

퍼지신경망을 이용한 도로 영상의 양불량 판정

Determination of Road Image Quality Using Fuzzy-Neural Network

이 운 근, 백 광 렬, 이 준 웅

(Un-Kun Yi, Kwang Ryul Baek, and Joon Woong Lee)

Abstract : The confidence of information from image processing depends on the original image quality. Enhancing the confidence by an algorithm has an essential limitation. Especially, road images are exposed to lots of noisy sources, which makes image processing difficult. We, in this paper, propose a FNN (fuzzy-neural network) capable of deciding the quality of a road image prior to extracting lane-related information. According to the decision by the FNN, road images are classified into good or bad to extract lane-related information. A CDF (cumulative distribution function), a function of edge histogram, is utilized to construct input parameters of the FNN, it is based on the fact that the shape of the CDF and the image quality has large correlation. Input pattern vector to the FNN consists of ten parameters in which nine parameters are from the CDF and the other one is from intensity distribution of raw image. Correlation analysis shows that each parameter represents the image quality well.

According to the experimental results, the proposed FNN system was quite successful. We carried out simulations with real images taken by various lighting and weather conditions and achieved about 99% successful decision-making.

Keywords : lane-related information, cumulative distribution function (CDF), fuzzy-neural network, image processing, image quality

I. 서론

주행중인 차량이 운전자의 의도와 무관하게 주행차선을 벗어나는 상황을 미연에 방지하려는 차선이탈 경보나 방지 시스템의 개발이 시도되고 있다. 이러한 기술을 구현하기 위해서는 도로의 차선정보를 추출하여야 하는데 컴퓨터비전의 영상처리기술에 의존하는 것이 일반적인 경향이 되고 있다[1]-[4].

본 논문에서는 아스팔트나 시멘트로 포장되어 있고, 차선을 구분짓는 차선경계의 표식(lane mark)이 도색되어 있는 도로를 대상으로 한다. 이러한 도로의 입력영상에서 차선경계의 위치나 차선경계의 기울기정보 등으로 구성된 차선정보를 추출하여 차선이탈 경보에 활용하는데 관심을 갖고 있다. 그러나, 실제의 도로영상은 예측이 어려운 여러 가지 랜덤(random)한 잡음성분(각종 그림자, 타이어 자국, 차선경계의 마모, 강우 시, 광량의 급격한 변화)이 존재하기 때문에 영상에서 정확한 차선정보를 추출하는 것은 무척 어려운 일이다. 왜냐하면 영상처리에 의한 차선정보추출의 문제점은 날씨나 조명조건에 영상처리기술이 너무 민감하다는 것이다. 심지어 사람의 육안으로도 차선표식을 식별할 수 없는 조건이 발생한다. 이러한 상황에서 획득된 도로영상에 대해 영상처리 알고리즘을 적용하여 추출된 정보는 신뢰하기 어렵고, 궁극적으로 차선이탈 경보나 방지시스템의 본래 취지와는 다르게 차량의 안전운전에 방해가 되는 요소로 작용할 수 있다.

따라서 차선정보추출 이전 단계에서 획득된 도로영상의 양불량을 미리 판단할 수 있다면 신뢰할 수 없는 정보의 추

출은 충분히 막을 수 있고, 결과적으로 차량제어의 안전성을 높일 수 있으리라고 기대할 수 있다. 여기에서 도로영상의 양불량에 대한 의미는 차선경계의 표식이 잡음에 가려져 있지 않고, 얼마나 잘 보이는가 하는 것이다. 양불량에 대한 정량적인 척도(measure)를 마련하는 것은 쉽지 않기 때문에 우리는 경험적(heuristic approach)으로 사람의 판단능력에 의존한다. 만약 차선표식이 거의 보이지 않는 불량한 영상으로 입력영상이 판정을 받는다면 차선정보추출 과정을 생략하고, 다음 입력영상으로 처리과정을 넘길 수 있다.

이러한 연구는 실체적인 시스템(practical system)을 구현하기 위해서는 필수적으로 요구되며, 안정성 확보라는 측면에서 매우 중요하다. 그러나, 빛의 변화나 도로포장 색깔의 변화와 그림자 등과 같은 변화뿐만 아니라 예기치 못할 상황들이 실제에서는 발생하지만, 이런 가능성을 모두 고려한다는 것은 쉬운 일이 아니다. 이를 극복하기 위해 잡음이 많은 영상의 처리기술에 관한 연구는 진행되고 있으나 입력영상의 양불량 판정에 관한 연구는 미약한 실정이다[5][6].

Takahash 등은 에지 포인트(edge point)에서 추출한 파라미터 공간에서 RVP-I(real-time voting processor-I)을 이용하여 고속도로에서 획득한 강우 시, 그림자가 있는 영상에 대해 개인화 차선정보 검출을 이루었으며[5], Kreucher와 Lakshmanan은 주파수영역에서 차선정보의 특징치를 추출하여 조명변화와 차선이 가려진 경우 등의 잡음환경 하에서 신뢰성 있는 차선정보 검출을 이루었다[6]. 그렇다고 하더라도 기타의 또 다른 잡음환경 즉, 외관상 도로차선이나 경계처럼 보이는 많은 유사 특징치가 존재하는 경우, 햇빛반사, 도로경계가 마모된 경우 등에서의 작동은 신뢰성에 한계를 보일 수밖에 없다.

본 논문에서는 차선이탈 경보시스템 실현을 위해 필수적으로 요구되는 신뢰성 있는 차선정보를 제공하기 위하여

논문접수 : 2001. 10. 29., 채택확정 : 2002. 3. 26.

이운근 : 부산대학교 전자공학과 박사과정(yiuk@pusan.ac.kr)

백광렬 : 부산대학교 전자전기정보컴퓨터공학부(krbaek@pusan.ac.kr)

이준웅 : 전남대학교 산업공학과 교수(joonlee@chonnam.ac.kr)

차선정보추출 수행 이전 단계에서 입력영상의 양불량을 판정하여 차선정보추출이 양호한 영상인지 아닌지에 대한 정보를 시스템에 제공하는 것에 초점을 맞춘 것이며, 차선정보의 추출 및 이의 활용은 본 논문의 범위에 포함되지 않는다.

도로영상의 양불량을 판정하기 위해서 본 논문에서는 입력된 영상에 대한 에지의 방향성분을 누적시킨 누적분포함수(cumulative distribution function, CDF)를 사용한다[7]. CDF의 모양을 육안으로 잘 분석하면 차선정보의 추출이 가능한 영상인지 아닌지를 판정할 수 있다. 이를 컴퓨터로 구현하기 위해서는 CDF에서 특징치를 추출하여 차선정보추출의 가능성을 추론하여야 한다. 여기에서 추론의 방법으로는 무작위(brute-force) 방법, 베이지안(bayesian) 이론에 근거한 통계적인 방법[8] 및 페지나 신경망에 의한 접근방법[9][10] 등이 있다. 무작위 방법은 경우의 수가 많아 표현하는데 한계가 있고, 베이지안 알고리즘에 의한 방법은 사전 확률(a priori probability)이 필요하다. 사전확률은 표본집단에 대한 특성에서 나오는데 정확한 사전확률을 얻는 것은 쉽지 않을 뿐만 아니라 표본집단에 대한 상당한 지식을 요구한다[8]. 그러므로 도로영상처럼 매우 다양하게 나타나는 경우에는 영상의 양불량을 판정하는 알고리즘을 구성하는데 한계가 있다. 이러한 문제를 효과적으로 처리하기 위해서는 다양하고, 동적인 도로환경에 대처하는 지능(intelligence)이 가미되어야 한다.

이에 적절한 방법으로 페지(fuzzy) 및 신경망(neural network)이론을 들 수 있다. 최근에는 이들의 각각의 장점을 융합한 페지신경망(fuzzy-neural network, FNN)에 대한 연구가 활발히 이루어지고 있고, 이는 여러 가지 문제해결에 있어서 양호한 결과를 보이고 있다[9][10]. 특히 페지신경망 기반 진단기법은 비선형성이 강한 데이터가 주어질 경우, 다양한 학습기법에 의해 이를 효과적으로 매핑할 수 있다는 점과 학습시 경험하지 못한 데이터에 대해서도 효율적인 보간을 수행할 수 있다는 점 때문에 진단분야에서 적극적으로 도입되고 있다[11].

따라서 본 논문에서는 인간의 언어적 행동을 정량화 하기에 용이한 페지와 인간의 행동을 학습하여 일반화 능력이 있는 신경망의 두 가지 방법을 혼합한 페지신경망을 사용하여 도로영상의 양불량을 판정한다. 구현된 페지신경망의 입력은 입력된 영상에 대해 구축한 CDF로부터 추출한 9개이며, 이들의 특징 파라미터는 입력영상과의 상관관계 해석을 통하여 영상의 양불량 예측과 깊은 상관성을 갖고 있음을 밝힌다. 페지신경망의 구조는 실시간 처리와 효율적인 판정을 위하여 입력수를 5개인 경우, 7개인 경우, 그리고 9개인 경우로 나누어 실험을 실시하며, 도로영상의 양불량 판정에 대한 유용성을 검증한다.

II. 도로영상의 양불량 판정시스템

도로영상의 양불량 판정은 차량에 장착된 CCD 카메라에 의해 입력된 영상에 대하여 차선의 방향이나 차선표식 등과 같은 정보를 정확히 검출해 낼 수 있는 것인지, 없는 것인지 를 미리 판별하기 위한 것으로 그 구성은 그림 1과 같다.

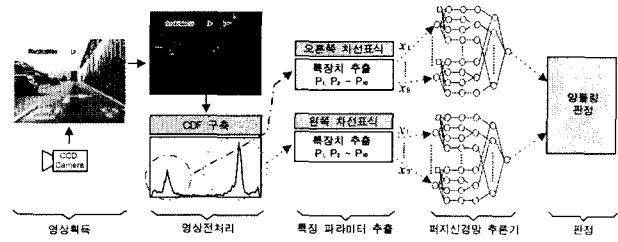


그림 1. 전체 시스템의 구성.

Fig. 1. Structure of the system.

그림 1에서와 같이 입력된 도로영상에는 많은 양의 퍽셀 정보를 갖고 있다. 각 퍽셀을 페지신경망 추론기의 입력단에 모두 사용할 수는 없다. 왜냐하면, 데이터의 양이 너무 많기 때문에 추론기의 구조가 복잡해지고, 판정에 소요되는 계산 시간이 증가될 뿐만 아니라 판정할 특징이 잘 표현되지 않아 오히려 성능이 감소될 수 있다. 그러므로 영상의 양불량 판정에 영향을 미치는 중요한 특징이 되는 값을 추출함으로써 페지신경망의 입력을 단순하게 하고, 판정도 용이하게 하는 전처리 과정이 필요하다.

영상의 전처리 과정은 차선이 갖는 두 가지 사실적 증거 즉, 1) 차선표식은 배경보다 더 밝은 색으로 도색되어 있다. 2) 차선의 방향은 완만하게 변하고, 국부적으로 직선이며 평행하다.라는 증거에 근거하여 에지픽셀들의 크기를 방향에 대하여 누적시켜 CDF를 구축한다[11]. CDF의 형상은 차선 정보를 잘 반영하고 있으므로 이를 고찰하면 도로영상의 양불량을 판별할 수 있는 중요한 정보가 된다. 따라서 본 논문에서는 CDF에서 특징치를 추출하고, 이를 특정 파라미터로 하여 도로영상의 양불량을 판정하기 위한 추론기인 페지신경망에 입력한다. 여기서 페지신경망은 영상의 양불량을 판정하기 위한 맵핑 함수(mapping function) 역할을 하며, 학습에 의해 이루어진다. 최종 판정결과는 입력영상에서 신뢰성 있는 차선정보의 추출이 가능한가를 나타내며, 차선정보추출 양호(1) 및 불량(0)을 나타낸다.

III. 특징 파라미터 추출

1. CDF 구축

페지신경망에 입력되는 특징 파라미터를 추출하기 위해 영상의 에지정보를 사용하여 (1)과 같이 CDF로 명명한 일차원 함수를 정의한다[7][12].

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

여기에서 θ 는 에지의 각도 $\alpha(x, y)$ 를 가리키며, $\nabla f(x, y)$ 는 에지의 크기를 나타낸다.

CDF는 방향성분이 동일한 에지픽셀들의 크기를 누적시킨 함수로서, 도로영상에서 차선표식의 경계는 다른 부분에 비해 크기가 크고 비교적 일관된 방향성분의 에지픽셀을 많이 갖고 있기 때문에 CDF를 구축해 보면 차선경계의 방향에 해당되는 곳에서 큰 값을 갖는다. 그림 2 (a)에 나타낸 것과 같이 오른쪽 차선경계와 왼쪽 차선경계의 방향을 각각 θ_1 과

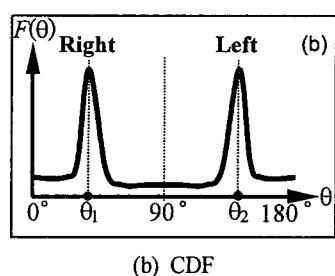
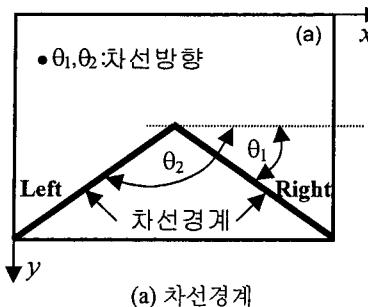


그림 2. 차선경계와 CDF.

Fig. 2. Lane boundary and CDF.

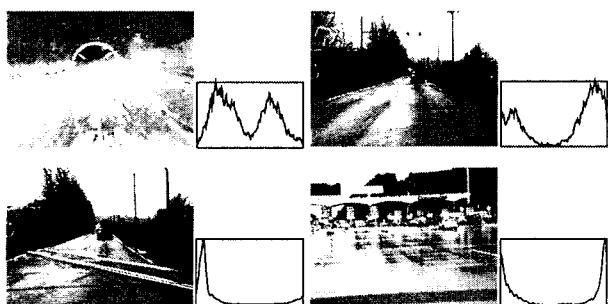
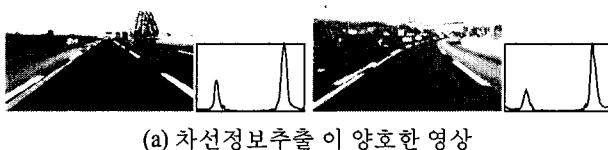


그림 3. 대표적인 도로영상과 CDF.

Fig. 3. Typical road images and its CDF.

θ_2 라 가정한다. 이때 CDF를 $F(\theta)$ 라 놓고 $F(\theta)$ 를 0° 부터 180° 사이에서 정의하면 그림 2 (b)에 나타낸 것과 같은 CDF가 구축된다. 이 그림에서 차선경계와 CDF와의 관계를 알 수 있다.

그림 3은 도로영상의 양불량 판정을 위한 대표적인 영상과 이의 CDF를 나타낸다. 그림에 나타나듯이 CDF의 모양은 차선방향에 해당되는 각도의 근방에서 큰 값을 갖는다. 이는 차선방향은 급격한 변화 없이 연속성을 갖는 반면 차선 이외의 객체들은 이러한 특성을 갖고 있지 않기 때문이다. 이렇게 구축된 CDF는 영상의 양불량 판정을 위한 많은 정보를 포함하고 있음을 알 수 있다. 결국 CDF는 입력영상에 나타

난 차선경계의 기울기정보를 잘 묘사해 주므로 CDF의 형상을 분석하면 신뢰성 있는 차선정보의 추출이 가능한 영상인지 아닌지를 판정할 수 있다.

2. 특징 파라미터 추출

퍼지신경망의 입력에 사용된 특징 파라미터는 CDF의 모양을 고찰하여 확률적인 분포로 허리스틱(heuristic)하게 정의하였다. 특징 파라미터는 총 10개이며, 이중 9개는 CDF에서 추출하고, 1개는 입력영상의 밝기분포에서 추출하였다. CDF에서 추출한 9개의 파라미터 중 4개는 그림 4에 나타낸 것과 같이 CDF를 5개 영역으로 분할하여 Zone0에서 Zone4의 서로 상대적인 영역과의 비교를 통하여 추출하고, 나머지 5개는 Zone1 또는 Zone3에 나타나는 함수의 형태를 고찰하여 추출하였다. CDF는 축대칭성분을 갖고 있다. 차선은 평행하므로 차량이 차선 중심을 주행하면 함수의 모양은 항상 90° 를 중심으로 좌우 대칭성을 유지한다. 그러므로 차선의 오른쪽 차선표식에 대한 특징 파라미터 추출은 Zone0~Zone2의 영역을, 왼쪽 차선표식에 대한 특징 파라미터 추출은 Zone2~Zone4의 영역을 활용한다. 다음에 정의되는 특징 파라미터 $P_1 \sim P_{10}$ 은 오른쪽 차선표식에 해당하는 Zone0~Zone2의 영역을 기준으로 정의하였으며, 만약 왼쪽 차선표식의 특징 파라미터 $P_1 \sim P_{10}$ 을 정의하기 위해서는 Zone2~Zone4의 영역을 사용하면 된다. 추출한 특징 파라미터 $P_1 \sim P_{10}$ 의 값은 0에 가까울수록 차선정보추출이 양호함을 나타낸다.

특징 파라미터 P_1 은 Zone0과 Zone1과의 상대적인 관계에 의해 생성되며, 다음 (2)와 같이 정의하였다.

$$P_1 = 1 - \frac{1}{2} \left\{ \frac{(\mu_1 + \sigma_1) - (\mu_0 + \sigma_0)}{(\mu_1 + \sigma_1) + (\mu_0 + \sigma_0)} + 1 \right\} \quad (2)$$

여기에서 μ 는 CDF의 평균값, σ 는 표준편차를 나타내며, μ 와 σ 의 아랫 첨자 0과 1은 CDF에서의 해당 Zone을 나타낸다.

차선표식이 없을 것이라고 기대한 영역(Zone0)과 차선표식이 있을 것이라고 기대한 영역(Zone1)을 서로 비교하여 차선표식이 없을 것이라고 기대한 영역에서 함수의 값이 크게 나타나면 입력영상이 불량일 수 있음을 나타낸다. 이 경우의 예를 들면, 차선표식이 없는 곳, 철로 건널목, 톤게이트 입출구, 자차선의 표식이 마모된 경우 등이 차선표식이 없을 것이라고 기대하는 영역에 애지 성분이 강하게 나타날 수 있는 경우이다.

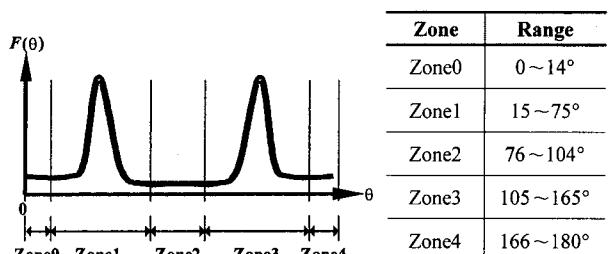


그림 4. CDF 영역분할.

Fig. 4. Division of the CDF.

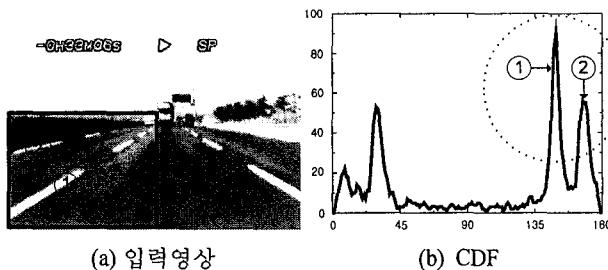


그림 5. 다차선이 검지되는 영상과 CDF.

Fig. 5. Road image with multiple lane detection and its CDF.

그러나, 그림 5에 나타낸 것과 같이 다차선이 검지되는 영상의 경우에는 차선의 차선성분이 잘 나타남에도 불구하고 CDF의 모양은 두 개의 국부최대값(local maxima point, LMP)를 나타내고, P_1 은 1에 가까워지며 차선정보추출 불량에 가까운 값을 나타낸다. 이를 보완하기 위해 추가로 P_2 , P_3 을 다음의 (3)과 (4)로 정의하였다. P_2 , P_3 은 P_1 과 달리 다차선이 검지되는 영상일 경우에도 주행중인 차선 영역의 에지정보가 강하면 양호의 값을 출력한다.

$$P_2 = 1 - \frac{1}{2} \left\{ \frac{u_1 - u_0}{u_1 + u_0} + 1 \right\} \quad (3)$$

여기에서

$$u_0 = \frac{\sum_{\theta \in R_0} F(\theta)}{\|R_0\|}, \quad R_0 = \{\theta \mid F(\theta) > \mu_1, 0 \leq \theta \leq 14\}$$

$$u_1 = \frac{\sum_{\theta \in R_1} F(\theta)}{\|R_1\|}, \quad R_1 = \{\theta \mid F(\theta) > \mu_1, 15 \leq \theta \leq 75\}$$

$$P_3 = 1 - \frac{1}{2} \left\{ \frac{S_{i_1} - S_{i_0}}{S_{i_1} + S_{i_0}} + 1 \right\} \quad (4)$$

여기에서

$$S_{i_0} = \frac{\sum_{\theta \in R_0'} F(\theta)}{\|R_0'\|}, \quad R_0' = \{\theta \mid F(\theta) > \mu_1 + \sigma_1, 0 \leq \theta \leq 14\}$$

$$S_{i_1} = \frac{\sum_{\theta \in R_1'} F(\theta)}{\|R_1'\|}, \quad R_1' = \{\theta \mid F(\theta) > \mu_1 + \sigma_1, 15 \leq \theta \leq 75\}$$

특정 파라미터 P_4 는 Zone1, Zone2 및 Zone3와의 상대적인 관계에 의해 생성되며, 다음의 (5)와 같이 정의하였다.

$$P_4 = \frac{u_1 + u_3 - u_2}{u_1 + u_3 + u_2} \quad (5)$$

여기에서

$$u_2 = \frac{u' + u''}{2}$$

$$u' = \frac{\sum_{\theta \in R'} F(\theta)}{\|R'\|}, \quad R' = \{\theta \mid F(\theta) > \mu_1, 76 \leq \theta \leq 90\}$$

$$u'' = \frac{\sum_{\theta \in R''} F(\theta)}{\|R''\|}, \quad R'' = \{\theta \mid F(\theta) > \mu_3, 91 \leq \theta \leq 104\}$$

P_4 는 Zone1과 Zone3에 비해 Zone2의 에지성분이 강하게 나타나는 경우를 구분하기 위한 파라미터이다. 이러한 상황은 앞 차량에 의해 차선표식이 가려져 있는 경우에 나타난다. 또한 도로에서 차량이 차선경계와 차량의 중심(카메라의 광축)이 일치하여 주행하는 경우도 Zone1과 Zone3에 비해 Zone2의 에지성분이 강하게 나타난다. 후자의 경우는 그림 6에 보인 바와 같이 앞 차량에 의해 차선이 가려져 있는 경우와 CDF의 모양이 유사하여 본 논문에서 정의한 파라미터로 구별하기에는 어렵다. 이러한 경우는 차선을 변경하여 주행하고 있는 것으로 실제 거의 나타나지 않을 뿐만 아니라 차선변경의 상황을 미리 인지할 수 있으므로 본 논문에서는 폐지신경망의 학습 데이터에서 제외시켰다.

특정 파라미터 $P_5 \sim P_9$ 은 Zone1 또는 Zone3에 나타나는 함수의 모양을 분석한 입력영상의 잡음정도를 나타내는 파라미터이다. 그림 7 (a)는 비교적 잡음이 심한 영상을 보여준 것이며, 그림 7 (b)는 이 영상의 CDF로서 ④로 표시된 부분의 형상을 확대해서 본 그림이 그림 7 (c)이다. 그림 7 (c)를 보면 함수의 형상이 유통불통(uneven)하다는 것을 알 수 있는데, 이는 영상의 잡음 때문이다. 이와 같이 함수의 모양에서 유통불통한 정도를 나타낸 것이 P_5 이며, 다음 (6)과 같이 정의하였다.

$$P_5 = \frac{F_{req_updown}}{\max\{R\} - \min\{R\} + 1} \quad (6)$$

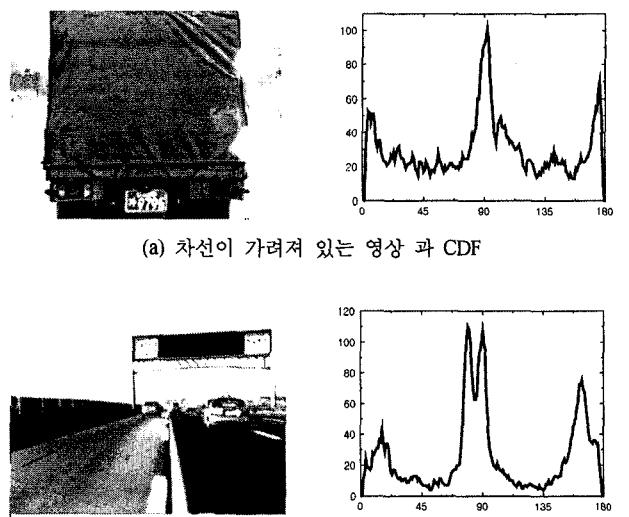


그림 6. 차선이 가려져 있는 경우와 차선변경 중인 영상의 CDF.

Fig. 6. Road image with occlusion and lane change and their CDF.

여기에서

$$\mathcal{R} = \{\theta \mid F(\theta) > \mu_1 + \sigma_1, 15 \leq \theta \leq 75\}$$

$$\max_{\theta}\{\mathcal{R}\} = \max_{\theta}\{F(\theta)\}, \min_{\theta}\{\mathcal{R}\} = \min_{\theta}\{F(\theta)\}$$

(6)에서 F_{freq_updown} 은 함수 $F(\theta)$ 가 $\min\{\mathcal{R}\}$ 과 $\max\{\mathcal{R}\}$ 내에서 들쑥날쑥거리는 횟수이며, 그림 7(c)에서 화살표의 갯수와 같다. 따라서 P_5 는 0이 될 수는 없다. 그러나 0에 가까우면 양호한 것으로 간주된다.

특징 파라미터 P_6 은 불량한 도로영상일수록 $\min\{\mathcal{R}\}$ 과 $\max\{\mathcal{R}\}$ 사이에 $\mu + \sigma$ 를 교차하는 봉우리가 많을 것이라는 가정을 토대로 다음의 (7)과 같이 정의하였다.

$$P_6 = 1 - \frac{\|\mathcal{R}\|}{\max\{\mathcal{R}\} - \min\{\mathcal{R}\} + 1} \quad (7)$$

여기에서 $\|\mathcal{R}\|$ 은 집합 \mathcal{R} 의 원소의 갯수를 나타내며, 그림 7(d)에서 빛금친 부분이 이에 해당된다. 만약 $\min\{\mathcal{R}\}$ 과 $\max\{\mathcal{R}\}$ 사이에 $\mu + \sigma$ 를 교차하는 봉우리가 많다면 이는 그림 7(a)와 같이 차선표식 이외의 성분들이 영상에 존재할 가능성이 크다는 것을 의미할 수 있다. P_6 은 이런 사실을 뒷받침하는 파라미터이다.

특징 파라미터 P_7 은 불량한 도로영상일수록 $\min\{\mathcal{R}\}$ 과 $\max\{\mathcal{R}\}$ 사이의 간격이 넓을 것이라는 가정을 토대로 다음의 (8)과 같이 정의하였다.

$$P_7 = \frac{\max\{\mathcal{R}\} - \min\{\mathcal{R}\} + 1}{w} \quad (8)$$

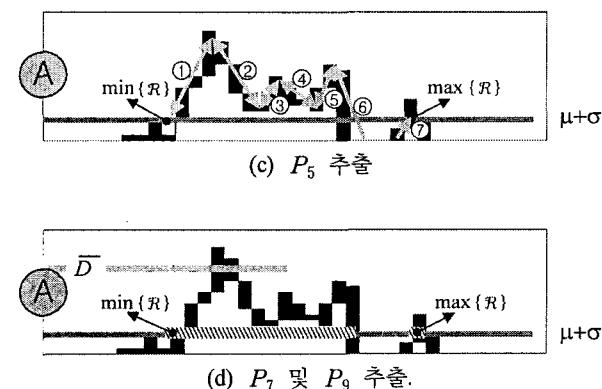
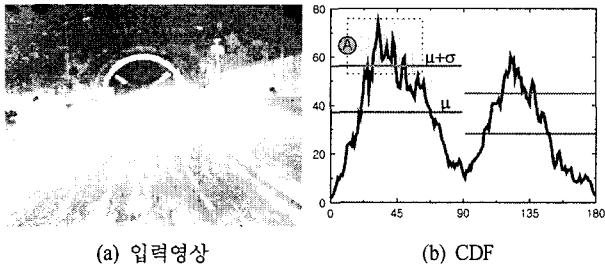


그림 7. 특징 파라미터 추출.

Fig. 7. Extraction of feature parameters.

여기에서 w 는 Zone2의 범위를 나타내며, 그 값은 75-15+1로 61이다. 그림 7(d)에 나타낸 것과 같이 $\min\{\mathcal{R}\}$ 과 $\max\{\mathcal{R}\}$ 사이의 간격이 넓을수록 불량한 영상을 나타내며, 그 간격이 좁을수록 CDF 모양은 뚜렷(sharp)하여 차선식별이 양호하리라는 것을 예고한다.

특징 파라미터 P_8 은 차선식별이 어려운 도로영상의 경우 $\min\{\mathcal{R}\}$ 이 15° 이하 즉, 차선표식이 없을 것으로 기대한 영역 Zone0에 존재할 가능성이 크다는 가정을 토대로 다음의 (9)와 같이 정의하였다.

$$P_8 = \begin{cases} 1, & \text{if } \min\{\mathcal{R}\} - 15 \leq 1 \\ 0, & \text{otherwise} \end{cases} \quad (9)$$

그림 8(a)는 톨게이트 진입영상을 보인 것으로 잡음이 심함을 알 수 있고, 그림 8(b)는 이 영상의 CDF를 표시한 것으로 $\min\{\mathcal{R}\}$ 이 Zone0 부근에 있음을 보이고 있다.

특징 파라미터 P_9 은 차선식별이 어려운 도로영상은 CDF의 평균과 최대값(그림 7(d)의 D 로 표시) 사이의 차가 작을 것이라는 가정을 토대로 다음의 (10)과 같이 정의하였다.

$$P_9 = \frac{\mu_1}{D} \quad (10)$$

여기에서 D 는 Zone1내에서 CDF의 가장 큰 값 5개의 평균을 취한 값이다.

특징 파라미터 P_{10} 은 입력영상의 밝기분포에서 추출하였으며, 차선식별이 불량한 영상일수록 밝기의 평균값은 클 것이라는 가정을 토대로 다음의 (11)과 같이 정의하였다.

$$P_{10} = \frac{\frac{1}{n} \sum_{i=1}^n f(x, y)}{255} \quad (11)$$

여기에서 $f(x, y)$ 는 영상의 밝기를 나타낸 것이며, n 은 관심영역의 픽셀의 수이다.

3. 특징 파라미터의 상관성 평가

퍼지신경망의 입력에 사용되는 특징 파라미터에 대한 유효성을 평가하기 위해 다양한 환경의 도로영상을 사용하였다. 평가에 사용된 도로영상은 400개를 선별하였으며, 이는

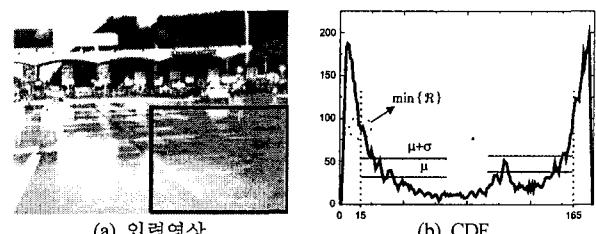


그림 8. 톨게이트 진입 영상과 CDF.

Fig. 8. Tollgate entry image and its CDF.

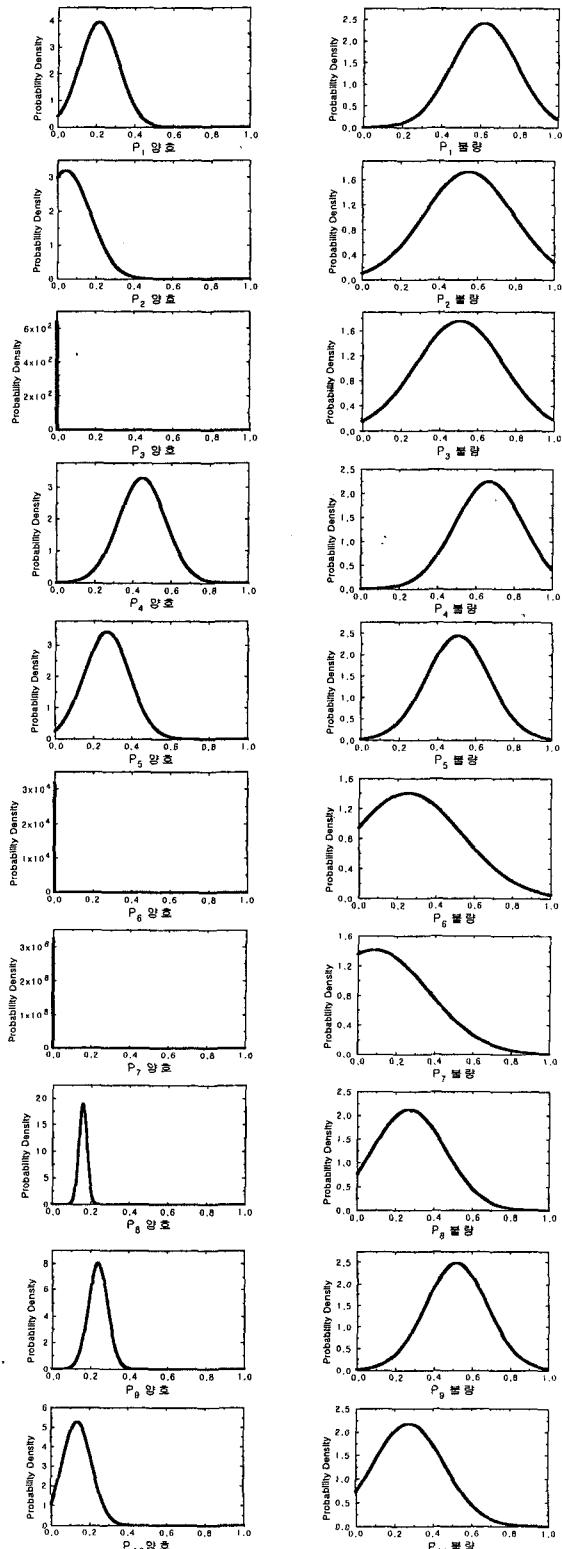


그림 9. 특징 파라미터의 확률분포.

Fig. 9. Probability distribution of feature parameters.

도로표식이 심하게 마모된 경우, 강우 시, 톤게이트 진출입시, 전방차량에 의해 차선이 가려져 있는 경우 또는 터널 입출구에서 순간적으로 조도차가 심하게 발생하는 경우, 도로바닥에 표식 및 글자가 새겨져 있는 경우, 곡선도로, 잡음이 많고 도로폭이 좁은 교외도로 등이다. 입력영상에 대한 양불

량의 판단은 사람의 판단능력에 의존하였다. 즉 서너명의 사람에게 선별한 400개의 영상을 제시하고, 차선표식이 잘 보이는가를 판정하도록 하여 양불량을 판정하였다. 그림 9는 이들 영상의 양불량 판정결과에 대한 특정 파라미터 $P_1 \sim P_{10}$ 의 상관관계를 나타낸 것이다.

그림 9에 나타낸 특정 파라미터 $P_1 \sim P_{10}$ 의 분포는 도로영상의 양불량을 판정하기 위해 큰 변별력을 가짐을 알 수 있다. 따라서 추출한 특정 파라미터 $P_1 \sim P_{10}$ 의 조합에 의한 판단은 신뢰성 있는 정보를 제공하며, 이는 앞 절에서 정의한 특정 파라미터의 유효성을 검증할 수 있음을 알 수 있다.

IV. 퍼지신경망의 구성 및 학습

1. 퍼지신경망의 구성

본 논문에서 사용된 퍼지신경망의 구조는 그림 10과 같다 [10]. 이는 후건부 소속 함수를 상수값으로 표현하는 퍼지신경망으로 비퍼지화기를 추론기에 포함시킨 형태이다. 도로영상의 양불량을 판정하기 위한 퍼지신경망의 입력은 CDF 및 입력영상에서 추출한 특정 파라미터 10개를 활용하여, 각 입력에 대한 퍼지변수는 '차선정보추출 양호', '흐릿', '불가'의 3개, 그리고 1개의 출력을 갖는다.

전건부 (C)층 유닛은 시그모이드 함수를 내부함수로 가지며, 출력 O_j^c 는 결합하중 w_c , w_g 를 이용하여 다음의 (12)와 같이 된다.

$$O_j^c = \frac{1}{1 + \exp\{-w_g(x_j + w_c)\}} \quad (12)$$

퍼지규칙은 다음과 같은 퍼지합의(fuzzy implication)로 표현된다.

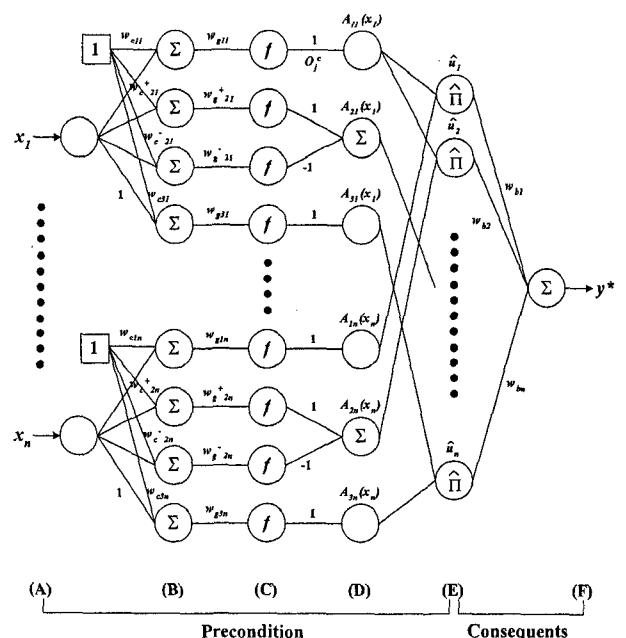


그림 10. 퍼지신경망의 구조.

Fig. 10. Structure of FNN.

$R^i: IF x_1 \text{ is } A_{i1} \text{ AND } \cdots \text{ AND } x_n \text{ is } A_{in} \text{ THEN } y_i \text{ is } w_{bi}$
 $(i=1, 2, \dots, n)$

$$y^* = \frac{\sum_{i=1}^n \mu_i w_{bi}}{\sum_{i=1}^n \mu_i} = \sum_{i=1}^n \hat{\mu}_i w_{bi} \quad (13)$$

여기에서 R^i 는 i 번째 퍼지규칙, x_1, \dots, x_n 은 입력, A_{i1}, \dots, A_{in} 은 퍼지변수, 그리고 y_i 는 i 번째 규칙의 출력이며 이때 w_{bi} 는 후건부 상수이다. μ_i 는 i 번째 규칙 R^i 의 전건부 적합도를 의미하며, $\hat{\mu}_i$ 는 μ_i 의 정규화된 값으로 (E)층의 출력이다. 또한 n 은 퍼지규칙의 갯수를 나타내며, 이는 각 입력에 대한 소속함수 갯수의 합이다. 퍼지신경망의 후진부는 (E)~(F)층으로 표현되며, 실제 판정값 발생을 위한 최종 추론값을 계산한다. 그리고, 입력에 대한 최종 추론값 y^* 는 명확한 값(crisp value)으로 본 논문에서는 영상의 양불량을 판정한 값을 나타낸다.

2. 퍼지신경망의 학습

퍼지신경망의 결합하중 변화량을 구하는 출력오차 E_p 는 다음과 같다.

$$E_p = \frac{1}{2} (y_p - y_p^*)^2 \quad (14)$$

여기에서 y_p 는 p 번째 학습 데이터의 목표값, y_p^* 는 y_p 에 대한 퍼지신경망의 추론값이다. 결합하중 w_{bi} 의 변화량을 역전파 알고리즘에 의하여 구하면 다음의 (15)와 같다.

$$\begin{aligned} \Delta w_{bi} &= -\eta \frac{\partial E_p}{\partial w_{bi}} \\ &= -\eta \frac{\partial E_p}{\partial y^*} \frac{\partial y^*}{\partial I^F} \frac{\partial I^F}{\partial w_{bi}} \\ &= \eta(y_p - y_p^*) \cdot 1 \cdot \hat{\mu}_i \end{aligned} \quad (15)$$

여기에서 η 는 학습률이다. 그리고, I^F 는 (F)층 유닛의 입력의 합으로 다음의 (16)과 같다.

$$I^F = y^* = \sum_{i=1}^n w_{bi} \hat{\mu}_i \quad (16)$$

마찬가지로 결합하중 w_c, w_g 의 개선량도 동일한 방법으로 구할 수 있다. 기호의 복잡함을 피하기 위하여 구체적인 결합하중 w_{g11} 및 w_{c11} 의 변화량을 유도하면 다음의 (17), (18)과 같다.

w_{g11} 의 변화량은

$$\Delta w_{g11} = -\eta \frac{\partial E_p}{\partial w_{g11}}$$

$$\begin{aligned} &= -\eta \frac{\partial E_p}{\partial y^*} \frac{\partial y^*}{\partial I^F} \sum_{k=1}^{19683} \left(\frac{\partial I^F}{\partial \hat{\mu}_k} \cdot \frac{\partial \hat{\mu}_k}{\partial I_k^F} \cdot \frac{\partial I_k^F}{\partial A_{11}} \right) \cdot \frac{\partial A_{11}}{\partial w_{g11}} \\ &= \eta(y_p - y_p^*) \cdot 1 \cdot \sum_{i=1}^3 \sum_{m=1}^3 \sum_{n=1}^3 \sum_{o=1}^3 \sum_{p=1}^3 \sum_{q=1}^3 \sum_{r=1}^3 \sum_{s=1}^3 \\ &\quad \left(w_{bj} \cdot \frac{1 - \hat{\mu}_j}{\sum_{i=1}^{19683} \mu_i} \cdot A_{22} A_{m3} A_{n4} A_{o5} A_{p6} A_{q7} A_{r8} A_{s9} \right) \\ &\quad \cdot (x_1 + w_{c11}) A_{11} (1 - A_{11}) \end{aligned} \quad (17)$$

여기에서 $j = 3^7(i-1) + 3^6(m-1) + 3^5(n-1) + 3^4(o-1) + 3^3(p-1) + 3^2(q-1) + 3^1(r-1) + 3^0(s-1) + 1$ 이며, I_k^F 는 (E)층의 k 번째 유닛의 입력의 합이다.

w_{c11} 의 변화량도 유사하게 유도하면 다음과 같다.

$$\begin{aligned} \Delta w_{c11} &= -\eta \frac{\partial E_p}{\partial w_{c11}} \\ &= \eta(y_p - y_p^*) \cdot 1 \cdot \sum_{i=1}^3 \sum_{m=1}^3 \sum_{n=1}^3 \sum_{o=1}^3 \sum_{p=1}^3 \sum_{q=1}^3 \sum_{r=1}^3 \sum_{s=1}^3 \\ &\quad \left(w_{bj} \cdot \frac{1 - \hat{\mu}_j}{\sum_{i=1}^{19683} \mu_i} \cdot A_{22} A_{m3} A_{n4} A_{o5} A_{p6} A_{q7} A_{r8} A_{s9} \right) \\ &\quad \cdot w_{g11} A_{11} (1 - A_{11}) \end{aligned} \quad (18)$$

V. 실험 및 결과

1. 퍼지신경망의 학습결과

본 논문에서는 실시간성 및 판정성 그리고, 향후 차선정보를 이용한 응용시스템의 하드웨어 구현시 비용 등을 고려하여 입력수를 3종류로 하여 퍼지신경망을 구성하였으며, 아래의 표 1과 같다.

표 1에 나타낸 것과 같이 퍼지신경망의 구성 1은 입력수가 5개인 경우이며, 사용된 특징 파라미터는 CDF에서 차선표식이 존재할 가능성이 높은 영역 Zone1 또는 Zone3의 합수모양을 고찰하여 추출한 $P_5 \sim P_9$ 이다. 구성 2는 입력수가 7개인 경우이며, 사용된 특징 파라미터는 구성 1에서 사용된 특징 파라미터 $P_5 \sim P_9$ 외에 차선이 가려져 있는 경우를 구별하기 위한 P_4 , 입력영상의 밝기분포에서 추출한 P_{10} 을 추가하였다. 그리고, 구성 3은 입력수가 9개인 경우이며, 사용된 특징 파라미터는 정의된 특징 파라미터 $P_1 \sim P_{10}$ 중 P_8 만을 제외하였는데, 이는 특징 파라미터 $P_1 \sim P_3$ 가 파라미터 P_8 의 역할을 포함하고 있기 때문이다.

표 1. 입력수에 따른 퍼지신경망 구성.

Table 1. Input number and structure of FNN.

| FNN 구성 | FNN 입력 수 | 사용된 특징 파라미터 |
|--------|----------|-----------------------------|
| Case 1 | 5 | $P_5 \sim P_9$ |
| Case 2 | 7 | $P_4 \sim P_{10}$ |
| Case 3 | 9 | $P_1 \sim P_7, P_9, P_{10}$ |

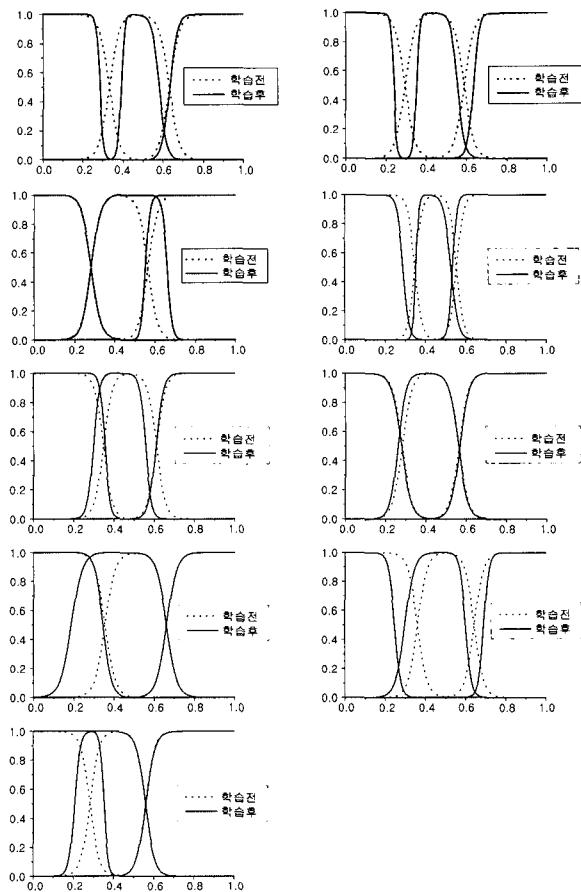


그림 11. 퍼지신경망의 학습결과.

Fig. 11. Learning results of FNN.

학습에 사용된 입력 패턴은 총 200개이며, 다양한 도로영상에 대하여 선별하였으며, 이들 샘플 영상은 사람이 차선식별 양호로 판정한 경우 32.5%, 흐릿 43.5%, 불량 24.0%로 구성되었다. 학습 완료 정도를 판단하기 위해 사용된 오차식은 퍼지신경망의 실제 출력값과 목표값과의 차이를 누적한 값이며, 학습 완료시점의 오차는 퍼지신경망의 입력수가 5, 7 및 9개일 때 각각 0.0824225, 0.0821424 및 0.0866539이었다.

그림 11은 퍼지신경망의 입력수가 9개일 때의 학습결과를 나타내며, 퍼지신경망의 초기 결합하중에 의한 퍼지변수의 소속함수와 학습을 완료한 후의 소속함수를 나타낸다. 초기의 후건부 결합하중은 모두 0으로 초기화하여 학습을 수행하였다.

2. 양불량 판정결과

학습이 완료된 퍼지신경망 추론기에 학습에서 사용되지 않은 영상을 대상으로 도로영상의 양불량 판정 실험을 하였으며, 이의 구현은 Visual C++환경 하에서 처리하였다. 사용된 영상 데이터는 총 8,732개로 양호 49.1%, 흐릿 31.7%, 불량 19.2%로 구성되었다. 이를 이용한 도로영상의 양불량 판정에 대한 실험은 퍼지신경망의 입력수가 5개, 7개 및 9개일 때 각각 수행하였으며, 그 결과는 표 2에 나타낸다.

실험결과 퍼지신경망의 입력수가 5개일 때는 전체적으로 88.4%, 7개일 때는 93.1% 그리고, 9개일 때는 99.5% 이상으로 퍼지신경망의 입력수가 증가할수록 판별력은 증가함을 알 수 있었다. 이는 CDF에서 정의한 특징 파라미터가 도로영상

의 양불량 판정과 깊은 상관성을 갖고 있음을 나타낸다.

퍼지신경망의 입력수가 5개, 7개일 때의 실험에서는 사람이 차선식별 불가로 판단한 영상을 흐릿과 양호로 또는 흐릿과 양호 영상을 불량으로 판정하는 경우가 발생되었다. 이러한 원인은 퍼지신경망의 학습시간 및 계산시간을 줄이기 위하여 5개 및 7개로 선택된 특정 파라미터가 도로영상에서 구축한 CDF의 다양한 함수모양을 특징짓기에는 충분하지 못한 것으로 판단된다. 그러나 퍼지신경망의 입력수가 9개일 때의 실험결과에서는 차선식별 불가에 해당하는 영상은 100% 차선식별 불가로 분류해 냄을 알 수 있는데, 이는 앞에서 정의한 특정 파라미터가 도로영상의 양불량을 판단하기에 유용한 정보임을 나타낸다. 또한, 양불량 판정의 맵핑함수 역할을 한 퍼지신경망의 유연한 제어성능을 보여준다.

VI. 결 론

본 논문에서는 CDF에서 추출한 특정 파라미터를 이용하여 도로영상의 양불량을 판정하기 위한 퍼지신경망을 제안하였다. 제안된 퍼지신경망의 구조는 실시간성 및 판정의 효율성을 고려하여 입력 수를 3종류 즉, 5개, 7개 및 9개로 구성하였으며, 각 입력에 대한 퍼지변수는 3개, 그리고 1개의 출

표 2. 양불량 판정 실험결과.

Table. 2. Experimental results of determination of image quality.

| 실험 영상 “양호” : 4,287개 | | | | | | |
|---------------------|-----------|-------|-----------|------|-----|------|
| FNN 입력수 | FNN 정상 판정 | | FNN 잘못 판정 | | | 판정률 |
| | 양호 | | 흐릿 | | 불가 | |
| | 영상수 | 판정률 | 영상수 | 판정률 | 영상수 | |
| 5 | 3,875 | 90.4% | 176 | 4.1% | 236 | 5.5% |
| 7 | 3,905 | 91.1% | 210 | 4.9% | 172 | 4.0% |
| 9 | 4,248 | 99.1% | 39 | 0.9% | 0 | 0.0% |

| 실험 영상 “흐릿” : 2,768개 | | | | | | |
|---------------------|-----------|-------|-----------|------|-----|------|
| FNN 입력수 | FNN 정상 판정 | | FNN 잘못 판정 | | | 판정률 |
| | 흐릿 | | 양호 | | 불가 | |
| | 영상수 | 판정률 | 영상수 | 판정률 | 영상수 | |
| 5 | 2,358 | 85.2% | 183 | 6.6% | 227 | 8.2% |
| 7 | 2,596 | 93.8% | 103 | 3.7% | 69 | 2.5% |
| 9 | 2,751 | 99.4% | 17 | 0.6% | 0 | 0.0% |

| 실험 영상 “불가” : 1,676개 | | | | | | |
|---------------------|-----------|--------|-----------|------|-----|------|
| FNN 입력수 | FNN 정상 판정 | | FNN 잘못 판정 | | | 판정률 |
| | 불가 | | 양호 | | 흐릿 | |
| | 영상수 | 판정률 | 영상수 | 판정률 | 영상수 | |
| 5 | 1,502 | 89.6% | 72 | 4.3% | 102 | 6.1% |
| 7 | 1,582 | 94.4% | 37 | 2.2% | 57 | 3.4% |
| 9 | 1,676 | 100.0% | 0 | 0.0% | 0 | 0.0% |

력을 갖는 구조로 하였다.

퍼지신경망의 입력으로 사용된 특정 파라미터는 도로영상에 대한 예지의 방향성분에 대해 예지의 크기를 누적시켜 구축한 CDF에서 추출한 9개의 파라미터와 입력영상의 밝기 분포에서 추출한 1개의 파라미터이다. 추출된 특정 파라미터는 도로영상의 양불량 판정과 깊은 상관성을 갖고 있음을 밝혔으며, 상관분석을 통하여 특정 파라미터가 도로영상의 양불량을 판정할 수 있는 인자임을 확인하였다.

학습이 완료된 퍼지신경망 추론기에 학습에서 사용하지 않았던 다양한 도로환경에서 얻은 영상을 대상으로 수행한 실험결과는 퍼지신경망의 입력수가 9개 일 때 99%이상의 판별력을 나타냈으며, 만족할 만한 신뢰성을 얻었다. 이러한 결과는 차선정보 추출을 필요로 하는 시스템에 직접 적용이 가능하며, 차선정보 추출 이전 단계에서 입력된 도로영상의 차선표식이 거의 보이지 않는 불량한 영상으로 입력영상이 판정을 받을 경우 차선정보추출 과정을 생략하고 다음 입력 영상으로 처리과정을 넘기는 등 결과적으로 시스템이 신뢰 할 수 없는 정보의 추출을 방지할 수 있다.

향후 본 논문에서 도출된 결과를 차선이탈 경보나 방지시스템에 적용하기 위한 정보활용 방안에 대한 지속적인 연구가 진행되어야 한다. 또한, 제안된 영상의 양불량 판정시스템은 도로환경의 영상처리에 한정된 것이 아니라 각종 패턴 분류, 인식시스템 등에 직접적인 응용이 가능하며, 신뢰성을 요구하는 진단시스템 등 타 분야로의 확장 적용이 가능할 것으로 사료된다.

참고문헌

- [1] S. Ozawa, "Image processing for intelligent transport systems," *IEICE Trans. Information and Systems*, vol. E82-D, no. 3, pp. 629-636, 1999.
- [2] M. Bertozzi, A. Broggi and A. Fascioli, "Vision-based



이 운 근

1969년 3월 12일생, 1991년 울산대학교 전기공학과 졸업. 동대학원 석사(1993). 부산대학교 전자공학과 박사수료(2000). 1992년~1998년 동환산업(주) 연구소 주임연구원. 1999년~현재 삼창 기업(주) 제어기술연구소 선임연구원. 관심분야는 컴퓨터비전, 지능제어, 지능형 자동차, 자율주행시스템.

intelligent vehicles : State of the art and perspectives," *Robotics and Autonomous Systems*, vol. 32, pp. 1-16, 2000.

- [3] M. Aoki, "Image processing in ITS," *Proc. IEEE Intelligent Vehicles '98*, pp. 1-4, 1998.
- [4] J. W. Lee, K. S. Kim, S. S. Jeong, and Y. W. Jeon, "Lane departure warning system : Its logic and on-board equipment(20005331)," *Proc. JSAE*, pp. 9-11, Japan, 2000.
- [5] A. Takahashi, Y. Ninomiya, M. Ohta, and K. Tange, "A robust lane detection using real-time voting processor," *Proc. IEEE/IEE/JSAI Int. Conf. on Intelligent Transportation Systems*, pp. 577-580, 1999.
- [6] C. Kreucher and S. Lakshmanan, "A frequency domain approach to lane detection on roadway images," *Proc. 1999 Int. Conf. on Image Processing*, vol. 2, pp. 31-35, 1999.
- [7] J. W. Lee, U. K. Yi, and 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.
- [8] R. O. Duda and P. E. Hart, *Pattern Classification and Scene Analysis*, Jone Wiley & Sons, Inc., 1973.
- [9] C. T. Lin and C. S. George Lee, *Neural Fuzzy Systems*, Prentice Hall, Inc., 1996.
- [10] 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, no. 5, pp. 801-806, 1992.
- [11] Y. Maki and K. A. Laparo, "A neural-network approach to fault detection and diagnosis in industrial process," *IEEE Trans. on Control Systems*, vol. 5, no. 6, pp. 529-541, 1997.
- [12] R. G. Gonzalez and R. E. Woods, *Digital Image Processing*, Addison-Wesley, Reading, Massachusetts, 1992.

백 광 렬

현재 부산대학교 공과대학 전자전기정보컴퓨터공학부 교수. 부산대학교 컴퓨터 및 정보통신연구소 연구원. 제어·자동화·시스템공학 논문지 제5권 제1호 참조.

이 준 용

현재 전남대학교 공과대학 산업공학과 교수. 제어·자동화·시스템공학 논문지 제4권 제3호 참조.