$ 이므로, 모든 결함의 θ 가 평균 m_θ 를 기준으로 $-180[^\circ] \sim +180[^\circ]$ 로 사상

(Mapping)되도록 다음과 같이 새롭게 정의하였다.




그림 6. 평균 기준으로 재정의된 결함 각도 θ'
Fig. 6. Redefined θ' with respect to m_θ

$$\theta' = \begin{cases} \theta - m_\theta, & \text{if } -180^\circ \leq (\theta - m_\theta) \leq 180^\circ \\ \theta - m_\theta - 360^\circ, & \text{if } 180^\circ \leq (\theta - m_\theta) \\ \theta - m_\theta + 360^\circ, & \text{if } (\theta - m_\theta) \leq -180^\circ \end{cases} \quad (6)$$

그림 6은 표준편차를 구하기 위해서 평균으로부터 새롭게 정의된 결함의 각도를 나타낸다.

(6)과 같이 재정의된 각도를 이용하여 표준편차를 구하면,

$$\sigma_{\theta'} = \sqrt{\sum_{i=1}^n (\theta'_i)^2 / n}, \quad (7)$$

과 같이 표현되며, 이는 “평균에서 분포된 정도”라는 표준편차의 물리적인 의미에 부합하게 된다.




그림 7. 두 개의 각도 기준 축 θ_1 과 θ_2
Fig. 7. Two Reference Angles θ_1 and θ_2

또한 본 연구에서는 극좌표계의 특성을 고려한 평균을 구하기 위해서, 입력 데이터를 직접 이용하여 구한 평균 m_{θ_1} , 그리고 9시 방향을 극좌표계의 새로운 기준 축으로 변환하여 구한 평균 m_{θ_2} 를 각각 계산하였다. 그림 7은 두 개의 각도 축을 나타내며, 새로운 기준 축 θ_2 는 9시 방향으로부터 반시계 방향으로 증가하도록 설정하였음을 알 수 있다.

그 후 두 개의 기준 축에 의해서 각각 구해진 평균 m_{θ_1} 과 m_{θ_2} 를 기반으로 (7)을 이용하여 각각 σ_{θ_1} 과 σ_{θ_2} 를 구하였다. 최종적으로는 두 σ_{θ_1} 과 σ_{θ_2} 중 작은 값을 각도 성분의 분포도로 정의하였다.

$$\theta \text{ 성분의 분포도} = \min(\sigma_{\theta_1}, \sigma_{\theta_2}) \quad (8)$$

즉 두 개의 기준 축을 바탕으로 각각 두 개의 평균을 구한 후, 이를 바탕으로 각각 구한 표준 편차 중 작은 값을 선택하여 극좌표상에서 각도의 분포도를 계산하였다.

예를 들어 그림 5와 같은 결합분포의 경우, (4)에서 m_{θ_1} 이 121[°]로 계산되며, 이를 기반으로 (6)에서와 같이 재정의된 각도(-120[°], -118[°], -122[°])를 이용하여 표준편차 σ_{θ_1} 을 구하면,

$$\sigma_{\theta_1} = \sqrt{\sum_{i=1}^3 \theta_{1i}^2 / 3} = 120.01 \quad (9)$$

로 계산된다.

그 후 9시 방향을 극좌표계의 새로운 기준 축으로 재정의하면, 각도는 (181[°], 183[°], 179[°])로 변환되며, m_{θ_2} 는

$$m_{\theta_2} = (181^\circ + 183^\circ + 179^\circ) / 3 = 181^\circ \quad (10)$$

로 나타난다. 따라서 이를 기반으로 표준편차 σ_{θ_2} 를 구하기 위하여, (6)과 같이 각도를 재정의하면, (d_1 , d_2 , d_3)의 각도 θ_2 는 (0[°], 2[°], -2[°])로 나타나게 된다. 이를 이용하여 σ_{θ_2} 를 구하면,

$$\sigma_{\theta_2} = \sqrt{\sum_{i=1}^3 \theta_{2i}^2 / 3} = 1.633 \quad (11)$$

와 같이 나타나게 된다. 따라서 (8)에 의해서, 최종적으로 작은 값을 갖는 σ_{θ_2} 가 결합의 θ 성분 분포도로 선택되게 된다. 결과적으로 그림 5의 결합분포는 각도 성분의 분포정도가 작게 나타나게 되어 물리적인 특성에 부합하게 된다.

이러한 θ 성분의 분포도는 루프형이나 분침형의

경우에는 약 80이상의 큰 값을, 그리고 찍힘형이나 방사형의 경우 10이하의 작은 값으로 나타나게 된다.

4. 패턴 특징의 퍼셉트론 학습

기술된 5가지의 특징들은 모두 표준 패턴 클래스를 구분할 수 있는 가능성을 내포하고 있다. 하지만 하나의 특징이 각 패턴을 독립적으로 결정할 수 없고 각 특징들의 상호 연관을 통하여 패턴이 구분되어야 하는 상황으로 분석되었다. 본 연구에서는 앞에서 기술된 5가지의 특징들에 기반하여 각 패턴을 구분하는 다층 퍼셉트론을 구성하였다.




그림 8. 패턴 분류 퍼셉트론의 구조
Fig. 8. Structure of a classification perceptron

이를 위하여 5가지 특징 값들을 입력 받아, 두 개의 은닉층을 거쳐서, 6개의 출력 노드를 갖는 다층 퍼셉트론을 구성하였다. 그림 8은 제시된 패턴 분류 퍼셉트론을 나타낸다. 즉 5가지의 특징 값(x_1 , x_2 , x_3 , x_4 , x_5)를 입력 받아, 15개와 8개의 은닉층 노드를 통과한 후, 6개의 노드 값 (p_1 , p_2 , p_3 , p_4 , p_5 , p_6)를 출력하도록 정의하였다.

이와 같은 구조하에서 패턴의 클래스에 따른 출력 값을 (12)와 같이 정의하여 학습에 사용하였다.

즉 수리사가 미리 분류한 클래스 정보를 이용하여, 해당하는 패턴 클래스의 출력 노드에서는 1의 값을 갖고, 그 밖의 출력 노드는 0의 값을 갖도록 출력 값을 구성하였다. 따라서 해당하는 패턴 클래스의 출력 노드값은 다른 출력 노드값보다 큰 값을 출력하게 된다.

다중 퍼셉트론 신경망을 이용한 하드 디스크 결함 분포의 패턴 인식

Loop : Pattern 1 : [100000]
 Watch : Pattern 2 : [010000]
 Whole : Pattern 3 : [001000]
 Radial : Pattern 4 : [000100]
 Spot : Pattern 5 : [000010]
 Arc : Pattern 6 : [000001]

(12)




그림 9. 신경망 오차 수렴 과정
 Fig. 9. Error conversion of a perceptron training

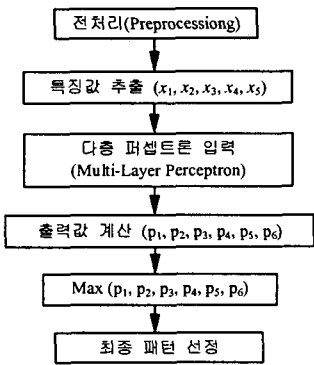


그림 10. 제시된 패턴 분류시스템의 전체 과정
 Fig. 10. Proposed Pattern Classification Process

실제 학습을 위하여 각 패턴별로 수리사가 미리 분류한 100개씩의 샘플을 수집하여 총 600개의 학습 데이터를 선정하였다. 퍼셉트론의 학습을 위해서는 matlab에서 제공하는 toolbox의 LM (Levenberg-Marquardt) 오차 역전파 함수를 이용하였다. 초기에 임의로 설정된 가중치(Weight)에서는 오차가 1.0141이었으나 291회의 학습 결과, 오차는 0.002까지 줄어들었으며, 학습 과정에서 오차가 수렴하는 과정을 그림 9에 나타내었다. 그림에서 y축은 오차함수의 log값이며, x축은 학습 횟수이다.

따라서 전체 오차가 충분히 작은 값으로 수렴하기 때문에 주어진 구조의 퍼셉트론은 패턴 분류에 효율적으로 적용될 수 있음을 알 수 있다.

새롭게 입력된 분류 대상 패턴에 대해서 먼저 5개의 특징값 (x_1, x_2, x_3, x_4, x_5)이 계산되고, 이는 학습된 퍼셉트론 신경망의 5개의 입력노드에 각각 입력되어, 6개의 출력 값이 계산된다. 이 때 최종적인 패턴은 (13)과 같이 6개의 노드중 최대값을 갖는 노드로 결정되게 된다.

$$\text{Pattern Class } i = \arg \max_i [p_i] \quad (13)$$

즉 출력값이 최대로 나타나는 패턴을 최종적인 클래스로 결정하게 된다. 그림 10은 본 연구에서 제안한 패턴 분류의 전체 과정을 나타낸다.

5. 실험 결과

학습된 퍼셉트론은 실제 제조공정에서 발생한 불량 HDD의 결함 분류에 적용되었다. 그림 11은 세 개의 예제 패턴을 나타내며, 표 2는 이러한 세 개의 패턴이 제시된 알고리즘에 의하여 분류되는 과정을 나타낸 것이다. 표에서 첫 번째 패턴의 특징값은 각각 (124, 15, 3.4109, 84.3144, 32.22)로 계산되었으며, 이 값이 인공신경망에 입력된 결과, 노드의 출력 $P = [-0.0001, 0.9440, 0.0928, -0.0040, -0.0092, 0.9171]$ 로 나타나 최종적으로 분침형으로 판정된 결과를 나타낸다.




그림 11. 세개의 예제 패턴
 Fig. 11. Three Example Patterns

구현된 결과를 확인하기 위하여 학습에 사용되지 않은 250개의 결함 분포에 대해서 실험한 결과, 수리사의 판별과 238개가 일치하여 95.2[%]의 적응률을

나타내었다. 이 때 일치하지 않은 12개 패턴은 대부분 실제 수리사의 판단으로도 적절하게 나누어지지 않는 불분명한 패턴으로 분석되어, 패턴 분류의 결과는 신뢰할 만한 것으로 입증되었다.

표 2. 예제 패턴 분류 과정
Table 2. Classification Procedure of Example Patterns

		Pattern 1	Pattern 2	Pattern 3
특 징	x_1	124	14	11
	x_2	15	49	42
	x_3	3.4109	42.7240	31.4174
	x_4	84.3144	10.5473	4.9074
	x_5	32.22	3.889	1.667
신 경 망 출 력	$L p_1$	-0.0001	0.0000	0.0002
	p_2	0.9440	0.0010	-0.0032
	$L p_3$	0.0928	0.3962	0.2997
	p_4	-0.0040	0.2180	0.9441
	p_5	-0.0092	0.0329	0.5130
	p_6	0.9171	0.0185	-0.0021
결과		Watch	Whole	Radial

6. 결 론

본 연구에서는 다층 퍼셉트론(Multi-Layer Perceptron)을 하드 디스크 드라이브(Hard Disk Drive, HDD) 결합 분포의 패턴 분류에 적용한 연구 결과를 제시하였다.

퍼셉트론의 입력은 각 패턴을 구분할 수 있는 5개의 특징들을 추출하여 사용하였다. 퍼셉트론의 출력은 6개의 표준 패턴 클래스를 나타내는 노드를 구성한 후, 해당 노드에서 최대값을 갖도록 정의하였다. 그 후 전문가에 의해서 미리 분류된 패턴 데이터를 이용하여 다층 퍼셉트론을 학습하였다. 실험 결과 만족스러운 분류 성능을 확인하였으며, 본 연구 결과는 수작업에 기초한 수리판정 작업의 자동화에 유용하게 응용될 수 있을 것으로 기대된다.

본 연구는 2006년도 중앙대학교 학술연구비(일반연구비) 지원에 의한 것임.

References

- [1] S. Theodoridis and K. Koutroumbas, Pattern Recognition, Academic Press, 1999.
- [2] R. Xu and D. Wunsch II, "Survey of Clustering Algorithms", IEEE Transactions on Neural Networks, Vol. 16, No. 3, pp.645-678, May 2005.
- [3] George Nagy, "State of the Art in Pattern Recognition", Proceedings of the IEEE, Vol. 56, No. 5, May 1968.
- [4] S. I. Callant, "Perceptron-Based Learning Algorithms", IEEE Transactions on Neural Networks., Vol. 1, No. 2, pp.179-191, June 1990.
- [5] B. W. Widrow and M. A. Lehr, "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", Proceedings of IEEE, Vol. 78, No. 9, pp. 1415-1442, Sep. 1990.
- [6] Mayer Aladjem, "Recursive Training of Neural Networks for Classification," IEEE Trans. Neural Netw., vol. 11, no.2, pp.496-503, Mar. 2000.
- [7] S. K. Pal and S. Mitra, "Multilayer Perceptron, Fuzzy Sets, and Classification", IEEE Transactions on Neural Networks., Vol. 3 No. 5 pp. 683-697, Sep. 1990.
- [8] O. J. Murphy, "Nearest Neighbor Pattern Classification Perceptron", Proceedings of IEEE, Vol. 78, No. 10, pp. 1595-1598, Sep. 1990.
- [9] A. M. Sharf and T. T. Lie, "ANN Based Pattern Classification of Synchronous Generator Stability and Loss of Excitation", IEEE Transactions on Energy Conversion, Vol. 9, No. 4, Dec. 1994.
- [10] T. Auld, A. W. Moore and S. F. Gull, "Bayesian Neural Networks for Internet Traffic Classification", IEEE Transactions on Neural Networks., Vol. 18, No. 1, pp.223-239, Jan. 2007.
- [11] 문운철, 이승철, 남창우, "Hard Disk Drive 검사 시스템의 고장 진단을 위한 퍼지-이진 논리 결합형 전문가 시스템에 관한 연구" 대한전기학회논문지, 53-D권 6호, pp. 457-464, 2004년 6월.
- [12] 정정주, 이승희, 추상훈, "디스크 드라이브의 기술 동향과 제어기술", 제어자동화시스템 공학회지, 1998년 5월호, pp. 15-21.
- [13] 이호성, "하드 디스크 드라이브 서보 제어기의 설계", 제어자동화시스템 공학회지, 1998년 5월호, pp. 22-28.

◇ 저자소개 ◇

이재두 (李在斗)

1980년 9월 28일생. 2006년 중앙대 전자전기공학부 졸업. 현재 중앙대학교 대학원 전자전기공학부 석사과정 재학중.
 관심분야 : 지능시스템 및 자동제어 이론.

문운철 (文雲哲)

1968년 10월 1일생. 1991년 서울대 전기공학과 졸업. 1996년 동 대학원 전기공학과 졸업(박사). 2002년~현재 중앙대학교 전자전기공학부 조교수.
 관심분야 : 지능시스템과 자동제어 이론 그리고 전력 계통 및 산업계의 적용