

저조도 개선 및 차량 후미등 검출을 이용한 야간 차량 인식 기법

박진우⁰, 송병철*

인하대학교 전자공학과

*bcsong@inha.ac.kr

요 약

야간 차량 인식은 빛이 적은 환경 때문에 인식에 필요한 정보가 부족하고 주간 차량 인식에 비해 인식 성능이 부족하다. 본 논문은 야간 차량 인식 성능을 높이기 위한 두 가지 기법을 이용한다. 먼저 야간 환경의 가장 부각되는 특징인 차량 후미등을 검출한다. 후미등의 적색 빛 특성을 이용하여 문턱치 처리를 통해 후미등 초기 검출한 후 상관성이 높은 두 후미등을 페어링하여 차량으로 인식하는 방법이다. 후미등 페어링만 적용하면 차량 검출율은 나쁘지 않지만 오검출이 많이 발생한다. 따라서 후미등 페어링을 통해 얻은 차량 후보에 대하여 저조도 개선 기법으로 야간 영상을 개선한 후 학습에 기반한 인식 기법을 적용한다. 야간 영상에 대하여 저조도 개선을 한 후 차량 인식 기법을 적용하면 저조도 개선 전보다 검출율이 상승한다. 실험 결과는 전처리 없이 차량을 검출한 결과보다 전처리를 한 후 차량을 검출한 결과가 성능이 더 좋았고, 후미등 검출 및 저조도 개선 두 기법을 적용한 차량 인식이 인식 측면에서 좋은 성능을 보였다.

1. 서론

최근 자동차는 단순한 운송수단을 벗어나 운전자의 안전과 편의를 위하여 다양한 전자 기술을 차량에 접목하고 있다. 특히 차량의 사고를 미연에 방지하기 위하여 차량 자동 항법 장치, 적응형 순항 제어 장치, 차선 유지 보조 시스템 등의 기능을 할 수 있는 운전 보조 장치(Advanced Driver Assistance System)의 발전을 가져왔다. 이러한 운전 보조 장치는 컴퓨터 비전 기반의 차량 인식을 통하여 연구가 활발히 진행되고 있다. 차량 인식 기법은 주간 영상에서는 각 기법의 성능 구현이 용이하고 활발히 개발되어 왔지만 야간 영상의 경우 저조도 환경에 의하여 차량을 인식하기 어렵기 때문에 차량 인식률을 높이기 쉽지 않다.

차량을 인식하기 위해 다양한 기법들이 있는데 대표적으로 야간 차량에서 후미등을 통한 검출 기법[1]과 물체 학습을 통한 차량 인식 기법[2,5]이 있다. 먼저 후미등 검출 기법의 경우 야간 환경에서 가장 쉽게 얻을 수 있는 차량 정보인 전방 차량의 후미등을 검출하는 기법으로 후방 후미등의 붉은 빛 특성과 양쪽 두 후미등이 유사한 특성을 이용한다. 기법 순서는 후미등의 붉은 빛을 직관적으로 검출할 수 있는 HSV 채널에서 문턱치 처리하여 후미등 후보군을 검출한 뒤 각 후미등 후보군마다 서로간 상관성이 일정 이상이 되면 두 후미등을 페어링한다. 이 방법은 조도가 매우 낮은 환경에서

성능을 얻을 수 있고 조도가 높은 경우에는 초기 문턱치 처리에서 후미등 이외의 아웃라이어들이 많이 생기기 때문에 오검출이 늘어난다. 다음으로 물체 인식 기법[2,5]을 차량에 적용하는 방법인데 다양한 주행환경에서 획득한 데이터 세트를 사용하여 차량을 학습한 뒤 인식하는 방식이다. 이 기법은 저조도 환경에서 물체의 특징이 뚜렷하게 나타나지 않기 때문에 정확한 학습이 이루어지지 않고 오검출이 발생한다.

본 논문에서는 야간 저조도 환경에서 차량 내부에 설치된 카메라에서 얻은 전방 영상을 바탕으로 전방 도로의 차량 인식을 위한 기법을 제안한다. 제안하는 기법은 학습 데이터를 저조도 개선 기법[3]으로 영상을 개선한 뒤 물체 인식 기법[5]을 통하여 학습하였고 테스트 입력 영상 또한 저조도 개선 기법[3]으로 전처리 한 뒤 더 정확한 검출 성능을 위하여 후미등 검출 기법[1]과 융합하는 방식을 취하였다.

2. 저조도 개선 및 후미등 검출을 이용한 야간 차량 인식 방법

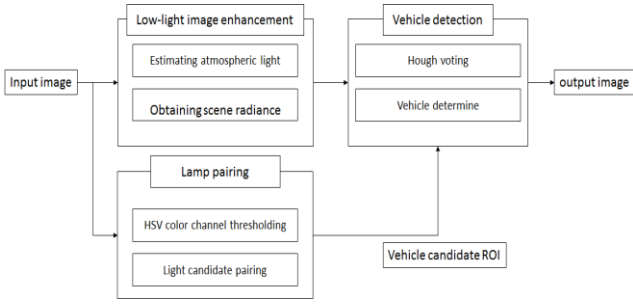


그림 1. 제안 기법의 블록도

전체 동작 기법은 그림 1 과 같다. 입력 영상에 후미등 검출 기법으로 차량 후보를 검출한다. 이와 병렬적으로 저조도 환경의 입력영상을 저조도 개선 기법으로 전 처리를 한 뒤, 차량 후보에 대하여 학습된 분류기로 차량 판별을 진행한다.

2.1 저조도 개선 전처리 방법

본 논문에서 사용할 저조도 개선 전처리 기법은 주로 안개제거 기법[4]에 사용되고 있는 Dark channel prior(이하 DCP)를 이용한 기법[3]이다. DCP 를 이용한 기법[3]은 저조도 영상을 반전시킨 경우 어두운 영역이 안개와 같이 대기 중의 빛으로 인하여 왜곡되는 특성을 이용한다. 식 (1)은 입력 영상의 반전 영상인 $I_{inv}(x)$ 가 반전된 영상의 실제 물체의 색인 $J_{inv}(x)$ 와 영상 전체 대기중의 빛(global atmospheric light)인 A 가 $t(x)$ 의 비율로 분포되어 있음을 의미한다.

$$I_{inv}(x) = J_{inv}(x)t(x) + A(1-t(x)) \quad (1)$$

$t(x)$ 는 식 (2)와 식 (3)으로 구할 수 있다. 식 (2)에서 ω 는 $t(x)$ 의 영향을 조절하는 상수이고 I_{dark}^c 는 반전 영상의 dark channel map(이하 DCM)을 의미한다. DCM 은 깨끗한 영상에서 일정 구간 내의 RGB 채널의 값 중 한 채널은 0 에 가까운 즉 어두운 값을 갖는 픽셀이 존재한다는 특성을 이용한다. 식 (3)에서 I_{inv}^c 는 RGB 채널 상에서 입력 영상의 반전 영상이며 A^c 는 각 채널의 대기중의 빛으로 본 논문에서는 반전 영상에서 처음 5 프레임의 각각 가장 밝은 화소값의 평균으로 정하였다.

$$t(x) = 1 - \omega I_{dark}(x) \quad (2)$$

$$I_{dark}^c(x) = \min_{c \in \{r, g, b\}} \left(\frac{I_{inv}^c(x)}{A^c} \right) \quad (3)$$

같은 물체의 화소값은 동등한 깊이 값을 가진다. 그러나 DCM 은 동등한 물체라도 화소마다 같은 값을 가지고 있지 않는 경우도 존재한다. DCM 을 그대로 식 (1)에 적용하여 영상을 개선하면 세부 디테일 정보는 사라진다. 이러한 문제를 해결하기 위

하여 식 (4)를 이용한다. $I_{smooth}(x)$ 는 $I_{dark}^c(x)$ 에 중간 값 필터를 적용한 영상이다. $I_{dark}(x)$ 를 얻은 뒤 식 (2)를 통하여 $t(x)$ 를 구하면 안개가 제거된 영상 $J_{inv}(x)$ 를 얻을 수 있다. 마지막으로 $J_{inv}(x)$ 를 반전시키면 저조도 개선 영상을 얻을 수 있다.

$$I_{dark}(x) = \begin{cases} \mu I_{dark}^c(x) & \text{if } \mu I_{dark}^c(x) < I_{smooth}(x) \\ I_{smooth}(x) & \text{others} \end{cases} \quad (4)$$

2.2 후미등 페어링 기법과 차량 검출 기법

후미등 검출 기법[1]의 경우 일반적으로 후미등 후보군을 찾기 위하여 어두운 영상에서 HSV 채널에서 문턱치 처리를 한다. RGB 채널이 아닌 HSV 채널에서 문턱치 처리를 하는 이유는 후미등의 붉은 빛을 좀 더 직관적으로 검출할 수 있기 때문이다. 다음으로 초기 검출지도에서 형태학적 필터를 이용하여 아웃라이어 제거한다. 그 후 같은 차량의 후미등 쌍을 찾기 위하여 각 후미등 후보를 찾고 식 (5)를 통하여 상관성이 일정 이상을 넘어가면 같은 차량의 후미등으로 간주하고 바운딩 박스를 얻는다. T 는 후미등 후보이며 B 는 T 와 비교할 다른 후미등 후보다. \bar{T}, \bar{B} 는 T, I 내부 화소값의 평균이고 바운딩 박스안의 화소 좌표이고 σ_T, σ_I 는 T, I 의 표준편차이다.

$$\gamma = \sum_x \frac{(T(x) - \bar{T})(B(x) - \bar{B})}{\sigma_T \sigma_I} \quad (5)$$

후미등 페어링 방식을 이용하여 차량 후보 바운딩 박스의 좌표를 알고 있으므로 차량 후보에 대해서만 학습에 기반한 물체 인식을 기법인 Hough Forest[5]방식을 이용한다. 차량 후보 관심영역에서 Hough voting 을 실시하여 차량이라고 인정된 누적 값이 일정 이상이 되면 차로 판별하여 최종 차량을 인식한다.

3. 실험 결과 및 분석

실험 영상은 1280 x 720 크기의 비디오 영상을 사용하고 HDR 기능이 적용된 카메라 센서를 사용하였다. 저조도 개선 기법에서 적용한 변수로 ω 는 0.6, 상관계수인 γ 의 문턱값은 0.7 로 적용하였다. 그림 2 는 저조도 개선 전처리 전, 후 차량 인식 기법 적용 결과 영상 및 후미등 페어링, 두 가지를 융합한 기법을 적용한 결과 영상을 나타낸다. 표 1 은 그림 2 의 검출율(detection rate) 및 오검출(false positive per image 이하 FPPI) 수치를 나타낸다.



그림 2. 차량 인식 결과, (a)저조도 개선 전 차량 인식 결과 (b) 저조도 개선 후 차량 인식 결과 (c) 후미등 검출 결과 (d) 후미등 검출 및 저조도 개선 후 차량 인식 결과

표 1. 실험 결과

	Detection rate (%)	FPPI (프레임 당 false positive 수)
Result without pre-processing	5	0.25
Result with pre-processing	29	0.19
Result with lamp pairing	72	0.81
Result with pre-processing and lamp pairing	40	0.38

표 1 을 보면 저조도 개선 전 차량 인식 기법을 적용한 영상은 저조도 개선 후 차량 인식 기법을 적용한 영상에 비하여 검출율이 낮게 측정되었다. 또한 후미등 페어링을 이용한 차량 인식 기법은 검출율은 높으나 오검출이 매우 많다. 후미등 검출 기법의 오검출을 줄이기 위하여 차량 후보군에 저조도 개선 후 차량 인식 기법을 적용하면 오검출이 현저히 감소한다.

4. 결론

본 논문에서는 야간 영상에서 전방 차량 인식을 하기 위하여 후미등 검출 기법으로 차량 후보를 찾은 뒤 야간 저조도 개선 후 차량 인식 기법을 적용하여 차량 인식 성능을 보였다. 야간 영상은 다양한 조도 환경을 가지고 있기 때문에 한가지 방법만으로는 검출 성능이 부족하다. 이후에는 두 가지 기법을 각각 최적화하여 검출율 향상시키고 FPPI 를 줄이도록 할 것이다.

감사의 글

본 연구는 산업통상자원부 산업핵심기술개발 사업의 연구비 지원으로 수행된 연구 결과임 (과제 번

호: 10052982).

참고문헌

- [1] R. O'Malley, E. Jones and M. Glavin, "Rear-lamp vehicle detection and tracking in low-exposure color video for night conditions," *IEEE Trans. Intelligent Transportation Systems*, vol 11, no. 2, pp. 453-462, June 2010.
- [2] P. Viola and M. Jones, "Rapid object detection using a boosted cascade of simple features," *IEEE Conf. Computer Vision and Pattern Recognition*, vol. 1, pp. 511-518, 2001.
- [3] X. Jiang, H. Yao, S. Zhang, X. Lu and W. Zeng, "Night video enhancement using improved dark channel prior," *IEEE Conf. Image Processing*, pp.553-557, Sept. 2013.
- [4] K. He, J. Sun and X. Tang, "Single image haze removal using dark channel prior," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 33, no. 12, Dec. 2011.
- [5] J. Gall, A. Yao, N. Razavi, L. Van Gool "Hough forest for object detection, tracking, and action recognition," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 33, no. 11, pp. 2188-2202, April 2011.

광 패턴인식을 통한 자동 수위 측정 알고리즘

김낙우^o, 이문섭, 민기현, 이병탁
한국전자통신연구원 관제디바이스연구실
{nwkim, mslee21, ghmin, bytelee}@etri.re.kr

요약

본 논문은 광패턴 조사(照射)용 광모듈을 설계·개발하고 패턴영역 처리를 통해 투사된 광패턴을 인식하여 하천 수위를 자동으로 측정하는 기법을 제안한다. 광조명계 및 제어보드 등을 포함한 광모듈을 통해 참조용 광패턴을 교각이나 제방 등에 조사(照射)하고, 조사된 광패턴 영상 처리 후 조사 대상물 위에 가상 수위표를 생성함으로써, 난시야(難視野) 환경 및 잡음 대응에 효과적이면서 포터블 형태로 주야간 이용이 가능하며, 별도 조명 설치를 요구하지 않는 강건한 자동 수위 측정 기법을 제공한다. 본 실험은 최대거리 30m, 최대높이 1.8m 환경에서 수위측정을 수행하였으며, 최대 측정 오차는 약 7cm 수준이다.

1. 서론

최근 집중호우 발생 빈도가 증가하고 있으며 이로 인해 대형하천뿐 아니라 중소하천에서도 홍수가 발생, 도심 침수 사례가 빈번히 제기되고 있다^[1]. 이에 대부분의 교각이나 제방에는 수위 측정을 위한 수위표가 부착되어 있거나, 혹은 압력식^[2], 부자식^[3], 초음파식^[4], 레이더식^[5,6] 등의 수위 측정 장비가 설비되어 있고, 이를 통해 획득한 수위 측정 정보는 침수 예측이나 재해 방지 활동 등에 이용된다.

최근에는 상기의 수위 측정 방식뿐 아니라, 카메라와 같은 영상 촬영 장치를 설치하여 동시 사용하는 영상기반 수위 측정 방식 이용이 늘고 있다. 교량에 부착된 마커 인식을 통해 상대적으로 수위를 계측하는 방법^[7], Mean-shift 알고리즘과 Watershed 기법을 통해 영상에서의 수면 경계를 구분한 후 수위를 검출하는 방법^[8], 영상에서의 수평 에지 분석을 통해 수면 인식 및 마커를 인식하고 이를 통해 수위를 측정하는 기법^[9] 등이 제안되고 있다. 이러한 영상기반 수위 측정 기법은 오염, 멸실, 훼손 등으로 인하여 정확한 수위표 인식이 어렵고, 영상 수면 경계 인식이 부정확하다는 문제점을 갖고 있다.

본 논문에서는 능동형 광패턴 조사를 통해 기존 수동형 영상기반 수위 측정 기법의 한계를 극복한 새로운 자동 수위 측정 기법을 제안하고 있다. 참조용 광패턴을 능동적으로 피측정 대상물(교각이나 제방 등)에 조사하고, 카메라 장치로 조사된 참조용 광패턴과 주변 제방 환경을 동시에 촬영하여, 입력된 영상을 처리·분석 후 자동 수위측정 및 대상물과의 거리 측정을 수행한다.

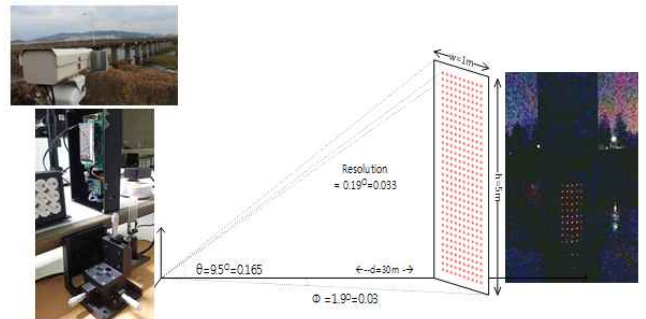


그림 1. 광모듈 기반 자동 수위 측정 시스템 개요

본 논문의 구성은 다음과 같다. 먼저 2장에서는 광패턴 조사 장치 및 자동 수위측정 기법에 대해 소개하고, 3장에서 시험 환경 및 실험 결과를 보인다. 최종적으로 4장에서 결론을 맺는다. 그림 1은 광모듈 기반 원격 수위 측정 시스템 구성 환경을 보이고 있다.

2. 광모듈 기반 자동 수위 측정 기법

2.1 광모듈 장치 설계 및 구현

광모듈 장치에서 광조명계의 레이저 다이오드(LD)는 최대출력 110mW, 파장 658nm 대역을 사용하는 모듈을 선택하였다. 최대출력은 야간에서 최대 30m 이상 동작가능한 수준이며, 가시광 대역은 설치구성 시에 편의를 제공한다. 시준기(Collimator)는 수치구경 0.4, 초점길이 3.13. 동작거리 2.4mm로 설계한다. 그림 2에서와 같이 설계데이터를 기준으로 광조명계의 레이저 스폿 크기는 30m 거리에서




그림 2. 광패턴 레이저 크기 시뮬레이션 결과




그림 3. 광패턴 조사용 광모듈 장치 (a) 광조명계 (b) 광패턴제어보드 (c) 광패턴 (d) 수위 조정계

약 3~4cm² 수준이다. MEMS 모듈의 경우 스캐닝 속도는 15Hz 이상이며, FOV는 가로 1.9°, 세로 9.5°로 설계하였다. 그림 3은 참조 광패턴 조사를 위한 광모듈 장치 및 수위 조정계를 나타낸다.

2.2 자동 수위 측정 기법

자동 수위 측정 기법은 그림 4와 같다. 먼저 이미지 센서로 피측정 대상물에 조사된 광패턴 영상을 프레임 단위로 실시간 입력받는다. 영상 처리 시간 및 오류 발생으로 인한 측정오차를 줄이기 위해, 입력 영상 중 광패턴 조사 영역만을 대상으로 ROI(Region of Interest) 설정을 설정하고, 모폴로지 연산을 수행하여 잡음을 제거 한 후 적응형 임계처리를 수행한다. 이 때, 단위 패턴 간 중첩이 발생하지 않도록 주의한다.

다음으로, 윤곽선 기반으로 단위패턴에 대한 레이블링을 수행한다. 오검출 영역에 강건한 신뢰성 있는 영역 레이블링을 위해, Border Following

Algorithm 적용 후, Iterative End-point Fit 기법을 수행하여 단위패턴과 동일 모양인 타원형 형상 영역만을 대상으로 처리한다.

이 후, 유사 Y 좌표를 갖는 레이블 영역끼리 군집화를 수행한 후 순서화한다. 유사 Y 좌표의 기준은 하나의 영상프레임에서 각 단위패턴 간의 평균 거리 d를 구하고, 임의의 단위패턴을 하나 선택한 후 해당 레이블의 중심좌표를 기준으로 상하로 d/2 내에 위치한 영역을 말하는 것으로, 이 영역 내의 모든 단위패턴을 동일한 군집으로 처리하여 재(再)레이블링한다. 재 레이블링된 단위패턴을 제외하 나머지 단위패턴 중 임의의 것을 선택하여 동일 과정을 반복함으로써 모든 단위패턴을 군집화한 후 순서화한다. 같은 방법으로 X 좌표 기준으로 동일 과정을 거친다. 다음으로 참조 광패턴 조사 과정이나 영상 획득 과정에서 오류로 인해 누락된 단위패턴 영역 오류에 대한 보간이 수행된다.

참조 광패턴의 유사 Y 좌표를 갖는 단위패턴의 총개수, 즉 X축 상의 단위패턴의 총개수(X_t)를 기준으로 현재 보간 수행된 레이블 영역에서의 X축 상의 ‘유효 레이블’ 개수, 즉 유사 Y좌표를 갖는 k 번째 군집에서의 ‘유효 레이블’ 개수 (pX_t^k) 와 비교하여 임계치(α)이상이면 Y축에 수직으로 해당 X축 기준의 가상선을 생성한다 (수식 1 참조). Y축에 수직인 모든 각 군집에 대해 반복 수행하며, 그림 5와 같이 가상 수위표를 완성한다.

$$Y^k = \begin{cases} 1 & \text{for } \alpha \geq \frac{pX_t^k}{X_t} \\ 0 & \text{for } \alpha < \frac{pX_t^k}{X_t} \end{cases}, \text{ where } 0 < \alpha < 1 \quad (1)$$

이 때, 참조 광패턴의 총 가로선 수를 M이라 할 때, 생성된 가상 가로선의 총합 N은

$$N = \sum_{k=1}^M Y^k \quad (2)$$

이고, 교각 상단에서 수위까지의 높이 H는

$$H = N * Td \quad (3)$$

이 되며, 최종 예측 수위 WL은 원교각 높이 P에서 H를 제하고서 구한다.

$$WL = P - H \quad (4)$$

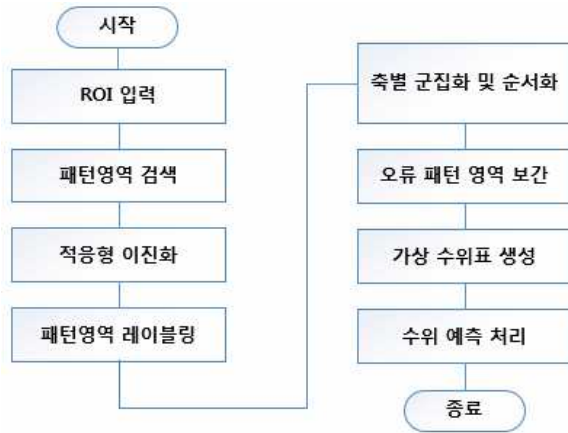


그림 4. 자동 수위 측정 기법 순서도

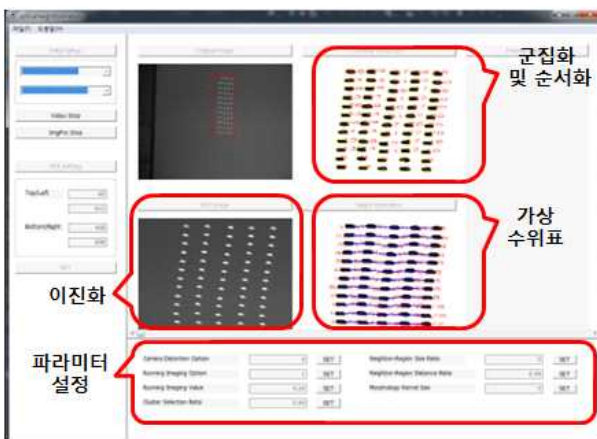



그림 5. 자동 수위 측정용 S/W 플랫폼

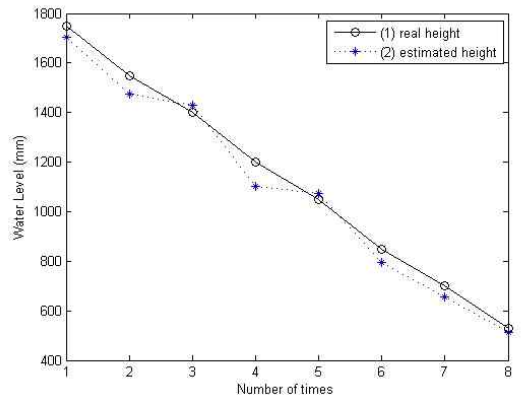
3. 실험 결과 및 분석

본 논문에서 제안하는 수위 측정 기법을 검증하기 위한 실험 환경은 다음과 같다. 실크 스크린 상에 既 생성된 패턴을 디스플레이하고, 3축 트랜스레이터를 통해 패턴 가림막을 설치한 후 높이를 조정하여 패턴 기반의 가상수위를 조정한다. 디스플레이 된 패턴에서 카메라까지의 최소거리는 5m, 최대거리는 30m이다. 본 논문에서 자동 수위 측정 실험은 단위 패턴들 사이에 수위가 위치하도록 조정하여 최대오차가 발생하도록 시험 진행하였다. 별도 제작된 임베디드 기반 프레임그래버의 최대 영상 처리 해상도가 HD급(720p) 이므로, 이를 기준으로 수위 측정 시뮬레이션을 수행하였다.

표 1에서 보이는 바와 같이 5m 에서 평균절대오차(MAE)는 약 12mm, 평균제곱오차(MSE)는 약 648 로써 비교적 정확한 수위 예측을 나타내고 있다. 30m 시험 환경에서 평균절대오차(MAE)는 약 63mm, 평균제곱오차(MSE)는 약 5,090으로써 적은



(a)



(b)

그림 6. 자동 수위 측정 실험 결과 (a) 5m (b) 30m
표 1. 자동 수위 측정 오차

Classification		5m	30m
Env.	Resolution	1280 x 720	1280 x 720
	Test height	~1.4m	~1.8m
MAE(mm)		11.9	62.7
MSE		648	5.09E+3

오차 범위에서 정확한 수위를 예측하고 있다. 단위 패턴 간의 중심 거리가 수위 측정 결과의 해상력을 결정하기 때문에, 실험에 사용한 단위패턴 간 거리가 최대 오차거리가 될 수 있다. 그림 6은 각 실험 차수당 수위를 변경하였을 때, 자동적인 수위 측정 실험 결과를 보이고 있다.

4. 결론

본 논문에서는 카메라 장치와 함께 광조사 장치를 설치하여 참조 광패턴을 교각이나 보로 직접 조사하는 방법을 이용함으로써, 기존 영상식 수위 측정 방식의 수위표 오염, 손상, 멸실 등을 문제에서 벗어날 뿐 아니라, 능동형 광조사를 통한 패턴의 사용으로 난시야(亂視野)환경 (열은 연기나 안개가

긴 환경, 야간 환경)에서의 가시거리 제한 상황에서도 보다 정확한 수위 및 피측정 대상과의 거리 계산이 가능하도록 하였다. 시뮬레이션 결과는 측정 거리 5m에서, 1.4m 높이의 수위측정 시 오차는 약 1cm 수준이며, 30m에서 1.8m 높이 수위측정 시 오차는 약 7cm로 양호한 측정 성능을 보이고 있다.

Acknowledgement

본 연구는 정부출연금사업인 ETRI R&D사업(과제명:지역 광부품 고도화를 위한 광융합 기술 개발,16ZI2200)의 일환으로 수행하였음

참고문헌

- [1] Y.S. Kim, J.H. Seong, and J.H. Lee, "Analysis of the Recent Flood Characteristics in Korea," Magazine of Korea water resources association, Vol. 47, no. 5, pp. 35-40, 2014.
- [2] C.W. Park and H.S. Park, "A water level measurement system using pressure sensor," Proceedings of the KIEE Conference, pp. 2708-2710, 2005.
- [3] B.Y. Lee, J.C. Park, S.W. Jang, and J.S. Han, "Observation characteristic of float-well type water-level recorder," Proceedings of the Korean Environmental Sciences Society Conference, pp. 209-210, 2006.
- [4] J.H. Eom, "Characteristic consideration of ultrasonic wave based level sensor for non-contacting type water-level recorder," Environmental engineer, Vol. 162, pp. 30-36, 2000.
- [5] D. Brumbi, "Low power FMCW radar system for gaging," IEEE MTT-S international microwave symposium digest, Vol. 3, pp. 11-16, 2000.
- [6] K.U. Shin and S.T. Hong, "Best Measurement Capability and Standard Test Facility for the Water-level Gauges, Journal of Control," Automation and Systems Engineering, Vol. 13, no. 10, pp. 1012-1017, 2007.
- [7] J.S. Shin and D.S. Kang, "A Study on Measure Method of Water Level Using Marker Recognition and Rotation Algorithm," Journal of KIIT, Vol. 11, no. 5, pp. 167-173, 2013.
- [8] U. Hwang, J.S. Yoo, and J.C. Jeong, "Computer Vision based Water-level Detection," Proceedings of the Korean Society of Broadcast Engineers Conference, pp. 303-306. 2013.
- [9] J. Yu and H. Hahn, "Remote detection and monitoring of a water level using narrow band channel," Journal of information science and engineering, Vol. 26, pp. 71-82, 2010.

분산 안정화 변환을 이용한

회전 변조 시준기(RMC) 영상화 알고리즘 시뮬레이션

*신영준⁽¹⁾, 김기현⁽²⁾, 이계민⁽¹⁾

⁽¹⁾서울과학기술대학교 NID융합기술대학원 방송통신프로그램

⁽²⁾세종대학교 원자력공학과

e-mail : 158321101@seoultech.ac.kr, gkim01@sejong.ac.kr, gyemin@seoultech.ac.kr

요약

Rotating Modulation Collimator(RMC) is a useful technique for detecting remote radiation sources. To visualize the location of the detected sources, we previously proposed an image reconstruction algorithm. However, the algorithm produces undesirable artifacts for weak source activities due to data-dependence of the Poisson noise variance. In this paper, we propose an improved the algorithm using variance-stabilization transformation. Our experiments on simulated data show reduced artifacts in the reconstruction images for weak radiation sources.

keyword: RMC, image reconstruction, MLEM, variance stabilization transformation

1. 서론

방사선의 계측을 통한 방사능의 탐지는 핵안보 검증 및 핵 활동 가능성 탐지에 있어서 중요한 기초 기술의 하나로 활용되고 있으며, 최근 영상 기술과 접목하여 방사능의 분포를 영상화하는 기술들이 개발되어 방사선 및 원자력 안전 분야의 핵심기술로 각광을 받고 있다. 방사선 영상을 획득하는 방법론 중의 하나로, 회전 변조 집속기(RMC)를 통과하여 계측된 방사선의 변조 패턴(Modulation Profile)을 이용한 영상화 기법이 있으며, 이는 그림 1에서 나타낸 바와 같이 검출기에 두 개의 마스크들을 부착하여 구성한다. 이 마스크들은 그림 2와 같이 함께 회전하여 선원에서 방사된 방사선을 막거나 통과시킨다[1]. 회전각도에 따라 통과된 방사선의 일부를 계측하여 변조 패턴이 생성되고, 그것을 영상화 알고리즘을 통해 방사선원의 위치를 시각화할 수 있다.

우리는 이전 연구를 통해 RMC에서 획득한 변조 패턴을 이용하여 시각화하는 영상화 알고리즘을 제안하였다[2]. 이 알고리즘은 선원의 방사능이 강할 경우 검출 입자 수가 많아 좋은 성능으로 영상화하지만, 선원이 약해 검출되는 입자의

수가 적은 경우 아티팩트를 만들어 실제 선원이 없는 위치에서도 선원이 있는 것처럼 예측하는 문제가 있다.

본 논문에서는 RMC에서 획득한 변조 패턴에 분산 안정화 변환을 적용하여 입자 수가 적게 계측되어도, 안정적으로 영상을 시각화 할 수 있는 알고리즘을 제안한다. 그리고 변조 패턴에 대한 시뮬레이션을 통해 기존 알고리즘 대비, 본 논문에서 제시한 알고리즘의 성능을 비교한다.




그림 1. RMC의 구조와 동작원리 [2].




그림 2. 회전에 따른 마스크 열린 공간의 변화.

2. 기존 RMC 영상화 알고리즘

기존 영상화 알고리즘을 유도하기 위해 우선 RMC 시스템 모델을 기술한다[2].

2-1. RMC 시스템 모델

계측기에서 검출하는 입자의 수는 푸아송(Poisson) 분포를 따르며[3], 이는 선원의 위치와 방사능, 디텍터의 효율, 마스크 회전 각도의 함수로 나타낼 수 있다.

$$y_i \sim \text{Poisson}(\tau_i[\alpha \cdot \epsilon(E) \cdot \frac{\Omega(\rho, \phi, z)}{4\pi} \cdot$$

$$[P_i(\rho, \phi, z) + P_i(\rho, \phi, z)^c \cdot \lambda(E)] + b(E)] \quad (1)$$

여기서 τ_i 는 일정 각도에서 RMC가 머문 시간(dwelling time)을 나타내며 α 는 선원의 방사능(Bq), $\epsilon(E)$ 은 에너지에 따른 계측기의 검출 효율이다.

입체각 $\frac{\Omega(\rho, \phi, z)}{4\pi}$ 는 등방성 선원에서 방출된 방사선이 앞 마스크의 정면을 향해 입사할 확률이다. 입사한 방사선이 두 개 마스크들의 슬릿을 통과할 확률은 $P_i(\rho, \phi, z)$ 이며 통과하지 못하더라도 물질과 에너지에 따라 투과하는 비율은 $\lambda(E)$ 로 나타내며, $b(E)$ 는 백그라운드 입자 수이다.

2-2 기존 RMC 영상화 알고리즘

우리는 이전 연구에서 RMC 데이터를 영상화하는 알고리즘을 유도하였다[2]. 우선 대상 공간을 픽셀화하고, 픽셀 j 에서의 선원의 방사능을 λ_j 로 나타낸다. 이 픽셀에서 방출된 방사선이 마스크 회전 각도 i 에서 검출될 확률을 p_{ij} 라 하면, 각도 i 에서의 측정값 y_i 는 기댓값이

$$\bar{y}_i(\lambda) = \sum_j \lambda_j p_{ij}$$

인 푸아송 분포를 따른다.

이 때, 로그 가능도(likelihood) 함수는 다음과 같이 쓸 수 있다.

$$l_p(\lambda) = \sum_{i=1}^I [y_i \log(\bar{y}_i(\lambda)) - \bar{y}_i(\lambda) - \log(y_i!)]$$

이 식의 1차 편미분으로부터

$$0 = \lambda_j \frac{\partial l(\lambda)}{\partial \lambda_j} \Big|_{\hat{\lambda}} = -\hat{\lambda}_j \sum_i p_{ij} + \sum_i \frac{y_i \hat{\lambda}_j p_{ij}}{\sum_k \hat{\lambda}_k p_{ik}}$$

반복 계산 알고리즘을 얻을 수 있다. 따라서 (n+1)번 째 반복횟수에서 픽셀 j 에서의 선원의 방사능 λ_j^{n+1} 는

$$\lambda_j^{n+1} = \frac{\lambda_j^n}{\sum_i p_{ij}} \sum_i p_{ij} \left(\frac{y_i}{\sum_k \lambda_k^n p_{ik} + b_i} \right)$$

를 통해 반복적으로 갱신하여 찾을 수 있다.

3. 분산 안정화 변환을 이용한 개선된 RMC 영상화 알고리즘

앞에서 도출한 RMC 영상화 알고리즘은 선원의 방사능이 약할 경우 소스의 위치를 정확히 찾지 못하는 문제가 발생한다. 이를 해결하기 위해 본 논문에서는 푸아송 분포의 분산 안정화 변환을 이용하여 개선된 영상화 알고리즘을 도출한다.

3-1 분산 안정화 변환

평균이 λ 인 푸아송 분포의 확률 질량 함수와 분산은

$$\Pr(X=k) = \frac{\lambda^k e^{-\lambda}}{k!},$$

$$\lambda = E(X) = \text{Var}(X)$$

이다. 이 때 푸아송 잡음은 $\eta = X - \lambda$ 로 쓸 수 있으며, $E(\eta) = 0, \text{Var}(\eta) = \lambda$ 로 λ 가 커짐에 따라 잡음의 분산도 증가하게 된다. 이러한 λ 와 분산과의 관계를 제거하기 위해 분산 안정화 변환을 이용한다. 이 변환은 푸아송 분포를 분산이 1인 정규분포로 변환시켜 데이터와 분산 간의 종속 관계를 제거할 수 있다[4].

본 논문에서는 푸아송 분포의 분산을 안정화하는 여러 대표적인 변환[4,5,6,7] 중 Bartlett 변환

$$\text{Bartlett}(x) = 2\sqrt{x}$$

을 이용한다[4]. 이를 통해 평균과 분산이 λ 인 푸아송 데이터는 변환 후 대략적으로 평균이 $2\sqrt{\lambda} - \frac{1}{4\sqrt{\lambda}}$, 분산이 1인 정규분포 데이터가 된다 [4].

3-2 변환된 변조 패턴 영상화 알고리즘

분산 안정화 변환으로 변환 된 데이터로 이미지

영상화를 하기 위해 MLEM 알고리즘을 유도한다.
Bartlett 변환을 통해 변환 된 측정 값은

$$\text{Bartlett}(y_i) = z_i \sim N(t(\bar{y}_i), 1)$$

$$t(\bar{y}_i) = 2\sqrt{\bar{y}_i} - \frac{1}{4\sqrt{\bar{y}_i}}$$

에 근사한다[7]. 이 때, λ 의 로그-가능도함수는

$$l_g(\lambda) = -\prod_{i=1}^I (z_i - t(\bar{y}_i))^2 + \text{Constant}$$

이며 이것의 1차 편미분

$$\frac{\partial l_g(\lambda)}{\partial \lambda_j} = \sum_i (z_i - t(\bar{y}_i)) t'(\bar{y}_i) p_{ij}$$

이 0이 되는 $\hat{\lambda}$ 으로 MLE를 찾을 수 있다. 여기서 t' 은 t 의 도함수를 나타낸다. 수식을 다시 쓰면

$$0 = \lambda_j \frac{\partial l_g(\lambda)}{\partial \lambda_j} \Big|_{\hat{\lambda}} = \hat{\lambda} \sum_i (z_i - t(\bar{y}_i)) t'(\bar{y}_i) p_{ij}$$

이 되며 이를 정리하면 다음과 같은 반복 계산 알고리즘을 얻을 수 있다.

$$\bar{y}_i^{n+1} = \sum_j p_{ij} \lambda_j^n$$

$$\lambda_j^{n+1} = \lambda_j^n \frac{\sum_i z_i t'(\bar{y}_i^{n+1}) p_{ij}}{\sum_k t(\bar{y}_k^{n+1}) t'(\bar{y}_k^{n+1}) p_{kj}}$$

4. 실험 및 결과

이 장에서는 RMC 시스템 모델로부터 변조 패턴 데이터를 생성하고 이를 푸아송 분포로 유도한 영상화 알고리즘(2장)과 분산 안정화 변환을 이용한 개선된 영상화 알고리즘(3장)에 적용하여 비교한다.

이 때, 마스크 물질은 납으로 가정하고 지름은 6cm 두께는 1.27cm로 설정한다. 각 마스크에는 6개의 슬릿이 있으며 너비(w)는 4mm, 피치(p)는 8mm, 각 슬릿의 길이(h_k)는 지름 5cm원에 맞도록 정한다(그림 3). 0.356MeV의 감마선을 방출하는 Ba-133 점선원을 (25cm, 25cm, 500cm) 위치에 두고 실험을 진행한다.

4-1. 강한 선원(1.7mCi)

수식(1)의 확률 모델에 따라 디텍터가 검출하게 될 입자의 수를 확률적으로 생성한다. 선원의 방사능이 1.7mCi일 때, 생성된 데이터는 그림 4a와




그림 3. 앞면 마스크의 구조. 뒷면 마스크는 앞면 마스크와 동일하다.

같으며 그 데이터를 분산 안정화 변환을 통해 변환한 결과는 그림 4b이다. 그림 4a에서 보듯이, 2장의 시스템 모델로 만든 변조 패턴 데이터는 기댓값이 50개 정도로 클 때가 5개 정도로 작을 때에 비해 기댓값과 더 많은 차이가 나는 것을 볼 수 있다. 이러한 데이터와 분산 간의 종속 관계를 제거하기 위해 Bartlett 변환을 적용한 결과는 그림 4b와 같다. 변환 전과 비교해보면 변조패턴 측정 데이터와 기댓값의 차이가 값의 크기에 관계없이 일정해 진 것을 볼 수 있다.

생성한 변조 패턴 데이터와 변환된 값들을 이용하여 2장과 3장의 알고리즘들을 통해 각각 영상화 한 이미지들은 그림 4c와 4d에 비교하였다. 이 때 사각형들은 예측한 선원의 위치, 원은 실제 선원의 위치를 나타낸다.

영상화 결과를 보면, 실제 선원의 위치(25cm, 25cm)뿐 아니라 원점에 대해 대칭인 위치(-25cm, -25cm)에도 선원이 있는 것으로 예측이 되는데 이는 그림 2에서 볼 수 있듯이 마스크가 180° 회전하면 동일해지는 구조적 한계 때문이다. 선원의 방사능 세기가 클 경우 예상 검출 입자 수 역시 많아져 두 결과에서 실제 선원의 위치를 정확히 예측한 것을 확인할 수 있다.

두 영상화 알고리즘을 비교하기 위해 RMC 데이터 생성과 영상화하는 실험을 1000번 반복한다. 그 후 실험 결과를 정량적으로 비교하기 위해 신호 대 잡음비(SNR)와

$$SNR = 10 \log_{10} \left(\frac{\sum_j (\hat{\lambda}_j)^2}{\sum_j (\hat{\lambda}_j - \lambda_j)^2 / N} \right)$$

최대신호 대 잡음비(PSNR)을 측정한다.

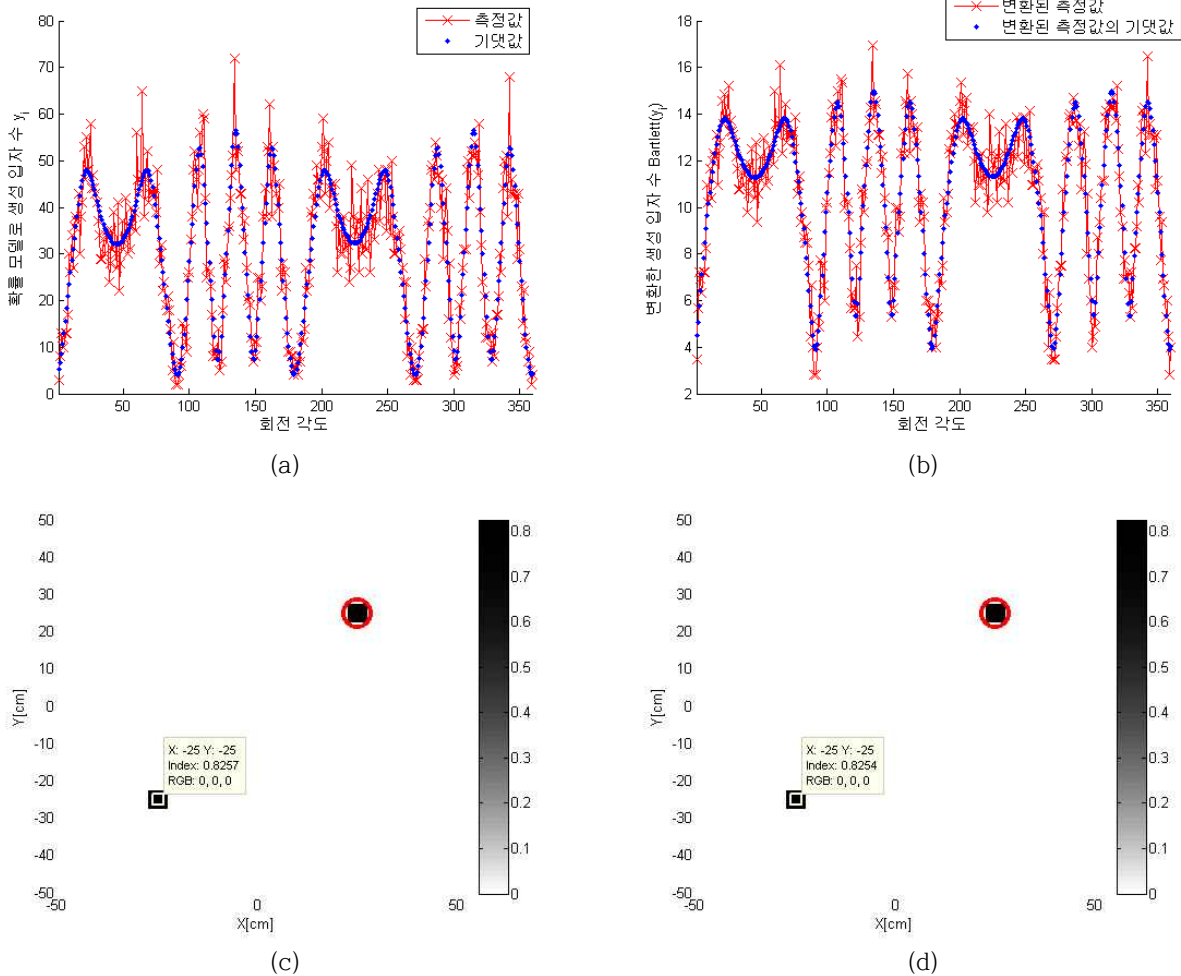


그림 4. 방사선원의 세기가 1.7mCi일 때 (a) 확률 모델로 생성한 RMC 변조 패턴 (b) 분산 안정화 변환한 RMC 변조 패턴 (c) 기존 영상화 알고리즘으로 영상화한 결과 (d) 분산 안정화 변환 후 영상화한 결과.

$$PSNR = 10 \log_{10} \left(\frac{\max_j (\lambda_j)^2}{\sum_j (\hat{\lambda}_j - \lambda_j)^2 / N} \right)$$

여기서 N은 픽셀의 수를 나타낸다.

변환 전의 SNR은 54.04 ± 0.14 (dB), PSNR은 51.35 ± 0.14 (dB)이며, 변환 후의 SNR과 PSNR은 각각 54.23 ± 0.15 (dB), 51.53 ± 0.14 (dB)로 큰 차이가 없는 것을 확인할 수 있다.

4-2. 약한 선원(0.2mCi)

이번에는 방사선원의 방사능을 0.2mCi로 바꾸어 앞의 실험보다 약한 선원인 경우를 비교한다. 생성된 RMC 변조 패턴은 그림 5a에 나타내었다. 약한 선원의 경우 이전 강한 선원일 때의 실험 결과(그림 4a)와 다르게 검출기에서 검출되는 입자의 수가 매 각도 당 5개 내외 정도로 확연히 줄어든 것을 볼 수 있다. 이 데이터를 이용하여 영상화를 할 경우 그림 5c와 같이 선원의 원위치가

아닌 위치에도 약한 선원이 있는 것으로 예측이 된다. 이러한 아티팩트는 각 회전 각도에서의 측정값들이 다른 정도의 잡음 레벨을 갖기 때문인 것으로 추정되며, 약한 소스의 경우 그 차이가 결과 이미지의 아티팩트로 나타나는 것으로 보인다(아티팩트는 본 논문의 전자문서 버전에서 시각적으로 더욱 정확하게 확인할 수 있다). 하지만 분산 안정화 변환 후의 데이터(그림 5b)의 경우 변환된 측정값과 그 기댓값의 차이가 고르게 분포함을 볼 수 있으며, 이를 이용하여 영상화할 경우 그림 5d와 같이 아티팩트가 육안으로도 현저히 줄어 든 것을 볼 수 있다.

이전 실험과 마찬가지로 변조 패턴 데이터를 랜덤하게 생성하고 영상화하는 실험을 1000번 반복하여 두 영상화 알고리즘의 SNR과 PSNR을 비교하였다. 기존 영상화 알고리즘을 이용했을 때 SNR과 PSNR은 각각 44.00 ± 0.15 (dB)와 41.88 ± 0.14 (dB)이었으며, 개선된 영상화

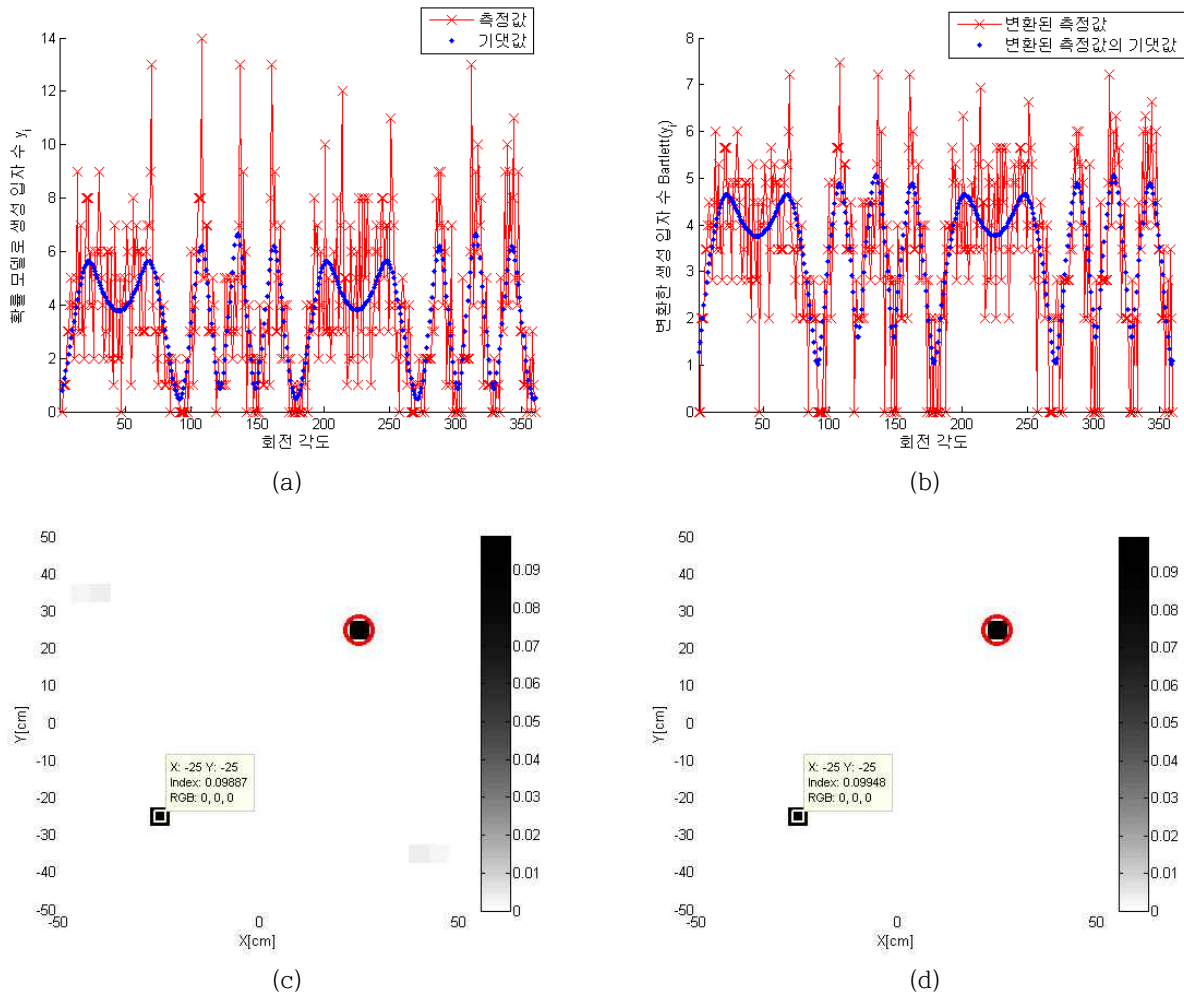


그림 5. 방사선원의 세기가 0.2mCi일 때 (a) 확률 모델로 생성한 RMC 변조 패턴 (b) 분산 안정화 변환한 RMC 변조 패턴 (c) 기존 영상화 알고리즘으로 영상화한 결과 (d) 분산 안정화 변환 후 영상화한 결과.

알고리즘의 SNR과 PSNR은 각각 46.67 ± 0.19 (dB)와 44.29 ± 0.18 (dB)이 되어 성능이 향상됨을 확인할 수 있다.

5. 결론

본 논문에서는 RMC 변조 패턴을 분산 안정화 변환을 통해 변형한 변조 패턴으로부터 방사선원의 위치를 시각화하여 보여주는 개선된 영상화 알고리즘을 도출하였다. 확률 모델로 생성한 RMC 데이터를 이용하여 제안한 알고리즘과 기존의 영상화 알고리즘을 비교한 결과, 강한 방사능 선원의 경우 큰 차이가 없었지만 방사능이 약한 선원의 경우 복원된 이미지에서 아티팩트가 감소하였고 SNR과 PSNR을 통해 정량적으로 성능이 향상됨을 검증하였다.

감사의 글

본 논문은 한국 연구 재단(NRF-2014R1A1A1003458)과 한국 방사선 안전재단(1403024)의 지원을 받아 수행되었음.

참고문헌

[1] B. R Kowash, "A Rotating Modulation Imager for Orphan Source Search Problem", Ph.D. Dissertation, University of Michigan, September, 2008.
 [2] 신영준, 김기현, 이계민, "회전 변조 시준기 (RMC) 데이터와 영상화 알고리즘 시뮬레이션", 2015년 대한전자공학회 추계학술 대회 논문집, pp 516-519, 2015.
 [3] F. Knoll, "Radiation Detection and Measurement", Wiley, August, 2010.

- [4] M. S. Bartlett, "The use of transformations. Biometrics", vol. 3 pp. 39-51, 1947.
- [5] F. J. Anscombe, "The transformation of Poisson, binomial and negative-binomial data", Biometrika, vol. 35, no. 3-4, pp. 246-254, 1948.
- [6] M. F. Freeman and J. W. Tukey, "Transformations related to the angular and the square root", The Annals of Mathematical Statistics, vol. 21, no. 4, pp. 607-611, 1950.
- [7] M. Mäkitalo, A. Foi, "Optimal inversion of the Anscombe transformation in low-count Poisson image denoising", IEEE Transactions on Image Processing, vol. 22, no. 1, pp. 99-109, 2011.

Joint Fine-Tuning in Deep Neural Networks for Facial Expression Recognition

정희철, 이시행, 김준모
한국과학기술원
{heechul, haeng, junmo.kim}@kaist.ac.kr

요 약

시간 정보는 얼굴 표정을 인식하는데 유용한 정보를 지니고 있다. 하지만 hand-crafted feature와 같이 수동으로 유용한 특징을 추출하여 좋은 성능을 거두기까지 많은 노력이 요구된다. 본 논문에서는, 이러한 노력을 줄이기 위해 데이터에서 자동으로 유용한 특징을 추출할 수 있게 딥러닝 (deep learning) 기법을 이용하여 표정인식을 하고자 한다. 본 논문에서 제안한 기법은 두 개의 서로 다른 deep neural network (DNN) 모델에 기초한다. 하나는 시간에 따른 얼굴 landmark를 입력으로 받는 네트워크이며, 다른 하나는 얼굴 외관 (appearance)의 특징을 추출하기 위한 네트워크이다. 이러한 두 개의 모델은 표정 인식의 성능을 향상시키기 위해 joint fine-tuning 기법을 이용하여 결합되어진다. 그 결과, 우리는 CK+와 Oulu-CASIA 데이터베이스에서 다른 최첨단 기법에 비해 우수한 성능을 달성하였다.

1. 서론

딥러닝 기법은 다양한 영상인식 문제에서 월등한 성능을 기록하였으나, CK+와 같은 작은 데이터셋을 이용하는 표정 인식 문제에서는 좋은 성능을 기록하지 못하였다. 이러한 문제점을 해결하기 위해 본 논문에서는 appearance와 geometry 두 가지 유용한 정보를 이용하여 표정인식을 수행한다. 또한 joint fine-tuning 기법을 이용하여 두 종류의 네트워크가 적은 데이터 셋에도 불구하고 잘 학습되도록 한다.

2. 제안 기법 및 결과

제안 기법은 아래 그림과 같다. 두 개의 네트워크는 표정인식 학습데이터를 이용하여 각각 학습을 시키며, 학습된 네트워크는 통합에 사용되어진다. 두 네트워크에 통합을 할 때 총 세 개의 loss function을 이용하여 학습하며, 각 네트워크의 최상위 layer의 weight만 fine-tuning 하게 된다.

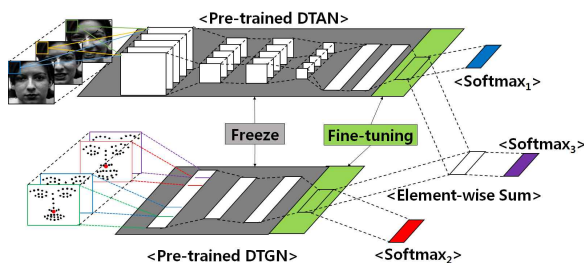


그림 1. 제안 기법

제안 기법을 검증하기 위해 CK+, Oulu-CASIA, MMI dataset을 이용하여 성능을 평가하였으며, 최신의 표정인식 기법들과 성능을 비교하였다.

표 1. 알고리즘 성능 평가

	CK+	Oulu-CASIA	MMI
STM-ExpLet[4]	94.19	74.59	75.12
3DCNN-DAP[5]	85.9	-	63.4
3D SIFT[6]	-	55.83	64.39
제안기법	97.25	81.46	70.24

CK+와 Oulu-CASIA의 경우 최고기록을 달성하였으며, MMI의 경우에도 어느정도 뛰어난 성능을 달성하였다.

3. 결론

본 논문에서는 DNN 기반의 joint fine-tuning 기법을 제안하였으며, 실험을 통하여 성능의 우수성을 입증하였다. 또한 제안한 joint fine-tuning 기법은 표정인식 뿐만 아니라 다양한 분야에서 활용되는 딥러닝 모델 융합에도 사용할 수 있을 것으로 기대한다.

참고문헌

[1] M. Valstar and M. Pantic. Induced disgust, happiness and surprise: an addition to the mmi facial expression database. In Proc. Intl Conf. Language Resources and Evaluation, Workshop on

EMOTION, pages 65 - 70, 2010.

- [2] P. Lucey, J. F. Cohn, T. Kanade, J. Saragih, Z. Ambadar, and I. Matthews. The extended cohn-kanade dataset (ck+): A complete dataset for action unit and emotion-specified expression. In CVPRW, 2010 IEEE Computer Society Conference on, pages 94 - 101. IEEE, 2010.
- [3] G. Zhao, X. Huang, M. Taini, S. Z. Li, and M. Pietikainen. Facial expression recognition from near-infrared videos. *Image and Vision Computing*.
- [4] M. Liu, S. Shan, R. Wang, and X. Chen. Learning expressionlets on spatio-temporal manifold for dynamic facial expression recognition. In CVPR, 2014 IEEE Conference on, pages 1749 - 1756. IEEE, 2014.
- [5] M. Liu, S. Li, S. Shan, R. Wang, and X. Chen. Deeply learning deformable facial action parts model for dynamic expression analysis. In ACCV, 2014, pages 1749 - 1756. IEEE, 2014.
- [6] P. Scovanner, S. Ali, and M. Shah. A 3-dimensional sift descriptor and its application to action recognition. In Proceedings of the 15th international conference on Multimedia, pages 357 - 360. ACM, 2007.