

폐지 추론과 개선된 폐지 RBF 네트워크를 이용한 컨테이너 식별자 인식

주이환^a, 김재용^b, 김광백^b

^a신라대학교 컴퓨터 정보공학부
부산시 사상구 괘법동 산 1-1

^b신라대학교 컴퓨터공학과
부산시 사상구 괘법동 산 1-1

Abstract

일반적으로 운송 컨테이너의 식별자들은 크기나 위치가 정형화되어 있지 않고 외부 잡음으로 인하여 식별자의 형태가 변형될 수 있기 때문에 일정한 규칙으로 찾기는 힘들다. 본 논문에서는 이러한 특성을 고려하여 컨테이너 영상에 대해 Canny 마스크를 이용하여 에지를 검출하고, 검출된 에지 정보에서 영상획득 시 외부 광원에 의해 수직으로 길게 발생하는 잡음을 폐지추론 방법을 적용하여 제거한 후에 수직 블록과 수평 블록을 검출하여 컨테이너의 식별자 영역을 추출하고 이진화 한다. 이진화된 식별자 영역에 대해 검정색의 빈도수를 이용하여 흰바탕과 민바탕을 구분하고 윤곽선 추적 알고리즘을 적용하여 개별 식별자를 추출한다. 추출된 개별 식별자의 인식은 개선된 폐지 RBF 네트워크를 제안하여 적용한다. 제안된 폐지 RBF 네트워크는 폐지 C-Means 알고리즘을 중간층으로 적용하고 중간층과 출력층 간의 학습에는 일반화된 델타 학습 방법과 Delta-bar-Delta 알고리즘을 적용하여 학습 성능을 개선한다. 실제 컨테이너 영상을 대상으로 실험한 결과, 기존의 식별자 추출 방법보다 제안된 식별자 추출 방법이 개선되었고 기존의 폐지 RBF 네트워크 보다 제안된 폐지 RBF 네트워크가 컨테이너 식별자의 학습 및 인식에 우수함을 확인하였다

Keywords:

컨테이너, C-Means, Delta-bar-Delta, 폐지 RBF 네트워크

1. 서론

오늘날 해로를 통한 수출입 물량의 증가로 인하여 항만에서 신속하고 정확하게 운송 컨테이너 물류 처리를 하기 위한 자동화 방법들이 적용되고 있다. 운송 컨테이너 물류 처리를 자동화하기 위해 적용되고 있는 시스템은 바코드 시스템과 영상

처리를 기반으로 한 운송 컨테이너 식별자 인식 시스템 등이 있다. 운송 컨테이너 식별자의 ISO규격은 4개의 영역으로 구성되어 있다. 식별자 코드는 운송회사 코드, 일련번호, 검사숫자, 컨테이너 유형코드의 순으로 표기되며 검사 숫자까지 11자는 규정 사항이므로, 컨테이너를 식별하기 위해서는 컨테이너 식별자의 처음 11자만을 인식하면 된다[1,2].

일반적으로 식별자 추출은 식별자 영역과 배경 영역으로 구분하여 추출한다. 컨테이너 식별자의 경우에는 문자의 크기나 위치, 간격들이 특별히 정형화되어있지 않고, 문자색과 배경색 또한 일정하게 정해져 있지 않다. 따라서 식별자 모양이나 형태와 같은 정보로 컨테이너의 식별자를 구별하기는 힘들다. 차량 번호판과 같은 경우에는 번호판의 가로와 세로 비율이 2 : 1로 구성된 사각형이라는 형태학적 정보를 얻을 수 있지만 컨테이너 식별자의 경우에는 식별자들이 길게 수평으로 나열되어 있고 몇 줄에 걸쳐 나열된 경우도 있다[2,3]. 따라서, 어디부터 어디까지가 식별자 영역이라고 정의하기가 힘들다. 또한 컨테이너 영상의 식별자들은 모두 컨테이너의 외부에 표시되어 있기 때문에 문자 형태가 훼손되거나 불필요한 기타 잡음으로 인하여 식별자를 개별적으로 분할하기 힘들고, 컨테이너 표면의 훼손 또는 굽곡에 의하여 식별자의 형태가 변형될 수 있다. 따라서 칼라 정보를 이용하여 컨테이너의 식별자를 추출하는 것은 정확성이 낮아진다.

본 논문에서는 컨테이너의 식별자를 추출하기 위하여 컨테이너 영상을 Canny 마스크를 이용하여 에지를 추출하고 추출된 에지 정보에서 영상획득 시 발생하는 빛에 의한 수직 잡음을 제거하여 수직 블록과 수평 블록을 검출하고 컨테이너의 식별자 영역을 추출하고 이진화 한다. 이진화된 식별자 영역에 대해 검정색의 빈도수를 이용하여 흰바탕과 민바탕을 구분하고 윤곽선 추적 알고리즘을 적용하여 개별 식별자를 추출한다.

RBF 네트워크는 빠른 학습 시간, 일반화(generality), 단순화(simplicity)의 특징으로 학습 데이터를 분류하는 작업과 비선형 시스템 모델링 등에 적용되고 있다[4]. 기존의 오류 역전과 학습 알고리즘과 같은 다중 퍼셉트론(multi-layer perceptron)의 연결 가중치들이 지역 최소화에 위치하여 학습 패턴들이 잘 분류되지 않은 경우를 방지할 수 있으며 학습 시간을 단축시킬 수 있다[5]. RBF 네트워크의 중간층은 클러스터링 하는 층이다. 즉 이 층의 목적은 주어진 자료집합을 유사한 클러스터들(homogenous cluster)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터로 분류하고 정해진 반경 내에 존재하지 않으면 다른 클러스터로 분류한다[6]. 그러나 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다. RBF 네트워크는 학습이 완료된 상태, 즉 연결 강도가 특정값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습시키는데 상당한 학습 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴들이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류하여 인식률을 저하시킨다[7]. 따라서 본 논문에서는 RBF 네트워크의 학습 구조를 개선한다. 제안된 학습 구조에서 입력층과 중간층 간의 연결구조는 퍼지 C-Means의 구조와 같다. 제안된 학습 구조는 전체적으로 완전 연결구조이나 출력층에서 목표 벡터와 출력 벡터를 비교하여 역전파 시킬 때는 대표 클래스와 연결된 가중치만을 역전파 시켜 연결 가중치를 조절하므로 새로운 패턴들이 이전에 학습 패턴으로 분류되는 부분을 개선한다. 그리고 중간층의 대표 클래스와 연결된 출력층의 노드만 일반화된 텔타 방법을 적용하여 지도 학습으로 수행한다. 이 때에 학습 시간을 단축하기 위하여 delta-bar-delta 방법을 적용하여 학습률을 동적으로 조정한다. 따라서 개선된 퍼지 RBF 네트워크를 제안하여 컨테이너의 개별 식별자 인식에 적용한다.

2. 식별자 영역 및 개별 식별자 추출

본 논문에서의 컨테이너 개별 식별자 추출 과정은 획득된 컨테이너 영상에서 식별자 영역을 추출하는 부분과 추출된 식별자 영역에서 개별 식별자를 추출하는 부분으로 구성된다

2.1 컨테이너 식별자 영역 추출

본 논문에서는 컨테이너의 형태학적 특성에 의해서 수직으로 나타나는 잡음으로 인해 컨테이너의

식별자 영역 추출에 실패하는 경우를 개선하기 위하여 퍼지 추론 방법을 적용하여 컨테이너 식별자 영역을 추출하는 방법을 제안한다.




그림 1 - 원본 영상




그림 2 - Canny마스크 적용 영상 및 수직 히스토그램




그림 3 - 잡음 제거 영상 및 수직 히스토 그램

먼저, 컨테이너 영상으로부터 식별자 영역을 추출하기 위해 Canny 마스크를 이용하여 에지를 검출한다. Canny 마스크를 이용한 에지 결과는 실제 에지와 추출된 에지와의 거리가 적고, 에지가 존재하는 곳에서 여러 개의 에지가 발생하지 않기 때문에, 실제 영상에 더욱 가까운 에지를 추출할 수 있다[8,9]. 따라서 컨테이너 영상을 대상으로 Canny 마스크를 적용한 에지 결과는 정확한 에지의 검출로 인하여 컨테이너의 배경과 문자 영역을 구분할 수 있도록 유도된다. 그러나 컨테이너의 형태적인 특징으로 인해 수직 방향으로 잡음이 나타나기 때문에, 에지 결과에 대해 퍼지 추론 방법을 적용하여 이러한 문제점을 해결한다.

2.1.1 퍼지추론에 의한 잡음 제거

외부 광원에 의해 발생하는 잡음을 제거하기 위하여 Canny 마스크가 적용된 이미지에서 에지의 수평 연속성과 수직 연속성에 대하여 퍼지 추론기법을 적용하여 각 값들을 추론하여 잡음인지 아닌지를 검증한다.

2.1.1.1 수평, 수직 에지 연속성 값에 대한 소속함수

수직 에지의 연속성에 대한 소속 함수는 그림 4와 같고 수평 에지의 연속성에 대한 소속 함수는 그림 5와 같다.




그림 4 - 수직 에지의 연속도(C)

$$If(C \leq 90) \text{ or } (C \geq 130) \text{ then } \mu(C) = 0$$

$$Else If(C > 110) \text{ then } \mu(C) = \frac{(130-C)}{(130-110)} \quad (1)$$

$$Else If(C < 110) \text{ then } \mu(C) = \frac{(C-90)}{(110-90)}$$

$$Else If(C = 110) \text{ then } \mu(C) = 1$$

표 1 - C 값에 대한 소속도

퍼지값	소속구간
C 의 빈도수가 낮다(L).	[0,70]
C 의 빈도수가 중간정도다(M).	[90,130]
C 의 빈도수가 높다(H).	[120,160]




그림 5 - 수평 에지의 연속도(D)

$$If(D \leq 2) \text{ or } (D \geq 7) \text{ then } \mu(D) = 0$$

$$Else If(D > 5) \text{ then } \mu(D) = \frac{(7-D)}{(7-5)} \quad (2)$$

$$Else If(D < 5) \text{ then } \mu(D) = \frac{(D-2)}{(5-2)}$$

$$Else If(D = 5) \text{ then } \mu(D) = 1$$

표 2 - D 값에 대한 소속도

퍼지값	소속구간
D 의 빈도수가 낮다(L).	[0,3]
D 의 빈도수가 중간정도다(M).	[2,7]
D 의 빈도수가 높다(H).	[6,9]

2.1.1.2 추론규칙

수평과 수직 에지의 연속도에 대한 퍼지 추론 규칙은 다음과 같다.

$$If C \text{ is } H \text{ and } D \text{ is } H \text{ then } Y \text{ is } H$$

$$If C \text{ is } H \text{ and } D \text{ is } M \text{ then } Y \text{ is } H$$

$$If C \text{ is } H \text{ and } D \text{ is } L \text{ then } Y \text{ is } H$$

$$If C \text{ is } M \text{ and } D \text{ is } H \text{ then } Y \text{ is } H$$

$$If C \text{ is } M \text{ and } D \text{ is } M \text{ then } Y \text{ is } M$$

$$If C \text{ is } M \text{ and } D \text{ is } L \text{ then } Y \text{ is } M$$

$$If C \text{ is } L \text{ and } D \text{ is } H \text{ then } Y \text{ is } L$$

$$If C \text{ is } L \text{ and } D \text{ is } M \text{ then } Y \text{ is } L$$

$$If C \text{ is } L \text{ and } D \text{ is } L \text{ then } Y \text{ is } L$$

2.1.1.3 추론 및 비퍼지화

여기서 수평, 수직 에지의 연속성에 대해서 위의 각 퍼지 추론 규칙을 이용하여 Max_Min 방법으로 추론한다.

$$\begin{aligned} \mu_{R_i}(C_m, D_m, Y_m) \\ = \min(\mu_C(C_i), \mu_D(D_i), \mu_Y(Y_i)) \\ = \max(\min(\mu_C(C_i), \mu_D(D_i), \mu_Y(Y_i))) \end{aligned} \quad (3)$$

각각의 추론 결과들 중 소속도가 가장 높은 값을 찾는다. 여기서 찾은 값은 아직 확정적인 값이 아니기 때문에 비퍼지화를 수행한다. 본 논문에서는 다음과 같은 무게 중심법을 이용한 비퍼지화 방법을 수행한다[10,11].

$$x^* = \frac{\sum_{i=1}^n m_i w_i}{\sum_{i=1}^n m_i} \quad (4)$$

여기서 x^* 은 비퍼지화의 출력값이며, m_i 는 각 규칙의 소속도이다. 그리고 w_i 는 각각의 규칙에 연관된 무게이다. 비퍼지화에 의한 최종적인 잡음의 평가 결과는 표 3과 같다.

표 3 - 최종 평가

최종 평가	평가 범위
비 잡음	$0 \leq x^* < 0.4$
잡음	$0.4 \leq x^* \leq 1.0$

수직 잡음이 제거 된 예지 영상에서 수직 방향 히스토그램 방법을 이용하여 식별자의 수직 블록을 검출한다. 검출된 식별자의 수직 블록에서 수평 방향 히스토그램을 적용하여 식별자의 수평 블록을 검출한다. 컨테이너의 식별자 영역 추출 과정은 그림 6과 같다.




그림 6 - 식별자 영역 추출 과정

2.2 컨테이너 개별 식별자 추출

추출된 식별자 영역에서 윤곽선 추적 알고리즘을 이용하여 개별 식별자를 추출할 때 그림 7와 같이 민바탕의 식별자의 경우에는 이진화 영상에서 개별 식별자의 추출이 가능하지만, 그림 8과 같이 흰바탕의 식별자의 경우에는 이진화 영상에서 개별 식별자를 추출할 수 없다.



그림 7 - 민바탕의 식별자 영역 및 추출 성공 영상



그림 8 - 흰바탕의 식별자 영역 및 추출 실패 영상

2.2.1 제안된 흰바탕 영상 처리

그림 8과 같이 흰바탕으로 구성된 식별자의 영역에 대해서는 식별자 영역을 이진화하고 반전한다. 그리고 원쪽에서 오른쪽으로, 위에서 아래로 스캔하면서, 검정색을 탐색한다. 탐색된 지점의 오른쪽의 지점 역시 검정색이면 탐색된 지점을 흰색으로 대체하고, 오른쪽 지점이 흰색이면 식별자의 수평 영역이 끝나는 지점까지 흰색을 대체한다. 그림 9의 아래 영상과 같이 식별자는 검정색으로, 바탕색은 흰색으로 처리한다.




그림 9 - 반전된 영상(위), 흰바탕 처리 후 영상(아래)

2.2.2 컨테이너 개별 식별자 추출

윤곽선 추적 알고리즘을 이용한 컨테이너 개별 식별자 추출 방법은 추출된 식별자 영역의 이진화




그림 10 - 윤곽선 추적을 위한 2x2 마스크

영상에서, 윤곽선 추적의 속도를 높이기 위해서 4방향 2x2마스크를 이용하여 윤곽선을 추적한다. 윤곽선 추적은 이진 영상에서 경계 픽셀을 만나기 전까지 원쪽에서 오른쪽으로, 위쪽에서 아래쪽으로

스캔한다.

그림 10은 4방향 윤곽선 추적에 사용된 2×2 마스크로 경계 픽셀을 만나면 시작점으로 선택하여 마스크를 x_k 에 위치시키고 a와 b에 대응하는 두 픽셀을 고려하여 마스크의 진행 방향을 표 4와 같이 설정하여 윤곽선을 추적한다[12].

표 4 - 2×2 마스크에 의한 a와 b의 진행방향



	a	b	x_{k+1}	y_{k+1}
전진	1	0	a	b
우측	0	1	b	y_k
우측	1	1	a	x_k
좌측	0	0	x_k	a

여러 줄로 구성된 컨테이너 수평 식별자 영역의 경우에는 식별자의 위치나 크기가 정형화되어 있지 않으므로 윤곽선 추출 마스크를 적용했을 때 개별 식별자들이 순서대로 추출되지 않는 경우가 발생한다. 또한 컨테이너 영상의 개별 식별자들은 모두 컨테이너의 외부에 표시되어 있기 때문에 기타 불필요한 잡음으로 인하여 이진화 과정에서 불필요한 정보가 포함되는 경우가 발생한다. 그러므로 추출된 영역이 개별 식별자인지 아닌지를 검증하고 추출된 개별 식별자들이 순서대로 추출되도록 한다.

컨테이너의 수평 식별자 영역에서 개별 식별자와 잡음을 구분하기 위하여 식(5)와 같이 유클리디언 거리 공식을 적용한다.

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (5)$$

개별 식별자를 ISO규격과 같이 4개의 영역 순으로 추출하기 위해서 식별자 영역의 첫 줄 4개의 식별자에 대해서 정렬을 수행하여 첫 번째 식별자를 찾는다. 첫 번째 식별자의 y좌표를 기준으로 모든 개별 식별자들의 y좌표가 첫 식별자 y좌표 크기의 $1/2$ 범위 안에 있는 개별 식별자들에 대해서 첫 식별자의 x와 y좌표를 기준으로 식 5을 적용하여 거리가 가장 가까운 순서대로 개별 식별자들을 추출한다. 윤곽선 추적 알고리즘을 이용하여 수직, 수평 식별자 영역에서 개별 식별자를 추출하는 과정은 각각 그림 11, 그림 12와 같다.



3. 개선된 퍼지 RBF 네트워크를 이용한 컨테이너 식별자 인식

본 논문에서는 퍼지 RBF 네트워크의 학습 성능을 개선하여 컨테이너 식별자 인식에 적용한다. RBF 네트워크의 중간층은 학습 패턴들을 클러스터링 하는 층이다. 이 중간층의 목적은 주어진 학습 패턴들을 유사한 클러스터들로 분류하는 것이다. 여기서 유사하다는 것은 학습 패턴들에 대한 특징 벡터 공간 사이에서 한 클러스터 내의 벡터들 간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터에 속하고 정해진 반경 내에 존재하지 않으면 다른 클러스터에 속한다.




그림 13 – 제안된 학습 모형

그러나 정해진 반경 내에 존재하지 않으면 다른 클러스터에 속하게 된다. 정해진 반경 내에서 클러스터링 하는 것은 잘못된 클러스터를 선택하여 출력층의 입력값으로 구성하므로 RBF 네트워크의 학습 성능을 저하시킨다. 또한 학습 과정에서 중간층의 노드는 그 노드의 목표 벡터를 알 수 없기 때문에 출력층 노드의 오차를 역으로 중간층 노드들로 책임 분담(credit assignment)하는 방법을




그림 14 – 제안된 퍼지 RBF 네트워크의 학습 알고리즘

사용하여 정체현상이 일어나므로 학습 시간이 많이 소요된다. 따라서 본 논문에서는 중간층에 퍼지 C-Means 알고리즘을 적용하여 소속도가 가장 큰 노드를 승자 노드로 선택하여 출력층으로 전달하는 학습 구조를 제안한다. 그리고 중간층과 출력층 사이의 학습으로는 일반화된 델타 학습 방법을 적용하고 학습 시간을 개선하기 위하여 delta-bar-delta 알고리즘을 적용한다. 제안된 학습 모형은 그림 13과 같다.

제안된 퍼지 RBF 네트워크의 학습 방법은 다음과 같이 요약할 수 있다.

1. 입력층과 중간층의 연결 구조는 퍼지 C-Means 알고리즘과 같고, 퍼지 C-Means 알고리즘의 출력층이 제안된 학습 구조의 중간층이다.
2. 중간층의 노드는 각 클래스를 의미한다. 따라서 전체적으로는 완전 연결 구조이나 목표 벡터와 실제 출력 벡터와 비교하여 역전파 시킬 때는 대표 클래스와 연결된 가중치만 역전파 하는 승자 노드 방식을 채택한다.
3. 중간층의 승자노드는 퍼지 C-Means 알고리즘에서 소속도가 가장 큰 중간층의 노드를 승자 노드로 선택한다.
4. 중간층과 출력층 사이의 학습 구조로는 일반화된 델타 학습 방법을 적용하여 지도 학습으로 동작한다.
5. 학습 성능을 개선하기 위하여 일반화된 델타 학습에 delta-bar-delta 알고리즘을 적용하여 학습률을 동적으로 조정하는데 목표 벡터와 출력 벡터의 차이가 0.1 보다 적으면 정확성으로 정의하고 크면 부정확성으로 정의하여 총 패턴의 정확성의 수가 부정확성의 수보다 크거나 같은 경우에만 delta-bar-delta 알고리즘을 적용한다. 그 이유는 학습과정에서 경쟁 단계로 인하여 초기 포화 현상(premature situation)이 발생하여 오류가 거의 일정하게 유지되면서 학습이 진전되지 않거나 진동하는 부분을 방지하기 위해서이다. 따라서 제안된 알고리즘은 그림 14와 같다.

4. 실험 및 결과 분석

실험 환경은 Intel Pentium-IV 2GHz CPU와 256MB RAM이 장착된 IBM 호환 PC상에서 C++빌더 6.0으로 구현하였다. 640×480 크기의 컨테이너 영상 45개를 수집하여 성능 평가 실험에 적용하였다. 그림 15의 컨테이너 영상에 대하여 개별 식별자를 추출한 결과는 그림 16과 같고 인식 결과는 그림 17과 같다.

제안된 식별자 추출 방법을 적용하여 45개의 컨테이너 영상에서 45개의 식별자 영역이 모두 추출되었고, 추출된 식별자 영역에서 표 5와 같이 180개의 개별 문자와 315개의 개별 숫자가 모두 추출 되었다.



그림 15 - 컨테이너 사진

C R X U 4 0 5 1 9 0 6

그림 16 - 개별 문자 추출 결과

CRXU
4051909

그림 17 - 인식 결과

표 5 - 개별 코드 추출 결과

개별 코드 추출된 수	문자	숫자
기존 방법[13]	152/180	266/315
제안된 방법	180/180	315/315

표 5에서와 같이 기존의 개별 식별자 추출 방법은 그림 8과 같은 흰바탕의 식별자 영역에 대해서는 개별 식별자를 추출하는데 실패하였다. 그러나 제안된 개별 식별자 추출 방법은 흰바탕 영상 처리 방법을 적용하여 기존의 방법에서 추출에 실패했던 부분을 개선하므로 개별 식별자의 추출률이 개선되었다.

제안된 퍼지 RBF 네트워크의 학습 성능을 분석하기 위하여 추출된 495개의 개별 코드 중에서 문자 40개와 숫자 40개를 기존의 ART2 기반 RBF 네트워크, 기존의 퍼지 RBF 네트워크와 제안된 퍼지 RBF 네트워크에 적용하여 학습 및 인식 성능을 비교 분석하였다. 제안된 퍼지 RBF 네트워크의 파라미터 설정은 표 5와 같다.

표 5 - 제안된 퍼지 RBF 네트워크의 파라미터

파라미터 학습방법	α	μ	κ	γ	β
제안된 퍼지 RBF 네트워크	0.9	0.5	0.05	0.5	0.7

개선된 RBF 네트워크에서 ε 는 0.1로 설정하였다.

표 5에서 α 는 학습률, μ 는 모멘텀 계수, κ, γ, β 는 delta-bar-delta 상수이다.

기존 ART2 기반 RBF 네트워크와 퍼지 RBF 네트워크에서 학습률과 모멘텀을 각각 0.5와 0.6으로 설정하였다. 그리고 제안된 퍼지 RBF 네트워크에서 초기 학습률은 0.5로 설정하였고 총 패턴의 부정확성의 수가 0보다 적거나 같은 경우에만 학습을 종료하였다.

표 6 - 학습 방법에 따른 학습 결과

평가방법 학습방법	패턴 종류	중간층 노드수	Epoch 수	TSS	인식 개수
ART2 기반	숫자	13	950	0.067065	298
	문자	24	1652	0.081230	177
퍼지 RBF 네트워크	숫자	10	822	0.82591	295
	문자	20	1997	0.84208	177
제안된 퍼지 RBF 네트워크	숫자	10	526	0.85005	301
	문자	20	1348	0.87521	177

표 6에서 알 수 있듯이 제안된 퍼지 RBF 네트워크가 ART2 기반 RBF 네트워크 보다 학습 속도가 개선되었다. ART2 기반 RBF 네트워크는 ART2의 단점인 경계변수 설정에 따라 중간층의 노드의 수가 증가하거나 감소하였다. 따라서 표 6에서는 경계 변수를 0.15로 설정하는 것이 최적으로 나타났다. 퍼지 RBF 네트워크와 제안된 퍼지 RBF 네트워크에서는 퍼지 C-Means 알고리즘을 중간층으로 적용하므로 중간층의 노드의 소속도에 따라서 클러스터를 생성하므로 ART2 기반 RBF 네트워크보다 중간층의 노드가 적게 생성되었다.




그림 15 - 학습 방법에 따른 TSS 변화율

그러나 학습 패턴이 이진 패턴으로 구성되므로 퍼지 RBF 네트워크에서는 중간층의 노드를 클러스터링하는 과정에서 학습 시간이 비교적 많이 소요되었다. 제안된 퍼지 RBF 네트워크에서는 학습 과정에서 경쟁 단계에 해당하는 조기포화 현상을 줄이기 위하여 학습률을 동적으로 조정하므로 기존의 퍼지 RBF 네트워크 보다 학습 시간이 적게 소요되었다. 그림 15는 기존의 방법들과 제안된 방법들 간의 오차 제곱 합 곡선을 나타내었다. 그림 15에서와 같이 제안된 방법이 기존의 방법들보다 초기의 수렴 속도가 빠르고 학습 시간이 적게 소요되는 것을 확인할 수 있다.

결론

본 논문에서는 Canny 마스크를 이용하여 컨테이너 영상의 에지를 검출하고, 검출된 에지 정보에서 영상 획득 시 발생한 외부 광원에 의해 수직으로 길게 발생하는 잡음들을 퍼지 추론 방법을 적용하여 잡음을 제거한 후에 수직 블록과 수평 블록을 검출하여 컨테이너의 식별자 영역을 추출하였고 이진화 하였다. 이진화된 식별자 영역에 대해 검정색의 빈도수를 이용하여 흰바탕과 민바탕을 구분하고 윤곽선 추적 알고리즘을 적용하여 개별 식별자를 추출하였다. 추출된 개별 식별자의 인식은 개선된 퍼지 RBF 네트워크를 제안하여 적용하였다. 제안된 퍼지 RBF 네트워크는 퍼지 C-Means 알고리즘을 중간층으로 적용하였고 중간층과 출력층의 학습에는 일반화된 엘타 학습 방법과 Delta-bar-Delta 알고리즘을 적용하여 학습 성능을 개선하여 개별 식별자 인식에 적용하였다.

45개의 컨테이너 영상에 대해 제안된 방법을 실험한 결과, 180개의 개별 문자 코드와 315개의 개별 숫자 코드가 모두 추출되었고 제안된 퍼지 RBF 네트워크가 기존의 ART2 기반 RBF 네트워크와 퍼지 RBF 네트워크 보다 학습 성능이 개선되었고 개별 코드 인식에도 효율적인 것을 확인하였다.

참고문헌

- [1] Freight Containers-Coding, Identification and marking [ISO 6346 1995(E)]
- [2] 김낙빈, “형태학적 연산을 이용한 운송 컨테이너 여상의 문자 분할,” 한국멀티미디어학회 논문지, 제2권, 제4호, pp.390-399, 1999.
- [3] 김광백, 김영주, “동적인 임계화 방법과 개선된 학습 알고리즘의 신경망을 이용한 차량 번호판 인식,” 정보처리학회 논문지, 제9-B권, 제1호, pp.119-128, 2002.
- [4] M. L. Kothari, S. Madnani and R. Segal, “Orthogonal Least Square Learning Algorithm Based Radial Basis Function Network Adapive Power System Stabilizer,” Proceeding of IEEE SMC, Vol.1 pp.532-547, 1997.
- [5] 황영섭, 방승양, “RBF 신경망 분류기의 효율적 구성 방법,” 한국정보과학회논문지, Vol.21, No.5, pp.451-460, 1997.
- [6] C. Panchapakesan, D. Ralph and M. Palaniswami, “Effects of Moving the Centers in an RBF Network,” Proceedings of IJCNN, Vol.2, pp..1256-1260, 1998.
- [7] K.B.Kim, S.W.Jang and C.K.Kim, “Recognition of Car License Plate by Using Dynamical Thresholding Method and Enhanced Neural Networks,” Lecture Notes in Computer Science, LNCS 2756, pp.309-319, 2003.
- [8] R.C.Gonzalez and R.E.Woods, Digital Image Processing, Addison Wesley, 1992.
- [9] Gregory A, Baxes, Digital Image Processing, John Wiley and Sons Inc, 1994.
- [10] L.Zadeh, “The Concept of a Linguistic Variable and Its Application to Approximate Reasoning,” Inf. Science, Vol.8, No.3, pp.199-249, 1975.
- [11] Duvois D, and Parade. H, Fuzzy Sets and Systems : Theory and applications, Academic Press, 1980.
- [12] 김성영, 권태균, 김민환, “추적에 의한 단순화된 윤곽선 추출,” 한국멀티미디어학회 춘계발표논문집, 제2권, 제1호, pp.356-361, 1999.
- [13] 주이환, 김광백, “퍼지 추론 규칙을 이용한 컨테이너 영상의 식별자 추출,” 한국멀티미디어 학회 춘계발표논문집, pp.497-501, 2004.