

---

# Delta-bar-Delta 알고리즘을 이용한 ODVS의 좌표 교정

김도현\* · 박용민\* · 차의영\*

## Coordinate Calibration of the ODVS using Delta-bar-Delta Neural Network

Do-Hyeon Kim\* · Young-Min Park\* · Eui-Young Cha\*

---

이 논문은 2004년도 한국학술진흥재단의 지원에 의하여 연구되었음(KRF-2004-036-D00385)

---

### 요 약

본 논문에서는 카타디옵트릭 카메라로부터 획득한 전 방향 구면 왜곡 영상에서의 좌표를 실제 거리 좌표로 변환하기 위해서 3차원 포물면 좌표 변환 방법과 Delta-bar-delta 알고리즘에 의한 좌표 교정 방법을 제시하였다. 실험을 통해 살펴본 결과 제안된 좌표 변환 방법이 환경 변수에 민감한 좌표 변환에서의 정확성 및 신뢰성을 가짐을 알 수 있었다.

### ABSTRACT

This paper proposes coordinates transformation and calibration algorithm using 3D parabolic coordinate transformation and delta-bar-delta neural algorithm for the omni-directional image captured by catadioptric camera. Experimental results shows that the proposed algorithm has accuracy and confidence in coordinate transformation which is sensitive to environmental variables.

### 키워드

Catadioptric Camera, Omni-Directional Image, Delta-bar-delta Learning

### 1. 서 론


컴퓨터를 이용한 자동 인식 기술이 점차 보편성을 가지게 되면서 다양한 응용 사례들이 모든 산업 분야로 급속히 확대되고 있으며, 특히 컴퓨터 비전을 이용하여 실시간으로 변화하는 객체에 대한 정보를 분석, 활용하는 기술은 영상 보안 감시, 무인 경비, 객체 추적, 생태학적 움직임 분석, 신호 제어 등 많은 분야에서 그 필요성이 증대되고 있다.

현재 컴퓨터 비전을 이용한 영상 처리 기술은 일반적으로 CCD 또는 USB 형태의 일반 카메라를 통하여 영상 정보를 획득하여 처리하고 있으나 카메라의 시각 범위가 좁으며 3차원 실세계에 대해

2차원 영상으로 획득되는 카메라 자체의 물리적 제약으로 인해 많은 환경적 제약 조건을 가지고 있다. 이런 제약을 탈피하기 위하여 여러 대의 다중 카메라를 결합한 시도들이 이루어져 왔으나 설치 위치의 선정 및 고비용성을 비롯한 실제적인 문제뿐만 아니라 다중 영상 통합(merging) 등의 기술적인 문제점으로 인하여 실질적으로 많은 어려움에 처해 있는 실정이다.

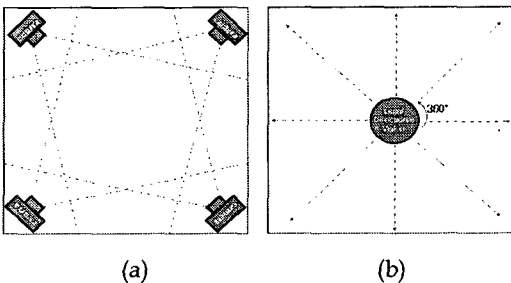
일반 카메라와 전(全)방향 영상 획득이 가능한 볼록거울로 구성된 카메라의 조합을 카타디옵트릭(catadioptric) 카메라 또는 Omni-directional Vision Sensor(ODVS)라고 한다.

그림 2와 같이 추적 대상 공간에서 객체가 움직일 수 있는 후보 영역 전체를 효과적으로 관찰하



(a) (b)  
 그림 1. Omni-directional Vision  
 Fig 1. Omni-directional Vision.  
 (a) ODVS, (b) Omni-directional image

기 위해서는 일반적으로 최소한 4대의 카메라를 필요로 하며 그 공간상의 제약도 따르게 되지만, 카타디옵트릭 카메라를 통해 얻어지는 영상의 시각 범위는 일반 카메라보다 넓은 시각 범위를 가지기 때문에 영상의 모든 영역을 한 번에 획득할 수 있는 유용성을 가진다. 즉, 설치 공간상의 제약 없이 1대의 카메라만을 설치함으로써 360° 전 방향에 대한 영상 획득이 가능하며 실시간 영상 처리를 위한 비용도 줄일 수 있다.



(a) (b)  
 그림 2. Multi-Vision과 Omni-Vision의 비교  
 Fig 2. Comparison of Multi-Vision and Omni-Vision  
 (a) Multi-Vision, (b)Omni-Vision.

이런 관점에서 일반 카메라의 구조에서 탈피한 카타디옵트릭 카메라와 같은 특수 카메라의 이용은 매우 효율적이며 합리적인 접근 방법으로 판단되고 있으나, 새롭게 개척되는 분야로써 산업에 응용된 사례가 불충분하고 실질적인 활용을 위해서 거울면의 초점 거리, 거울의 특성에 따른 영상 왜곡(distortion) 등의 애로점으로 인하여 그 유용성 및 효율성에 비해 많이 응용되지 않고 있으며 체계적인 연구 또한 미흡한 실정이다.

본 연구에서는 이러한 관점에서 카타디옵트릭 카메라로부터 획득한 전 방향 구면 왜곡 영상에서의 이미지 좌표를 3차원 포물선 좌표 변환 함수에

의해 실제 거리 좌표(실 좌표)로 변환하고 Delta-bar-delta 신경망 알고리즘에 의해 실 좌표를 교정하는 정확한 좌표 변환 방법을 제시하고자 한다.

먼저 Omni-directional image에서의 좌표  $(x_0, y_0)$ 는 포물선 좌표 변환 함수에 의해  $(x_p, y_p)$ 로 변환되고  $(x_p, y_p)$ 는 다시 신경망의 교정 출력  $(dx, dy)$ 과 더해져 최종 좌표  $(x_f, y_f)$ 로 변환된다. 제안하는 좌표 교정 시스템의 구성은 그림 3과 같다.

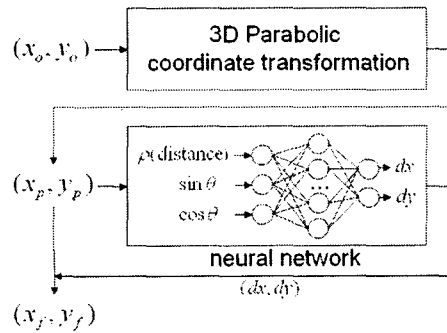


그림 3. 좌표 교정 시스템  
 Fig 3. Coordinate calibration system.

## II. 관련 연구

네덜란드 암스테르담 대학의 Roland 및 Ben은 한 쌍의 Omni-directional 이미지를 이용하여 추정치를 정리하는 연구[1]와 Omni-directional vision system으로 이미지의 재건축(reconstruction)에 대한 연구[2]를 수행하였으며, 프랑스의 Arnaud, Laurent, Eric, Claude는 공동으로 다중 매체의 추적을 위하여 ODVS를 도입하였다[3]. 또한 체코 테크니컬 대학의 Micusik 와 Pajdla는 Nikon FC-E8 Fish-eye Lens를 이용하여 Epipolar Geometry를 평가하는 연구를 수행[4]하는 등 활발한 연구가 이루어지고 있다.

한편, 국내의 경우 3차원 영상을 기반으로 파노라믹하게 영상을 구성하고 이를 이용하여 가상의 환경을 생성하는 연구[5], 전 방향 이미지의 왜곡 보정을 위해서 구면 투영 알고리즘을 구현하는 연구[6], 카타디옵트릭 카메라(거울을 이용하여 360°의 3차원 이미지를 한 장에 촬영할 수 있는 이미지 시스템)를 이용한 직각 교차 실린더 맵에 관한 연구[7], 전 방향 이미지를 이용하여 환경 맵을 구성하고 이를 추정하는 연구[8] 등이 있다.

3D 영상 기반 파노라마를 이용한 가상 환경 생

성 연구는 다수의 멀티 뷰 카메라를 사용하여 영상의 3D 깊이 정보에 기반한 파노라믹 영상 생성과 이를 통한 가상 환경 구축 방법을 제안한다. 이러한 가상환경의 구축으로 실제로 사람이 수행하기 힘든 지역에서의 동작을 미리 로봇으로 실험해 보는 것이 가능해진다.

전 방향 이미지를 이용한 환경 맵 추정에 관한 연구는 한대의 카메라와 하나의 볼록거울의 조합을 이용하여 실시간으로 얻어지는 전 방향 이미지로부터 바닥 정보를 추출하여 지역정보(Local Map)를 얻고, 그 정보에 기반 하여 로봇의 이동을 제어하고 전역정보(Global Map)를 구성하는 새로운 방법을 제안하고 있다.

### III. 포물선 좌표 변환 함수

포물면 거울로 구성된 카타디옵트릭 카메라를 이용하여 이미지 상의 좌표  $(x_0, y_0)$ 에 대응하는 실 좌표  $(x_p, y_p)$ 를 구하는 포물선 좌표 변환 함수는 다음과 같다. 먼저 이미지 상의 좌표  $(x_0, y_0)$ 에서 포물면 거울 위로 투영시킨 3차원 점  $(x', y', z')$ 을 구한다. 포물선의 초점  $F(0, 0, p)$ 에서 포물면 거울 위의 점  $(x', y', z')$ 의 방향으로 직선 벡터를 구한 후, 이 직선 벡터를 실제 물체가 있는 바닥으로 투영시킨 교점이 구하고자 하는 실 좌표  $(x_p, y_p)$ 이다.

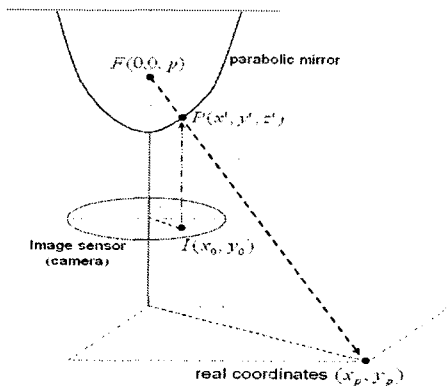


그림 4. 3차원 포물선 좌표 변환

Fig 4. 3D parabolic coordinate transformation.

포물선 좌표 변환 함수는 다음과 같이 계산한다.

**Step 1.** 이미지의 중심을 원점(0, 0)으로 하여 이

미지 상의 관심 물체 좌표를 입력  $(x_0, y_0)$  받는다.

**Step 2.** 이미지 상의 좌표  $(x_0, y_0)$ 에서 포물면 거울 위의 점  $(x', y', z')$ 으로 투영한다.

포물면 거울에서의 실제 거리 계산을 위해 식 (1)과 같이 실제 픽셀 당 거리 비율(T)를 계산한다. 여기서, R은 포물면 거울의 반지름, r은 이미지 상의 반지름이다.

$$T = R/r \quad (1)$$

구해진 실제 픽셀 당 거리 비율을 이용하여 이미지 상의 좌표에 비율이 반영된 좌표가 포물면 거울에서 어디에 맺히는지 포물면 거울 위로 투영시킨 3차원 점을 포물선 방정식을 이용하여 식 (2)와 같이 계산한다.

$$\begin{aligned} x' &: x_0 \times T \\ y' &: y_0 \times T \\ z' &: \sqrt{(x')^2 + (y')^2 / 4 \times p} \end{aligned} \quad (2)$$

**Step 3.** 포물선 초점  $F(0, 0, p)$ 과 포물면 거울 위의 점  $(x', y', z')$ 을 잇는 직선 벡터를 설정한다.

직선 벡터는 포물면 거울 초점  $F(0, 0, p)$ 으로부터 포물면 거울 위의 3차원 점  $(x', y', z')$ 의 방향으로의 벡터이고 실 좌표는 다음과 같이 t를 매개 변수로 하는 직선식으로 구할 수 있다.

$$x_p = a \times t + a \quad (3)$$

$$y_p = b \times t + \beta \quad (4)$$

$$z_p = c \times t + \gamma \quad (5)$$

여기서,  $a, b, c$ 는 포물면 거울 초점에서 포물면 거울 위의 3차원 점으로 가는 기울기 벡터 ( $a=x', b=y', c=z'-p$ )이고,  $a, \beta, \gamma$ 는 초점을 지난다고 설정할 경우 각각  $0, 0, p$  또는 점  $(x', y', z')$ 을 지난다고 설정할 경우 각각  $x', y', z'$ 가 된다.

**Step 4.** 직선 벡터와 실제 물체가 있는 바닥과의 교점인 실 좌표  $(x_p, y_p)$ 를 계산한다.

실 좌표는 직선 벡터와 실제 물체가 있는 바닥 (x,y평면)과의 교점이다. 실 좌표의 z 축의 좌표 ( $z_p$ )는 사전에 조사된 포물면 거울과 바닥과의 높이이므로 식 (5)에서 t를 구한다. 구해진 매개변수 t를 식 (3),(4)에 대입하여 변환 좌표  $(x_p, y_p)$ 를 구

한다.

#### IV. 신경망에 의한 좌표 교정

##### 1. Delta-bar-delta 학습 알고리즘

오류 역전파 알고리즘(BP)은 순방향 다층 신경망의 학습에 널리 사용되는 대표적인 알고리즘이다. BP 알고리즘은 출력층 오차 신호를 이용하여 은닉층과 출력층간의 연결 강도를 변경하고, 이 오차 신호를 다시 은닉층에 역전파 해서 은닉층과 입력층 사이의 연결 강도를 변경시키는 학습 방법을 사용한다. BP 알고리즘을 이용한 다층 신경망의 학습 절차는 다음과 같다[10].

**Step 1.** 입력층 패턴벡터  $x$  은닉층 출력벡터  $z$  출력층 출력벡터  $y$ 를 다음과 같이 표현한다.

$$\begin{aligned} x &= [x_1, x_2, \dots, x_n] \\ z &= [z_1, z_2, \dots, z_p] \\ y &= [y_1, y_2, \dots, y_m] \end{aligned} \quad (6)$$

입력층과 은닉층간의 연결강도  $v(p \times n)$ , 은닉층과 출력층간의 연결강도  $w(m \times p)$ 를 임의의 작은 값으로 초기화하고 임의의 학습률  $\alpha$ 를 설정한다.

**Step 2.** 학습 패턴 쌍을 차례로 입력하여 다음과 같이 은닉층의 가중합  $\neq T_z$  및 출력  $z$  출력층의 가중합  $\neq T_y$  및 최종 출력  $y$ 를 구한다.

$$\neq T_z = xv^T \quad (7)$$

$$z = f(\neq T_z) = \frac{1}{1 + \exp(-\neq T_z)} \quad (8)$$

$$\neq T_y = zw^T \quad (9)$$

$$y = f(\neq T_y) = \frac{1}{1 + \exp(-\neq T_y)} \quad (10)$$

**Step 3.** 목표치  $d$ 와 최종 출력  $y$ 를 비교하여 오차를 구하고 출력층의 오차 신호  $\delta_y$ 와 은닉층에 전파되는 오차 신호  $\delta_z$ 를 구한다.

$$E = \frac{1}{2}(d - y)^2 \quad (11)$$

$$\delta_y = (d - y)y(1 - y) \quad (12)$$

$$\delta_z = z(1 - z) \sum_{i=1}^m \delta_y w \quad (13)$$

**Step 4.** 식 (12), (13)에 의해  $k$  학습 단계에서의 은닉층과 출력층간의 연결강도 변화량  $\Delta w^k$  및 입력층과 은닉층간의 연결강도 변화량  $\Delta v^k$ 를 구하고 각각의 연결강도를 수정한다.

$$w^{k+1} = w^k + \Delta w^k = w^k + \alpha \delta_y z \quad (14)$$

$$v^{k+1} = v^k + \Delta v^k = v^k + \alpha \delta_z x \quad (15)$$

**Step 5.** 학습 패턴 쌍을 반복 입력하여 연결강도를 변경하며, 오차  $E$ 가 특정 범위  $E_{\max}$ 보다 적어지거나 지정된 반복회수를 수행하면 학습을 종료한다.

학습률  $\alpha$ 와 오차신호  $\delta_z, \delta_y$ 에 의해서만 결정되는 연결강도 변화량  $\Delta w, \Delta v$ 에 이전 학습 단계에서의 연결강도 변화량을 보조적으로 활용하는 모멘텀(momentum) 알고리즘을 사용함으로써 학습 속도를 개선시킬 수 있다. 모멘텀 알고리즘을 사용한 연결강도의 변화량은 다음과 같다. 여기서  $\eta$ 는 모멘텀 상수이다.

$$w^{k+1} = w^k + \alpha \delta_y z + \eta \Delta w^{k-1} \quad (16)$$

$$v^{k+1} = v^k + \alpha \delta_z x + \eta \Delta v^{k-1} \quad (17)$$

Delta-bar-delta ( $\Delta - \bar{\Delta}$ ) 학습 알고리즘은 각 학습 단계마다 연결강도의 변화에 따라서 학습률을 적응적으로 변경함으로써 학습 단계를 단축하고 궁극적으로 학습 시간을 효과적으로 감소시키는 방법이다. BP 알고리즘은 학습률  $\alpha$ 에 의존하여 연결강도가 변하는데[9], 일반적으로 여러 학습 단계에 걸쳐 연결강도가 계속 증가하거나 혹은 증가와 감소를 반복하는 경우가 발생한다. 만약, 연결강도가 계속 증가한다면 이것은 학습률  $\alpha$ 가 너무 적기 때문에 연결강도를 적절히 변화시키는 데 상당히 많은 학습 단계가 요구될 것이라고 판단할 수 있으므로 학습률을 보다 큰 값으로 변경하여 학습 속도를 개선할 수 있다. 반면, 학습이 진행되면서 연결강도가 변화가 증가하거나 감소한다면 학습률이 너무 크기 때문에 연결강도가 적절히 변화되지 못한 것이라고 판단할 수 있으므로, 이 경우에는 반대로 학습률을 감소시킴으로써 학습 속도를 개선할 수 있다.

Delta-bar-Delta 알고리즘에서  $\Delta$ 와  $\bar{\Delta}$ 는 다음과 같이 정의된다.

$$\overline{\Delta}_w^k \equiv -\delta_z x^k \quad (18)$$

$$\overline{\Delta}_w^k \equiv (1-\beta)\Delta_w^k + \beta \overline{\Delta}_w^{k-1} \quad (19)$$

$$\overline{\Delta}_v^k \equiv -\delta_x x^k \quad (20)$$

$$\overline{\Delta}_v^k \equiv (1-\beta)\Delta_v^k + \beta \overline{\Delta}_v^{k-1} \quad (21)$$

위와 같이 정의한  $\Delta$ 와  $\overline{\Delta}$ 를 이용하여  $k+1$  단계에서의 새로운 학습률  $\alpha^{k+1}$ 은 다음과 같이 구한다.

$$\alpha^{k+1} = \begin{cases} \alpha^k + x & ; \overline{\Delta}^{k-1} \cdot \Delta^k > 0 \\ (1-\gamma)\alpha^k & ; \overline{\Delta}^{k-1} \cdot \Delta^k < 0 \\ \alpha^k & ; \overline{\Delta}^{k-1} \cdot \Delta^k = 0 \end{cases} \quad (22)$$

여기서,  $\beta$ ,  $x$ ,  $\gamma$ 는 임의의 상수이며 학습률은  $\Delta$ 와  $\overline{\Delta}$ 가 같은 부호를 가지면  $x$ 만큼 증가시키고 다른 부호를 가지면  $(1-\gamma)$ 만큼 감소시키는 방법으로 변경된다.

제안된 신경망에서의 연결강도의 변화는 다음과 같다.

$$w^{k+1} = w^k + \alpha^k \delta_z + \eta \Delta w^{k-1} \quad (23)$$

$$v^{k+1} = v^k + \alpha^k \delta_x + \eta \Delta v^{k-1} \quad (24)$$

## 2. 좌표 교정 신경망의 구성

좌표 교정을 위한 신경망 구조는 입력층 3개, 은닉층 100개, 출력층 2개로 구성하였으며, 입력층의 입력 벡터로는 포물선 좌표 변환 좌표  $(x_p, y_p)$ 의 원점으로부터의 거리를 0과 1사이의 값으로 정규화한 값, 원점으로부터의 방향각인  $\sin\theta$ ,  $\cos\theta$ 를 사용하였다. 출력층은  $(x_p, y_p)$ 의 최종 교정값  $(dx, dy)$ 이다.




그림 5. 교정 패널  
Fig 5. Calibration panel.

좌표 교정 신경망의 학습을 위하여 100mm 등

간격의 격자로 구성된 교정(calibration) 패널을 사용하였다. 그림 5에서 살펴볼 수 있는 바와 같이 실제 등간격의 격자가 Omni-directional image에서 왜곡되어 나타남을 알 수 있다.

신경망의 목표 출력은 Omni 이미지상에서 68개 교차점 좌표(이미지 픽셀 좌표)를 포물선 좌표 변환 함수에 의해 실제 mm 좌표로 변환하고 변환된 좌표와 미리 계산된 기준이 되는 좌표와의 차이를 신경망의 목표값(target value)으로 사용하였다.

## V. 실험 및 결과 분석

본 논문의 유용성을 검증하기 위하여 Pentium IV 2.8GHz, 512MB에서 Visual C++6.0으로 실험하였다.

### 1. 신경망 학습 성능 비교

실 좌표 교정을 위한 신경망 학습 성능을 평가하기 위해서 기존의 BP 알고리즘과 모멘텀을 추가한 방법, 그리고 Delta-bar-delta 학습 방법을 서로 비교하였다. 학습 파라미터의 설정은 표 1과 같다.

표 1. 신경망 학습 파라미터  
Table 1. Neural network learning parameters

학습방법	$\alpha$	$\eta$	$\beta$	$x$	$\gamma$
BP1	0.01	-	-	-	-
BP2	0.1	-	-	-	-
BPM1	0.1	0.1	-	-	-
BPM2	0.1	0.01	-	-	-
BPMD1	0.1	0.1	0.1	0.01	0.01
BPMD2	0.1	0.01	0.1	0.01	0.01
BPMD3	0.01	0.1	0.1	0.01	0.01

그림 6에서는 각각의 학습 알고리즘에 따른 출력 노드의 최대 오차의 변화를 비교하고 있다. 기존의 BP 알고리즘을 사용한 경우(BP1, BP2) 학습률에 따라서 오차의 감소 속도가 다르게 나타나고 있으며 이것은 학습률 설정에 의해서 학습 능력의 차이가 나타남을 의미한다. 모멘텀을 추가하여 사용한 경우(BPM1, BPM2)도 학습 속도의 개선을 가져오지 못하고 있으며 Delta-bar-delta 알고리즘을 사용한 경우(BPMD1, BPMD2, BPMD3)는 학습률 설정에 관계없이 학습 속도가 매우 빠름을 알 수 있으며 학습 알고리즘에 의해서 자동으로 적절

한 학습률을 조정하므로 학습에 대한 수렴성과 학습 속도가 개선된 것을 확인할 수 있다.




그림 6. 신경망 학습 성능 비교  
Fig 6. Comparison of learning performance of neural network.

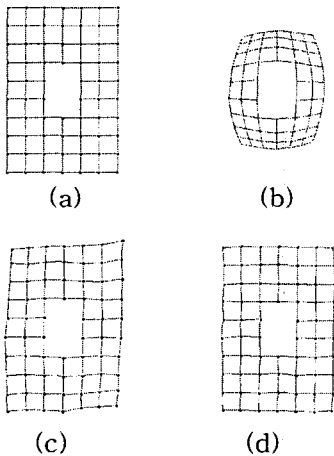


그림 7. 좌표 교정 결과  
Fig 7. Result of Coordinate calibration.  
(a) real coordinate, (b) omni map, (c) parabolic transformed map, (d) neural calibration map

2. 좌표 교정 성능 평가

그림 7은 학습된 신경망을 바탕으로 교정된 좌표가 실제 좌표와 얼마나 유사한지를 나타내는 그림이다. (a)는 기준이 되는 실 좌표를 나타내고 있고 (b)는 구면 왜곡 현상이 일어난 Omni 이미지 좌표를 나타내고 있으며 (c)는 포물선 방정식에 의해 유도된 실 좌표로 기준 좌표와 많은 차이를 나타냄을 알 수 있다. 이것은 카메라의 설치 및 교차점을 구하는 방법, 초점 거리 설정에서의 오차 등 환경 변수에 민감하게 영향을 받을 수밖에 없는

결과라고 할 수 있다. (d)는 신경망에 의해 교정된 실제 좌표로 기준 좌표와 매우 유사하게 나타남을 알 수 있다.

제안된 좌표 변환 방법을 사용하여 구면 왜곡 영상에서의 좌표를 실제 좌표로 변환했을 경우의 오차를 표 2로 나타내었다.

표 2. 좌표 변환 오차  
Table 2. Coordinate conversion error

	Parabolic transform error (mm)		Neural calibration error (mm)	
	dx	dy	dx	dy
최대	20.0	32.0	4.0	6.1
평균	6.7	8.9	1.1	1.3
표준편차	5.2	6.3	1.0	1.4

VI. 결론 및 향후 연구 과제

본 논문에서는 카타디옵트릭 카메라로부터 획득한 전 방향 구면 왜곡 영상에서의 좌표를 포물선 좌표 변환 함수에 의해 실 좌표로 변환하고 Delta-bar-delta 알고리즘에 의해 실 좌표를 교정하는 좌표 변환 방법을 사용하였다. 제안된 방법의 성능을 확인하기 위하여 실험한 결과, 제안된 좌표 변환 방법이 환경 변수에 민감한 좌표 변환에서의 정확성 및 신뢰성이 있음을 확인하였다.

향후 연구 과제로는 관련 연구를 확대하여 실제적인 활용으로써 좀 더 넓은 범위의 영상에 대한 좌표 변환 연구와 함께 이를 활용한 객체의 움직임 추적 연구를 수행할 계획이다.

참고문헌

[1] Roland Bunschoten, Ben Kröse, "Range estimation from a pair of omni-directional images", Autonomous Learning Functions LAB, Amsteldam, Holland, 2001.  
[2] Roland Bunschoten and Ben Kröse, "Robust scene reconstruction from an omnidirectional vision system", IEEE TRANSACTIONS ON ROBOTICS AND AUTOMATION, VOL. 19, NO. 2, APRIL 2003.  
[3] Arnaud CLERENTIN, Laurent DELAHOCHÉ, Eric BRASSART, Claude PEGARD, "Omni-

directional sensors cooperation for multi-target tracking", CREA - Centre de Robotique, d'Electrotechnique et d'Automatique, IUT, département Informatique, Avenue des Facultés, 80000 Amiens - France, 2001.

- [4] Branislav Micusik, Tomas Pajdla, "Estimation of Omnidirectional Camera Model from Epipolar Geometry(Nikon FC-E8 fish-eye Lens)", Center for Machine Perception, Dept. of Cybernetics, Faculty of Electrical Engineering, Czech Technical University in Prague, 2003.
- [5] 박화진, 조세홍 "몰입형 가상현실 시스템을 위한 기술 및 사례에 대한 연구", 한국 정보처리학회 제 10권 제 1호 pp. 64-72, 2003.
- [6] 장원두, 서영욱, 강진숙, 차의영, "카타디옵트릭 카메라의 전방향 이미지의 왜곡보정을 위한 구면투영 알고리즘에 관한 연구", 2003 춘계학술발표논문집, 제10권 제1호, pp.679-682, 2003.
- [7] 구경모, 김병훈, 김하영, 차의영 "카타디옵트릭 카메라를 이용한 직각교차 실린더맵에 관한 연구", 한국 정보처리학회 춘계 학술 발표대회, 제 11권 제1호, 2004.
- [8] Koo Kyung-mo, Park Young-mi, Cha Eui-young, "Study on Environment Estimation from Omnidirectional Images", Proceedings of the 5th Cross Straits Symposium, pp. 237-238, October, 2003.
- [9] 김광백, 박충식, "퍼지 제어 시스템을 이용한 학습률 자동 조정 방법에 의한 개선된 역전파 알고리즘", 한국해양정보통신학회논문지, 제8권, 2호, pp.464-470, 2004.
- [10] 오창석, '뉴로컴퓨터', 내하출판사, 2000.
- [11] Laurene Fausett, 'Fundamentals of Neural Networks', Prentice Hall, 1994.


저자소개



**김도현(Do-Hyeon Kim)**

2001년 부산대학교 전자계산학과 졸업.  
 2003년 부산대학교 전자계산학과 석사 졸업.  
 2004 부산대학교 컴퓨터공학과 박사 재학 중.


※ 관심분야 : 패턴인식, 영상처리 및 컴퓨터비전, 퍼지 및 신경망, 제어자동화 시스템.



**박용민(Yong-Min Park)**

2004년 부산대학교 정보컴퓨터공학전공 졸업.  
 2004년 부산대학교 컴퓨터공학과 석사 재학 중

※ 관심분야 : 신경망, 개체 추적, 영상처리 및 컴퓨터비전



**차의영(Eui-Young Cha)**

1979년 경북대학교 전자공학과 졸업.  
 1982년 서울대학교 전자계산학과 석사 졸업.  
 1998년 서울대학교 컴퓨터공학과 박사졸업.  
 1981년~1985년 한국전자기술

연구소 연구원.  
 1995년~1996년 University of London 방문교수.  
 1985년~현재 부산대학교 컴퓨터공학과 교수  
 ※ 관심분야 : 컴퓨터비전, 신경망 이론, 웨이블릿