

화살 탄착점 측정을 위한 레이저 스캔 카메라 파라미터 보정

백경동⁺, 천성표⁺⁺, 이인성⁺, 김성신^{*}

(논문접수일 2011. 06. 29, 수정일 2011. 10. 08, 심사완료일 2011. 10. 21)

Parameter Calibration of Laser Scan Camera for Measuring the Impact Point of Arrow

Gyeongdong Baek⁺, Seong-Pyo Cheon⁺⁺, Inseong Lee⁺, Sungshin Kim^{*}

Abstract

This paper presents the measurement system of arrow's point of impact using laser scan camera and describes the image calibration method. The calibration process of distorted image is primarily divided into explicit and implicit method. Explicit method focuses on direct optical property using physical camera and its parameter adjustment functionality, while implicit method relies on a calibration plate which assumed relations between image pixels and target positions. To find the relations of image and target position in implicit method, we proposed the performance criteria based polynomial theorem model that overcome some limitations of conventional image calibration model such as over-fitting problem. The proposed method can be verified with 2D position of arrow that were taken by SICK Ranger-D50 laser scan camera.

Key Words : Image calibration(영상보정), Performance criteria(성능지수), Polynomial theorem model(다항정리모델), TSK neuro-fuzzy model(TSK 뉴로퍼지모델), Nonlinear system identification(비선형시스템 동일화)

1. 서론

화살은 Fig. 1(a)에서와 같이 화살대, 화살깃, 그리고 화살촉이 가지는 각각의 고유한 특성이 결합되어 탄착점, 탄착군, 이동궤적이 달라진다. 화살은 동일한 슈팅시 탄착점이 높은 집적도로 분포할수록 우수한 제품으로 평가받는다. 탄착점의 정밀 자동 측정은 블록단위로 나누어진 표적지와 화살의 탄착점을 측정하는 장치가 필요하다. 제안한 머신비전 시스템은 기존의 수작업검사(Manual inspection)를 대체하여 기술로 머신비전 카메라를 이용하여 대상을 측정하고 분석한다⁽¹⁾. 머신비전 기술은 대상체의 위치 인식, 크기/부피 측정, 형상/얼굴 인식, 제품 검사/분류 등의 분야에서 응용되고 있다. 위치 인식은 대상

체의 위치와 방향을 계측하며, 측정은 대상체의 지름, 굴곡, 면적, 높이, 부피 등을 측정한다. 인식은 숫자, 문자, 바코드에서 정보를 얻어내거나, 색상이나 얼굴의 표정 등을 읽는 데 사용하며, 검사는 라벨의 여부, 조립과정의 나사 유무, 포장상태를 판단하여 양품과 불량품 등으로 분류한다^(2,3).

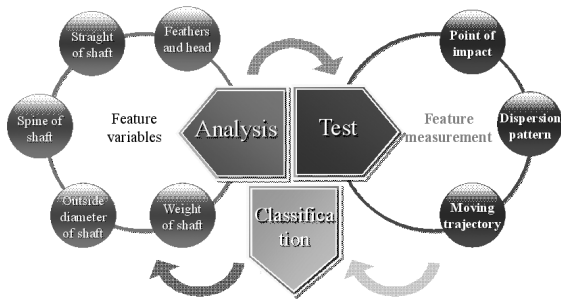
머신비전 시스템은 카메라로부터 획득한 영상 데이터에서 정보를 추출하기 때문에 좋은 품질의 영상을 획득하는 것이 매우 중요하다⁽⁴⁾. 특히, 화살의 탄착점 영상의 경우 렌즈의 중심에서 벗어나면 방사왜곡(Barrel distortion)과 실타래형왜곡(Pincushion distortion)이 뚜렷하게 나타나는 특징이 있다⁽²⁾. 이러한 Fig. 2와 같은 왜곡 현상들로 인해 영상 좌표계를 이용한 화살의 탄착점과 전역 좌표계에서의 화살의 탄착점 사이에 오차가 발생한

⁺ 부산대학교 전자전기공학과

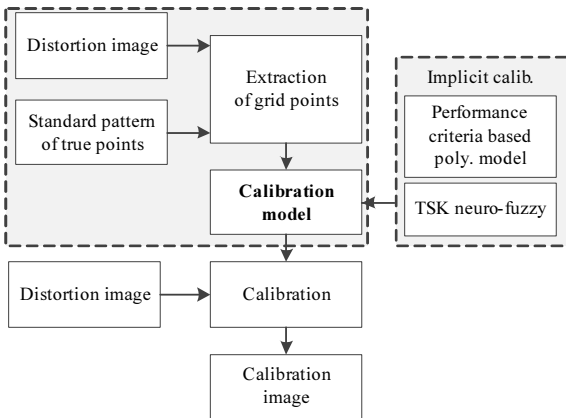
⁺⁺ 영진전문대학 신재생에너지전기계열

^{*} 교신저자, 부산대학교 전자전기공학부 (sskim@pusan.ac.kr)

주소: 609-735 부산시 금정구 장전2동 부산대학교 특성화공학과관 313호 전자전기공학과 정보제어실험실



(a) The schematic diagram of arrow testing using impact points, moving trajectory



(b) Calibration process of distorted image

Fig. 1 Definition of measurement target and solving process of calibration problem




Fig. 2 Examples of distorted image

다. 이러한 오차를 보정하는 방법은 크게 외재적(Explicit) 방법과 내재적 방법(Implicit)으로 나눌 수 있다^(5,6). 외재적 보정은 카메라의 위치, 회전각, 초점거리, 왜곡률 등 이미지 획득 과정에 영향을 주는 외부 변수(Extrinsic parameter)와 고유 변수(Intrinsic parameter)들로 보정 모델을 만들어 영상을 보정한 다⁽⁴⁾. 이러한 외재적 보정은 왜곡 변수들의 인과 관계가 복잡하여 보정 모델에 따라 특정한 왜곡 보정에만 한정되는 한계가 있다. 한편, 내재적 보정은 영상 좌표계(이미지)와 전역 좌표계(체커판 또는 격자점)의 입·출력 데이터를 대응시켜 보정하는 다층신경망(Multi-layer neural networks), 다항식 신경망(Polynomial neural networks), TSK 뉴로-퍼지(TSK neuro-fuzzy) 등의 모델들이 제안되었다⁽⁷⁾.

본 논문에서는 내재적 보정법을 적용하여 화살의 정밀 탄착

점을 찾으려 한다. Fig. 1(b)는 왜곡영상 보정모델의 생성과정과 보정과정을 정리한 것이다. 왜곡 보정모델은 격자점을 카메라를 이용해서 촬영한 영상의 좌표값과 실제 좌표값을 대응시켜 보정모델을 만드는데, 여기서는 보정모델로 성능지수기반 계층형 다항정리 모델(Performance criteria based hierarchical polynomial theorem model)을 제안한다. 제안한 모델이 성능은 비교실험을 통해서 검증하였다. 실험장치는 조도 변화에 강한 학습데이터를 얻기 위해 레이저 광원을 채택하였고 격자점 교정판에 대상체를 위치시키고 영상 좌표를 획득하여 왜곡과 보정의 결과를 비교하였다.

2. 왜곡영상의 내재적 보정모델

왜곡영상의 보정모델은 식 (1)의 왜곡현상을 최소화하는데 있다. 왜곡된 영상의 좌표를 u_d, v_d 라 하면 이들은 식 (1)로 표현할 수 있다.

$$\begin{aligned} u_d &= u + \delta_u(u, v) + \epsilon_u \\ v_d &= v + \delta_v(u, v) + \epsilon_v \end{aligned} \quad (1)$$

여기서, u, v 는 왜곡이 없는 영상의 좌표점, ϵ_u, ϵ_v 는 측정오차, $\delta_u(u, v), \delta_v(u, v)$ 는 u, v 각각의 왜곡을 의미한다. 영상 왜곡의 종류는 축왜곡(Radial distortion), 편심왜곡(Decentering distortion),

얇은 프리즘 왜곡(Thin prism distortion)으로 나눌 수 있으며 식 (2)~(4)로 정의된다. 축왜곡 δ_{ur}, δ_{vr} 은 렌즈의 구면수차(Spherical aberration)에 의해서 영상의 외곽에서 방사왜곡(Barrel distortion) 또는 실타래형왜곡(Pincushion distortion)이 발생한다. 편심왜곡 δ_{ud}, δ_{vd} 은 렌즈와 공학 요소들이 동일 선상에 놓이지 않을 때 발생하며, 얇은 프리즘 왜곡 δ_{up}, δ_{vp} 은 이미지센서 또는 렌즈의 기울기에 의해 발생한다.

$$\begin{aligned} \delta_{ur} &= u(k_1 r^2 + k_2 r^4 + k_3 r^6 + \dots) \\ &\approx u(k_1 r^2 + k_2 r^4) \\ \delta_{vr} &= v(k_1 r^2 + k_2 r^4 + k_3 r^6 + \dots) \\ &\approx v(k_1 r^2 + k_2 r^4) \end{aligned} \quad (2)$$

여기서, k_1, k_2, k_3 는 축왜곡 계수, r 은 u, v 의 영상 좌표점에서 왜곡이 발생한 좌표까지의 거리를 나타낸다.

$$\begin{aligned} \delta_{ud} &= p_1(3u^2 + v^2) + 2p_2 uv \\ \delta_{vd} &= p_2(u^2 + 3v^2) + 2p_1 uv \end{aligned} \quad (3)$$

$$\begin{aligned} \delta_{up} &= s_1(u^2 + v^2) \\ \delta_{vp} &= s_2(u^2 + v^2) \end{aligned} \quad (4)$$

여기서, p_1, p_2 는 편심왜곡 계수, s_1, s_2 는 얇은 프리즘 왜곡계수이다. 최종으로 식 (1)의 영상왜곡은 식 (6)으로 정리된다.

$$\begin{aligned} \delta_u &= k_1 u(u^2 + v^2) + k_2 u(u^2 + v^2)^2 \\ &\quad + p_1(3u^2 + v^2) + 2p_2 uv + s_1(u^2 + v^2) \\ \delta_v &= k_1 v(u^2 + v^2) + k_2 v(u^2 + v^2)^2 \\ &\quad + p_2(3v^2 + u^2) + 2p_1 uv + s_2(u^2 + v^2) \end{aligned} \quad (5)$$

식 (5)의 영상왜곡을 최소화하기 위해 식 (6)의 왜곡보정함수 δ_{ud}, δ_{vd} 를 정의하였다.

$$\begin{aligned} u &= \omega_{0u} u_d + \delta_{ud}(u_d, v_d) \\ v &= \omega_{0v} v_d + \delta_{vd}(u_d, v_d) \end{aligned} \quad (6)$$

본 논문에서 사용한 왜곡보정함수 δ_{ud}, δ_{vd} 는 내재적 보정방법인 TSK 뉴로-퍼지 모델과 제안하는 성능지수기반 다항식 모델이며 왜곡보정 결과를 비교하였다.

2.1 TSK 뉴로-퍼지 모델

TSK(Takagi-Sugeno-Kang) 퍼지 모델은 비선형 시스템의 특성을 복수 개의 선형 다항식의 조합으로 근사화하며 (7)과 같이 if-then 형식으로 기술하였다.

$$\begin{aligned} R^i: & \text{If } u_d \text{ is } A_1^i(p_{1k}^i) \wedge v_d \text{ is } A_2^i(p_{2k}^i) \\ & \text{then } y^i = a_0^i + a_1^i u_d + a_2^i v_d \end{aligned} \quad (7)$$

여기서, $R^i(i=1,2,\dots,n)$ 는 i 번째의 퍼지규칙(Fuzzy rule), y^i 는 i 번째 추론의 출력, a_j^i 는 후건부(Consequent) 파라미터, A_1^i, A_2^i 는 소속함수(Membership function), p_{1k}^i, p_{2k}^i 는 소속함수의 파라미터이다. TSK 뉴로-퍼지 모델의 최종 출력은 다음 식으로 주어진다.

$$\begin{aligned} \hat{u} &= \left(\sum_{i=1}^n \omega_u^i y_u^i \right) / \left(\sum_{i=1}^n \omega_u^i \right), \quad \omega_u^i = A_1^i(u_d) A_2^i(v_d) \\ \hat{v} &= \left(\sum_{i=1}^n \omega_v^i y_v^i \right) / \left(\sum_{i=1}^n \omega_v^i \right), \quad \omega_v^i = A_1^i(u_d) A_2^i(v_d) \end{aligned} \quad (8)$$

TSK 뉴로-퍼지 모델 결정은 입-출력 데이터로부터 식 (8)의 파라미터를 학습시키는 과정이 필요하다. 학습 방법은 소속함수의 파라미터는 식 (9)의 최급강하법(Steepest descent algorithm)으로 후건부의 파라미터는 식 (10)의 최소자승법(Least squared algorithm)으로 수행하며 혼합형 학습 방법을 사용하였다.

$$\Delta p_{jk}^i = \gamma(y_{des} - \hat{y})(y^i - \hat{y}) \frac{1}{\sum_{i=1}^n \omega^i} \frac{\partial \omega^i}{\partial p_{jk}^i}, \quad j=1,2 \quad (9)$$

여기서, γ 는 학습률(Learning rate), y_{des} 는 목표값, \hat{y} 는 퍼지모델의 추론값이다.

$$\Delta a_m^i = \gamma(y_{des} - \hat{y}) \frac{1}{\sum_{i=1}^n \omega^i} \omega^i x_m, \quad m=0,1,2 \quad (10)$$

여기서, γ 는 학습률(Learning rate), y_{des} 는 목표값, \hat{y} 는 퍼지모델의 추론값이다. TSK 뉴로-퍼지는 식 (13)의 성능지수를 사용하여 훈련데이터에만 지나치게 학습되어 새로운 데이터에 추정오차가 커지는 과대적합문제를 분석하였다.

2.2 성능지수기반 계층형 다항정리 모델

성능지수기반 계층형 다항정리 보정모델의 각 노드는 Fig. 3과 같이 다항식의 항(term)으로 구성되며 두 개의 입력변수로부터 하나의 출력을 생성하는 일반화된 형태를 식 (11)로 정의하였다.

$$\begin{aligned} \hat{u} &= [1 \sum_{i=1}^n u_d^n \sum_{j=2k=1}^{j-1} u_d^{(j-k)} v_d^k \dots \sum_{i=1}^n v_d^n] [b_u \ p_u \ \dots \ p_v]^T \\ &= b_u + \sum_{i=1}^n (p_{iu} u_d^i + p_{iv} v_d^i) + \sum_{j=2k=1}^{j-1} p_{uv} u_d^{j-k} v_d^k \\ \hat{v} &= [1 \sum_{i=1}^n u_d^n \sum_{j=2k=1}^{j-1} u_d^{(n-k)} v_d^k \dots \sum_{i=1}^n v_d^n] [b_v \ p_u \ \dots \ p_v]^T \\ &= b_v + \sum_{i=1}^n (p_{iu} u_d^i + p_{iv} v_d^i) + \sum_{j=2k=1}^{j-1} p_{uv} u_d^{j-k} v_d^k \end{aligned} \quad (11)$$

제안한 성능지수기반 계층형 다항정리 보정모델은 영상좌표와 실제좌표를 학습데이터로 사용하고 성능지수를 이용하여 모델 구조를 동일화(Identification)하는 방법이다. 일반적으로 모델 동일화의 과정은 다항식의 구조와 차수를 결정하는 구조 동일화(Structure identification) 과정과 결정된 다항식 구조에 따른 파라미터를 선정하는 파라미터 동일화(Parameter identification) 과정으로 나눌 수 있다. 식 (12)는 결정된 다항식 구조




Fig. 3 Performance criteria based hierarchical polynomial theorem model

에 따른 파라미터를 선정한다.

$$\begin{aligned} \hat{u} &= f_u(u_d, v_d; b_u, \omega_u) \leftarrow \min_{b, \omega} \{PC^L(u_d, v_d)\} \\ \hat{v} &= f_v(u_d, v_d; b_v, \omega_v) \leftarrow \min_{b, \omega} \{PC^L(u_d, v_d)\} \end{aligned} \quad (12)$$

여기서, L 은 다항식 레이어(차수), b, ω 는 학습데이터를 사용해 최종 정의된 모델 파라미터, PC 는 목표값과 모델의 출력값 사이의 오차를 정의한 성능지수(Performance criteria) 함수이며 식 (13)으로 정의하였다. 제안한 성능지수 PC 는 흔히 훈련데이터에만 최적화되어 새로운 데이터(Unseen data)에 대한 모델의 예측오차가 지나치게 커지는 과대적합문제(Over-fitting problem)를 해결하면서, 동시에 다항식의 차수와 파라미터를 스스로 최적화하는 두 가지 목적을 동시에 이룰 수 있도록 교차 검증법이 적용된 모델 동일화 기법이다.

$$\begin{aligned} mRMSE &= \frac{1}{2} \left\{ \sqrt{\sum_{i=1}^{K_a} \frac{(y_i^a - y_i^{ac})^2}{K_a}} + \sqrt{\sum_{i=1}^{K_c} \frac{(y_i^c - y_i^{ca})^2}{K_c}} \right\} \\ mMAE &= \frac{1}{2} \left\{ \frac{\sum_{i=1}^{K_a} |y_i^a - y_i^{ac}|}{K_a} + \frac{\sum_{i=1}^{K_c} |y_i^c - y_i^{ca}|}{K_c} \right\} \\ PC &= \frac{\omega_1(mRMSE) + \omega_2(mMAE)}{\omega_1 + \omega_2} \end{aligned} \quad (13)$$

여기서, y_i^{ac} 는 훈련데이터 c 로 학습시킨 모델에 시험데이터 a 를 입력했을 때의 출력값, y_i^{ca} 는 훈련데이터 a 로 학습시킨 모델에 시험데이터 c 를 입력했을 때의 출력값, y_i^a, y_i^c 는 목표값, K_a, K_c 는 훈련데이터와 시험데이터로 사용된 개수이다.


$$\begin{aligned} L_u &= L_u + 1 \leftarrow \Delta E_u = (PC^L - PC^{L-1})_u < 0 \\ L_v &= L_v + 1 \leftarrow \Delta E_v = (PC^L - PC^{L-1})_v < 0 \end{aligned} \quad (14)$$

식 (13)의 성능지수 PC 는 시험데이터를 입력했을 때의 오차 가중합으로 정의했기 때문에 최종으로 선정될 다항식은 성능지수 PC 가 최소가 되는 모델이다. 다항식의 차수는 식 (14)와 같이 다항식의 차수를 증가시켜도 성능지수 PC 가 좋아지지 않을 때까지 증가시킨다.

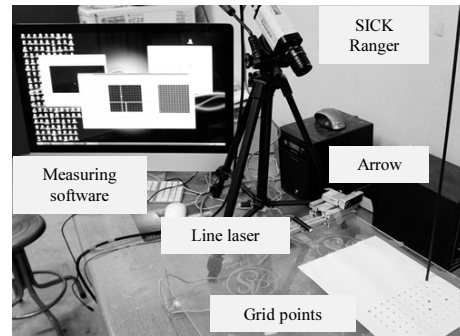
본 논문에서는 성능지수기반 다항식 보정모델의 파라미터를 결정하기 위해 비선형 최소자승법(Nonlinear least squared algorithm)과 강인형 최소자승법(Robust least squared algorithm)을 사용하여 성능오차를 비교하였다.

3. 화살 탄착점 측정시스템

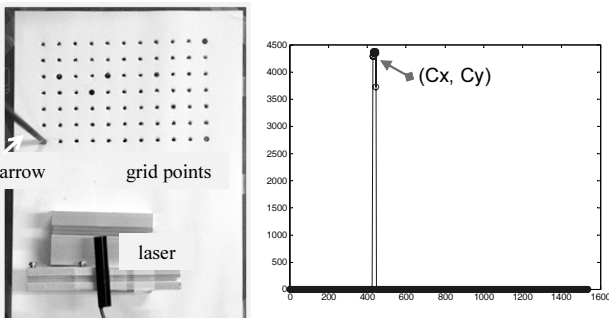
Fig. 4(b)의 머신비전 시스템은 화살 제조공정의 마지막 단계인 생산된 화살의 품질측정 과정에 활용된다. 발사된 화살의




(a) SFOV(Selective field of view) measured area



(b) Experimental apparatus of arrow's point of impact



(c) Measurement data using grid calibration points



(d) Measured distortion data with nonlinear features

Fig. 4 Measurement system and data of arrow's point of impact and using grid calibration plate

탄착점 위치를 비전장치로 인식하여 실제 탄착점을 자동으로 정밀하게 측정하는데 적용된다. 측정데이터 획득을 위해 사용한 머신비전 카메라는 SICK Ranger로 대상체의 위치를 고속 고정밀로 계측하며 레이저의 파장만을 광원으로 사용하기 때문에 일반 카메라와 비교하여 외부 조도 변화에 강인한 것이 장점이다. 카메라 화각(View angle)내 레이저의 측정영역은 Fig. 4(a)에 나타난 SFOV(Selected field of view)내이며 이론적인 측정 정밀도는 SFOV 면적이 폭 50cm, 높이 20cm일 경우 약 0.32mm정도로 알려져 있으나 센서왜곡(Sensor distortion)이 발생하므로 이론적인 정밀도를 얻기 어렵다. 본 논문에서는 보다 정밀한 영상 좌표계와 전역 좌표계의 탄착점 데이터를 얻기 위해서 가로 100mm, 세로 60mm 영역내 가로 10mm, 세로 10mm 간격으로 전체 77개의 격자점을 표시한 격자 교정판을 배치하여 측정하였다. Fig. 4(c), (d)는 격자점 교정판의 격자점에 화살을 쏘고 교정판과 수평으로 레이저를 조사하여 측정한 결과이다. 측정데이터를 살펴보면 전역 좌표계의 동일 높이에서 비선형적인 신호 변화를 볼 수 있으며 센서왜곡의 영향이 그 원인이다.

4. 실험 및 결과고찰

화살 탄착점 위치의 정확성은 왜곡이 존재하는 영상 좌표계에서 전역 좌표계로 변환하는 보정모델의 정확성에 의해 결정된다. 레이저광원 스캔 카메라로부터 측정된 데이터를 이용하여 내재적 보정모델인 TSK 뉴로-퍼지 모델과 제한한 성능지수 기반 다항식 모델을 각각 학습시켜 화살의 탄착점 추정 성능을 비교하였다. 입력변수는 영상 좌표계 (C_x, C_y, C_z)의 격자점 측정값을 사용하였으며, 출력변수는 전역 좌표계 (W_x, W_y, W_z)에서 격자점의 위치값으로 사용하였다. 본 논문에서는 C_z, W_z 변수는 0로 설정하여 공간상의 높이를 제한하고 측정데이터는 평균과 표준편차로 정규화했다. Fig. 5와 같이 학습데이터를 2개의 데이터그룹으로 나누어 훈련데이터와 시험데이터로 사용하였다.

4.1 TSK 뉴로-퍼지 모델링

Fig. 5에 있는 영상 좌표계의 데이터로부터 취득한 77개의 격자점에 대해 TSK 뉴로-퍼지 모델 알고리즘을 이용하여 전역 좌표점을 예측한 결과는 다음과 같다. 추정 모델은 영상 좌표 (C_x, C_y)를 입력, 전역 좌표 W_x, W_y 를 각각 출력으로 가지는 2입력, 1출력 TSK 뉴로-퍼지 구조를 가진다. Fig. 6은 TSK 뉴로-퍼지 모델의 퍼지룰의 증가에 따른 학습오차, RMSE, MAE, 그리고 PC 값의 변화를 나타냈으며 PC 값이 룰이 4개 일 때 최소가 됨을 알 수 있다. 학습된 W_x 의 퍼지 규칙은 식 (15)~(18)과 같다.

$$R^1: \text{If } C_x \text{ is } A_1^1 \wedge C_y \text{ is } A_1^1 \text{ then } y^1 = 43.75 + 2.88C_x + 62.12C_y \quad (15)$$

$$R^2: \text{If } C_x \text{ is } A_2^1 \wedge C_y \text{ is } A_2^1 \text{ then } y^2 = 54.20 + 8.06C_x + 36.30C_y \quad (16)$$

$$R^3: \text{If } C_x \text{ is } A_1^2 \wedge C_y \text{ is } A_1^2 \text{ then } y^3 = 41.33 + 12.23C_x + 78.75C_y \quad (17)$$

$$R^4: \text{If } C_x \text{ is } A_2^2 \wedge C_y \text{ is } A_2^2 \text{ then } y^4 = 51.87 + 21.67C_x + 8.29C_y \quad (18)$$

학습된 W_y 의 퍼지 규칙은 식 (19)~(22)와 같으며 모델의 소속함수는 식 (23), 식 (24)로 정의 및 Table 1과 같이 학습되었다.

$$R^1: \text{If } C_x \text{ is } B_1^1 \wedge C_y \text{ is } B_1^1 \text{ then } y^1 = -4.02 + 25.62C_x + 27.50C_y \quad (19)$$

$$R^2: \text{If } C_x \text{ is } B_2^1 \wedge C_y \text{ is } B_2^1 \text{ then } y^2 = -7.41 + 28.01C_x + 31.33C_y \quad (20)$$

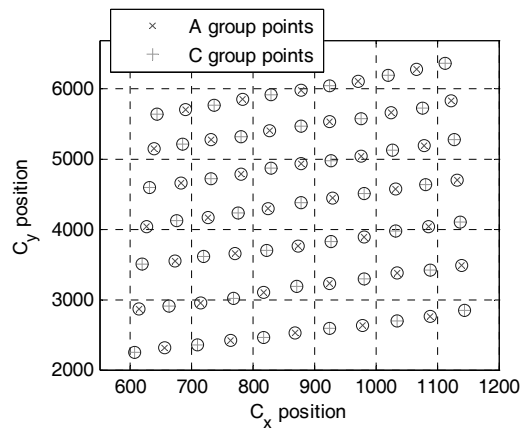


Fig. 5 Division measured data to use training and testing

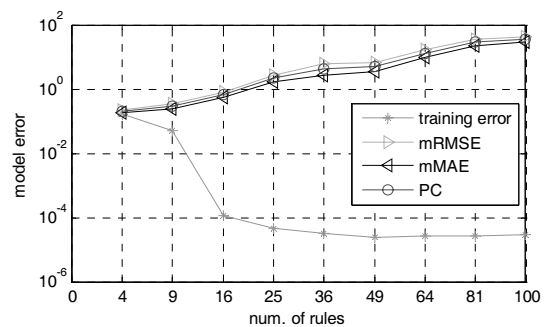


Fig. 6 Model performance with increasing fuzzy rules

Table 1 Membership functions of TSK neuro-fuzzy model

W_x of fuzzy rules	a	b	c
A_1^1	1.29	2.08	-0.92
A_1^2	1.22	1.91	1.22
A_2^1	1.80	2.11	-0.91
A_2^2	1.67	1.58	1.26
W_y of fuzzy rules	a	b	c
B_1^1	0.99	2.14	-1.10
B_1^2	0.76	2.13	1.22
B_2^1	1.09	2.96	-0.46
B_2^2	1.14	2.33	1.16

Table 2 Estimated error of TSK neuro-fuzzy model

fuzzy rules	training (mRMSE)	mRMSE	mMAE	PC
4	0.167	0.227	0.185	0.206
9	0.052	0.350	0.234	0.292
16	1.186e-4	0.767	0.555	0.661
25	4.566e-5	2.572	1.726	2.149
36	3.170e-5	5.839	2.624	4.232
49	2.402e-5	6.677	3.465	5.071
64	2.577e-5	16.875	9.334	13.105
81	2.687e-5	35.171	22.007	28.589
100	2.778e-5	41.236	29.254	35.245

Table 3 Absolute error of TSK neuro-fuzzy model (4 rules condition, Fig. 7 (b))


W_x		W_y	
mean	var.	mean	var.
0.206	0.019	0.170	0.016

$$R^3: \text{If } C_x \text{ is } B_1^2 \wedge C_y \text{ is } B_2^1 \text{ then } y^3 = -3.80 + 24.66C_x + 26.49C_y \quad (21)$$

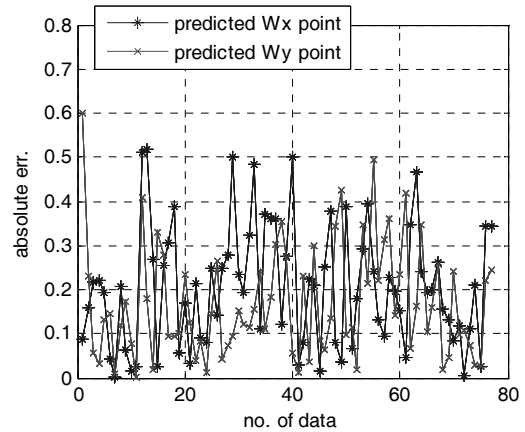
$$R^4: \text{If } C_x \text{ is } B_2^2 \wedge C_y \text{ is } B_2^2 \text{ then } y^4 = -7.85 + 27.61C_x + 33.39C_y \quad (22)$$

$$A_j^i(x;a,b,c) = 1 / (1 + \left| \frac{x-c}{a} \right|^{2b}) \quad (23)$$

$$B_j^i(x;a,b,c) = 1 / (1 + \left| \frac{x-c}{a} \right|^{2b}) \quad (24)$$



(a) Estimated positions (4 rules condition)



(b) Absolute error (4 rules condition)

Fig. 7 Experimental result using TSK neuro-fuzzy model

Table 2, Table 3, Fig. 7은 TSK 뉴로-퍼지 모델의 예측오차와 보정결과를 보여준다. 예측결과는 퍼지룰이 4개일 때 작은 오차를 보여주고 룰이 복잡해짐에 따라 Fig. 6과 같이 훈련데이터에 과하게 학습되어 새로운 입력 데이터에 대해 예측오차가 커지는 것을 알 수 있다. TSK 뉴로-퍼지 모델 출력을 참값과 비교해 보았을 때 비선형의 특성을 복수개의 소속함수와 선형다항식으로 표현이 가능함을 알 수 있다.

4.2 성능지수기반 계층형 다항정리 모델

성능지수기반 계층형 다항정리 접근법으로 선정된 최종모델은 식 (11)을 기반으로 식 (12), 식 (14)의 조건으로 선정되었다. 추정 모델은 영상 좌표 (C_x, C_y)를 입력, 전역 좌표 W_x, W_y 를 각각 출력으로 가지는 2입력, 1출력 다항식 구조를 가진다. Table 5, Table 6, Table 7, Fig. 10은 제안한 모델의 차수가 증가함에 따라 학습오차, RMSE, MAE, 그리고 PC 값의 변화를 나타냈으며 PC 값은 다항식 4차일 때 최소가 됨을 알 수 있다. 학습된 W_x, W_y 의 다항식은 식 (25)와 같다.

Table 4 Parameters of PC based hierarchical polynomial theorem model

W_x	Fitting method	
	nonlinear (trust-region)	robust (bisquare)
p_{00}	28.74	28.74
ω_{10}	-5.07	-5.09
ω_{11}	28.39	28.38
ω_{20}	0.04	0.05
ω_{21}	-0.95	-0.93
ω_{22}	1.73	1.72
ω_{30}	-0.10	-0.09
ω_{31}	-0.05	-0.06
ω_{32}	-0.23	-0.22
ω_{33}	0.04	0.05
ω_{43}	-0.45	-0.47

W_y	Fitting method	
	nonlinear (trust-region)	robust (bisquare)
p_{00}	28.73	28.72
ω_{10}	-5.05	-5.07
ω_{11}	28.44	28.42
ω_{20}	0.03	0.05
ω_{21}	-1.20	-1.20
ω_{22}	1.73	1.73
ω_{30}	-0.04	-0.05
ω_{31}	-0.01	-0.02
ω_{32}	-0.26	-0.25
ω_{33}	0.019	0.04
ω_{43}	-0.16	-0.17

Table 5 Estimated error of PC based hierarchical polynomial theorem model (trust-region method)

nonlinear (trust-region)	training (mRMSE)	mRMSE	mMAE	PC
1	1.198	1.199	0.913	1.056
2	0.260	0.270	0.207	0.238
3	0.203	0.225	0.179	0.202
4	0.197	0.224	0.180	0.202
5	0.187	0.253	0.199	0.226
6	0.130	0.295	0.211	0.253
7	0.075	0.694	0.385	0.540
8	0.075	0.694	0.385	0.540

$$W_x = p_{00} + \omega_{10}C_x + \omega_{11}C_y + \omega_{20}C_x^2 + \omega_{21}C_xC_y + \omega_{22}C_y^2 + \omega_{30}C_x^3 + \omega_{31}C_x^2C_y + \omega_{32}C_xC_y^2 + \omega_{33}C_y^3 + \omega_{43}C_xC_y^3 \quad (25)$$

$$W_y = p_{00} + \omega_{10}C_x + \omega_{11}C_y + \omega_{20}C_x^2 + \omega_{21}C_xC_y + \omega_{22}C_y^2 + \omega_{30}C_x^3 + \omega_{31}C_x^2C_y + \omega_{32}C_xC_y^2 + \omega_{33}C_y^3 + \omega_{43}C_xC_y^3$$

Table 6 Estimated error of PC based hierarchical polynomial theorem model (bisquare method)

robust (bisquare)	training (mRMSE)	mRMSE	mMAE	PC
1	1.203	1.204	0.908	1.056
2	0.269	0.281	0.213	0.247
3	0.203	0.225	0.179	0.202
4	0.198	0.224	0.180	0.202
5	0.187	0.254	0.199	0.227
6	0.131	0.296	0.212	0.254
7	0.075	0.690	0.383	0.537
8	0.075	0.690	0.384	0.537

Table 7 Absolute error of PC based hierarchical polynomial theorem model (trust-region method, Fig. 10 (b))

W_x		W_y	
mean	var.	mean	var.
0.197	0.020	0.163	0.015

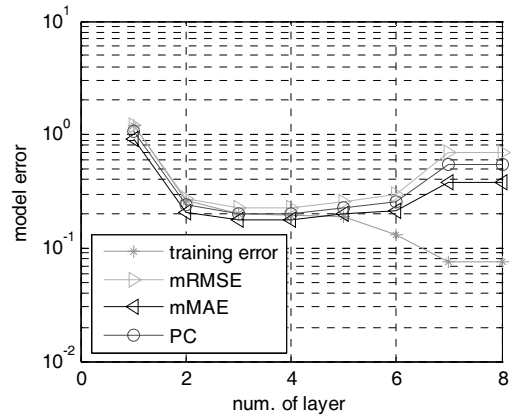


Fig. 8 Performance with increasing polynomial layer of nonlinear least squared fitting

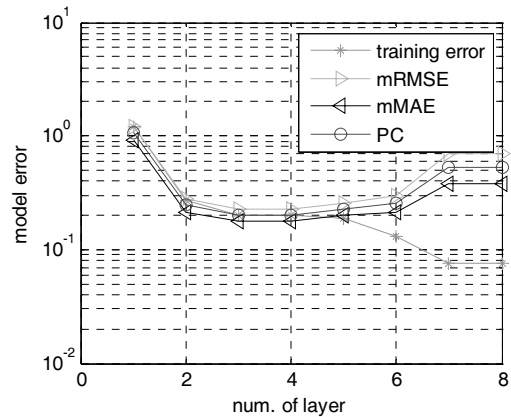


Fig. 9 Performance with increasing polynomial layer of robust least squared fitting

성능지수기반 계층형 다항정리 모델의 경우, 자기조직화 기능 때문에 다항식 구조가 고정되지 않고 주어진 데이터를 이용하여 결정되고, 결정된 다항식 구조에 최적인 파라미터 역시 데이터를 이용해서 추정하는 것이 특징이다. Table 4는 차수가 증가함에 따라 선택된 다항식 구조의 변수들이 어떻게 변하는지를 나타내었다. TSK 뉴로-퍼지 보정모델과 성능지수기반 다항식 보정모델을 비교했을 때 TSK 뉴로-퍼지 모델은 ‘테스트오차 - 학습오차’ 0.060, PC 0.206를 가지는 반면 성능지수기반 다항식 모델은 ‘테스트오차 - 학습오차’ 0.001, PC 0.202를 가진다. ‘테스트오차 - 학습오차’ 값, 교차검증방법이 적용된 PC 성능지수는 학습되지 않은 데이터에 대한 예측성능을 보여주기 때문에 제안한 모델은 과대적합문제를 해결함을 확인할 수 있다. 또한 최종 위치 보정 결과인 Fig. 7, Fig. 10을 비교했을 때 내재적 보정으로 사용된 TSK 뉴로-퍼지 모델과 계층형 다항정리 방법들은 성능이 우수함을 알 수 있다.

5. 결론

본 논문에서는 머신비전으로 획득한 왜곡영상을 보정하는 방식으로 왜곡현상이 가진 비선형성을 보다 잘 보정하기 위해서 성능지수기반 계층형 다항정리 모델을 제안한다. 제안한 모델은 내재적 보정방법인 TSK 뉴로-퍼지 모델과 비교하여 보정 결과가 유사하였고 교차검증방법이 적용된 성능지수 PC를 이용한 자기 조직적 동일화 과정으로 다항식 모델 구조와 계수를 최적화함으로써 향상된 예측 성능을 보여주었다. 제안한 모델을 화살 생산 공정에서 품질측정에 필요한 과녁의 탄착점을 자동으로 측정하는 영상장치에 적용하여 그 성능을 입증하였다.

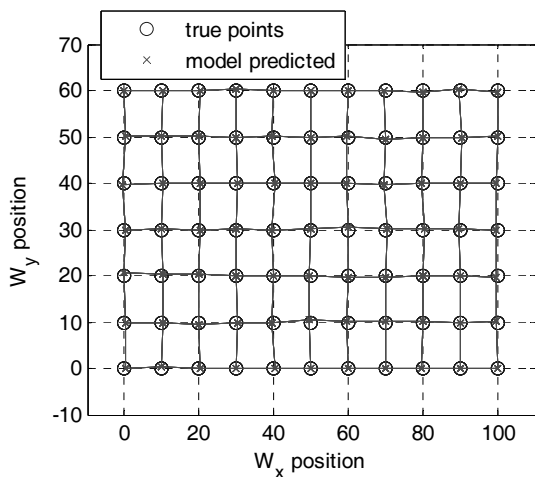
화살의 탄착점 데이터를 이용한 성능지수기반 다항식 모델은 분석 결과 Fig. 9에서 알 수 있듯이 4번째 층 이상의 다항정리 구조는 보정성능이 오히려 좋지 않음을 알 수 있었다. 또한, 과도학습에 따른 모델의 성능 저하를 방지하고 최적의 성능을 가진 모델을 선정하기 위해 교차검증방법이 적용된 RMSE, MAE를 이용한 성능지수 PC를 도입하였다. 제안한 방법은 왜곡영상과 물체의 비선형적인 입·출력 관계를 보정하는 효과가 뛰어나며, 모델의 구조를 고정시키는 것보다 측정환경에 맞추어 모델의 구조와 계수를 스스로 조정하는 바람직한 보정모델의 형태가 될 것으로 생각된다. 향후 과제로서 성능지수기반 다항정리 모델이 외란에 대해 더욱 강인한 성능을 갖도록, 더 많은 학습데이터와 외란 환경에서의 비정상적인 왜곡 현상까지 보정할 수 있는 추가적인 연구를 수행할 것이다.

후 기

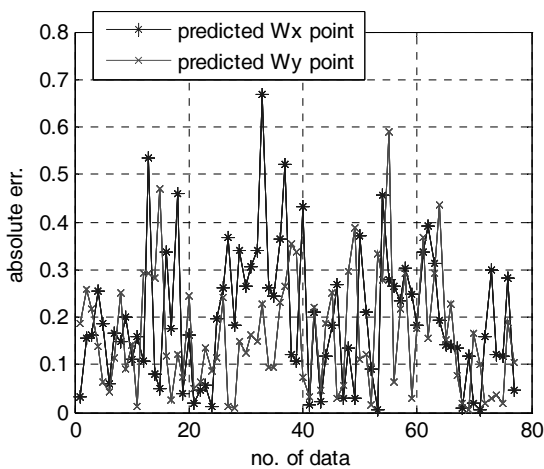
이 논문은 2010년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2010-0024110)

참 고 문 헌

- (1) Wang, J., Shi, F., Zhang, J., and Liu, Y., 2008, “A New Calibration Model of Camera Lens Distortion,” *Pattern Recognition*, Vol. 41, No. 2, pp. 607~615.
- (2) Shin, D. S., and Chung S. C., 2011, “2.5D Quick Turnaround Engraving System through Recognition of Boundary Curves in 2D Images,” *Korean Society of Manufacturing Technology Engineering*, Vol. 20, No. 4, pp. 369~375.
- (3) Jeong, K., and Ahn, K. U., 2010, “Inspection of the Knuckle Bracket Holes of a Shock-absorber using Image Processing Method,” *Korean Society of Manufacturing Technology Engineering*, Vol. 19, No. 6, pp. 768~775.



(a) Estimated positions (trust-region)



(b) Absolute error (trust-region)

Fig. 10 Experimental result of PC based hierarchical polynomial theorem model

- (4) Lee, J. H., 2010, "A Study on Interpolation Algorithm to Improve the Blurring of Magnified Image," *Korean Society of Manufacturing Technology Engineering*, Vol. 19, No. 4, pp. 562~569.
- (5) Roh, S. B., Oh, S. K., and Pedrycz, W., 2010, "A Fuzzy Ensemble of Parallel Polynomial Neural Networks with Information Granules Formed by Fuzzy Clustering," *Knowledge-Based Systems*, Vol. 23, No. 3, pp. 202~219.
- (6) Yu, W., 2004, "Image-based Lens Geometric Distortion Correction using Minimization of Average Bicoherence Index," *Pattern Recognition*, Vol. 37, No. 6, pp. 1175~1187.
- (7) Bai, Y., and Wang D., 2010, "On the Comparison of Trilinear, Cubic Spline, and Fuzzy Interpolation Methods in the High-accuracy Measurements," *IEEE Trans. on Fuzzy Systems*, Vol. 18, No. 5, pp. 1016~1022.