

도로영상의 잡음도 식별을 위한 퍼지신경망 알고리즘

A Fuzzy Neural-Network Algorithm for Noisiness Recognition of Road Images

이 준웅*
Joon Woong Lee

Abstract

This paper proposes a method to recognize the noisiness of road images connected with the extraction of lane-related information in order to prevent the usage of erroneous information. The proposed method uses a fuzzy neural network(FNN) with the back-propagation learning algorithm. The FNN decides road images good or bad with respect to visibility of lane marks on road images. Most input parameters to the FNN are extracted from an edge distribution function(EDF), a function of edge histogram constructed by edge phase and norm. The shape of the EDF is deeply correlated to the visibility of lane marks of road image. Experimental results obtained by simulations with real images taken by various lighting and weather conditions show that the proposed method was quite successful, providing decision-making of noisiness with about 99%.

주요기술용어 : Noisiness recognition(잡음도식별), Fuzzy neural network(퍼지신경망), Image processing(영상처리), Edge distribution function(에지분포함수)

1. 서 론

도로영상은 특성상 인위적으로 없애기 어려운 여러 형태의 자연발생적인 잡음에 노출되어 있기 때문에 원하는 정보를 안정적으로 추출하기란 쉽지 않다. 바로 이 점이 도로영상처리의 덜 레마다. 왜냐하면 잘못된 정보의 추출은 더 큰 문제를 낳기 때문이다. 따라서 관련정보추출에 앞서 입력된 영상으로부터 과연 신뢰할만한 정보를 추출할 수 있는지의 여부를 판단하는 일은 중요하다.

* 회원, 전남대학교 산업공학과, 자동차연구소

본 논문에서는 도로이미지에 대해 신뢰할만한 차선정보추출이 가능할지를 판정할 목적으로 차선표식(lane marks)의 가시도(visibility)의 관점에서 영상의 양·불량을 판정한다. 이를 위해 BP(back propagation)알고리즘을 가진 FNN과 FNN의 입력파라메터 추출방법을 제안한다. 순수 NN(neural network)이나 퍼지체어 대신에 FNN을 사용하게 된 것은 영상이 양호하나 불량하나 하는 기준 자체가 기존의 크리스프집합(crisp set)으로 표현하기 힘든 퍼지(fuzzy)한 특성을 가지고 있고, FNN이 NN의 학습기능에 의해 퍼지규칙(fuzzy rules)을 동정(identification)

하고 소속함수(membership functions)를 조정(tuning)할 수 있다는 점 때문이다.^{11,12,15)} 논문에서 사용할 FNN의 구조는 Horikawa¹²⁾가 제안한 바 있는 퍼지싱글톤(singleton) 구조를 본 논문의 목적에 맞게 활용한 것이다. 일반적으로 퍼지규칙의 동정에는 많은 시간이 걸리고, 퍼지추론(fuzzy reasoning)의 소속함수 튜닝에는 퍼지추론의 전문가를 필요로 하지만 논문에서 사용한 FNN은 BP알고리즘에 의해 이와 같은 문제를 극복한다.

지금까지 차선과 관련된 영상처리연구는 주로 차선표식의 위치 검출에 초점이 맞추어졌다.^{1,3,4,7,10)} 반면에 도로영상에서 차선표식의 가시도나 잡음도를 검출하려는 연구는 거의 찾기 힘들다. Pomerleau¹¹⁾는 차량과 양 차선경계 사이의 높은(offset)을 검출하였고 이 높은이 발생되지 않도록 차량을 제어하였다. Bimbo³⁾는 차선의 흰 방향검출에 NN을 적용하였다. Liou와 Jain⁷⁾은 소실점을 추출하여 차량의 운전을 제어하는데 관심이 있었고, Takahasi와 Ninomiya¹⁰⁾는 미리 많은 모델을 구축해 놓고 입력영상이 이 가운데 어느 모델과 유사한지 찾아내는 방법으로 차선정보를 추출하였다. 몇몇 논문에서 국부적으로 잡음의 효과를 줄이려는 시도는 있다. 존재 할지 모를 잡음에 대비하여 연속 입력된 몇 장의 영상을 중첩시켜본다거나,⁸⁾ 추출된 정보의 평균을 취해본다거나,^{8,9)} 예측기^{6,7)}를 사용하여 이전 프레임의 정보를 현재 프레임에 전파시키려 하는 것들이다. 그러나 이런 시도가 반대로 잡음의 효과를 배가시킬 수도 있다. 예를 들어 양호한 한 두 프레임의 영상이 영상중첩이나 평균을 취하는 것에 의해 잡음이 심한 영상들 속에 섞여 들어가는 경우도 발생한다.

논문에서 FNN의 입력파라메터는 EDF로부터 추출한다. EDF는 도로영상으로부터 추출된 에지방향(edge direction)의 함수로서 동일한 방향을 가진 에지픽셀들을 모아 그 픽셀들의 에지크기(edge magnitude)를 누적시킨 히스토그램 형태의 함수이다.^{8,9)} 구조화된 포장도로에서 좌·우

차선경계를 나타내는 차선표식은 노면보다 밝은 색으로 도색되어 있고, 방향이 급하게 변하지 않기 때문에 차선표식의 경계에 있는 에지픽셀들은 유사한 방향을 갖고 크기가 크다. 이러한 성질에 의해 EDF는 좌·우 차선경계의 방향에 대응되는 위치에서 큰 값을 갖는다. 역설적으로 EDF가 좌·우 차선경계에 대응되는 방향의 위치에서 큰 값을 갖지 않는다면 차선표식이 잘 보이지 않을 것이라고 유추할 수 있고, 이는 곧 영상이 잡음에 노출되어 있는 것으로 해석될 수 있다.

논문에서는 EDF의 특징을 잘 표현할 수 있는 파라메터들을 추출하고, 이들을 FNN을 통해 분석함으로써 차선표식이 잘 보이는 영상인지 아닌지를 알아낸다. 네트워크에서 사용하는 퍼지변수는 ‘양호’, ‘흐릿’, ‘불량’이다. 양호영상은 차선표식을 명확히 식별할 수 있는 경우이고, 불량영상은 반대로 차선표식이 거의 보이지 않는 경우이며, 흐릿영상은 차선표식을 배경으로부터 분리하기가 쉽지 않은 애매한 경우로 정했다. 결국 논문에서 다루는 문제는 입력된 도로영상이 ‘양호’, ‘흐릿’, ‘불량’의 어느 패턴에 속하는지를 판정하는 패턴분류의 문제로 볼 수 있다.

Fig. 1은 ‘양호’, ‘흐릿’, ‘불량’의 의미를 보이기 위해 여러 도로이미지를 모은 것이다. 차선표식이 뚜렷하게 보이는 영상이 있는 반면에 전혀 보이지 않는 영상도 있다. 좌·우 차선경계가 모두 보이지 않는 것도 있고, 우차선경계는 잘 보이지만 좌차선경계는 보이지 않는 영상도 있다. 모두 도로영상임에도 불구하고 잡음에 종류에 따라 차선표식의 가시도는 너무 다르다.

본 논문의 연구는 Fig. 2에 보인바와 같이 FNN의 학습부분과 입력영상의 잡음도 판정부분으로 나뉜다. FNN의 학습부에서는 준비된 입력과 목표값에 의해 FNN의 최적 연결강도를 계산해낸다. 영상의 잡음도 판정부에서는 영상처리에 의해 FNN의 입력파라메터 9개를 추출해 내고, FNN의 학습을 통해 얻은 FNN의 연결강도를 이용하여 영상의 잡음도판정을 실행한다.



Fig. 1 도로이미지 표본

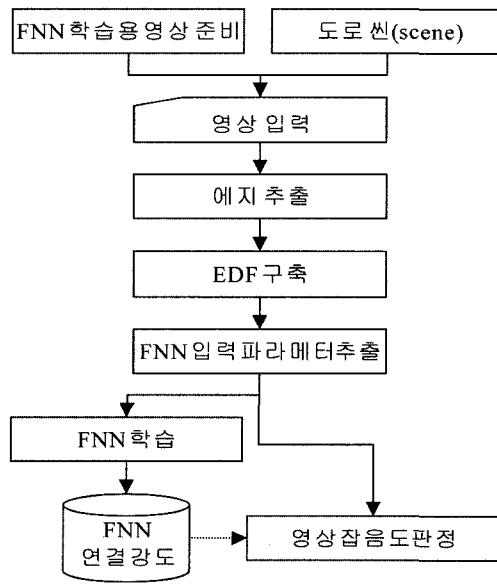


Fig. 2 FNN의 학습 및 영상의 잡음도 판정

2. FNN

2.1 FNN의 구조

퍼지신경망은 퍼지제어 입력의 퍼지화(fuzzi-

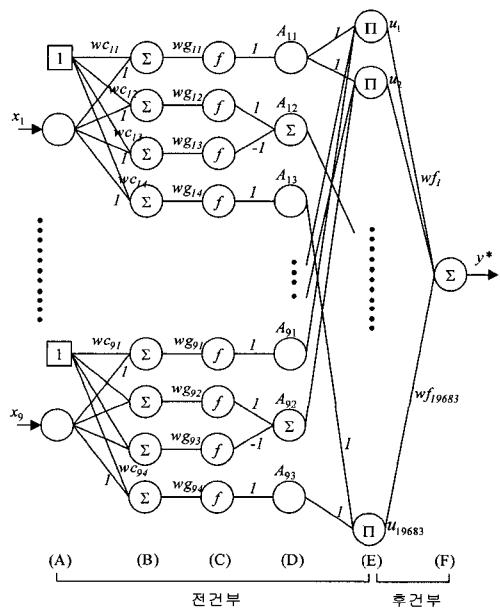


Fig. 3 퍼지신경망의 구조

fication), 퍼지추론, 비퍼지화(defuzzification) 과정을 신경회로망으로 구현한 것으로 논문에서 사용하는 FNN은 Fig. 3에 보인바와 같이 9-입력

$(x_j, j=1, \dots, 9)$, 1-출력(y^*), 그리고 각 전제(premise) 내에서 양호, 흐릿, 불량에 대응되는 3-퍼지변수 ($A_{j1}, A_{j2}, A_{j3}, j=1, \dots, 9$)의 구조를 갖는다. 그리고 Fig. 3에서 원과 사각형은 네트워크의 유닛들을 나타내며 유닛들 사이의 w_{ci}, w_{gi}, wf_k ($i=1, \dots, 4, j=1, \dots, 9, k=1, 2, \dots, 19683$) 1, -1은 연결강도를 의미한다.

A층의 기호 1을 가진 유닛은 바이어스(bias) 유닛으로서 출력은 항상 1이고, 기호 Σ 를 가진 유닛들의 출력은 자신들에게 들어온 입력들의 합이며, E층의 기호 $\hat{\Pi}$ 를 가진 유닛들의 입력 u_k 는 각 전제에서 하나씩 순차적으로 선택된 소속 함수의 등급(grade)의 곱으로 나타내어지고, 출력 \hat{u}_k 은 입력 u_k 의 정규화(normalization)된 값으로 각각 다음과 같다.

$$u_k = \prod_j A_{ji}, \quad i=1, 2, 3, \quad j=1, 2, \dots, 9, \quad k=1, \dots, n,$$

$$\hat{u}_k = \frac{u_k}{\sum_{l=1}^n u_l}$$

여기에서 n 은 퍼지규칙의 수로서 $n=m^{n_m}$ ($m=$ 퍼지변수의 수, $n_m=$ 입력의 수)로 주어진다. 따라서 Fig. 3의 구조에서는 $n=19,683$ 이 되며 이 값은 E층의 유닛의 개수가 된다. A층의 입력 x_j 는 B층에서 wc 에 의해 바이어스되고 wg 가 곱해져 C층의 입력이 되어 C층의 기호 f 를 가진 유닛의 내부 함수인 시그모이드함수의 입력이 된다. C층의 유닛들의 출력은 다음과 같이 정의된다.

$$f(x_j) = \frac{1}{1 + \exp(-wg(x_j + wc))}$$

이 함수에 의해 각 전제(premise)의 세 퍼지변수에 대응되는 소속함수의 모양이 결정된다. 여기에서 wc 는 소속함수의 중심위치를 결정하는 데 기여하고 wg 는 함수의 기울기를 결정하는데 기여한다. 따라서 wc 와 wg 를 적절히 초기화하면 Fig. 4에 보인바와 같은 형상의 소속함수가 전체 공간(universe of discourse)에 배치된다. 이 가운데

데 종형 소속함수는 Fig. 5에 보인 두 개의 시그모이드함수를 합성함으로써 결정된다.

결론부 즉, 후건부의 퍼지추론값(fuzzy infer-red value) y^* 는 Fig. 3의 E층의 출력인 정규화된 진리값(truth value)에 곱해진 상수들의 합으로 얻어진다. 하나의 출력을 가진 FNN의 퍼지규칙은 다음과 같은 퍼지함의(fuzzy implication)로 표현된다.

$R^k : \text{If } x_1 \text{ is } A_{1i} \text{ and } x_2 \text{ is } A_{2i} \text{ and } \dots \text{ and } x_9 \text{ is } A_{9i} \text{ then } y = f_k, \quad i=1, 2, 3, \quad k=1, 2, \dots, 19683$

$$y^* = \sum_{j=1}^{19683} \hat{u}_j f_j$$

여기에서 R^k 는 k 번째 퍼지규칙이고, $y=f_k$ 는 k 번째 규칙의 출력으로 네트워크의 연결강도 wf_k 가 된다. 이렇게 결정된 y^* 는 입력영상의 양·불량을 판정하는 값이 된다.

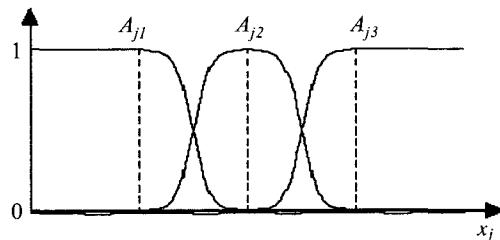
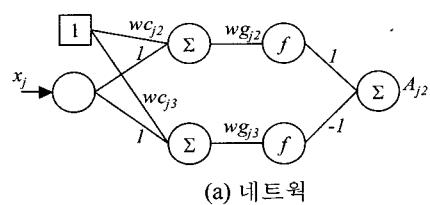
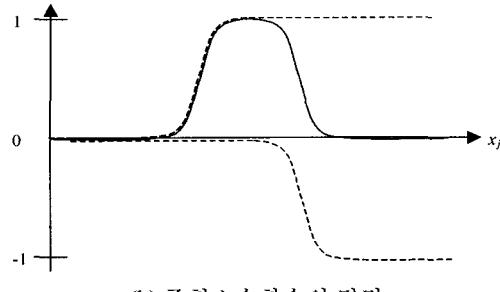


Fig. 4 전전부의 소속함수



(a) 네트워크



(b) 종형소속함수의 결정

Fig. 5 종형소속함수 A_{j2}의 결정

2.2 FNN의 학습

FNN의 학습데이터는 입력파라미터와 목표값으로 이루어진다. 먼저 학습에 사용할 영상을 선정하여 선정된 각각의 영상에 대해 9개의 입력파라미터를 추출하고 동시에 영상이 ‘양호’, ‘흐릿’, ‘불량’ 가운데 어느 것에 해당되는지를 정한다. 이 때 ‘양호’, ‘흐릿’, ‘불량’에 대한 목표값으로 각각 1, 0.5, 0을 부여한다. 학습데이터 준비과정에서 가장 중요한 점은 선정된 모든 영상에 대하여 입력파라미터와 목표값의 관련성이 일관되게 하는 일이다. 이러한 일관성이 유지되지 않으면 학습이 잘 되지 않을 뿐만 아니라 학습 후 실제 영상의 검증에서도 신뢰성 있는 판정을 기대할 수 없다.¹⁵⁾ 따라서 학습데이터의 목표값 설정은, 단순히 영상만 보고 해서는 안 되고, 구축해 놓은 EDF, 추출한 에지정보 등 여러 가지 정황을 보고 판단을 할 수 있는 상당한 전문성을 요한다. FNN의 학습은 퍼지규칙과 소속함수의 모양을 동정(identification)하기 위한 목적을 갖는다. Fig. 3의 네트워크에 있는 결합하중 w_{cji} , w_{gji} , w_{fk} , ($i=1,\dots,4$, $j=1,\dots,9$ $k=1,2,\dots,19683$)를 BP학습 알고리즘을 이용하여 갱신함으로써 이 목적은 실현된다. 주어진 학습데이터에 대해 FNN의 출력오차 E_p 를 다음과 같이 정의한다.

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

여기에서 y_p 는 p 번째 학습데이터의 목표값이고 y_p^* 는 y_p 에 대한 FNN의 출력이다. FNN의 학습은 패턴기반(pattern based) 방식으로 이루어진다. 매 패턴마다 출력오차 E_p 를 감소시키기 위해서 E_p 를 결합하중 w_c , w_g , w_f 각각에 대해 편미분을 취하고 각 결합하중의 변화량을 구하여 결합하중을 갱신한다.

결합하중 w_c , w_g , w_f 각각의 변화량 Δw_{cji} , Δw_{gji} , Δw_{fk} 를 BP알고리즘에 의하여 구하면 다음과 같다.

$$\Delta w_{cji} = -\eta \frac{\partial E_p}{\partial w_{cji}} \quad (2)$$

$$\Delta w_{gji} = -\eta \frac{\partial E_p}{\partial w_{gji}} \quad (3)$$

$$\Delta w_{fk} = -\eta \frac{\partial E_p}{\partial w_{fk}} \quad (4)$$

여기에서 η 는 학습률이다.

3. FNN의 입력데이터 추출을 위한 영상처리

3.1 영상처리영역 설정

도로이미지획득에 사용될 CCD 카메라 장치(set-up)에서 카메라의 광축은 차선의 접선방향과 일치되고, 틸트(tilt)각과 롤(roll)각은 0° 라는 가정을 한다. 실제 셋업에서도 이 가정이 만족되도록 한다. 이러한 가정하에서 영상에 보이는 차선경계의 소실점(vanishing point)은 Fig. 6에 보인 바와 같이 영상의 중심에 위치하므로 차선은 수직방향의 영상중심 이하에만 나타난다. 따라서 차선정보추출을 위한 영상처리는 영상의 중심 아래부분으로 국한한다. 또한 처리영역 설정시 차선경계는 수평과 수직에 가까운 즉, 0° , 180° , 90° 균방에는 존재하지 않을 것이라는 가정을 했다. 실제 진입로(ramp)와 같은 급커브도로를 제외하면 도로영상에서 수평방향의 차선경계는 나타나지 않는다. 이러한 제약조건과 가정하에 설정된 영상처리영역(region of interest, ROI)은 Fig. 6에 보인 음영영역으로 한다. 이 때 좌표축은 수평을 x축, 수직을 y축으로 한다.

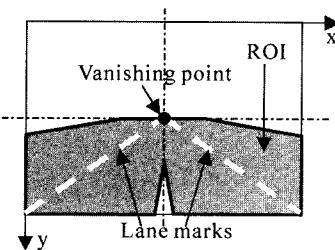


Fig. 6 영상처리영역의 설정

3.2 에지추출

입력된 영상을 함수 $f(x,y)$ 라고 했을 때 에지는 영상의 한 점 (x,y) 에서 다음 식 (5)와 같이 벡터로 표현되며, 이 벡터는 식 (6)과 (7)의 크기와 방향으로 나타내어진다.¹³⁾

$$\nabla f = [G_x \ G_y]^T = [\frac{\partial f}{\partial x} \ \frac{\partial f}{\partial y}]^T \quad (5)$$

$$\nabla f(x,y) = [G_x^2 + G_y^2]^{1/2} \approx |G_x| + |G_y| \quad (6)$$

$$\alpha(x,y) = \tan^{-1}(G_y/G_x) \quad (7)$$

영상의 에지는 밝기값의 차가 큰 곳에서 잘 나타나고 방향성분을 가지고 있기 때문에 “차선표식은 배경에 비해 밝다.”라는 성질에 잘 부합되며 또한 “차선경계의 방향은 급격하게 변하지 않는다.”라는 가정을 잘 추론할 수 있는 특징이 될 수 있다. 따라서 본 논문에서는 3×3 소벨(Sobel) 연산자¹³⁾를 이용하여 ROI내에서 에지를 추출한다.

에지추출에 있어서 한가지 중요한 점은 임계값 또는 문턱치(threshold value)의 설정이다. 차선경계에 있는 에지픽셀들은 다른 픽셀들에 비해 에지의 크기는 크지만 수량이 많지 않기 때문에 차선경계에 있는 에지픽셀들의 영향력이 배경의 많은 에지픽셀들에 의해 묻혀버릴 수 있다. 따라서 차선경계에 위치한 에지픽셀들을 부각시키려면 크기가 작은 픽셀들을 제거해야 한다. 이 때 에지크기의 임계값선정이 필요하다. 본 논문에서는 저자가 기 발표한 바 있는 참고문헌^{8,9)}에 제시된 알고리즘 스스로 입력영상의 밝기변화에 적용될 수 있는 임계값 갱신방법을 사용하였다. 임계값 \hat{r} 가 결정되면 검출된 에지에 대해 다음과 같이 thresholding을 수행한다.

$$\nabla f(x,y) = \begin{cases} 0 & \text{if } \nabla f(x,y) \leq \hat{r} \\ \nabla f(x,y) & \text{otherwise} \end{cases} \quad (8)$$

3.3 EDF 구축

EDF는 식 (7)에 의해 계산된 에지방향의 함수로서 동일한 방향을 가진 에지픽셀들을 모아 그

픽셀들의 크기를 다음 식 (9)의 방법으로 누적시킴으로써 구축된다.

$$F(d) = \sum_{n(d)} \nabla f(x,y) \quad (9)$$

여기에서 $n(d)$ 는 에지방향이 $d = \alpha(x,y)$ 인 픽셀의 수이며 $\nabla f(x,y)$ 는 식 (6)의 에지크기를 나타낸다. 에지추출단계에서 에지방향 $\alpha(x,y)$ 는 1° 단위로 0° 부터 180° 사이의 값을 갖도록 하였다. Fig. 7은 차선경계의 방향과 EDF와의 관계를 보인 것으로서 우차선경계의 방향을 θ_1 , 좌차선경계의 방향을 θ_2 라고 했을 때, θ_1 과 θ_2 부근에서 EDF는 큰 값을 갖는다. 그 이유는 차선표식은 노면보다 밝은 색으로 도색되었고, 방향이 급격하게 변하지 않는 성질을 가지므로 차선표식의 경계에 있는 픽셀들은 대개 비슷한 에지방향을 갖고, 에지크기가 여타의 픽셀들에 비해 상대적으로 크기 때문이다. 크기는 적지만 수적으로 우세한 노면 픽셀들이 식 (8)에 의해 제거된 점도 영향을 미쳤다. 만약 EDF가 θ_1 과 θ_2 가 존재할 위치에서 뚜렷한 큰 값을 갖지 못할 때는 좌·우 차선경계가 잡음의 영향을 받아 잘 보이지 않을 가능성이 크다는 것을 의미하며, 결국 관련된 정보를 추출해내기가 쉽지 않을 것임을 짐작할 수 있다. FNN의 입력파라메터로 EDF의 특징을 사용하는 것은 바로 이 성질에 근거한 것이다.

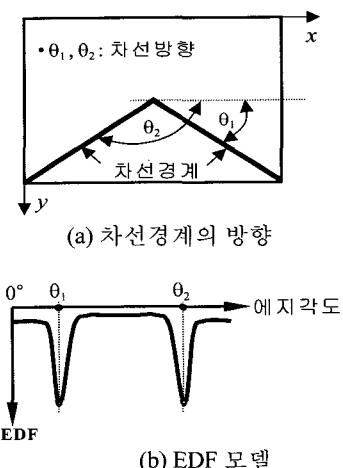


Fig. 7 좌우 차선경계의 방향과 EDF

3.4 FNN의 입력파라메터

3.4.1 EDF의 특징파라메터 추출

Fig. 8은 다양한 영상에 대해 구축된 EDF 사례를 보여준 것이다. Fig. 8(a)처럼 좌·우 차선경계가 뚜렷하게 보이는 영상에 대해 구축된 EDF는 Fig. 7(b)의 EDF모델에서 보인 바와 매우 유사한 모양을 한다. Fig. 8(b)의 경우는 영상에서 좌측의 차선표식이 보이지 않기 때문에 EDF도 좌측 차선경계의 방향에 대응되는 위치에 어떤 큰 값을 가진 곳이 나타나지 않는다. Fig. 8(c)는 고속도로 진입로(ramp)의 예로서 진입로가 급격한 곡로이기 때문에 자차선영역이 카메라에 잡히지 않은 경우이다. Fig. 8(d)는 전방의 트럭에 의해 좌·우 차선표식이 완전히 가려진 경우이다. Fig. 8(e)는 도로에 고인 빗물 때문에 차선표식이 거의 보이지 않은 경우이다. 특히 좌측 차선표식은 우측에 비해 더더욱 보이지 않는다. 따라서 EDF의 모양도 우측 차선경계에 대응되는 곳은 피크(peak)값이 어느 정도 나타난 반면에 좌측 차선경계에 대

응되는 곳은 노이즈(noisy)하다. Fig. 8(f)는 약간 영상인데 우측 차선경계는 실선으로 선명하게 보인 반면에 좌측 차선경계는 파선이면서 흐릿하게 보인다. 따라서 EDF도 좌측 경계에 대응되는 곳에 큰 값을 갖지 않는다. 이와 같이 차선표식의 가시도(visibility)에 따라 EDF가 큰 영향을 받는다는 것을 알 수 있다.

EDF가 정의되는 영역을 차선경계가 존재할 가능성이 높은 영역과 낮은 영역으로 분할한 후 분할된 영역별로 EDF의 모양을 잘 묘사할 수 있는 특징파라메터를 추출한다. EDF의 영역분할에 차선경계가 영상에서 대략 어떤 기울기를 갖는지 알 필요가 있다. 이를 위해 Fig. 9와 같이 월드좌표계와 카메라좌표계를 정의한다. 월드좌표계의 원점은 노면에 놓고 y축이 차선의 진행방향이 되도록 하며, 카메라좌표계는 z축을 카메라의 광축으로 놓는다. 두 좌표계간의 변환관계를 묘사하는 회전행렬 R 과 병진행렬 T 는 캘리브레이션을 통해서 구한다.¹⁴⁾ Fig. 9의 u 와 v 는 영상평

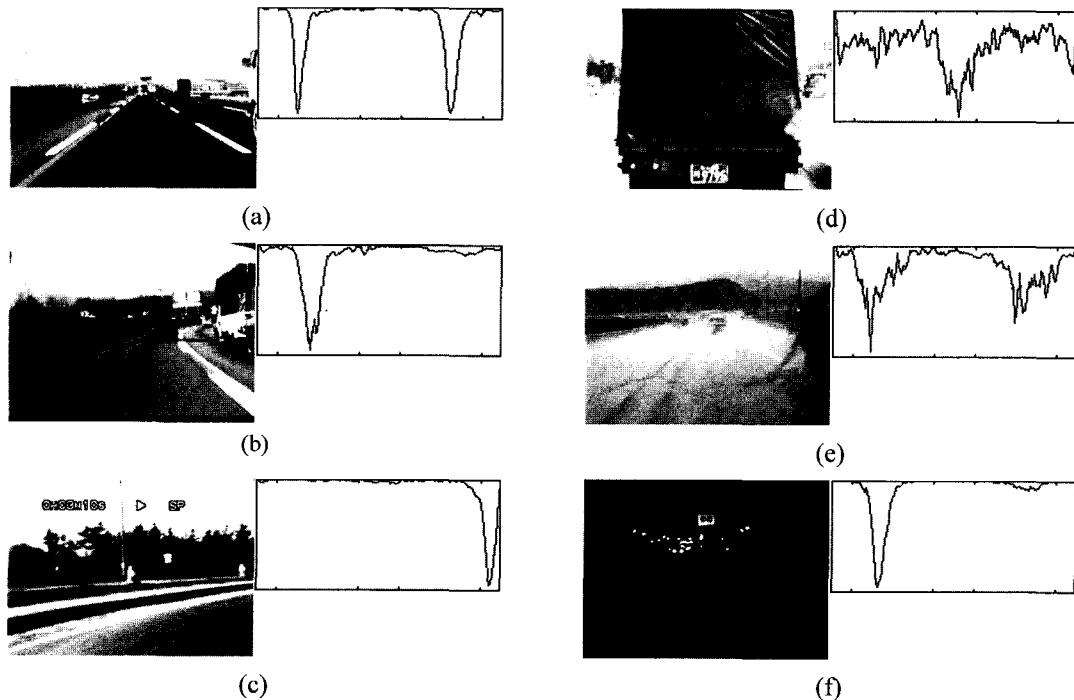


Fig. 8 차선표식의 가시도와 EDF

면의 수평, 수직 좌표를 뜻한다.

차선의 좌·우 차선경계의 영상평면에서의 기울기는 다음과 같이 계산된다. 월드좌표계의 한 점 $(aY_w + b, Y_w, 0)$ 은 다음 식에 의해 카메라좌표계 (x_c, y_c, z_c) 로 옮겨진다.

$$\begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} = \mathbf{R} \begin{bmatrix} aY_w + b \\ Y_w \\ 0 \end{bmatrix} + \mathbf{T} = \begin{bmatrix} r_1 & r_2 & r_3 \\ r_4 & r_5 & r_6 \\ r_7 & r_8 & r_9 \end{bmatrix} \begin{bmatrix} aY_w + b \\ Y_w \\ 0 \end{bmatrix} + \begin{bmatrix} T_x \\ T_y \\ T_z \end{bmatrix}$$

이 점이 영상평면에 투영되면 (u, v) 가 된다. 즉

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} fx_c \\ z_c \\ fy_c \\ z_c \end{bmatrix} = \begin{bmatrix} f \frac{(ar_1 + r_2)Y_w + br_1 + T_x}{(ar_7 + r_8)Y_w + br_1 + T_z} \\ f \frac{(ar_4 + r_5)Y_w + br_4 + T_y}{(ar_7 + r_8)Y_w + br_1 + T_z} \end{bmatrix}$$

여기에서 f 는 초점거리(focal length)이다. 영상에서 소실점(vanishing point) (u', v') 는 Fig. 9에 정의된 월드좌표계의 y 좌표가 무한대에 존재하는 점으로 다음과 같다.

$$\begin{bmatrix} u' \\ v' \end{bmatrix} = \begin{bmatrix} \lim_{r_c \rightarrow \infty} f \frac{(ar_1 + r_2)Y_w + br_1 + T_x}{(ar_7 + r_8)Y_w + br_1 + T_z} \\ \lim_{r_c \rightarrow \infty} f \frac{(ar_4 + r_5)Y_w + br_4 + T_y}{(ar_7 + r_8)Y_w + br_1 + T_z} \end{bmatrix} = \begin{bmatrix} f \frac{(ar_1 + r_2)}{(ar_7 + r_8)} \\ f \frac{(ar_4 + r_5)}{(ar_7 + r_8)} \end{bmatrix}$$

영상평면에 투영된 차선경계의 기울기 m 은 월드좌표계의 또 다른 한 점 $(b, 0, 0)$ 이 영상평면에 투영된 점과 소실점간의 관계로부터 구해진다.

$$m = \frac{(ar_4 + r_5)(br_1 + T_z) - (br_4 + T_y)(ar_7 + r_8)}{(ar_1 + r_2)(br_7 + T_z) - (br_1 + T_x)(ar_7 + r_8)}$$

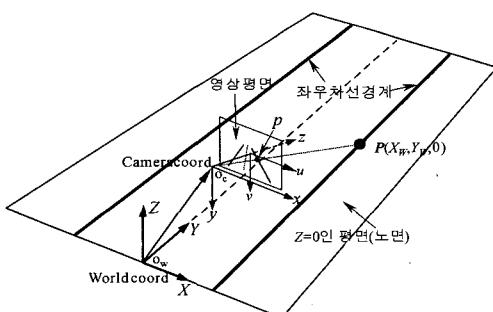


Fig. 9 차선경계와 좌표계

월드좌표계에서 차선경계의 기울기 a 가 0이면 상기 수식들은 간단해진다. 월드좌표계의 x 축 절편에 해당되는 b 를 차선의 폭 정보로 보고 차선경계가 영상에서 어떤 기울기일지는 상기 수식들에 의해 쉽게 계산된다. 이러한 계산과정을 통해 현재 사용된 카메라 세팅(set-up)에서는 한국의 도로구조·시설기준에 관한 규정¹⁰⁾을 지킨 차선의 경우 차차선의 우측차선경계는 15° 이하에는 나타나지 않고 좌측차선경계는 165° 이상에는 나타나지 않음을 알 수 있었다.

이상의 결과를 토대로 Fig. 10에 보인 바와 같이 EDF가 정의되는 영역인 0° 부터 180° 사이를 차선경계의 기울기가 존재할 가능성이 높은 영역과 낮은 영역으로 분할한다. 이때 차량이 차선경계를 중심에 두고 주행하는 경우는 없다고 가정한다. 만약 차량이 차선경계를 중심에 두고 주행하면서 촬영된 영상에서 차선경계의 기울기는 90° 에 가까운 값을 갖게 되는데, 이렇게 되면 90° 에 가까운 예지방향을 갖는 잡음과 실제 차선경계를 구별하기 어렵기 때문이다. 우차선경계의 기울기 θ_1 이 존재할 영역 1(zone 1)과 좌차선경계의 기울기 θ_2 가 존재할 영역 3(zone 3)이 차선경계와 관련된 영역이고 그 외의 영역은 차선경계가 존재할 가능성이 거의 없다고 본다.

EDF의 분할영역별 특징파라미터추출은 이론적 근거를 바탕으로 한 것은 아니지만, 많은 반복실험을 통하여 영상의 잡음도를 잘 묘사할 수 있는 방안을 찾아낸 것이다. 제안된 방법에서는 먼저 각 영역별로 EDF의 평균과 표준편차를 계산하고 다음과 같은 집합을 구축한다.

$$S_0 = \{x \mid F(x) > \mu_1, x \in Zone_0\},$$

$$S_1 = \{x \mid F(x) > \mu_1, x \in Zone_1\},$$

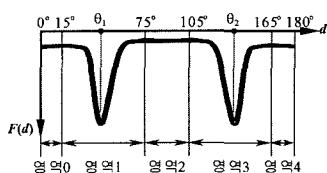


Fig. 10 EDF의 영역 분할

영역	범위
0	$0^\circ \sim 14^\circ$
1	$15^\circ \sim 75^\circ$
2	$76^\circ \sim 104^\circ$
3	$105^\circ \sim 165^\circ$
4	$166^\circ \sim 180^\circ$

$$S_0' = \{x | F(x) > \mu_1 + \sigma_1, x \in Zone_0\},$$

$$S_1' = \{x | F(x) > \mu_1 + \sigma_1, x \in Zone_1\},$$

$$S_1'' = \{x | F(x) > \mu_1 + 0.75\sigma_1, x \in Zone_1\},$$

$$S_3 = \{x | F(x) > \mu_3, x \in Zone_3\},$$

$$S_3' = \{x | F(x) > \mu_3 + \sigma_3, x \in Zone_3\},$$

$$S_3'' = \{x | F(x) > \mu_3 + 0.75\sigma_3, x \in Zone_3\},$$

$$S_4 = \{x | F(x) > \mu_3, x \in Zone_4\},$$

$$S_4' = \{x | F(x) > \mu_3 + \sigma_3, x \in Zone_4\}$$

여기에서 $F(x)$ 는 EDF이고, $\mu_1, \sigma_1, \mu_3, \sigma_3$ 은 각각 영역1, 영역3의 EDF 평균과 표준편차이다. EDF의 특징파라메터 산출은 이 집합을 토대로 이루어진다.

오른쪽 차선경계의 방향성분이 존재할 것으로 기대되는 영역1을 기준으로 한 EDF의 특징파라메터들의 정의는 다음과 같다. 먼저 영역0에 대해 영역1이 더 큰 EDF를 가지고 있는지를 묘사하는 3개의 파라메터는 다음과 같이 정의한다.

$$p_{1,0} = \frac{1}{2} \left\{ \frac{(\mu_0 + \sigma_0) - (\mu_1 + \sigma_1)}{(\mu_0 + \sigma_0) + (\mu_1 + \sigma_1)} + 1 \right\} \quad (10)$$

$$p_{1,1} = \frac{1}{2} \left\{ \frac{m_0 - m_1}{m_0 + m_1} + 1 \right\}, \quad m_0 = \frac{\sum_{x \in S_0} F(x)}{\|S_0\|}, \quad m_1 = \frac{\sum_{x \in S_1} F(x)}{\|S_1\|} \quad (11)$$

$$p_{1,2} = \frac{1}{2} \left\{ \frac{m_0' - m_1'}{m_0' + m_1'} + 1 \right\}, \quad m_0' = \frac{\sum_{x \in S_0'} F(x)}{\|S_0'\|}, \quad m_1' = \frac{\sum_{x \in S_1'} F(x)}{\|S_1'\|} \quad (12)$$

여기에서 μ_0, σ_0 는 영역0의 EDF의 평균과 표준편차이고 $\|S_0\|, \|S_1\|, \|S_0'\|, \|S_1'\|$ 는 각각 집합 S_0, S_1, S_0', S_1' 의 원소의 수를 나타낸다. 다음은 영역1에서의 EDF의 특징을 묘사하는 4개의 파라메터를 정의한다.

$$p_{1,3} = \frac{1}{2} \left\{ \frac{Freq_1'}{\max\{S_1'\} - \min\{S_1'\}} + \frac{Freq_1''}{\max\{S_1''\} - \min\{S_1''\}} + 1 \right\}$$

$$Freq_1' = \#\{ |F(x+1) - F(x)| > 0, x \in S_1'\}, \quad (13)$$

$$Freq_1'' = \#\{ |F(x+1) - F(x)| > 0, x \in S_1'' \}$$

$$p_{1,4} = \frac{1}{2} \left\{ 2 - \frac{\|S_1'\|}{\max\{S_1'\} - \min\{S_1'\}} + \frac{\|S_1''\|}{\max\{S_1''\} - \min\{S_1''\}} + 1 \right\} \quad (14)$$

$$p_{1,5} = \frac{1}{2} \left\{ \frac{\max\{S_1'\} - \min\{S_1'\}}{R} + \frac{\max\{S_1''\} - \min\{S_1''\}}{R} + 1 \right\} \quad (15)$$

$$p_{1,6} = \frac{\mu_1 + 0.75\sigma_1}{\bar{D}_1} \quad (16)$$

$$p_{1,7} = \frac{\mu_1}{\bar{D}_1} \quad (17)$$

여기에서 $Freq_1'$ 은 S_1' 에 속한 원소들의 함수값의 유통불통거리는 회수이고, $Freq_1''$ 는 S_1'' 에 속한 원소들의 함수값의 유통불통거리는 회수이며, $\min\{S_1'\}, \min\{S_1''\}, \max\{S_1'\}, \max\{S_1''\}$ 는 S_1' 과 S_1'' 의 최소값과 최대값을 나타내는 것으로서 Fig. 11에 묘사되어 있다. 식 (16)의 상수 0.75는 경험적으로 정해진 값이다. 모두 R 은 영역1의 범위인 61이다. $\|S_1''\|$ 는 집합 S_1'' 의 원소의 수를 나타낸다. 또한 \bar{D}_1 은 S_1' 에 속한 원소들의 함수값 가운데 최대인 것들 4개를 취해 이들의 평균을 계산한 값이다. 상기 4개의 특징파라메터산출에 집합 S_1' 과 S_1'' 을 동시에 사용한 이유는 어느 한 개를 사용했을 때의 우연성을 줄이기 위함

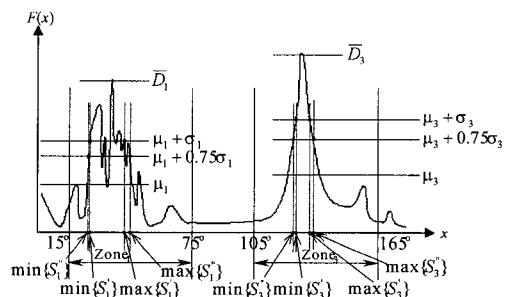


Fig. 11 영역1과 영역3의 특징파라메터 정의

이다. 이와 같은 방법으로 정의한 8개의 파라미터들의 값이 0에 가까우면 일단 입력영상이 차선표식의 가시도의 관점에서 양호한 것으로 해석할 수 있다.

왼쪽 차선경계의 방향성분이 존재할 것으로 기대되는 영역3을 기준으로 한 EDF의 특징파라미터들도 영역1의 EDF의 특징파라미터들을 정의한 동일한 방법으로 정의한다. 단지 고려하는 영역만 달라질 뿐이다.

$$p_{3,0} = \frac{1}{2} \left\{ \frac{(\mu_4 + \sigma_4) - (\mu_3 + \sigma_3)}{(\mu_4 + \sigma_4) + (\mu_3 + \sigma_3)} + 1 \right\} \quad (18)$$

$$p_{3,1} = \frac{1}{2} \left\{ \frac{m_4 - m_3}{m_4 + m_3} + 1 \right\}, \quad (19)$$

$$m_4 = \frac{\sum_{x \in S_4} F(x)}{\|S_4\|}, \quad m_3 = \frac{\sum_{x \in S_3} F(x)}{\|S_3\|}$$

$$p_{3,2} = \frac{1}{2} \left\{ \frac{m_4' - m_3'}{m_4' + m_3'} + 1 \right\}, \quad m_4' = \frac{\sum_{x \in S_4'} F(x)}{\|S_4'\|}, \quad (20)$$

$$m_3' = \frac{\sum_{x \in S_3'} F(x)}{\|S_3'\|}$$

여기에서 μ_4, σ_4 는 영역4의 EDF의 평균과 표준편차이고, $\|S_4\|, \|S_3\|, \|S_4'\|, \|S_3'\|$ 는 각각 집합 S_4, S_3, S_4', S_3' 의 원소의 수를 나타낸다. 다음은 영역3에서의 EDF의 특징을 묘사하는 4개의 파라미터를 정의한다.

$$p_{3,3} = \frac{1}{2} \left\{ \frac{Freq_3'}{\max\{S_3'\} - \min\{S_3'\} + 1} + \frac{Freq_3''}{\max\{S_3''\} - \min\{S_3''\} + 1} \right\}$$

$$Freq_3' = \#\{ |F(x+1) - F(x)| > 0, x \in S_3' \}, \quad (21)$$

$$Freq_3'' = \#\{ |F(x+1) - F(x)| > 0, x \in S_3'' \}$$

$$p_{3,4} = \frac{1}{2} \left\{ 2 - \frac{\|S_3\|}{\max\{S_3\} - \min\{S_3\} + 1} + \frac{\|S_3'\|}{\max\{S_3'\} - \min\{S_3'\} + 1} \right\} \quad (22)$$

$$p_{3,5} = \frac{1}{2} \left\{ \frac{\max\{S_3\} - \min\{S_3\} + 1}{R} + \frac{\max\{S_3'\} - \min\{S_3'\} + 1}{R} \right\} \quad (23)$$

$$p_{3,6} = \frac{\mu_3 + 0.75\sigma_3}{\bar{D}_3} \quad (24)$$

$$p_{3,7} = \frac{\mu_3}{\bar{D}_3} \quad (25)$$

여기에서 $Freq_3'$ 은 S_3' 에 속한 원소들의 함수값의 유통불통거리는 회수이고, $Freq_3''$ 은 S_3'' 에 속한 원소들의 함수값의 유통불통거리는 회수이며, $\min\{S_3'\}, \min\{S_3''\}, \max\{S_3'\}, \max\{S_3''\}$ 는 S_3' 과 S_3'' 의 최소값과 최대값을 나타내는 것으로서 Fig. 11에 묘사되어 있다. 모수 R 은 영역3의 범위값인 61이다. $\|S_3\|$ 는 집합 S_3'' 의 원소의 수를 나타낸다. 또한 \bar{D}_3 은 S_3' 에 속한 원소들의 합수값 가운데 최대인 것들 4개의 평균이다.

좌·우 차선경계의 가시도 분석에 공통으로 사용되는 파라미터는 영역2의 EDF가 영역1과 영역3에 비해 더 큰 값을 가지고 있는지의 여부를 평가할 수 있는 특징파라미터로서 다음과 같이 정의된다.

$$p_{2,0} = \frac{1}{2} \left\{ \frac{\mu_2 - \frac{\mu_1 + \mu_3}{2}}{\mu_2 + \frac{\mu_1 + \mu_3}{2}} + 1 \right\} \quad (26)$$

여기에서 μ_2 는 영역2의 EDF의 평균이다. 이렇게 정의된 9개의 특징파라미터 가운데 $p_{1,6}$ 과 $p_{3,6}$ 을 제외한 나머지 8개 파라미터들은 FNN의 입력파라미터가 되어 영상의 좌·우측 영역의 잡음도 평가에 사용된다.

3.4.2 영상의 밝기값 파라미터

Fig. 6에서 정의된 영상처리 영역을 수평방향의 중심을 기준으로 좌·우 2개의 영역으로 나누어 각 영역별로 밝기값의 평균을 구하고, 이 값을 최대 밝기값인 255로 나눈 것으로서 각각을 좌·우 차선경계의 가시도 평가를 위한 FNN의 9번째 입력파라미터로 활용한다. 밝기값을 FNN의 입력파라미터로 활용한 이유는 빛의 포화로 빛어진 영상의 잡음도를 평가하기 위해서다.

4. 실험결과

FNN의 학습을 위해 다양한 씬(scene)에서 ‘양호’, ‘흐릿’, ‘불량’을 거의 비슷한 비율로 하여 총 199개의 영상프레임을 선정하였다. 실험에 사용한 영상은 실험차량으로 도로를 직접 주행하면서 녹화한 것을 실험실에서 영상처리보드를 이용하여 획득한 것이다. 학습완료는 식 (1)의 출력 오차를 입력패턴에 대해 누적한 오차 E가 매우 적은 값이 될 때 이루어진다.

$$E = \sum_p E_p \quad (27)$$

여기에서 p 는 학습에 사용된 입력패턴의 수를 나타낸다. 실제 실험에서 학습완료는 E 가 약 0.087 일 때 마쳤다. 학습이 완료된 FNN 추론기의 입력 영상의 잡음도 판정을 위해 Fig. 3의 FNN의 후건부의 퍼지추론값(fuzzy inferred value) y^* 의 범위는 반복실험을 통해 다음 Table 1과 같이 정했다.

Table 1 잡음도 판정결과를 위한 y^* 의 설정범위

	양호	흐릿	불량
y^* 의 범위	0.7 이상	0.2~0.7	0.2 이하

차선표식의 가시도와 관련된 입력영상의 잡음도 판정결과는 다음 Table 2와 같다.

Table 2 입력영상의 잡음도 판정결과

사람육안 판정 (Ground truth)		FNN 판정결과						
		가 시 도	양호		흐릿		불량	
			영상수	판정율 (%)	영상수	판정율 (%)	영상수	판정율 (%)
양호	5000	4938	98.76	51	1.02	11	0.22	
흐릿	1428	5	0.35	1390	97.34	33	2.31	
불량	1676	0	0.0	6	0.36	1670	99.64	

판정결과가 당초 기대했던 목표인 95% 이상을 기록하였지만 판정결과에 오류가 나타난 이유를 나름대로 분석해 보면 다음과 같은 사항들을 수 있다. 첫째, 199개의 전체 학습패턴에 대해

FNN의 학습데이터 구성시 9개의 입력파라메터와 목표값과의 일관성 유지가 잘 되지 않았을 수 있다. 둘째, FNN 평가시 실제값(ground truth)판정을 사람이 육안으로 한 것이므로 주관성이 가미되어 일관성이 결여될 수 있다. 세째 표1의 y^* 의 범위설정에 오류가 있을 수 있다. 그러나 이러한 사항들은 신경망이나 퍼지제어 문제에서 완전하게 해결하기는 어려운 문제들이다.

다음 Fig. 12는 FNN 판정결과에 대한 몇 가지 예를 소개한 것이다. 먼저 Fig. 12의 첫 번째 컬럼은 원시영상을 표시한 것이고, 두 번째 컬럼은 EDF, 세 번째 컬럼은 3장에서 설명한 바 있는 EDF의 영역별 특징파라메터와 밝기값파라메터(그림에서 영역1과 영역3의 9번째 값이 이 값을 나타낸 것임) 그리고 FNN의 추론값인 y^* 가 표시되어 있다. Fig. 12(a)는 야간영상의 예로 차선표식이 실험차량 가까운 부근에는 보이지 않았고 보이는 부분도 사람눈에는 그렇게 설명하게 보이지 않았기 때문에 실제값 설정시 ‘흐릿’으로 하였는데 FNN의 결과는 ‘양호’로 판명된 예다. Fig. 12(b)는 우측차선경계의 가시도는 ‘불량’, 좌측차선경계의 가시도는 ‘흐릿’으로 설정하였는데 FNN판정결과는 우측은 ‘불량’ 판정을 내려 기대했던 대로였지만, 좌측은 ‘양호’판정을 내린 예로서 이 경우 FNN모델은 이와 같은 판정을 내릴 수밖에 없었다. 그 이유는 영역3의 EDF의 모양을 보면 양호한 영상의 EDF의 모양과 매우 흡사하기 때문이다. EDF의 모양이 양호한 형태로 나타난 것은 도로의 가장자리에 도색되어 있는 백선표식이 뚜렷하게 보였고 이는 차선경계의 성질을 잘 만족하고 있기 때문이다. Fig. 12(c)의 경우는 우측차선경계의 차선표식의 가시도는 ‘양호’, 좌측차선경계의 차선표식의 가시도는 ‘흐릿’으로 보았는데 FNN의 판정결과 좌측차선경계의 가시도가 기대와 달리 ‘흐릿’으로 나왔다. 현재 이 예의 원인은 정확하게 분석하기가 쉽지 않다. Fig. 12(d)-(g)는 사람의 육안으로 판정했던 결과와 FNN의 결과가 정확히 일치한 예를 보여준 것이다.

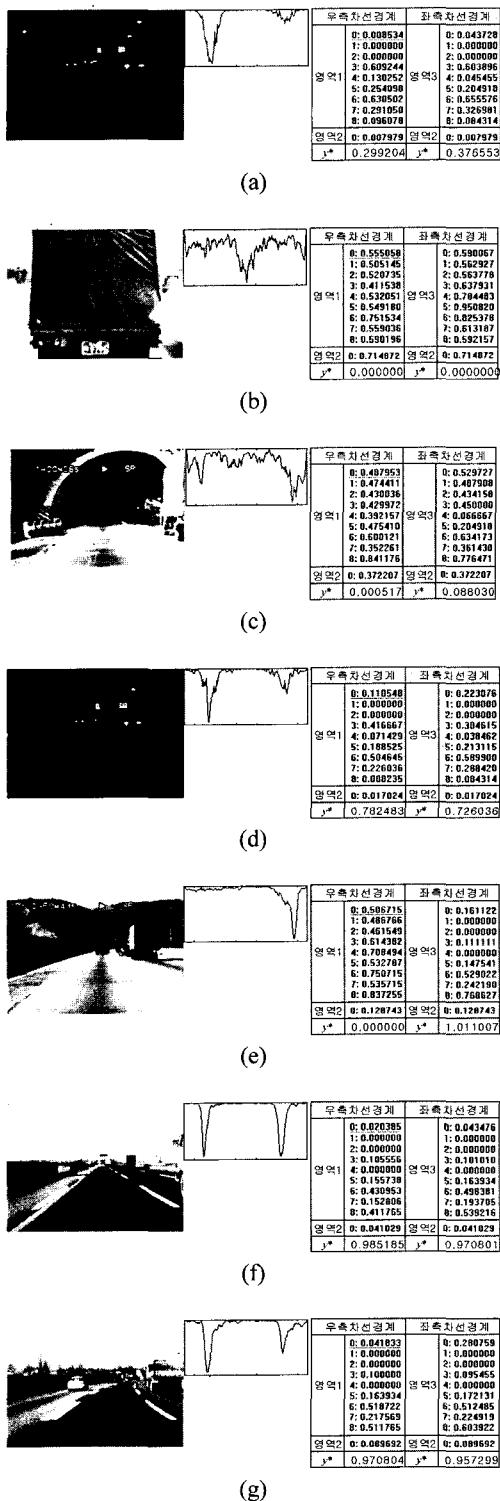


Fig. 12 FNN 판정 결과

5. 결 론

본 논문에서는 FNN과 EDF라고 하는 함수를 도입하여 지금까지 연구가 활성화되지 않았던 분야인 차선표식의 가시도의 관점에서 도로영상의 잡음도를 식별하였다. 잡음도 식별률은 당초 목표했던 95% 수준을 상회하는 만족스러운 결과를 얻을 수 있었다. 현재 수행된 연구결과는 Visual C++환경에서 구현되었고, 판정속도는 초당 17프레임(프레임 크기: 320×240) 정도의 수준이다. 차선관련정보의 추출이 단순히 영상처리 알고리즘을 적용해 보는 수준을 뛰어 넘어 차량의 안전도나 운전의 편의성 향상의 목적을 갖기 위해서는 신뢰성이 높은 정보가 요구되므로 본 논문의 연구 테마와 같은 분야의 연구가 활발히 이루어져야 한다. 현재의 연구에서는 FNN의 입력 파라메터 수를 늘리거나 줄였을 때 FNN의 판정결과가 어떻게 변할지에 대해서는 충분히 평가를 해 보지는 못했다. 또한 본 논문연구에 있어서 휴리스틱스나 매직넘버(magic number)에 의존한 점들은 그 근거를 제시하려고 노력하였지만 미비한 점은 앞으로도 보완해야 할 요소이다.

후 기

이 논문은 2001년도 전남대학교 학술연구비 지원에 의하여 연구되었음.

참 고 문 헌

- D. A. Pomerleau, T. Jochem, "Rapidly Adapting Machine Vision for Automated Vehicle Steering," IEEE Expert Intelligent System and Their App., April, pp.19-27, 1996.
- A. D. Bimbo, L. Landi, S. Santini, "Determination of Road Directions using Feedback Neural Nets," Signal Process, Vol.32, pp.147-160, 1993.
- K. Sato, T. Goto, Y. Kubota, "A Study on a Lane Departure Warning System using a Steering Torque as a Warning Signal," Proc. AVEC '98, pp.479-484, 1998.

- 4) A. Broggi, "A Massively Parallel Approach to Real-Time Vision Based Road Marking Detection," Proc. IEEE Intelligent Vehicle '95, pp.84-89, 1995.
- 5) M. Bertozzi, A. Broggi, "Real-Time Lane and Obstacle Detection on the GOLD System," Proc. IEEE Intelligent Vehicle '96, pp.213-218, 1996.
- 6) E. D. Dickmanns, A. Zapp, "Autonomous High Speed Road Vehicle Guidance by Computer Vision," Proc. IFAC 10th Triennial World Congress, pp.221-226, 1987.
- 7) S. P. Liou, R. C. Jain, "Road Following Using Vanishing Points," CVGIP, Vol.39, pp.116-130, 1987.
- 8) J. W. Lee, U. K. Yi, K. R. Baek, "A Cumulative Distribution Function of Edge Direction for Road Lane Detection," IEICE Trans. Information and systems, Vol.E84-D, No.9, pp.1206 -1216, 2001.
- 9) 이준웅, 이성웅, "에지분포함수 기반의 차선 이탈경보 알고리즘," 한국자동차공학회논문집, 제9권 제3호, pp.143-154, 2001.
- 10) A. Takahashi, Y. Ninomiya, "Model-Based Lane Recognition," Proc. IEEE Intelligent Vehicles '96, pp.201-206, 1996.
- 11) C. T. Lin, C. S. George Lee, Neural Fuzzy Systems, Prentice Hall, Inc., 1996.
- 12) S. Horikawa, T. Furuhashi, Y. Uchikawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm," IEEE Trans. Neural Networks, Vol.3, No.5, pp. 801-806, 1992.
- 13) G. G. Gonzalez, R. E. Woods, "Digital Image Processing," Addison-Wesley, 1992.
- 14) R. Y. TSAI, "A Versatile Camera Calibration Technique for High-Accuracy 3D Vision Metrology Using Off-the Self TV Cameras and Lenses," IEEE J. of Robotics and Automation, Vol.RA-3, No.4, pp.223-344, 1987.
- 15) L. Fausett, Fundamentals of Neural Networks, Prentice-Hall, 1994.