

학술논문

지능형 휠체어 적용을 위한 기울기 히스토그램의 상관계수를 이용한 도로위의 이륜차 인식

김범국¹ · 박상희² · 이영학³ · 이강화⁴

¹대구과학대학교 정보통신과, ²대구사이버대학교 언어치료학과,
³경운대학교 디지털전자공학과, ⁴영남대학교 전자공학과

Two Wheeler Recognition Using the Correlation Coefficient for Histogram of Oriented Gradients to Apply Intelligent Wheelchair

Bum-Koog Kim¹, Sang-Hee Park², Yeung-Hak Lee³ and Gang-Hwa Lee⁴

¹TaeguScience University, Department of Information and communication

²DaeguCyber University, Department of Speech and Language Pathology

³Kyungwoon University, Department of Digital electronic Engineering

⁴Yeungnam University, Department of Electronic Engineering

(Received October 19, 2011. Accepted December 22, 2011)

336

Abstract: This article describes a new recognition algorithm using correlation coefficient for intelligent wheelchair to avoid collision for elderly or disabled people. The correlation coefficient can be used to represent the relationship of two different areas. The algorithm has three steps: Firstly, we extract an edge vector using the Histogram of Oriented Gradients(HOG) which includes gradient information and unique magnitude for each cell. From this result, the correlation coefficients are calculated between one cell and others. Secondly, correlation coefficients are used as the weighting factors for normalizing the HOG cell. And finally, these features are used to classify or detect variable and complicated shapes of two wheelers using Adaboost algorithm. In this paper, we propose a new feature vectors which is calculated by weighted cell unit to classify with multiple view-based shapes: frontal, rear and side views(60°, 90° and mixed angle). Our experimental results show that two wheeler detection system based on a proposed approach leads to a higher detection accuracy than the method using traditional features in a similar detection time.

Key words: Histogram of Oriented Gradients, Adaboost algorithm, Correlation coefficient

I. 서 론

오늘날의 의료기기는 IT 융합을 기초로 점점 발전되어가고 있다. 이러한 융합 의료 기술의 발달로 인하여 고령인구의 수가 매년 증가하고 있으며, 노인이나 장애우 그리고 특수 환자들을 돋기 위한 보다 지능화된 휠체어가 점점 요구되고 있다. 이 가운데서 휠체어 및 스쿠터 등은 노령인구의 이동성을 보장하는 대표적인 시스템이다. 도로위에서의 운전은 실내와 달

리 많은 장애물에 부딪히게 된다. 일반 보행자의 경우는 움직이는 속도가 느리기 때문에 휠체어가 인지하여 피해 갈 수 있지만 이륜차의 경우는 그 속도가 빠르기 때문에 빠른 인식이 요구되어진다. 기존 휠체어는 신체적 제약을 가진 사용자에게 운전조작을 위한 많은 부하를 요구하고 있어 이를 해결하기 위한 보다 나은 지능형 휠체어가 제안되고 있다[1-4].

지능형 휠체어의 운전조작 및 장애물 인식에 관해서는 두 가지로 분류할 수 있다. 첫 번째는 미리 기억된 지도를 참조하여 정해진 장소로 경로를 따라 장애물을 피해서 가는 방법이다. 두 번째는 좁고 군중이 있는 지역을 카메라 센서, 올트라 소닉 혹은 기타 센서들을 이용하여 목적지로 가는 것이다[5-6].

위의 두 방법에 공통으로 적용되는 것은 휠체어를 제어하기에 앞서 먼저 물체나 사람(보행자) 그리고 이륜차를 인식해

Corresponding Author : 박상희

경상북도 경산시 진량읍 내리리 15번지, 대구사이버대학교
TEL: +82-53-850-4091, E-mail: 49811097@hanmail.net

이 논문은 2011년도 대구과학대학 교육역량강화사업단의 지원을 받아 수행된 연구임.

야 하는 것이다. 그래서 본 논문에서는 휠체어 앞에 이륜차가 있을 경우에 카메라 센서를 이용하여 휠체어가 보행자를 인지하기 위해 단일 입력 영상에서 특징을 추출하여 실시간으로 이륜차를 추출하는 새로운 알고리즘을 개발을 목표로 한다.

이륜차 및 보행자 검출을 위한 특징 추출 방법으로 Harr 웨이브릿(Wavelet)기반 방법, 기울기의 히스토그램(Histogram of Oriented Gradient (HOG))을 이용한 방법, 그리고 LRF (Local receptive field) 방법 등이 주로 연구되고 있으며, 분류 방법으로는 SVM(Support Vector Machine), 신경망, 아다부스트 알고리즘이 많이 적용되고 있다[7].

본 논문에서는 이륜차 검출을 위한 특징을 획득하기 위해 기존의 기울기 히스토그램 특징이 갖고 있는 제한된 물리적 구조에서 발생되는 많은 양의 특징 개수와 보다 높은 인식률을 얻기 위해 새로운 형태의 상관계수 계산에 의한 HOG특징을 적용한 알고리즘을 제안한다. 제안된 방법은 기존의 제안된 일반적인 방법의 기울기 히스토그램보다 많은 이륜차 및 비이륜차의 검출 능력을 향상시켰다. 2장에서는 특징 추출을 위한 기울기 히스토그램과 상관계수에 대해 설명하며, 3장에서는 분류에 사용된 아다부스트 알고리즘을 서술하고, 실험 및 결과를 4장에 그리고 5장에 결론을 나타내었다.

II. 특징 추출

1. 기울기 히스토그램(HOG)

HOG[8]는 영상의 국소 영역에 대한 밝기 분포를 기울기에 대한 방향성 히스토그램을 특징 벡터로 사용하는 것이다. 각 픽셀의 밝기 영상 $I(x,y)$ 로부터 x 축과 y 축의 변화에 대한 분포의 크기 m 과 $I(x,y)$ 변화에 대한 방향성을 나타내는 θ 는 식 (1)과 식 (2)을 이용하여 계산한다.

$$m(x,y) = \sqrt{f_x(x,y)^2 + f_y(x,y)^2} \quad (1)$$

$$\theta(x,y) = \tan^{-1} \frac{f_y(x,y)}{f_x(x,y)} \quad (2)$$

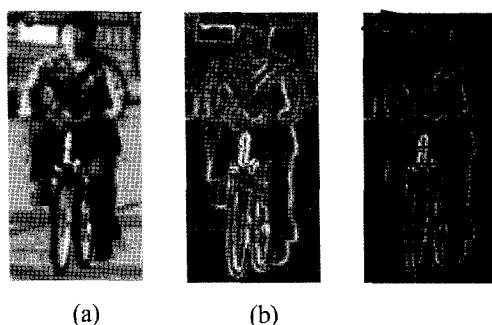


그림 1. 이륜차 HOG 정규화 예

Fig. 1. The example of bicycle HOG normalization

여기서 $f_x(x,y) = I(x+1,y) - I(x-1,y)$ 이며, $f_y(x,y) = I(x,y+1) - I(x,y-1)$ 이다.

2. 셀 벡터화

입력된 영상으로부터 8×8 픽셀 크기를 하나의 셀로 하였으며, 밝기영상분포의 크기 값 m 과 방향성 성분 θ 을 이용하여 각 셀에 대한 방향성 히스토그램을 작성한다. 크기 변화 값 m 과 방향성 분포 예를 그림 1의 (b)와 (c)에 나타내었다. 여기서 작성된 방향성분은 $0\text{-}360^\circ$ 로 나타나지만 본 논문에서는 $0\text{-}180^\circ$ 를 기준으로 나타내었으며, 20° 씩 분할하여 9개의 방향성에 대한 히스토그램의 특징량은 $F_{ij} = [f_1, f_2, \dots, f_9]$ 로 나타낸다. 만들어진 각 셀들에 대해 3×3 으로 블록 정규화 과정을 거친다. 각 셀이 9차원이므로 k번째 블록 특징량 81차원은 $B_k = [F_{ij}, F_{i+1j}, F_{i+2j}, F_{ij+1}, F_{i+1j+1}, F_{i+2j+1}, F_{ij+2}, F_{i+1j+2}, F_{i+2j+2}]$ 로 나타낼 수 있다.

임의 i 행 j 열의 셀 특징량(9차원)을 F_{ij} 라하고 k 번째 블록의 특징량(81차원) B_k 라 할 경우, 정규화 후의 특징 벡터 Π 는 식 (3)에 의해 구한다[7-8].

$$\Pi = \frac{f}{\sqrt{\|B_k\|_2^2 + \epsilon^2}} \quad (\epsilon=1) \quad (3)$$

0.000000	0.017287
0.001406	0.029049
0.061889	0.099122
0.058996	0.024183
0.002253	0.006498
0.076925	0.007468
0.010818	0.036457
0.002808	0.011718
0.034425	0.005769
0.102417	0.010733
.....
(a)	(b)

그림 2. HOG 특징 추출 예

Fig. 2. The example of extraction of HOG features

셀 정규화 과정을 그림 1의 (d)에 나타내었으며, 이때 블록의 이동은 오른쪽 1셀 그리고 아래로 1셀씩 움직이는 것으로 하였다. 영상의 크기가 128×64 픽셀 영상의 벡터 크기는, 가로방향으로 6블록 그리고 세로방향으로 14블록이 생성되며, 전체 84개의 블록에 대한 정규화가 이루어지므로 “84블록 \times 81차원”的 6,804차원 HOG의 특징 벡터가 만들어진다.

그림 2(a)는 이륜차에 대한 HOG 특징 벡터 값의 일부를 나타낸 것이며, 그림 2(b)는 비이륜차로부터 추출된 특징 벡터의 일부를 나타내었다.

3. 상관계수

두 셀의 국부적 영역에 대한 기울기 변화량의 상관관계 정도를 나타내는 상관계수 ρ 는 식 4와 5에서 얻어진다[9].

$$0 \leq \rho_{ci,cj} \leq 1 \quad (4)$$

$$\rho = \frac{C(ci,cj)}{\sigma_{ci}\sigma_{cj}} = \frac{C(ci,cj)}{\sqrt{V_{(ci)}}\sqrt{V_{(cj)}}} \quad (5)$$

여기서 σ_{ci} , σ_{cj} 는 두 셀 i , j 의 표준편차이며, $C(ci,cj)$ 는 공

분산이다. 본 논문에서는 배경과 사람이 타고 있는 이륜차 영역은 그림 3에 나타낸 것처럼 서로 다른 형태의 특징을 나타내고 있다. 그러므로 각 셀의 가로 방향의 상관관계와 세로 방향의 상관관계를 구하면 기울기 히스토그램 값의 새로운 특징 벡터를 구할 수 있는 것이다. 실험에서의 적용은 영상의 가로 셀과 세로 셀의 상관관계를 계산하여(파랑색 영역) 이를 미분하여 상관 계수의 절대값 구하여 역수를 취한 값을 이용

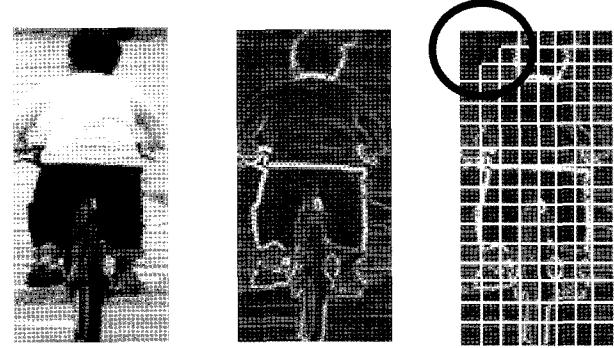


그림 3. 입력 영상에 대한 상관계수 계산 대상 영역
Fig. 3. Correlation coefficient target area for input image

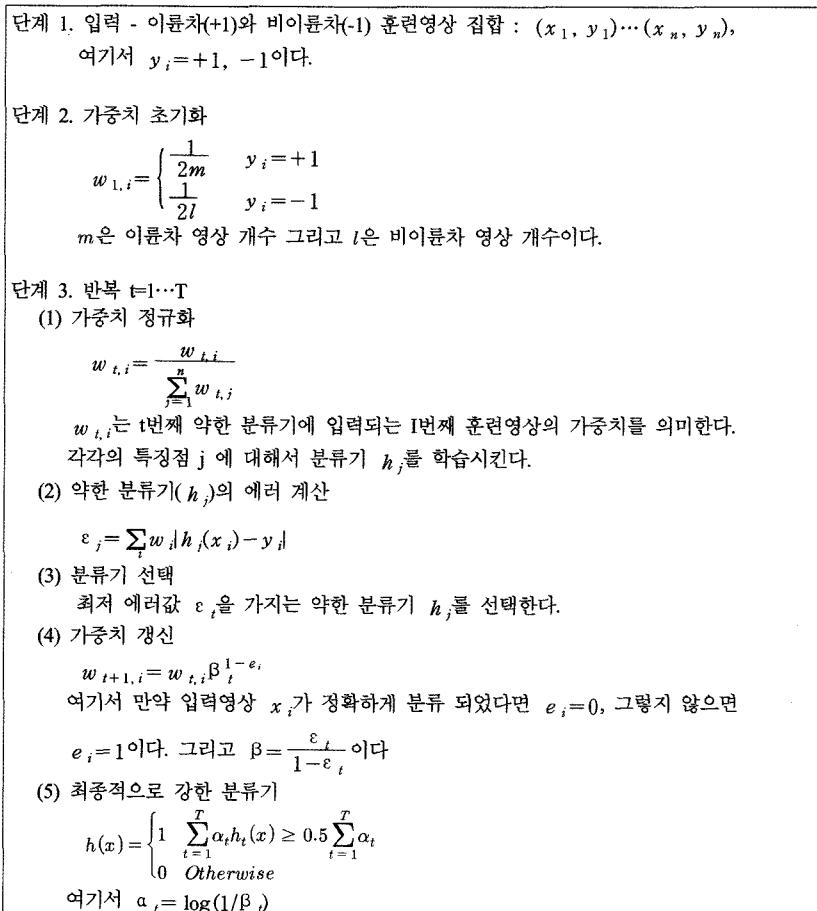


그림 4. 아다부스트 알고리즘 구조

Fig. 4. The architecture of Adaboost algorithm

한다. 이 결과 값을 각 셀의 기울기 히스토그램의 무게 값으로 사용하여 새로운 특징량을 구하였다.

III. 아다부스트 알고리즘

대상 물체를 분류하기 위해 가장 많이 이용되고 있는 방법이 SVM방법과 아다부스트 방법이다. SVM은 많은 계산량(혹은 메모리)을 요구하여 판별 시간이 많이 소요된다. 이외는 반대로 아다부스트는 빠른 속도의 분류를 나타내고 적용되는 특징벡터의 라운드 외에는 추가되는 인자가 없는 장점을 가진다[10]. 그래서 본 논문에서는 이륜차를 검출 하기위해 아다부스트 알고리즘을 사용하였다. 아다부스트의 기본 알고리즘은 약한 분류기를 선형적 결합에 의해 강한 분류기로 생성하고자 한다. 즉 약한 분류기를 학습 시킨 후 올바르게 분류된 데이터에 대해서는 낮은 에러 가중치가 부과되고 올바르지 않게 분류된 데이터에 대해서는 높은 에러 가중치를 부과 하는 것이다. 이는 실시간 검출에 있어서 기존의 방법에 비해 뛰어난 성능을 보이며, 복잡하고 다양한 배경에서 강인하게 이륜차를 추출 할 수 있는 장점을 가지고 있다. 이러한 점을 고려하여 본 연구에서는 이륜차를 검출하기위해 아다부스트 알고리즘을 사용하였으며, 과정을 요약해보면 그림 4와 같다.

1단계에서 초기 입력 값 x 는 2절에서 추출된 특징 값을 사용하는 훈련 영상이며, y 는 이륜차(+1)와 비이륜차(-1)의 구분을 나타낸다. 2단계에서는 가중치 초기화를 실시한다. 3단계는 약한 분류기를 생성하는 단계이다. 이 단계에서는 최소 에러를 가지는 약한 분류기를 선택하는 단계이며, 이 분류기에 대한 가중치를 부과한다. 이때 가중치 부과는 잘못 분류된 훈련 영상에 대해 가중치 $w(i)$ 를 증가시키고, 옳게 분류된 훈련 영상에 대해서는 가중치 $w(i)$ 를 감소시킨다. 이는 초기에 선택된 특징들은 쉽게 구별할 수 있는 역할을 담당 하지만 후반부에 선택된 특징들은 구별이 어려우므로 이를 담당하기 위한 것이다.

그림 4의 알고리즘 흐름 예를 그림 5에 나타내었다. 그림 5에서 파란색은 이륜차로 간주하며 빨강색은 비이륜차로 간주하여 해석한다. 결과는 3개의 약한 분류기를 결합해서 하나의

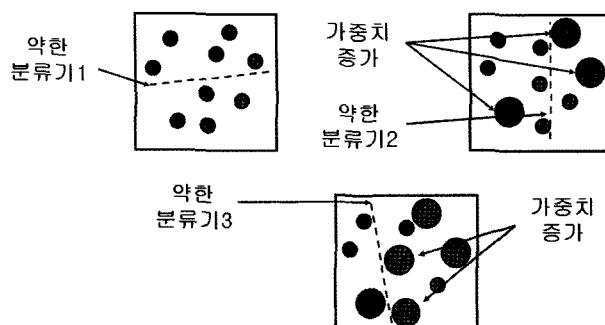


그림 5. 아다부스트 알고리즘 예

Fig. 5. The example of Adaboost algorithm

1	1	0.009608	0.188881	-1
2	1	0.212868	0.101796	-1
3	1	0.007798	0.195890	-1
4	1	0.601807	0.109831	-1
5	1	0.086676	0.092705	1
6	1	0.003506	0.094394	-1
			
2819	1	0.061481	0.171526	-1
2820	1	0.019487	0.136304	1
2821	1	0.037780	0.151482	1
2822	1	0.022380	0.161767	1
2823	1	0.013622	0.088042	1
2823	2	0.091751	0.089460	1
			
6799	2	0.038541	0.161731	-1
6800	1	0.016865	0.204314	-1
6801	1	0.016777	0.210797	1
6802	1	0.039779	0.154631	1
6803	1	0.004533	0.225616	1
6804	1	0.003625	0.212832	1

그림 6. 이륜차(positive)와 비이륜차(negative)를 훈련 결과 예

Fig. 6. The example of training for bike and non-bike

강한 분류기를 생성하게 된다.

그림 6은 2절과 3절에서 제시된 특징 추출 알고리즘을 이용하여 이륜차와 비이륜차로 부터 추출된 특징 벡터를 아다부스트 방법에 의한 훈련의 결과를 나타내었다.

그림 6에서 첫 번째 숫자는 특징 벡터의 순서(6,804개)를 의미하며, 두 번째는 각 순번에서 분류되는 수를 나타내며, 세 번째는 분류에 사용된 문턱치 값이고 네 번째는 약한분류기 생성에서의 에러 값이다. 그리고 마지막은 분류 기준을 의미한다. 입력된 테스트영상은 이 분류기를 이용하여 주어진 문턱치값에 의해 이륜차/비이륜차로 구분된다.

IV. 실험 및 결과

본 논문에서는 펜티엄 3.1 GHz의 일반 사용자 컴퓨터 환경에서 실험 하였다. 실험에 사용된 이륜차 데이터는 도로 위에서 직접 촬영해서 획득된 것과 인터넷으로부터 얻어진 데이터이다. 이륜차 영상은 자동차 안에서 여러 가지의 각도로 나타날 수 있다. 본 논문에서는 수평기준으로 정면(약 90도), 약간 기울어진각도(약 60도) 그리고 복합(90도 + 60도)에 대해서 각각 실험 하였다. 이는 이륜차가 자동차 앞에서 멀리 있는 경우(뒷모습)와 자동차를 향하여 달려오는 경우(앞모습)에 해당하는 것이다. 획득된 사진 640 × 480(가로 × 세로)으로부터 128 × 64(가로 × 세로)크기로 정규화된 이륜차 2,353장을 추출하였으며, 훈련영상과 실험영상으로 나누어 사용하였다. 실험에 사용된 60도 그리고 90도에 대한 자전거(B)와 모

표 1. 이륜차의 훈련영상과 실험영상 개수

Table 1. The number of training and test images for bike

각도	종류	앞면	뒷면	전체
60 도	자전거 (B)	훈련	160	145
		실험	190	150
	모토사이클 (M)	훈련	40	40
		실험	46	50
90 도	자전거 (B)	훈련	428	435
		실험	430	415
	모토사이클 (M)	훈련	102	117
		실험	119	115
234				

토사이클(M)의 영상 개수를 표 1에 나타내었다. 단 인터넷으로부터 획득된 사진의 크기는 여러 가지이므로, 실험에서는 이를 같은 크기 128×64 로 정규화하여 사용하였다. 비이륜차 영상은 일반 도시 거리의 사진(640×480)에서 랜덤하게 추출된 영상 128×64 크기를 사용하였다. 훈련에 사용된 비이륜차 영상은 이륜차 영상과 같은 개수(1:1) 그리고 두 배의 영상 개수(1:2)를 사용하였으며, 실험에서는 비이륜차 영상 3,000장을 사용하였다. 그림 7은 실험에 사용된 이륜차와 비이륜차의 영상 예를 나타내었다. 그림 7의 첫 번째 행은 자전거 영상이며, 두 번째 행은 모토사이클 영상 예이다.

실험은 기본적인 인식 방법인 HOG실험과 Haar-like실험을 실시하였으며, 그리고 상관계수를 이용한 제안된 방법을 실시하였다. 실험 결과의 분석을 위해 각각의 방법 및 각도에 대해 혼돈행렬(confusion matrix)의 참 긍정률(true positive rate)과 거짓 긍정률(false positive rate)을 이용한 ROC 곡선을 적용하였으며, 결과를 그림 8, 그림 9 그리고 그림 10에 나타내었다. 여기서 판별을 위해 적용된 문턱치 값의 범위는 $-20 \sim 20$ 이다. 제안된 방법에 의한 분류를 위한 특징 추출은 먼저

HOG 특징량을 계산 한 후 제안된 상관계수 이용 방법은 기존의 방법 HOG에서 계산된 각 셀과 셀의 상관관계 값을 무게 값으로 이용한 것이다. 식 3에서 얻어진 특징값을 식 4와 식 5를 이용하여 그림 3과 같이 셀과 셀의 상관관계를 계산하여 2.2절의 설명에 따라 식 6을 이용하여 계수값 K 를 얻는다. 이 결과 값을 식 3에 적용하여 식 7과 같이 새로운 HOG 셀 특징값을 구하였다.

$$K = 1/\rho_v - \rho_H \quad (6)$$

$$\Pi = K \frac{f}{\sqrt{\|B_k\|_2^2 + \varepsilon^2}} \quad (\varepsilon=1) \quad (7)$$

제안된 방법(HOG_CC)은 Haar-like방법 보다는 우수하였으며, HOG보다는 낮거나 일부에서는 조금 높은 성능을 나타내어 비슷한 수준의 시스템 성능을 나타내었다. 각도별 실험에서는 세 경우 모두 90도가 60도 보다는 높은 시스템 성능을 나타내었으며, 혼합(그림에서 _Mixed로 표기)인 경우는 중간을 나타내었다. 이러한 결과의 이유는 두 가지로 살펴 볼 수 있다. 첫 번째는 60도의 훈련 개수가 90도에 비하여 적었다는 것이다. 두 번째는 90도인 경우는 보행자와 거의 비슷한 자세의 보다 좁은 영역의 특징이 사용되며, 60도 경우는 보다 넓은 영역의 특징을 가져오므로 확산된 특징을 가지게 되므로 오인식 되는 확률이 높다고 판단되어진다. 인식 수행 시간은 특징이 추출된 영상 1장에 대해 제안된 방법은 약 20 ms로 나타났으며, 다른 방법들도 비슷하게 나타났다.

각각의 방법에 대한 최고의 정밀도(accuracy)를 식 8 [11]을 이용하여 표 2에 나타내었다. 식 8에서 True Positive는 이륜차 영상을 이륜차로 식별한 것이며, False Positive는 이륜차 영상을 비이륜차로 인식한 경우이다. 표 2에서 “혼합”은 90도와 60도를 합해서 실험한 것이다.



그림 7. 이륜차와 비이륜차의 예

Fig. 7. The example of bike and non-bike

표 2. 각 방법에 대한 정밀도(%)

Table 2. The accuracy for each method

훈련 비율	방법	각도			60 도			90 도			혼합		
		B	M	MB	B	M	MB	B	M	MB	B	M	MB
1:1 훈련	Haar-like	92.80	79.29	87.71	94.77	81.39	94.56	93.45	99.76	92.52			
	HOG	98.64	93.24	98.27	99.17	99.41	98.82	98.7	98.76	98.03			
	HOG_CC	98.77	98.24	97.67	98.78	98.91	97.50	98.37	98.24	97.59			
1:2 훈련	Haar-like	95.28	97.27	94.83	95.39	92.54	93.93	93.43	98.09	91.99			
	HOG	99.18	98.33	98.34	99.19	99.44	98.89	98.90	99.12	98.06			
	HOG_CC	98.10	98.52	97.67	98.97	99.19	98.11	98.00	98.52	97.65			

표 3. 문턱치 값에 대한 인식/오인식 결과

Table 3. The result of correct/incorrect for the threshold values

실험 결과	문턱 치값	20.0	10.0	0.0
	ROC_Threshold=20.000000	ROC_Threshold=10.000000	ROC_Threshold=0.000000	
	Nega_test_file_no=3000	Nega_test_file_no=3000	Nega_test_file_no=3000	
	Posi_test_file_no=1467	Posi_test_file_no=1467	Posi_test_file_no=1467	
	Nega_Correct_cnt=2992	Nega_Correct_cnt=2979	Nega_Correct_cnt=2941	
	Nega_Incorrect_cnt=8	Nega_Incorrect_cnt=21	Nega_Incorrect_cnt=59	
	Posi_correct_cnt=1272	Posi_correct_cnt=1392	Posi_correct_cnt=1441	
	Posi_incorrect_cnt=195	Posi_incorrect_cnt=75	Posi_incorrect_cnt=26	
	Positive Incorrect	Positive Incorrect	Positive Incorrect	
	Rate=0.132924	Rate=0.051125	Rate=0.017723	
	TPR=0.993750	TPR=0.985138	TPR=0.960667	
	FPR=0.061186	FPR=0.024558	FPR=0.008763	

$$\text{정밀도} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \times 100 \quad (8)$$

자전거와 모토사이클 그리고 여러 각도를 혼합한 경우에 대해, ROC곡선에서 문턱치 값에 따른 부분적 결과를 표 3에 나타내었다. 문턱치 값이 작아짐에 따라 이륜차의 검출은 낮아

지지만 비이륜차의 오인식률은 높아지는 경향을 나타내었다.

그리고 표 2의 각도에 대해, 자전거(표 2에서 B로 표기)의 경우가 모토사이클(표 2에서 M으로 표기)보다 높은 정밀도를 나타내었다. 이는 자전거가 모토사이클 보다 좀 더 특징 구분이 잘되는 경향을 나타낸 것이다. 그 원인은 모토 사이클의 경

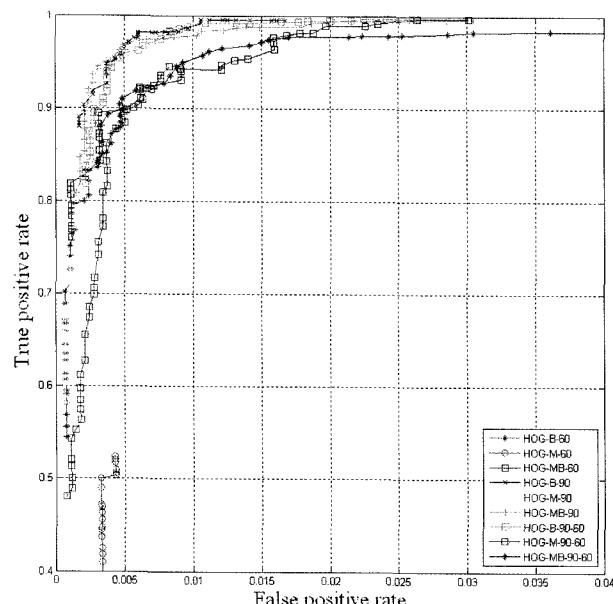


그림 8. HOG 특징 실험 결과 (훈련 비율 1:1)

Fig. 8. The result of experiment for HOG feature(training rate 1:1)

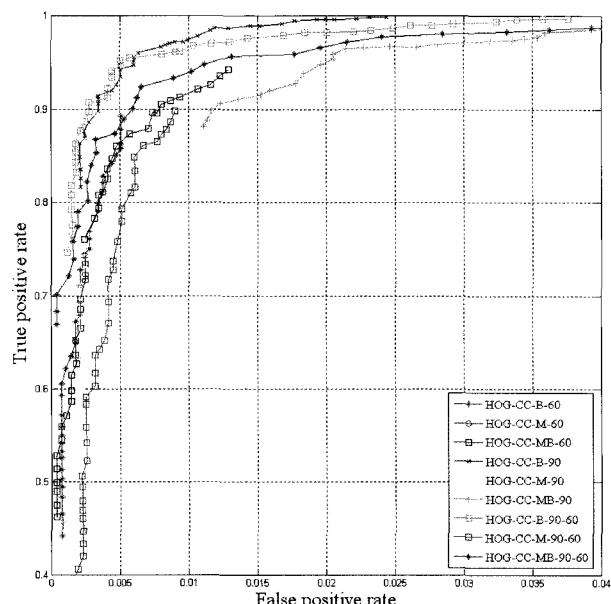


그림 9. 제안된 방법의 실험 결과

Fig. 9. The result of experiment for proposed algorithm

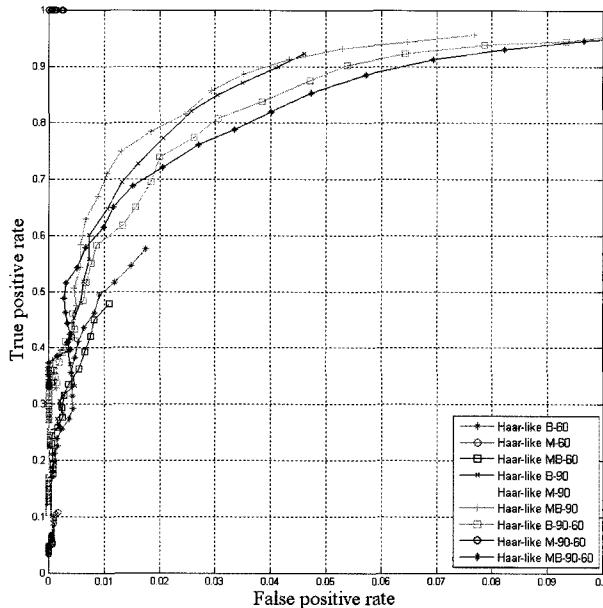


그림 10. Haar-like 방법의 비교 결과

Fig. 10. The result of experiment for Haar-like method

우 등 뒤로 높은 짐을 싣거나 높은 적재물에 의해 복잡성이 증가되었기 때문이라 생각되어진다. 각도와 두 종류의 이륜차 혼합 실험에서는 각도와 종류에 대해 부분적으로 혼조 형태를

나타내지만 전체 혼합에서는 제안된 방법이 다른 알고리즘보다 보다 높은 정밀도를 나타내었다.

HOG와 HOG_CC의 경우 ROC 곡선에서는 비슷한 모양의 결과를 나타내었지만 정밀도 분석에서는 제안된 HOG_CC방법이 기존의 방법 보다 높은 성능을 나타내었다.

실제의 640×480 영상에서 식 9에 의한 문턱치 값 10.0을 적용한 이륜차 검출 실험 결과를 그림 11에 나타내었다.

$$B(t) = \begin{cases} 1 & \sum_{t=1}^T h_t(x)H(x) \geq Th \\ 0 & \text{Otherwise} \end{cases} \quad (9)$$

여기서 $h_t(x)$ 는 t 번째의 128×64 영상을 의미하며, 3절에서 구한 $H(x)$ 는 강 분류기이며, x 는 특징 벡터이다. 식 9의 결과 $B(t)$ 에서 “1”은 이륜차 검출을 의미하며, “0”은 비이륜차 검출을 의미한다.

그림 11은 훈련 영상 비율이 1:1이고 자전거와 모토사이클, 전면과 후면 그리고 60도와 90도를 혼합한 전체의 경우이며, 문턱치 값 10.0을 적용한 것이다. 그림 11에서 (a)는 HOG 방법을, (b)은 Haar-like 방법을 그리고 (c)는 제안된 방법을 적용한 것으로서, 동일한 문턱치 값을 사용했을 경우 제안된

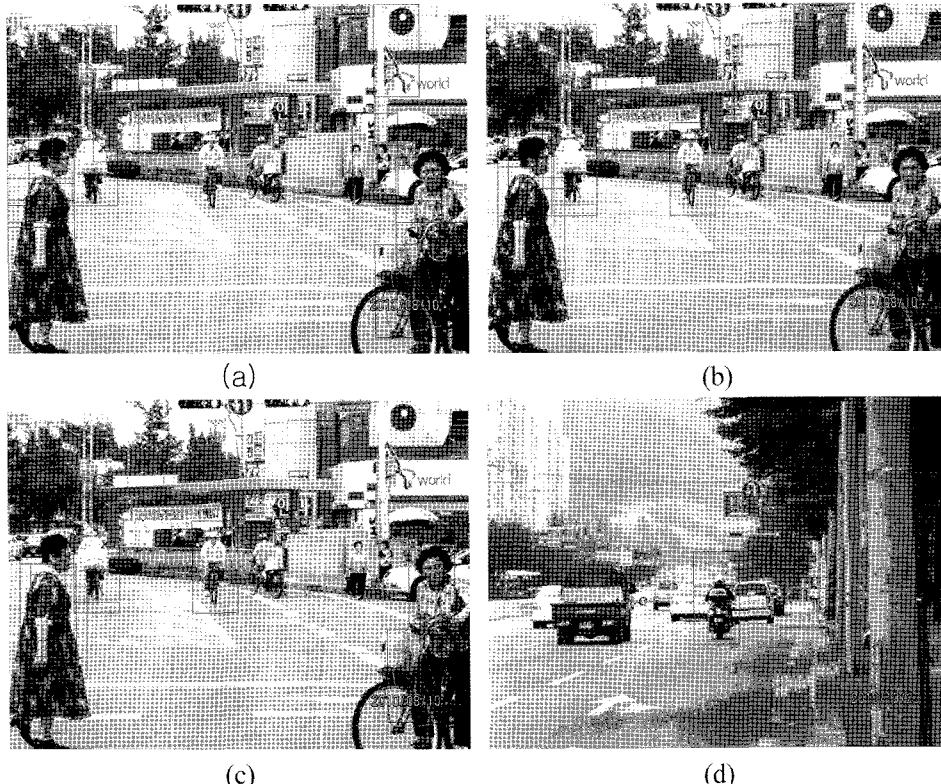


그림 11. 640×480 적용 결과 예 (문턱치 값 10.0) (a) Haar-like 방법, (b) HOG 방법, (c) 제안된 방법(자전거), (d) 제안된 방법(오토바이)

Fig. 11. The example result for 640×480 image(Threshold value 10.0) (a) Haar-like method, (b) HOG method, (c) proposed method(bike) (d) proposed method(motorcycle)

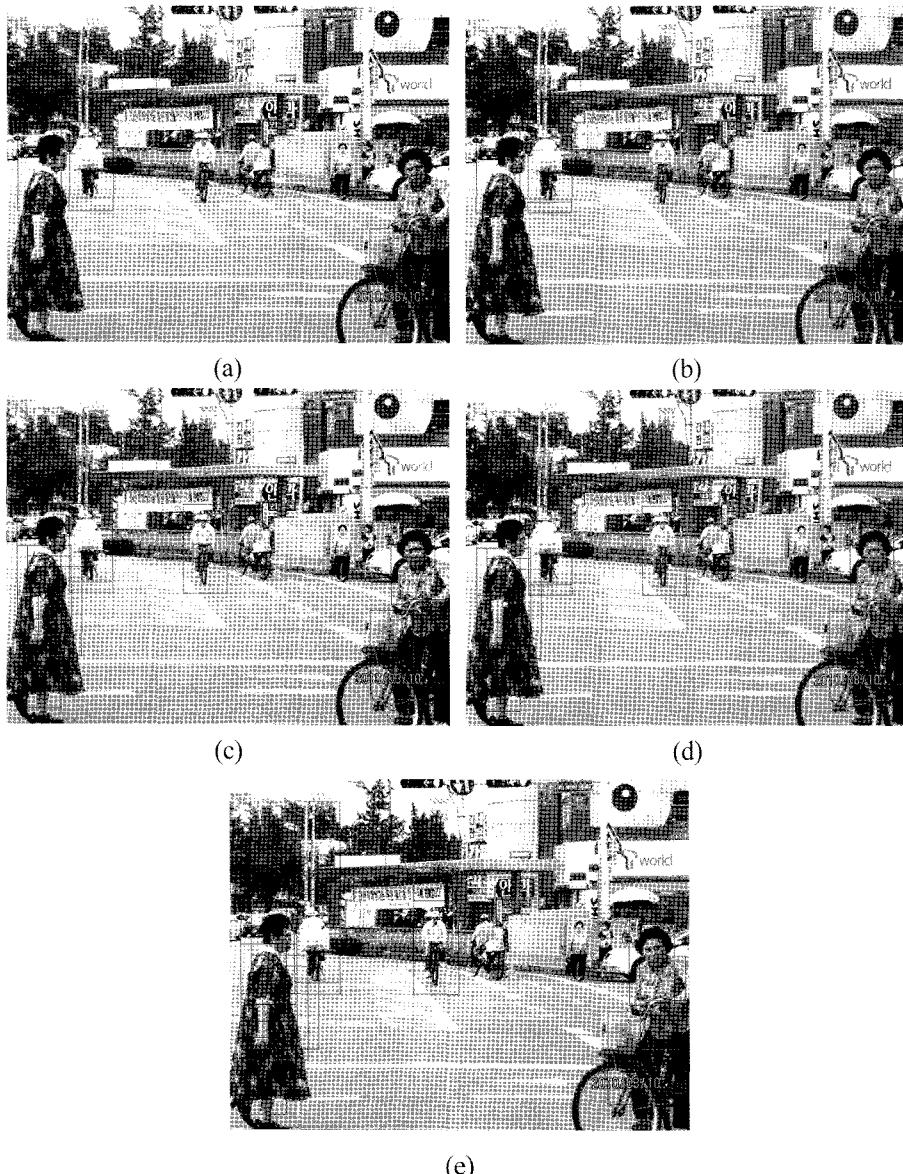


그림 12. 제안된 방법에 대한 문턱치 값 변화 적용 결과 예 (a) 문턱치 값 20.0, (b) 문턱치 값 15.0, (c) 문턱치 값 10.0, (d) 문턱치 값 5.0, (e) 문턱치 값 0.0

Fig. 12. The example result of threshold value for proposed method (a) Threshold value 20.0 (b) Threshold value 15.0, (c) Threshold value 10.0 (d) Threshold value 5.0, (d) Threshold value 0.0

알고리즘이 기존의 방법보다 높은 검출 능력을 나타내었다. 그리고 그림 11은 정지된 영상에 대해 제안된 알고리즘을 적용한 것이다. 만약 실시간으로 이륜차를 감시 혹은 감지를 하기 위해서는 처리 시간을 절약하기 위해 전처리과정이 있어야 할 것이다. 이러한 전처리는 영역분할이나 프레임간의 움직임을 이용하여 좁혀진 후보 영역을 만들게 되며, 실시간 감시 시스템을 만드는데 고려해야 할 사항이다. 필수 사항이 그림 11에서 오인식된 것을 살펴보면 나무, 전봇대 그리고 가로등과 같이 사람의 형상과 유사한 경우는 이륜차로 오인식 되었으며, 앞으로 보완되어져야 할 부분이다. 그리고 오인식된 부분 가운데서 사람이 많이 나타나는 원인은 이륜차를 이용하는 것

은 사람이므로 사람의 형상과 아주 유사하기 때문이다. 그림 12는 제안된 방법을 이용하여 여러 가지의 문턱치 값을 적용한 경우이다. 그림 12(a)보다 그림 12(e)는 오인식된 경우가 훨씬 많이 나타난다. 이는 표 3에서도 나타났지만 문턱치 값이 낮아짐으로써 이륜차의 검출은 향상되지만 비이륜차의 오인식이 증가하여 나타나게 되는 것이다.

V. 결 론

지능형 휠체어의 연구에서 도로위의 이륜차 검출 및 인식은 장애우의 미숙한 운전을 도울 수 있는 것으로써 제2의 사고를

미연에 방지하는 아주 중요한 연구 부분 중의 하나이다. 지금 까지의 연구에서는 여러 개의 haar-like 특징 혹은 HOG 특징을 추출하여 이륜차/비이륜차를 검출하는 방법을 많이 사용하여 왔다. haar-like 방법은 특징 개수도 많이 늘어나며 이로 인한 비교 시간이 길어지므로 특징 개수가 적은 것에 비해 많은 인식 시간이 소요된다. 그리고 기존의 HOG의 경우는 계산량은 줄어들지만 낮은 인식률을 나타내었다. 본 논문에서는 인식율 향상을 위해 상관계수를 이용한 새로운 특징 벡터에 의한 이륜차 검출 시스템을 제안하였다. 상관계수는 국부적인 셀과 셀의 상관관계를 이용하여 특징 벡터를 추출하였다. 실험 대상으로는 수평기준으로 90도 ± 60도의 영상에 대해 실험하였으며, 그 외의 각도에 대해서는 다른 해석이 추가되어져야 할 것 같다. 예를 들면 원의 일부를 찾아서 이륜차로 인식하는 알고리즘 등의 캐스케이드 혹은 복합적인 뉴럴방법등이 고려되어져야 할 것 같다. 그리고 이륜차의 분류를 위하여 아다부스트 방법을 이용하였으며, 기존의 방법과 비교해서 보다 높은 시스템 성능을 나타내었다. 실제의 시스템에 적용되어서도 다른 방법들 보다 높은 정확도를 나타내었다. 추후의 과제로써는 실시간 감시를 위해 전처리 작업도 같이 이루어져야 하며, 실험에 나타난 것처럼 이륜차와 유사한 경우의 구분이 잘되는 특징을 개발해야 하며, 다른 자세와 다른 모양 그리고 여러 각도의 이륜차에 대한 연구도 이어져야 할 것이다.

344

참고문헌

- [1] D. P. Miller and M. G. Slack, "Design and testing of a low-cost robotic wheelchair prototype," *Autonomous Robotics*, vol. 2, pp. 77-88, 1995.
- [2] R. C. Simpson and S. P. Levine, "Adaptive shared control of a smart wheelchair operated by voice control," *Proc. IROS 97*, vol. 2 , pp. 622-626, 1997.
- [3] H. A. Yanco and J. Gips, "Preliminary investigation of a semi-autonomous robotic wheelchair directed through electrodes," *Proc. Rehabilitation Engineering Society of North America 1997 Annual Conference*, 1997, pp. 414-416.
- [4] T. Gomi and A. Griffith, "Developing intelligent wheelchairs for the handicapped," *Assistive Technology and Artificial Intelligence, Lecture Notes in AI*, vol. 1458, pp.150-178, 1998.
- [5] Murakami. Y., Kuno. Y., and Shimada. N., and Shirai. Y., "Intelligent wheelchair moving among people based on their observations." *2000 IEEE International Conference*. Nashville, TN, USA, Oct, 2000, pp. 1466-1471.
- [6] M. Enzweiler, D. Gavrila, "Monocular pedestrian detection: survey and experiments", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, no. 12, pp. 2179-2195, Oct., 2009.
- [7] 이영학, 고주영, 석정희, 노태문, 심재창, "곡률과 HOG에 의한 연속 방법에 기반한 아다부스트 알고리즘을 이용한 보행자 인식", 정보과학회논문지: 컴퓨팅의 실제 및 레터, 제 16권 6호, pp. 654-662, 2010년 6월.
- [8] 松島千佳, 山内悠嗣, 山下隆義, 藤吉弘亘, "人検出のための real adaboostに基づくHOG特徴量の効率的な削減法", 情報處理學會研究報告, pp. 1-8, 2009年.
- [9] <http://adnoctum.tistory.com/188>.
- [10] P. Viloa, M. Jones and D. Snow, "Detecting pedestrians using patterns of motion and appearance", *The 9th ICCV*, pp. 153-161, Oct., 2003.
- [11] J. B. Tilbury, P. W. J. Van Eetvelt, J. M. Garibaldi, J. S. H. Curnow and E. C. Ifeachor, "Receiver operating characteristic analysis for intelligent medical system-a new approach for finding confidence intervals," *IEEE Transactions on Biomedical Engineering*, vol. 47, no. 7, pp. 952-963, July 2000.