

## 퍼지신경망을 이용한 도로 씬의 차선정보의 잡음도 판별

\*이운근\*, 백광렬\*, 권석근\*\*, 이준웅\*\*\*

\*부산대학교 전자공학과, \*\*울산대학교 전기공학과, \*\*\*전남대학교 산업공학과

### Fuzzy Neural Network-Based Noisiness Decision of Road Scene for Lane Detection

<sup>†</sup>Un Kun Yi\*, Kwang Ryul Baek\*, Seok Geon Kwon\*\*, Joon Woong Lee\*\*\*

\*Pusan National University, \*\*Ulsan University, \*\*\*Chonnam National University

**Abstract** - This paper presents a Fuzzy Neural Network (FNN) system to decide whether or not the right information of lanes can be extracted from gray-level images of road scene. The decision of noisy level of input images has been required because much noises usually deteriorates the performance of feature detection based on image processing and lead to erroneous results. As input parameters to FNN, eight noisiness indexes are constructed from a cumulative distribution function (CDF) and proved the indexes being classifiers of images as the good and the bad corrupted by sources of noise by correlation analysis between input images and the indexes. Considering real-time processing and discrimination efficiency, the proposed FNN is structured by eight input parameters, three fuzzy variables and single output. We conduct much experiments and show that our system has comparable performance in terms of false-positive rates.

## 1. 서 론

CCD 카메라로 부터 입력된 도로 씬(scene)에서 주행 및 상황판단을 위한 차선정보는 영상처리를 거쳐야만 추출되는 정보이며, 도로환경은 여러 가지 랜덤(random)한 잡음요인에 의하여 심지어는 사람의 육안으로도 차선식별이 어려운 경우가 있다. 예를 들면, 도로가 심하게 마모된 경우, 강우 시, 풀게이트 진출입시, 앞차에 의한 차선 가림 또는 터널의 입출구에서 광량의 급격한 변화가 발생할 때 등이 컴퓨터에 의한 차선정보 추출이 어려운 경우로 볼 수 있다. 만약 추출된 차선정보에 의존하여 제어를 행하는 시스템에서 차선정보 추출이 어려운 상황이 발생했을 때 이를 인지하지 못하고, 잘못 추출된 차선정보를 토대로 행한 경보 또는 액추에이팅 결과는 신뢰성을 보장할 수가 없다. 따라서, 시스템이 사전에 이러한 상황 즉, 차선정보 추출이 어려운 정보로부터 추출된 결과로 제어를 행하는 오류를 피하기 위한 판별 제어기의 구성은 시스템에 신뢰성 향상을 도모하기 위해 필수적이다.

본 논문에서는 차선정보 추출 이전에 입력된 도로 씬의 차선정보에 대한 잡음도 즉, 차선정보 추출에 대해 예측이 양호한 정도를 미리 판별하기 위한 제어기를 구현한다. 구현된 제어기는 다양하고 가변적인 도로환경에 대처하는 능력을 가지기 위해 지능(intelligence)이 가미되어야 하며, 본 논문에서는 인간의 행동을 학습하여 일반화 능력이 있는 신경망(neural network)과 인간의 언어적 행동을 정량화 하기 위해 퍼지제어(fuzzy control)의 두 가지 방법을 혼합한 퍼지신경망(fuzzy neural network)을 이용한다.[2, 5] 구현된 퍼지신경망의 입력 파라미터는 입력된 이미지에 대한 에지의 방향성분을 누적시켜 구축한 누적분포함수에서 추출한 8개의 잡음도 지수(Noisiness Index, NI)이며, 이들의 지수는 입력 이미지와의 상관관계 해석을 통하여 차선정보 예측과 깊은 상관성을 가지고 있음을 밝힌다. 퍼지신경망의 구조는 실시간 성 및 식별성을 고려하여 8개의 입력, 각 입력에 대한 3개의 퍼지변수, 그리고 1개의 출력률을 갖는 구조로 하였으며, 학습 후 차선정보 추출 가능성에 대한 유용성을 실험을 통하여 검증한다.

## 2. 차선정보의 잡음도 판별 알고리즘

### 2.1 전체 알고리즘의 구성

제안된 전체 알고리즘은 그림 1과 같다. 그림에서와 같이 CCD 카메라에 의해 입력된 영상은  $3 \times 3$  소벨(Sobel) 연산자를 이용하여 에지를 추출하고, 추출된 에지는 크기(magnitude)와 방향(direction)성분을 갖는다.[4] 특히, 도로영상에 대한 에지추출시 차선표식의 경계부가 다른 곳에 비해 뚜렷하게 나타남을 알 수 있으며, 본 논문에서는 이러한 특징을 이용하여 방향에 대한 누적분포함수(cumulative distribution function, CDF) 및 연속된 영상에 대한 평균누적분포함수(averaged CDF, ACDF)를 구축한다.[1, 3] 이렇게 구축된 CDF 및 ACDF에서 차선정보 추출 가능성을 판별하기 위한 특징치를 편의상 잡음도 지수(Noisiness Index, NI)라 명하고 이를 각각의 차선에 대해 추출하여 퍼지신경망에 입력한다. 그리고, 퍼지신경망의 최종출력은 차선정보 추출 양호, 흐릿 및 불가에 대한 상수값이다.

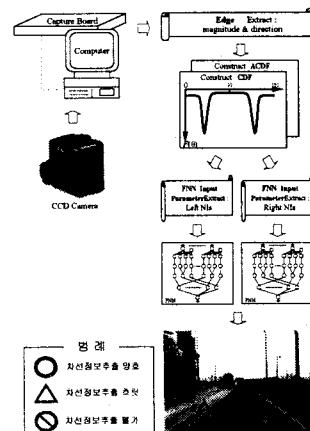


그림 1. 전체 알고리즘의 구성

### 2.2 영상의 전처리

본 논문에서는 그림 2에 나타낸 것과 같이 입력된 영상에서 차선정보의 추출 가능성을 판단하기 위한 퍼지신경망의 입력 파라미터 추출을 위하여 에지 픽셀들의 크기를 방향에 대하여 누적시켜 얻은 누적분포함수(cumulative distribution function, CDF)를 구축하였으며, 다음의 식(1)과 같다.

$$F(\theta) = \sum_{n(\theta)} \nabla f(x, y) \quad (1)$$

여기서,  $\theta$ 는 에지의 각도  $a(x, y)$ 를 가리키며,  $\nabla f(x, y)$ 는 에지의 크기를 나타낸다. 그리고,  $n(\theta)$ 는  $a(x, y) = \theta$ 를 갖는 에지 픽셀들의 수량이며, 이를 얻기 위하여 에지의 방향  $a(x, y)$ 를  $0^\circ$ 부터  $180^\circ$  사이에서  $1^\circ$  단위로 양자화 하였다.

그리고, CDF는 단일영상에서 얻어진 합수이므로 잡음이 많이 내재된 영상에서는 잡음의 영향으로 차선방향에 대응되는 각도 균방에서 누적값이 뚜렷하게 나타나지 않을 수도 있다. 따라서 연속된  $N$ 개의 영상에 대하여 이동평균의 원리에 따라 다음의 식(2)와 같이 누적분포함수를 다시 누적시키면 잡음의 효과는 거의 사라지고 차선의 방향성이 보다 명확하게 나타난다. 구축된 평균 누적분포함수(averaged CDF, ACDF)는 다음의 식(2)와 같다.

$$\hat{F}(\theta) = \frac{1}{N}(F_k(\theta) + F_{k-1}(\theta) + \dots + F_{k-N+1}(\theta)) \quad (2)$$

여기서,  $k$ 는 현재 프레임을 나타내며,  $N$ 은 실험적으로 5로 하였다.

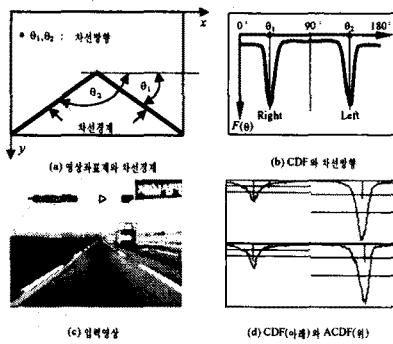


그림 2. CDF와 차선방향

이상에서와 같이 구축된 CDF와 ACDF는 그림 2에 나타낸 것과 같이 차선방향에 해당되는 각도의 근방에서 큰 값을 갖는다. 이는 차선방향은 급격한 변화없이 연속성을 갖는 반면 차선 이외의 객체들은 이러한 특성을 갖고 있지 않기 때문이다. 그러므로 구축된 CDF와 ACDF는 차선정보 추출을 위한 많은 정보를 포함하고 있음을 알 수 있다. 편의상 현재 입력된 단일영상에 대하여 구축한 CDF를 측정함수,  $N$ 개의 연속 영상에 대하여 구축한 ACDF를 모델함수라고 명한다.

### 2.3 퍼지신경망의 입력 파라미터 추출

차선정보 추출의 가능성을 판별하기 위한 퍼지신경망의 입력 파라미터 즉, 잡음도 지수  $NI$ 는 측정함수와 모델함수를 이용하여 왼쪽, 오른쪽 차선에 대하여 각각 8개의 파라미터를 추출하여 확률적인 분포로 나타내었다. 추출한 잡음도 지수  $P_1 \sim P_6$ 의 값은 1에 가까울수록 차선정보 추출은 양호하며, 0에 가까울수록 차선정보 추출 불가함을 나타낸다.

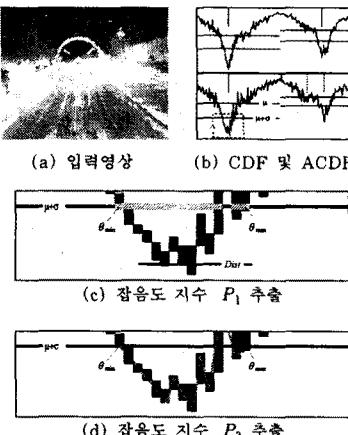


그림 3. 퍼지신경망의 입력 파라미터 추출(I)

잡음도 지수  $P_1$ 은 “차선정보 추출이 어려운 영상에 대한 측정함수 모양은 그림 3의 (b), (c)처럼 노이즈 성분이 많고, 측정함수의 평균과 최대값(그림 (c)에  $Dist$ 로 표시) 사이의 차이가 작을 것이다”라는 가정을 토대로 다음의 식(3)과 같이 정의하였다.

$$N = \frac{n(S_1)}{\theta_{\max} - \theta_{\min}}, S_1 = \{\theta | F(\theta) > \mu + \sigma, \alpha < \theta < \beta\}$$

$$Dist = \frac{1}{n} \sum_{i=1}^n F(\theta_i), S_2 = \{F_i(\theta_i) > F_{i+1}(\theta_k), \theta_i, \theta_k \in S_1\}$$

$$D = 1 - \frac{\mu}{Dist}$$

$$P_1 = \frac{1}{2}(N + D) \quad (3)$$

여기서  $\mu$ 는 측정함수의 평균값,  $\sigma$ 는 표준편차를 나타낸다.  $n(S_1)$ 은  $S_1$  요소의 개수를 나타낸다. 그리고,  $\alpha, \beta$ 는 오른쪽 차선에 대한 차선정보 추출 가능성을 판별하기 위한 파라미터 추출시 각각  $0^\circ, 90^\circ$ 이며, 원쪽 차선인 경우  $90^\circ, 180^\circ$ 이다.

잡음도 지수  $P_2$ 는 식(3)의  $P_1$ 과 같으나, 사용된 함수만 다르다. 다른 점은  $P_1$ 은 측정함수를 사용하고,  $P_2$ 는 모델함수를 사용한다.

잡음도 지수  $P_3$ 은 “차선정보 추출이 어려운 영상의 함수 모양은 그림 3의 (d)처럼 노이즈의 빈도 수가 많을 것이다”라는 가정을 토대로 다음의 식(4)와 같이 정의하였다.

$$P_3 = 1 - \frac{n(S_3)}{\theta_{\max} - \theta_{\min}}, S_3 = \{\theta | Q(\theta+1) - Q(\theta) \neq 0\},$$

$$Q(\theta) = \begin{cases} 1 & F(\theta+1) > F(\theta), \theta_{\min} \leq \theta \leq \theta_{\max} \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

잡음도 지수  $P_4 \sim P_6$ 은 그림 4 및 식(5)~(7)에 나타낸 것과 같이 “차선이 없을 것이라고 기대한 영역에 차선이 있을 것이라고 기대한 영역보다 차선성분이 강하게 나타나는가”에 대한 지수이다. 예를 들면, 잡음도 지수  $P_4, P_5$ 는 차선 마크가 없는 곳, 철로 전널목, 틀케이트 입출구, 차선의 마크가 마모된 경우 등이 차선이 없을 것이라고 기대하는 영역에 예지 성분이 강하게 나타날 수 있는 경우이다. 그리고,  $P_6$ 는 차선 이외의 표식이 있을 경우, 앞 차량에 의해 차선이 가려져 있을 경우 등이다. 또한 직선 도로에서 차량이 차선과 차량의 중심(카메라의 광축)이 일치하여 주행하는 경우인데 이 경우는 거의 나타나지 않는다.

$$P_4 = \frac{1}{2} \left( 1 + \frac{\mu_{R_0} - \mu_{R_r}}{\mu_{R_0} + \mu_{R_r}} \right) \quad (5)$$

$$P_5 = \frac{1}{2} \left( 1 + \frac{(\mu + \sigma)_{R_0} - (\mu + \sigma)_{R_r}}{(\mu + \sigma)_{R_0} + (\mu + \sigma)_{R_r}} \right) \quad (6)$$

$$P_6 = \frac{1}{2} \left( 1 + \frac{\mu_{R_1} - \mu_{R_r}}{\mu_{R_1} + \mu_{R_r}} \right) \quad (7)$$

여기서,  $R_0$ 은  $0^\circ \sim 15^\circ$ ,  $R_1$ 은  $75^\circ \sim 105^\circ$ ,  $R_r$ 은  $15^\circ \sim 75^\circ$ 이며, 입력 영상의 오른쪽 차선에 해당된다. 왼쪽 차선에 대한 잡음도 지수는  $R_r$  대신에  $R_1$ 을  $R_0$  대신에  $R_2$ 를 사용하면 된다. 여기서  $R_1$ 은  $105^\circ \sim 165^\circ$ ,  $R_2$ 는  $165^\circ \sim 180^\circ$ 이다.

잡음도 지수  $P_7, P_8$ 은 각각 식(5), (6)의  $P_4, P_5$ 와 같으나, 사용된 함수만 다르다. 다른 점은  $P_4, P_5$ 는 측정함수를 사용하고,  $P_7, P_8$ 는 모델함수를 사용한다.

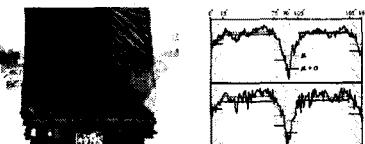


그림 4. 퍰지신경망의 입력 파라미터 추출(II)

### 2.4 입력 파라미터의 상관성 평가

퍼지신경망에 입력되는 특정 파라미터 즉, 제안한 잡음도 지수가 평가하고자 하는 차선정보 추출 가능성과 깊은 상관이 있을수록 퍼지신경망의 추론성능은 향상된다. 따라서, 본 논문에서는 제안한 입력 파라미터의 유효성을 평가하기 위해 다양한 환경의 영상 즉, 도로가 심하게 마모된 경우, 강우 시, 틀케이트 진출입 시, 전방차량에 의해 차선이 가려져 있는 경우 또는 터널 입출구에서 순간적으로 조도차가 심하게 발생하는 경우, 도로바닥에 표식 및 글자가 새겨져 있는 경우, 곡선 도로, 잡음이 많고 도로폭이 좁은 교외 도로 등에 대하여 차선정

보 추출 가능성을 차선정보 추출양호 및 불가로 구분하고, 또한 잡음도 지수  $P_1 \sim P_8$ 를 각각의 차선에 대하여 구하였다. 사용된 영상은 총 400개를 랜덤하게 선별하였으며, 이들 영상에 대한 잡음도 지수의 분포는 그림 5와 같으며, 이는 이들의 상관관계를 나타낸다.

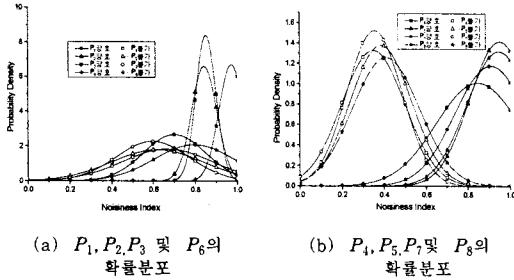


그림 5. 잡음도 지수의 확률분포

그림 5의 (b)에 나타낸 잡음도 지수  $P_4, P_5, P_7$  및  $P_8$ 의 분포는 차선정보 추출 양호, 또는 불가에 대해 큰 변별력을 가짐을 알 수 있다. 이에 반해 그림 5의 (a)에 나타낸 잡음도 지수  $P_1, P_2, P_3$  및  $P_6$ 의 분포는 변별력이 뚜렷하지 못하다. 그러나 잡음도 지수  $P_4, P_5, P_7$  및  $P_8$ 의 조합만으로 판별하기에 어려운 영상에 대하여 정확한 판별을 위한 실마리를 제공한다. 따라서 잡음도 지수  $P_1 \sim P_8$ 의 조합에 의한 판단은 신뢰성 있는 정보를 제공하며, 이는 앞 절에서 정의한 퍼지신경망의 입력 파라미터의 유효성을 검증할 수 있다.

### 3. 퍼지신경망의 구성 및 학습

#### 3.1 퍼지신경회로망의 구성

퍼지신경망은 퍼지규칙(fuzzy rule)과 퍼지추론 과정을 신경망으로 구현한 것으로 본 논문에서 사용된 퍼지신경망의 구조는 Horikawa가 제안한 방법 중 Type II를 사용하였다.(5) 이는 TSK 모델의 특별한 경우이며 후건부 소속 함수를 상수값으로 표현하는 퍼지신경망으로 비퍼지화기를 추론기에 포함시킨 형태이다. 그럼 6은 차선정보 추출 가능성을 판별하기 위한 잡음도 지수  $P_1 \sim P_8$  즉, 8개의 입력과 각 입력에 대한 퍼지변수는 '차선정보 추출 양호', '흐릿', '불가'의 3개, 그리고 하나의 출력력을 갖는 퍼지신경망을 나타낸다.

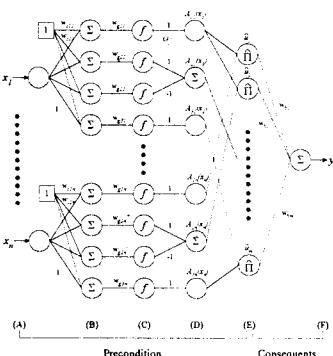


그림 6. 퍼지신경망의 구조

그림 6에서 ①의 유닛(unit)은 일정 값 1을 출력하는 바이어스 유닛이며, ⑦기호를 갖는 유닛은  $C^{\infty}$ 급의 소속 함수를 실현하고, 또한 가우스 기저와 달리 소속 함수의 좌우를 비대칭으로 조정할 수 있다는 점에 기인하여 시그모이드 함수를 이용하였으며 이를 내부함수로 가진다. 그러므로 전건부 (C)층 유닛의 출력  $O_i^c$ 는 결합하중  $w_c$ ,  $w_g$ 를 이용하여 다음의 식 (8)과 같이 된다.

$$O_i^c = \frac{1}{1 + \exp(-w_g(x_i + w_c))} \quad (8)$$

여기서, 결합하중  $w_c$ ,  $w_g$ 는 각각 시그모이드형 소속함수의 중심위치 및 기울기를 결정한다.

그리고, 본 논문에서 사용되는 퍼지규칙은 다음과 같은 퍼지합의(fuzzy implication)로 표현된다.

$$R^i : \text{IF } x_1 \text{ is } A_{i,1} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{i,n}, \text{ THEN } y_i \text{ is } f_i \quad (i=1, 2, \dots, n, i_1, \dots, i_n = 1, 2, 3) \quad (9)$$

여기서,  $R^i$ 는  $i$ 번째 퍼지규칙,  $x_1, \dots, x_n$ 은 입력,  $A_{i,1}, \dots, A_{i,n}$ 은 퍼지변수, 그리고  $y_i$ 는  $i$ 번째 규칙의 출력이며 이때  $f_i$ 는 후건부 상수이다.

퍼지규칙의 전건부 적합도는 (E)층에서 결정된다. 이때 입력공간(input space)은 (D)층의 소속함수에 의해 퍼지 분할(fuzzy partition)되어 각각의 퍼지 부공간(fuzzy subspace)에서의 퍼지규칙의 진리값은 product-operation 규칙에 따라 다음과 같이 계산된다.

$$u_i = \prod_{j=1}^n u_{A_{i,j}}(x_j) \quad (10)$$

$$\hat{u}_i = \frac{u_i}{\sum_{k=1}^m u_k} \quad (11)$$

여기서,  $u_i$ 는  $i$ 번째 규칙  $R^i$ 의 전건부 적합도를 의미하며.

$\hat{u}_i$ 는  $u_i$ 의 정규화된 값으로 (E)층의 출력이다. 또한  $m$ 은 퍼지규칙의 개수를 나타내며, 이는 각 입력에 대한 소속함수 개수의 곱이다. 본 논문의 경우는 6,561개로 (E)층 유닛의 개수에 해당한다. 그리고, 퍼지신경망의 후건부는 (E)~(F)층으로 표현되며, 실제 제어량 발생을 위한 최종 추론값을 계산한다. 이는 다음의 식 (12)와 같다.

$$y^* = \frac{\sum_{i=1}^m u_i f_i}{\sum_{i=1}^m u_i} = \sum_{i=1}^m \hat{u}_i f_i \quad (12)$$

여기서, 입력에 대한 최종 추론값  $y^*$ 은 명확한 값(crisp value)으로 본 논문에서는 차선정보 추출 가능성을 나타낸다.

#### 3.2 퍼지신경망의 학습

퍼지신경망에서는 결합하중을 학습에 의해 변화시킴으로서 퍼지규칙의 동정과 소속함수의 모양을 조정할 수 있다. 학습 알고리즘에는 역전파 알고리즘을 이용하며, 그림 7은 퍼지신경망의 학습법을 나타낸다.

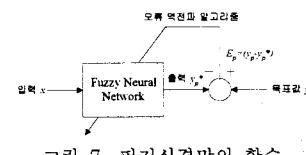


그림 7. 퍼지신경망의 학습

퍼지신경망의 학습 데이터가 주어졌을 때 출력오차  $E_p$ 가 다음과 같다고 정의한다.

$$E_p = \frac{1}{2} (y_p - y_p^*)^2 \quad (13)$$

여기서,  $y_p$ 는  $p$ 번째 학습 데이터의 목표값,  $y_p^*$ 는  $y_p$ 에 대한 퍼지신경망의 추론값이다. 이 출력오차  $E_p$ 를 감소시키기 위해서  $E_p$ 를 편미분하여 신경망의 결합하중  $w$ 를 체계적으로 변화시켜 입출력 관계를 학습시킨다. 결합하중의 변화량  $\Delta w$ 를 역전파 알고리즘에 의하여 구하면 다음의 식 (14)와 같다.

$$\Delta w_{bi} = -\eta \frac{\partial E_p}{\partial w_{bi}} \quad (14)$$

마찬가지로 결합하중  $w_c$ ,  $w_g$ 의 갱신량도 동일한 방법으로 구할 수 있다.

### 4. 실험 및 결과

#### 4.1 퍼지신경망의 학습결과

퍼지신경망의 경우 입력수가 많을수록 결합하중이 기하급수적으로 증가하기 때문에 본 논문에서는 실시간성 및 판별성을 고려하여 입력수를 8개 즉, 잡음도 지수  $P_1 \sim P_6$ 로 하였다. 그리고, 출력수는 1개로 차선정보 추출 가능성을 출력하며, 0(차선정보 추출 불가)과 1(차선정보 추출 양호)사이의 값을 갖는다. 학습에 사용된 데이터는 200개로 다양한 도로환경에 대하여 선별하였으며, 이를 샘플 영상은 정보추출 양호 27.6%, 정보추출 흐릿 33.9%, 정보추출 불가 38.5%로 구성되었다. 학습 완료 정도를 판단하기 위해 사용된 오차식은 다음의 식(15)와 같다. 이는 퍼지신경망의 실제 출력값과 목표값과의 차이를 누적한 값이며, 본 논문에서는 학습 완료시점의 오차가 0.0361189이었다.

$$E = \sum_p E_p, \quad (15)$$

여기서,  $p$ 는 학습 데이터 수를 나타낸다.

그리고, 퍼지신경망의 초기 결합하중에 의한 퍼지변수의 소속함수와 학습을 수행한 후의 소속함수를 그림 8에 나타낸다. 초기의 후진부 결합하중은 모두 0으로 하여 학습을 수행하였다.

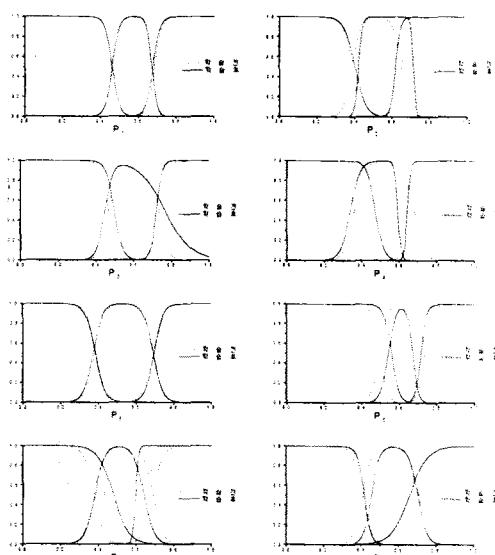


그림 8. 차선정보 추출 가능성 판별을 위한 소속함수

#### 4.2 차선식별 결과

차량내에 설치된 흑백 CCD 카메라로 전방의 주행환경을 촬영하여 비디오 테이프에 녹화하고, 비디오 플레이어로 이를 재생하여 컴퓨터에 설치된 이미지 캡쳐보드로 영상을 획득하였다. 실험에 사용된 영상의 크기는 160×120과 320×240의 두 종류로 하였다. 획득된 영상은 Visual C++ 환경 하에서 처리하였다.

학습이 완료된 퍼지신경망 제어기에 학습에서 제외된 영상을 대상으로 차선정보 추출 가능성에 대한 인식 실험을 하였고, 실험에는 두 가지로 나누어 수행하였다. 하나는 영상의 크기를 160×120으로 한 경우이고, 또 하나는 320×240 영상을 이용한 경우이다. 이를 비교하면 영상크기에 대한 잡음도 지수의 민감도를 확인할 수 있을 것이다.

사용된 영상 데이터는 160×120인 경우 총 4,563개로 차선정보 추출 양호 49.8%, 흐릿 33.5%, 불가 16.7%로 구성되고, 320×240인 경우는 총 6,832개로 차선정보 추출 양호 52.0%, 흐릿 30.8%, 불가 17.2%로 구성되었다. 이를 이용한 차선정보 추출 가능성에 대한 실험결과는 표 1과 2에 나타낸다.

실험결과 160×120 영상에 대해서는 전체적으로 95%의 판별력을, 그리고 320×240 영상에 대해서는 99%이상의 판별력을 갖는다. 특히, 160×120 영상에 대한 판별력이 320×240 영상에 비해 다소 떨어지는 이유는 영상의 전처리 과정 중 측정함수와 모델함수를 구축할 때 함수의 모양이 둔감해지며, 이는 양자화문제와 영상 처리 영역의 축소로 인한 정보 손

실에 기인한 것으로 판단된다.

한편 320×240 영상에 대한 실험결과를 살펴보면 정보추출 불가에 해당하는 영상은 100% 정보추출 불가로 분류해 냈을 수 있는데 이는 앞에서 정의한 잡음도 지수가 차선정보 추출을 판별하기에 유용한 정보임을 나타낸다. 또한 구현한 퍼지신경망 제어기의 유연하고 지적인 판단이 이루어지고 있음을 알 수 있다.

표 1. 160×120 영상에 대한 실험 결과

판별 정도	양호		흐릿		불가	
	영상수	판별률 (%)	영상수	판별률 (%)	영상수	판별률 (%)
양호 (2,275)	2,137	93.9	133	5.9	5	0.2
흐릿 (1,527)	82	5.4	1,427	99.4	18	1.2
불가 ( 761)	0	0.0	7	0.91	754	99.1

표 2. 320×240 영상에 대한 실험 결과

판별 정도	양호		흐릿		불가	
	영상수	판별률 (%)	영상수	판별률 (%)	영상수	판별률 (%)
양호 (3,552)	3,513	98.9	39	1.1	0	0.0
흐릿 (2,104)	17	0.8	2,087	99.2	0	0.0
불가 (1,176)	0	0.0	0	0.0	1,176	100.0

## 5. 결 론

본 논문에서는 입력된 도로 선의 차선정보 추출 가능성을 미리 분류하여 그 정보를 차선정보 추출 처리부에 넘겨 신뢰성 있는 인식결과를 도출할 수 있도록 차선정보 추출 가능성 판별을 위한 퍼지신경망 제어기를 구현하였다.

차선정보 추출 가능성을 판별하기 위한 퍼지신경망의 입력파라미터는 누적분포함수에서 추출한 잡음도 지수이며, 이들의 지수가 차선정보 추출 가능성과 깊은 상관성을 가지고 있음을 밝혔으며, 상관분석을 통하여 이를 파라미터가 차선정보 추출을 평가할 수 있는 인자임을 확인하였다.

그리고, 가변적인 도로환경에 대처하는 능력을 가지기 위해서는 지능(intelligence)이 가미되어야 하며, 본 논문에서는 신경망과 퍼지제어의 두 가지 방법을 혼합한 퍼지신경망을 이용하였다. 퍼지신경망의 구조는 실시간성 및 판별성을 고려하여 8개의 입력, 각 입력에 대한 3개의 퍼지변수, 그리고 1개의 출력력을 갖는 구조로 하였으며, 학습 후 차선정보 추출 가능성에 대한 유용성은 실험을 통하여 검증하였다.

## (참 고 문 헌)

- [1] 이준용, 자동차 추돌정보 시스템 개발을 위한 컴퓨터 비전과 레이저 레이다의 응용, 자동차공학회 논문집, 제7권, 제5호, pp. 258-267, 1999.
- [2] 박종웅, 강경영, 이준웅, 차선의 회전 방향 인식을 위한 신경회로망 응용 화상처리, 자동차공학회 논문집, 제7권, 제5호, pp. 178-185, 1999.
- [3] 이운근, 백광렬, 이준웅, 에지방향의 누적분포함수에 기반한 차선인식, 대한전기학회 하계학술대회 논문집, D권, pp. 2814-2818, 2000.
- [4] R. G. Gonzalez and R. E. Woods, *Digital Image Processing*, Addison-Wesley, Reading, Massachusetts, 1992.
- [5] S. Horikawa, T. Furuhashi and Y. Uchikawa, On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm, *IEEE Trans. Neural Networks*, Vol. 3(5), pp. 801-806, 1992.
- [6] S. P. Liou and R. C. Jain, Road Following Using Vanishing Points, *CVGIP*, Vol. 39, pp. 116-130, 1987.