

Scene-based Nonuniformity Correction by Deep Neural Network with Image Roughness-like and Spatial Noise Cost Functions

Yong-hee Hong*, Nam-Hun Song*, Dae-Hyeon Kim*, Chan-Won Jun**, Ho-Jin Jhee*

Abstract

In this paper, a new Scene-based Nonuniformity Correction (SBNUC) method is proposed by applying Image Roughness-like and Spatial Noise cost functions on deep neural network structure. The classic approaches for nonuniformity correction require generally plenty of sequential image data sets to acquire accurate image correction offset coefficients. The proposed method, however, is able to estimate offset from only a couple of images powered by the characteristic of deep neural network scheme. The real world SWIR image set is applied to verify the performance of proposed method and the result shows that image quality improvement of PSNR 70.3dB (maximum) is achieved. This is about 8.0dB more than the improved IRLMS algorithm which preliminarily requires precise image registration process on consecutive image frames.

▶ Keyword: Deep Neural Network, Image Roughness-like, SN, SBNUC, Improved IRLMS

1. Introduction

현재 의료, 군사, 과학 등 여러 분야에 적용되고 있는 적외선 센서는 종래의 1D 센서에서 발전을 거쳐 초점평면배열(Focal Plane Array, FPA) 2D 센서를 이용하여 물체의 적외선 방사에너지를 감지한다[1]. 적외선 센서 FPA는 제조 과정에서 발생하는 불균일성으로 인해 각 소자마다 다른 gain 및 offset을 보유하게 되며, 이로 인해 고정패턴잡음(Fixed Pattern Noise, FPN)이 나타나게 된다. 이를 보정하기 위한 방법으로는 흑체를 이용한 교정 기반 불균일보정(Calibration-based Nonuniformity Correction, CBNUC)과 FPA에 맺히는 영상을 이용한 영상 기반 불균일보정(Scene-based Nonuniformity Correction, SBNUC)이 있다.

CBNUC는 흑체와 같은 보정장비를 이용하여 gain과 offset을 획득 및 적용하는 방법으로 서로 다른 두 온도의 흑체를 이용하여 FPA의 gain 및 offset을 보정하는 two point NUC가 대표적으로 사용되고 있다[2]. CBNUC는 SBNUC에 비해 구현

하기 용이하며 정확한 보정데이터 획득이 가능하다는 장점이 있지만 가정에 벗어난 주변 환경 변화에 대응하지 못하며, 초기 불균일보정 후 장시간 경과 시 발생하는 FPA 특성변화를 보상하기 위하여 주기적인 보정이 수반되어야 한다. 특히, 센서 전 원인가 후 FPA에서 발생하는 온도 드리프트 현상에 대응하기 어려운 단점이 있다[3]. 이를 극복하기 위한 방법으로 센서 전면에 셔터를 장착하여 셔터보정을 수행함으로써 온도에 따른 드리프트 현상을 보상할 수 있으나, 셔터가 주기적으로 작동할 경우 센서면을 가리게 되어 연속 영상획득이 불가능하다.

SBNUC는 FPA에 맺히는 영상을 기반으로 FPA의 gain 및 offset을 획득 및 적용하는 방법으로 불균일보정을 위한 흑체나 챔버와 같은 보정장비가 필요 없다. 영상을 기반으로 하기 때문에 FPA 및 주변 변화에 대응하기 위한 셔터보정이 필요 없어 끊임없이 연속적인 영상 획득이 가능한 장점이 있다. 하지

• First Author: Yong-Hee Hong, Corresponding Author: Ho-Jin Jhee

*Yong-Hee Hong (yonghee.hong@lignex1.com), LIG Nex1

*Nam-Hun Song (namhun.song@lignex1.com), LIG Nex1

*Dae-Hyeon Kim (daehyeon.kim01@lignex1.com), LIG Nex1

**Chan-Won Jun (space606@add.re.kr), Defense Industry Technology Center

*Ho-Jin Jhee (hojin.jhee@lignex1.com), LIG Nex1

• Received: 2019. 04. 23, Revised: 2019. 05. 28, Accepted: 2019. 06. 10.

• This work was funded by the Critical Technology R&D Program through the Defense Industry Technology Center and the Defense Acquisition Program Administration.

만, CBNUC 방식에 비해 높은 연산량이 요구되어 한정된 시스템 자원 내에서 실시간 구현이 제한적이라는 단점이 있다.

SBNUC는 크게 통계 기반(Statistics based) SBNUC와 정합 기반(Registration based) SBNUC로 나눌 수 있다. 통계 기반 SBNUC는 scene의 방사에 의해 검출기 소자 단위의 출력 평균이 일시적으로 동일하며, 출력 변화의 분산이 동일하다는 가정하에 확률적으로 gain과 offset을 추정하여 적용한다. 통계 기반 SBNUC는 정합 기반 SBNUC에 비해 상대적으로 낮은 연산량과 메모리가 요구되어 실시간 적용에 유리하다. 하지만 가정과 달리 다양한 scene이 입력되지 않을 경우 고스트 현상이 발생하기 쉽다. 이 외에도 정합 기반 SBNUC에 비해 느린 수렴 속도를 가지고 있으며, 느린 수렴 속도를 극복하기 위해 학습율을 높일 경우 고스트 현상이 발생하기 쉬운 단점이 있다[4-5].

정합 기반 SBNUC는 연속적인 프레임 간의 scene이 동일하다고 가정하여 카메라 모션으로 인한 scene 이동이 발생하였을 때 동일 scene의 신호를 서로 다른 소자를 통하여 감지하고 두 소자 간의 신호 차이를 이용하여 gain 및 offset을 추정한다. 이 방식은 확률 기반 SBNUC에 비해 빠른 수렴속도와 고스트 현상이 거의 발생하지 않는 장점이 있다. 하지만, 정합 기반 SBNUC는 통계 기반 SBNUC에 비해 상대적으로 많은 연산량과 메모리가 요구되어 실시간 구현이 확률 기반 SBNUC에 비해 어려운 단점이 있다. 특히, 영상정합을 기반으로 하기 때문에 이전 프레임과 겹치지 않는 부분은 보정 계수가 업데이트되지 않거나 영상의 회전, 축소 및 확대 등과 같은 영상 이동이 발생하여 영상 정합에 불리한 경우 추가 보정이 수행되지 않거나 보정 오류율이 높아지는 단점이 있다[6-8]. 확률 및 정합 기반 SBNUC 알고리즘 이외에도 신경망을 이용한 방법과 [9], 두개 프레임을 이용한 Two Frame NUC (TFNUC)도 있으며 [10], column 단위로 midway equalization을 적용하여 단일 영상 프레임으로 보정이 가능한 알고리즘도 있다[11].

본 논문은 II장에서 SBNUC의 해외 및 국내 동향을 조사하였다. III장에서 제안한 알고리즘과 성능 비교를 위해 기존 확률과 정합 기반 알고리즘 중 간단하며 효율이 좋은 정합 기반 improved IRLMS(Interframe Registration-based Least Mean Square)알고리즘을 기술하였다. IV장에서는 제안하는 유사 영상 거칠기와 공간잡음을 비용함수로 이용하는 딥러닝 신경망 장면 기반 불균일보정 알고리즘의 신경망 학습 구조, 유사 영상 거칠기 비용함수, 공간잡음 비용함수, 학습 및 결과를 기술한다. V장에서는 결론 및 향후 연구방향을 다룬다.

II. Preliminaries

1. Related works

1.1 Overseas Trend

확률 기반 계열 SBNUC 알고리즘 동향은 다음과 같다. Hardi의 gated adaptive LMS 알고리즘은 확률 기반 SBNUC

의 고스팅 현상 방지를 위해 적응형 게이팅을 적용하였다[4]. Harris는 고스팅 현상 감소를 위해 constant statistics(CS) 알고리즘에 간단한 평균 및 분산의 문턱 값을 기준 초과 시 업데이트 하는 방법을 사용하였다[5].

정합 기반 SBNUC 방식으로 Hardi의 Motion Compensated Average(MCA) 알고리즘은 프레임에 일정 수 수집하고 정합을 하여 평균을 취하여 이용하는 방법으로 프레임 획득 시간 동안 NUC 진행이 불가능한 단점이 있다[6]. Zuo의 IRLMS 알고리즘은 프레임 간 정합하여 error를 구하고 이에 LMS 알고리즘을 사용하여 보정테이블을 구하였다[7]. 이 방식은 MCA와 달리 프레임 획득과 동시에 보정테이블 추정 및 보정이 가능하나 프레임 단위로만 업데이트를 하여 느린 수렴속도와 낮은 화질을 보이는 단점이 있다. 이러한 단점들은 improved IRLMS 알고리즘에서 마스킹 위상 상관 정합, 비정상 데이터 제외, 가변 학습률을 추가하여 개선하였다[8].

1.2 Domestic Trend

이종호는 프레임 간의 업데이트만 사용하는 기존 IRLMS에 프레임 내 업데이트를 도입하였으며, 이를 안정적으로 수행하기 위해 Meaningless Residual Removal(MRR)를 사용하고, 프레임 내 업데이트 시 residual의 pair matching을 위해 anti-propagation masking으로 overlap되지 않은 영역을 제외시키는 방법으로 수렴 속도와 화질을 개선하였다[12]. 김성민은 기존 칼만 필터 방식이 단방향 위평을 이용하고 offset 만을 보상하는 알고리즘을 양방향 위평과 gain과 offset을 결합 보정하여 영상경계 부근의 FPN을 효과적으로 제거하고 gain을 보정하지 못해 발생하는 왜곡을 줄였다[13]. 노건효는 기존 Scribner의 인접 픽셀 신경망 장면 기반 불균일보정 알고리즘에 렌즈 비네팅 효과를 보상할 수 있는 비용함수를 추가하여 광역적 불균일을 추가 보정하였다[14]. 홍용희는 기존 improved IRLMS 알고리즘에 블록 단위 에러 재평가와 광역 offset 초기화를 추가하여 보정 영상 품질을 높였다[15].

기존 방법들은 대부분 프레임 단위로 점차적으로 수렴 학습하는 방식으로 본 논문에서 제안한 알고리즘과 달리 순차적이며 다량의 무보정 영상을 필요로 한다.

III. Improved IRLMS

1. Nonuniformity Model

적외선 방사와 검출기 출력 관계 기본 모델을 식(1)과 같이 정의할 수 있다[16].

$$Y_n(i, j) = g_n(i, j) \cdot X_n(i, j) + o_n(i, j) \quad (1)$$

$g_n(i, j)$ 은 n번째 프레임의 gain, $o_n(i, j)$ 는 n번째 프레임의 offset, $X_n(i, j)$ 은 n번째 프레임의 실제 방사 받은 적외선량, $Y_n(i, j)$ 은 n번째 프레임에서 적외선 센서 출력 전압 값이다.

$$X_n(i, j) = w_n(i, j) \cdot Y_n(i, j) + b_n(i, j) \quad (2)$$

$$w_n(i, j) = \frac{1}{g_n(i, j)} \quad (3)$$

$$b_n(i, j) = -\frac{o_n(i, j)}{g_n(i, j)} \quad (4)$$

불균일보정은 $X_n(i, j)$ 을 추정하기 위해 적외선 센서 출력 $Y_n(i, j)$ 을 이용하므로 식(2)와 같이 변환하여 사용한다. 식(3)은 $w_n(i, j)$ 과 $g_n(i, j)$ 의 관계를 나타내고 있으며, 식(4)는 $b_n(i, j)$ 과 $o_n(i, j)$ 및 $g_n(i, j)$ 의 관계를 나타내고 있다.

2. Motion Estimation

인접한 두 프레임 사이의 모션량은 식(5)(6)와 같이 normalized cross-power spectrum의 피크점 위치를 이용하여 추정할 수 있다.

$$C(u, v) = \frac{\bar{Y}_n(u, v) \cdot \bar{Y}_{n-1}^*(u, v)}{|\bar{Y}_n(u, v) \cdot \bar{Y}_{n-1}^*(u, v)|} \quad (5)$$

$$(d_i, d_j) = \arg_{i, j} \max Re\{FFT^{-1}(C(u, v))\} \quad (6)$$

(u, v) 는 푸리에 좌표, \bar{Y} 는 푸리에 변환된 센서 측정 영상, n 은 현재 프레임, $n-1$ 은 이전 프레임, $*$ 는 켈레복소수, $||$ 은 L2-norm, $C(u, v)$ 은 normalized cross-power spectrum 결과, FFT^{-1} 은 푸리에 역변환, (d_i, d_j) 은 모션량을 나타낸다. FPN에 의해 발생하는 신호를 마스킹 처리하여 모션에 의해 발생하는 신호만 남겨 모션 추정에 사용한다. 그림 1은 FPN과 모션에 의해서 normalized cross-power spectrum에 발생하는 두 피크 신호 중 FPN에 의해 발생하는 피크 신호를 제거하는 과정과 두 프레임을 겹친 모습을 보여준다.




Fig. 1. (a) is Masked phase correlation registration, (b) is Schematic diagram of the overlay of two frames

3. Nonuniformity

인접한 두 프레임 간의 scene의 밝기는 동일하다고 가정하였기 때문에 불균일보정 시 인접한 두 프레임의 신호차이를 이용한다. 인접한 두 프레임 간의 신호 차이는 식(7)과 같이 모션 보정된 이전 프레임과 현재 프레임의 차이를 이용하여 구한다.

$$e_n(i, j) = \hat{X}_{n-1}(i-d_i, j-d_j) - \hat{X}_n(i, j) \quad (7)$$

$e_n(i, j)$ 은 이전 프레임과 현재 프레임의 신호 차이 에러, $\hat{X}_{n-1}(i-d_i, j-d_j)$ 은 불균일보정 및 모션보상된 이전 프레임, $\hat{X}_n(i, j)$ 은 불균일보정된 현재 프레임을 나타낸다.

$$\hat{X}_{n-1}(i-d_i, j-d_j) = w_{n-1}(i-d_i, j-d_j) \cdot Y_{n-1}(i-d_i, j-d_j) + b_{n-1}(i-d_i, j-d_j) \quad (8)$$

$$\hat{X}_n(i, j) = w_{n-1}(i, j) \cdot Y_n(i, j) + b_n(i, j) \quad (9)$$

$\hat{X}_{n-1}(i-d_i, j-d_j)$ 과 $\hat{X}_n(i, j)$ 는 식(8)(9)와 같이 불균일보정 및 모션보상으로 표현된다.

$$w_{n+1}(i, j) = \begin{cases} w_n(i, j) + \alpha \cdot e_n(i, j) \cdot Y_n(i, j) \\ w_n(i, j) \end{cases} \quad (10)$$

$$b_{n+1}(i, j) = \begin{cases} b_n(i, j) + \alpha \cdot e_n(i, j) \\ b_n(i, j) \end{cases} \quad (11)$$

수정된 gain w 와 offset b 는 식(10)(11)과 같이 모션 이동이 발생하여 신호 차이 에러 발생 시 이전 프레임과 현재 프레임이 겹쳐진 영역에 신호 차이 에러와 학습률 α 를 반영하여 업데이트한다.

인접한 두 프레임 정합 시 로컬 모션, 모션 블러, 회전, 확대 및 축소, 완전하지 않은 정합 과정 등으로 인해 신호 차이 에러 $e_n(i, j)$ 가 불완전하게 형성되어 최종 보정 결과에 영향을 미친다. 이를 방지하기 위해 식(12)와 같이 신호 차이 에러 값이 표준편차에 3배 이상일 경우 0으로 처리하여 업데이트가 되지 않도록 하여 비정상 데이터를 제거한다.

$$e'_n(i, j) = \begin{cases} 0 & \text{when } |e_n(i, j) - \mu_n| \geq 3\sigma_n \\ e_n(i, j) & \text{when } |e_n(i, j) - \mu_n| < 3\sigma_n \end{cases} \quad (12)$$

$e'_n(i, j)$ 는 비정상 데이터 제거 후 생성된 신호 차이 에러, μ_n 은 신호 차이 에러의 평균, σ_n 은 신호 차이 에러의 표준편차를 나타낸다.

인접한 두 프레임의 정합이 정확히 이루어졌을 경우 정확한 신호 차이 에러가 형성된다. 신호 차이 에러를 정합 정도에 따라 활용할 경우 수렴속도와 최종 보정 영상 품질을 올릴 수 있다. 이를 위해 정합의 정확성을 모션에 의해 발생된 normalized cross-power spectrum의 피크값을 학습률과 연동한다. Normalized cross-power spectrum의 피크값이 높을수록 정합이 정확하다 할 수 있으며 식(13)과 같이 기존 학습률과 연동할 수 있다.

$$\alpha_n = a_{\max} \cdot c_{\max} \quad (13)$$

α_n 은 학습률, a_{\max} 는 최대 가변 크기, c_{\max} 는 모션에 의해 발생된 normalized cross-power spectrum의 피크값을 나타

낸다. 그림 2는 Chao Zuo의 Improved IRLMS 장면 기반 불균일보정 알고리즘의 구조를 보여준다.




Fig. 2. Block Diagram of the Improved IRLMS

IV. The Proposed Scheme

1. Simplified Nonuniformity Model

본 논문에서는 식(14)과 같이 적외선 방사와 검출기 출력 관계 기본 모델에서 gain을 삭제 간소화 적용하며 offset을 추정한다.

$$Y_n(i, j) = X_n(i, j) + o_n(i, j) \quad (14)$$

$o_n(i, j)$ 는 n번째 프레임의 offset, $X_n(i, j)$ 은 n번째 프레임의 실제 방사 받은 적외선량, $Y_n(i, j)$ 은 n번째 프레임에서 적외선 센서에서 출력된 전압 값이다.

불균일보정은 $X_n(i, j)$ 을 추정하기 위해 적외선 센서 출력 $Y_n(i, j)$ 을 이용하므로 식(15)와 같이 변환하여 사용한다.

$$X_n(i, j) = Y_n(i, j) + b_n(i, j) \quad (15)$$

$$b_n(i, j) = -o_n(i, j) \quad (16)$$

식(16)는 $b_n(i, j)$ 과 $o_n(i, j)$ 의 관계를 나타내고 있다.

2. Structure of Neural Network Learning

본 논문이 제안한 딥러닝 신경망 장면 기반 불균일보정 알고리즘은 기존 확률 및 정합 기반 불균일보정 알고리즘과는 기반을 달리하고 있다. 보통 신경망 학습은 신경망 학습 목표에 해당하는 목표로 하는 신경망 출력 결과를 레이블 형태로 사용자가 정의한다. 하지만 장면 기반 불균일보정의 경우 목표로 정의할 수 있는 보정된 영상이나 offset이 없다. 이러한 이유로 입력으로 이용된 무보정 영상만을 이용하여 비용함수를 통한 규칙으로 보정 계수 offset을 추정해야 한다.

무보정 영상 데이터만을 이용하여 offset을 추정하기 위해 그림 3과 같은 딥러닝 신경망 학습 구조를 구축하였다. 입력으로 영상 센서에서 출력되는 무보정 영상 스트림 데이터가 사용되었으며 신경망 추론 결과를 offset으로 가정하였다. 신경망

추론 결과가 offset으로 가정하였으므로 신경망의 입력으로 이용된 무보정 영상과 offset 연산 결과가 불균일보정이 수행된 보정영상임을 가정할 수 있다. 가정된 불균일보정 보정영상에서 유사 영상 거칠기 비용함수와 공간잡음 비용함수를 이용하여 전체 비용함수를 계산하게 되며 이를 신경망 학습 시 피드백으로 이용하게 된다.

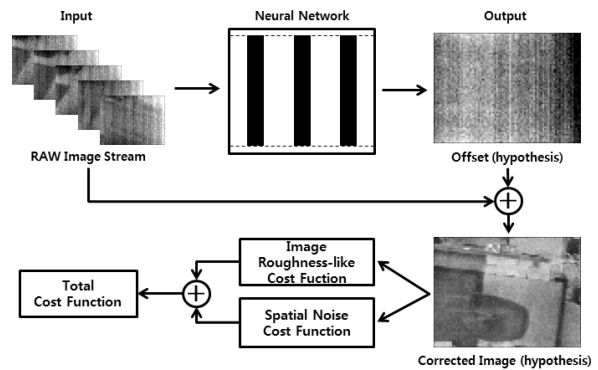


Fig. 3. Structure of Deep Neural Network Scene based Non-uniformity Correction

3. Image Roughness-like Cost Function

본 논문은 신경망 학습 시 사용되는 비용함수 두 가지 중에서 첫 번째로 유사 영상 거칠기 비용함수를 아래와 같이 정의하였다.

$$\rho = \frac{1}{MN} \sum \left\{ \frac{\|h_1 * I\|_1 + \|h_2 * I\|_1}{\|I\|_1} \right\} \quad (17)$$

기존 영상 거칠기 함수 ρ 는 식(17)과 같이 정의되어 있다. 인접 픽셀들과의 차이의 절대 값에 자신 픽셀 값으로 정규화한다.

$$\tilde{\rho} = \frac{1}{MN} \sum \{ \|h_1 * I\|_1 + \|h_2 * I\|_1 \} \quad (18)$$

기존 영상 거칠기 함수는 영상 값으로 정규화 하는 부분이 포함되어 있다. 유사 영상 거칠기 함수는 영상 값으로 정규화 부분이 제거되어 식 (18)과 같이 정의된다. 이를 통해 신경망 학습 시 연산량을 줄일 수 있으며, 공간잡음 비용함수와 균형을 이룰 수 있다.

유사 거칠기 함수를 그대로 이용할 경우 영상 거칠기가 커질 경우 값도 같이 커지는 특성이 있어 학습에 수정 없이 이용이 가능하나 글로벌 최저 값에서 멀어질 경우에 학습 시 이용되는 비용함수의 기울기가 일정하여 학습 속도가 느려지는 원인이 된다. 이러한 단점을 해결하기 위해 식 (19)와 같이 인접 픽셀과의 차이 값에 제곱을 추가하여 MSE(Mean Squared Error)를 적용한다. 이는 영상 거칠기가 커질수록 함수의 기울기 값을 더욱 높게 만들어 신경망 학습 시 빠르게 수렴이 가능하도록 만들어 준다.

$$Cost_{Rough}(\tilde{\rho}) = \frac{1}{MN} \sum \{ (\|h_1 * I\|_1)^2 + (\|h_2 * I\|_1)^2 \} \quad (19)$$

ρ 는 영상 거칠기, $\tilde{\rho}$ 는 유사 영상 거칠기, $Cost_{Rough}(\tilde{\rho})$ 는 유사 영상 거칠기 비용함수, I 는 영상, h_1 은 수평차이필터, h_2 는 수직차이필터, $\| \cdot \|_1$ 은 L1 norm, M 은 영상 가로 픽셀 수, N 은 영상 세로 픽셀 수를 나타낸다.

그림 4는 영상 거칠기 함수에 따른 영상의 예시를 보여준다. 영상 거칠기 값이 클 경우 (a)와 같은 영상 고주파가 강조된 영상을 확인 할 수 있으며, 영상 거칠기 값이 작을 경우 (b)와 같이 영상 저주파가 강조된 영상을 확인 할 수 있다.



Fig. 4. (a) is image with High Roughness, (b) is image with Low Roughness

4. Spatial Noise Cost Function

본 논문은 신경망 학습 시 사용되는 비용함수 두 가지 중에서 두 번째로 공간잡음 비용함수를 아래와 같이 정의 하였다.

$$Avr(I) = \frac{1}{MN} \sum I_{i,j} \quad (20)$$

$$SN(I) = \frac{1}{MN} \sum \| I_{i,j} - Avr(I) \|_1 \quad (21)$$

기존 공간잡음 함수는 식 (21)과 같이 식 (20)에서 정의된 영상 평균 대비 각 픽셀의 차이 값의 절대 값의 평균으로 정의 되어 있다. 공간잡음 함수도 영상 평균 대비 각 픽셀들 값이 많이 달라질수록 값이 커지는 성질이 있어 이를 그대로 학습에 이용해도 무방하지만 비용함수가 글로벌 최저값에서 멀어져도 같은 함수 기울기가 일정하기 때문에 신경망 학습 속도를 더디게 만드는 경향이 있다. 이를 극복하기 위해 식 (22)와 같이 기존 공간잡음에 제곱을 취해 MSE를 적용하여 신경망 학습 시 빠르게 수렴이 가능하도록 한다.

$$Cost_{SN}(I) = \frac{1}{MN} \sum \{ I_{i,j} - Avr(I) \}^2 \quad (22)$$

$Avr(I)$ 는 영상 평균, $SN(I)$ 는 영상 공간잡음, $Cost_{SN}(I)$ 는 영상 공간잡음 비용함수, $\| \cdot \|_1$ 은 L1 norm, M 은 영상 가로 픽셀 수, N 은 영상 세로 픽셀 수를 나타낸다.

그림 5는 영상 공간잡음 함수에 따른 영상의 예시를 보여준다. 영상 공간잡음 값이 클 경우 (a)와 같은 영상을 확인 할 수 있으며, 영상 공간잡음 값이 작을 경우 (b)와 같은 영상을 확인 할 수 있다.



Fig. 5. (a) is Image with High Spatial Noise, (b) is Image with Low Spatial Noise

5. Neural Network

본 논문 학습에 이용된 신경망은 아래와 같이 구성하였다.




Fig. 6. Structure of Neural Network




Fig. 7. Activation Function ReLU (Rectified Linear Unit)

신경망은 그림 6과 같이 입력층 1개, 은닉층 1개, 출력층 1개로 총 3층으로 구성하였다. 이는 은닉층 최소 2~3층 이상 사용하는 일반 딥러닝 신경망에 비해 얇은 것으로 튜닝에 의한 결과이다. 이는 부수적으로 적은 메모리 사용과 빠른 학습 속도에 도움이 된다. 신경망은 보정되지 않은 가로 80 픽셀, 세로 60 픽셀 영상의 입출력을 수행하기 위해 입출력 및 은닉층 모두 4800개 노드로 구성되어 있다.

활성 함수는 그림 7과 같이 ReLU(Rectified Linear Unit)를 적용하였다. ReLU 활성 함수는 Vanish Gradient 문제를 해결하는데 효과적이다. 그리고 신경망 초기화 시 Xavier 초기화를 적용하였다. 최종 비용함수로 유사 영상 거칠기 비용함수와 공간잡음 비용함수의 합을 사용하였다.

6. Learning Data




Fig. 8. Cardinal 640

본 논문에서는 학습용 데이터 무보정 영상을 SWIR 카메라를 이용하여 획득하였다. 시험에 이용된 센서 모듈은 그림 8의 Cardinal 640으로 SWIR(0.9~1.7 μ m) 파장을 감지하며, 60Hz 동작 속도와 640 \times 512 해상도를 지니고 있다. 시험에서는 영상을 서브샘

플링하여 80×60 해상도를 사용하였다. 학습용 무보정 영상은 실내를 촬영한 것으로 총 680 프레임으로 구성되어 있다.

7. Neural Network Learning Result

본 논문에서는 신경망 라이브러리로 “Tensorflow 1.8.0 for CPU”, 코드 작성은 “Python 3.5”, CPU는 “Intel i5-3470”, 메모리는 16GB를 적용하였으며, 80×60 14bit 영상을 사용하였다. 모든 노드의 학습을 위해 드롭아웃은 적용하지 않았다. 최적화 알고리즘으로 Adam 옵티마이저를 적용하였으며, 학습률 0.001로 총 200회 학습을 진행하였다.




Fig. 9. Learning Result of Total Cost Function

그림 9는 학습 10회 당 최종 비용함수 값을 표시한 것으로 학습 진행 시 비용함수가 안정적으로 수렴하는 것을 확인할 수 있다. 그리고 약 50회의 학습만으로도 빠르게 최종 비용함수 수렴 값에 근접하는 것을 확인할 수 있다.

그림 10은 학습 단계에 따른 신경망 출력 추정된 불균일보정 offset 영상을 보여주고 있다. 학습 1단계부터 점차적으로 추정된 offset이 완성되는 것을 확인할 수 있다. 그림 10에서 최종 비용함수가 약 50회 학습 단계에서 수렴된 것과 같이 예측된 offset 영상이 약 50회 단계부터 변화가 거의 일어나지 않는 것을 확인할 수 있다.




Fig. 10. Learning Result of Offset Image by Learning Step

제안한 유사 영상 거칠기와 공간잡음 비용함수를 이용한 딥러닝 신경망 장면 기반 불균일보정 알고리즘과 기존 improved IRLMS 장면 기반 불균일보정 알고리즘의 성능 차이 측정을 위해 두 영상 차이 측정 시 널리 사용되고 있는 signal-to-noise ratio(PSNR)을 이용하였으며 식(23)과 같이 정의된다. 는 영상에서 밝기를 표현할 수 있는 비트 단위로 14를 사용하였다. RMSE는 root mean square error로 식(24)과 같이 정의된다.

$$PSNR = 20 \log \left(\frac{2^b - 1}{RMSE} \right) \quad (23)$$

$$RMSE = \sqrt{\frac{1}{MN} \sum_{i,j} \{x(i,j) - \hat{x}(i,j)\}^2} \quad (24)$$

$x(i,j)$ 는 true 영상으로 비교 기준이 되며 true 영상은 기존 CBNUC 방식으로 보정된 결과를 사용한다. $\hat{x}(i,j)$ 는 불균일보정된 영상으로 제안한 장면 기반 불균일보정과 improved IRLMS 장면 기반 불균일보정 결과를 사용한다.

제안한 알고리즘과 기존 improved IRLMS 알고리즘은 기반이 다르므로 단순 비교가 어렵다. 이러한 이유로 다음과 같은 방법으로 보정 영상 품질을 평가 하였다. improved IRLMS 알고리즘은 기존 프레임 단위로 영상 데이터를 누적하여 offset을 추정 및 갱신하면서 true 영상과 비교하여 PSNR을 구하였으며, 제안한 알고리즘은 매 프레임마다 새로 신경망을 학습 및 평가하는 과정이 시간이 많이 소요되고 비순차적 프레임 입력이 가능하여 10 프레임 단위로 영상 데이터를 누적하며 학습 후 true 영상과 비교하여 PSNR을 구하였다.

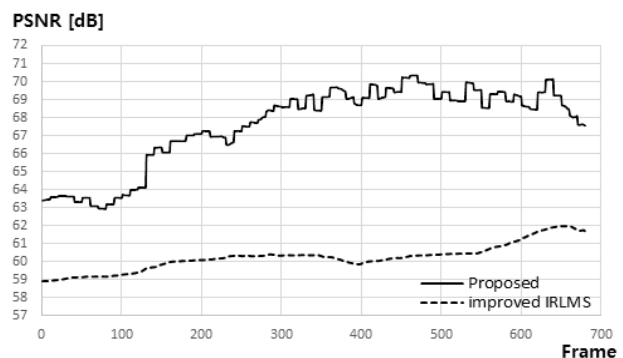


Fig. 11. PSNR Result

그림 11은 제안한 알고리즘과 improved IRLMS 알고리즘의 PSNR을 프레임 단위로 비교한 그래프다. 제안한 알고리즘은 처음 10개 영상 프레임으로도 63.4dB를 달성했다. 이후 누적 영상 데이터를 바탕으로 최대 70.3dB를 달성하였다. 그리고 약 300 프레임 누적 후 약 67.5~70.0dB 보정 영상 품질을 안정적으로 유지하는 것을 확인할 수 있다.

제안한 알고리즘은 10프레임 단위로 영상 데이터를 추가 누적 시 보정 영상 품질이 조금씩 요동하며 변화하는 것을 확인할 수 있다. 이러한 현상은 누적된 무보정 영상 데이터 특성, 신경망 초기화시 사용된 Xavier 초기화의 무작위성, Adam 옵티마이저 특성에서 기인하는 것을 추정할 수 있다.

기존 improved IRLMS 알고리즘은 약 58.9dB에서 시작하여 프레임 단위로 영상 품질이 높아지며 660번째 프레임에서 최대 약 62.0dB를 보인다. improved IRLMS는 이전 프레임과 정합 후 차이 값을 학습률 기준으로 업데이트 하는 방식으로 일정량 이상의 순차적 영상 데이터를 필요로 한다.

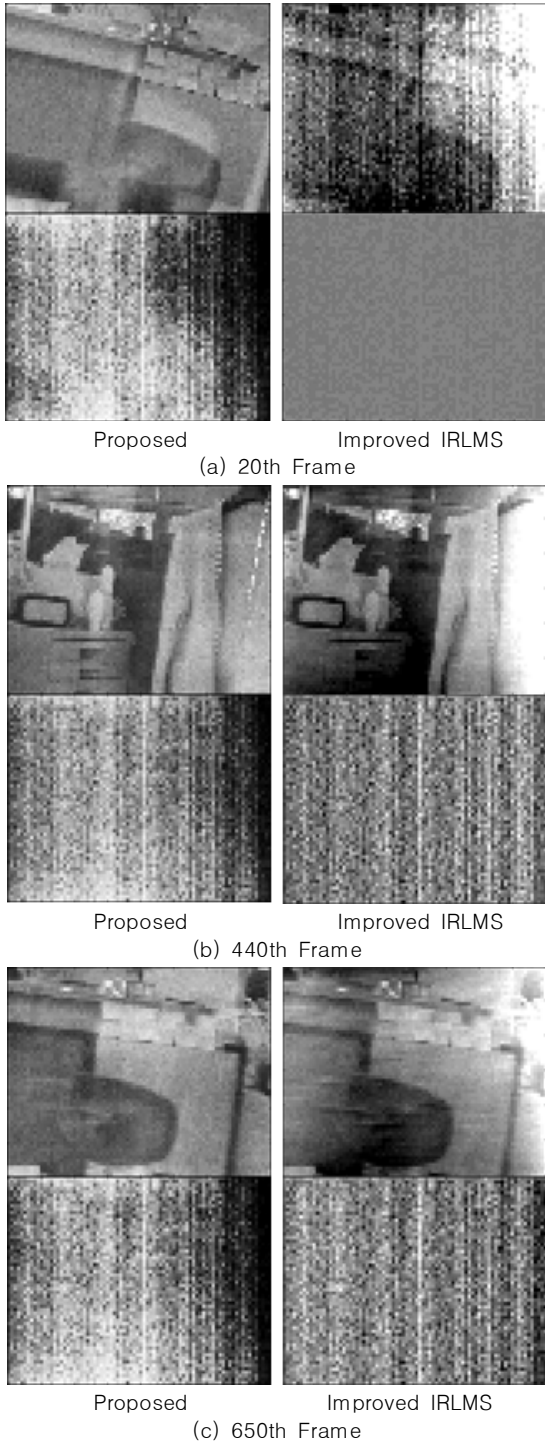


Fig. 12. Compare the Proposed Results. (a) is 20th frame results, (b) is 440th Frame Results, (c) is 650th Frame Results (In each section, left top: proposed output, left bottom: proposed estimated offset, right top: improved IRLMS output, right bottom: improved IRLMS estimated offset)

그림 12는 제안한 알고리즘과 improved IRLMS 알고리즘을 680 프레임에 적용 시 초반, 중반, 종반에 따른 불균일보정 결과를 비교한 영상으로 각각 알고리즘 수행 후 보정된 영상 결과와 추정된 offset을 차례대로 보여주고 있다. 초반 20번째 프레임 보정 시

기존 improved IRLMS 알고리즘은 추정된 offset이 충분히 형성되지 않아 보정 효과가 미미하다. 제안한 알고리즘은 초반 20개 프레임 만으로도 약 63.6dB의 만족 가능한 보정 결과를 보인다. 하지만 고스트 현상이 남아 있는 것을 확인할 수 있다. 중반 440번째 프레임 보정 시 두 알고리즘 모두 사용 가능한 수준의 보정 결과를 보이는 것을 확인할 수 있다. 하지만 기존 improved IRLMS 알고리즘은 광역적 offset 특성 보정이 이루어지고 있지 않음을 확인할 수 있다. 이는 improved IRLMS 알고리즘 보정 영상의 오른쪽 모서리 부분이 고정패턴잡음에 의해 밝게 나타나는 현상과 추정된 offset이 평면적으로 형성된 것을 통해 알 수 있다. 종반 650번째 프레임에서는 시험 중반 결과에서 큰 변화가 없는 offset 추정 결과를 보여 두 알고리즘 모두 시험 중반서부터 안정적으로 offset 추정 결과를 유지하는 것을 확인할 수 있다.




Fig. 13. Proposed Result with two frames. (Top to bottom : proposed output, true image, input image, proposed estimated offset)

제안한 알고리즘은 offset 추정 시 유사 영상 거칠기와 공간잡음 비용함수를 이용하여 지역적 특성과 광역적 특성을 모두 잘 반영하고 있는 것을 확인할 수 있다. 반면 improved IRLMS 알고리즘은 지역적 특성을 잘 반영하나 광역적 특성을 잘 반영하고 있지 못하는 것을 확인할 수 있다. 이는 improved IRLMS 알고리즘 구조상 프레임 간의 픽셀 이동량이 클수록 offset의 광역적인 특성이 잘 반영되기 때문이다. 따라서 프레임레이트가 높은 카메라에서 improved IRLMS 알고리즘은 프레임 간 픽셀 이동량이 상대적으로

작아 광역적 특성 추정 성능이 떨어진다.

제안한 알고리즘은 무보정 프레임 2장만으로도 offset 추정이 가능하다. 그림 13은 상이한 영상 프레임 2장을 이용하여 제안한 알고리즘으로 불균일보정 수행한 결과로 보정결과 영상, true 영상, 무보정 영상, 추정된 offset 결과를 차례로 보여 주고 있다. 보정된 결과 영상에서 서로의 영상 프레임에 고스트 현상을 보이고 있지만 offset 잡음이 대부분 사라진 것을 확인할 수 있다. 또한 추정된 offset 결과는 완벽하진 않지만 지역적 특성과 광역적 특성이 잘 반영된 것을 확인할 수 있다. 그리고 왜곡이 있지만 그림 12의 다수 프레임을 누적하여 추정한 offset 결과와 상당히 비슷하게 추정하는 것을 확인할 수 있다.

V. Conclusions

본 논문에서는 제안한 유사 영상 거칠기 비용함수와 공간잡음 비용함수를 이용한 딥러닝 장면 기반 불균일보정은 PSNR 기준 최대 70.3dB의 영상품질 보였으며, 기존 improved IRLMS 알고리즘에 비해 약 8.0dB 높은 영상 품질을 보였다. 이는 무보정 영상의 각 프레임 특성이나 연속적 특성에 의해 따라 달라질 수 있으나 기존 improved IRLMS 알고리즘에 비해 의미 있는 성능 개선을 보인 것을 확인할 수 있다.

본 논문에서 제안한 알고리즘은 기존 확률 및 정합 기반 알고리즘이 필요로 하는 연속적 다량의 영상 프레임이나 확대 축소 및 회전이 적은 영상 프레임 조건을 부합하지 않더라도 만족할 수준의 보정된 영상을 획득할 수 있었다. 하지만 일반적으로 딥러닝 신경망 학습 특성상 높은 시스템 자원을 요구한다. 이 때문에 현재 저해상도에서 불균일보정 테이블 추정에 유리하지만 일반적인 고해상도 무보정 영상에서 불균일보정 테이블을 추정하기 어려운 단점이 있다. 이를 개선하기 위해 영상 분할 가능성 검토, 신경망 노드 수 최적화, 학습 횟수 최적화, 학습 구조 최적화 등을 통해 성능을 유지하면서 고해상도 무보정 영상에서도 원활히 사용할 수 있도록 개선 예정이다.

REFERENCES

- [1] D. A. Scribner, M. Kruer, and J. Killiany, "Infrared focal plane array technology," *Proc. IEEE*, vol. 79, no. 1, pp. 66-85, Jan 1991.
- [2] A. Friedenber and I. Goldbatt, "Nonuniformity two-point linear correction errors in infrared focal plane arrays," *Opt. Eng.* 37(4), pp. 1251-1253, April, 1998.
- [3] O. Riou, S. Berrebi, and P. Bremond, "Nonuniformity correction and thermal drift compensation of thermal infrared camera," *Proc. SPIE* 5405, pp 294-302, April, 2004.
- [4] R. Hardie, F. Baxley, B. Brys, and P. Hytla, "Scene-based nonuniformity correction with reduced ghosting using a gated LMS algorithm," *Opt. Express* 17, pp. 14918-14933, 2009.
- [5] J. Harris and Y. Chiang, "Minimizing the 'ghosting' artifact in scene-based nonuniformity correction," *Proc. SPIE* 3377, pp. 106-113, 1998.
- [6] Russell C. Hardie, Majeed M. Hayat, Earnest Armstrong, and Brian Yasuda, "Scene-based nonuniformity correction with video sequences and registration," *Applied Optics* Vol. 39, Issue 8, pp. 1241-1250, 2000.
- [7] Chao Zuo, Qian Chen, Guohua Gu and Xiubao Sui, "Scene-Based Nonuniformity Correction Algorithm Based on Interframe Registration," *J Opt Soc Am A Opt Image Sci Vis* 28 (6), pp. 1164-1176, Jun, 2011.
- [8] Chao Zuo, Qian Chen, Guohua Gu, Xiubao Sui, and Jianle Ren, "Improved interframe registration based nonuniformity correction for focal plane arrays," *ELSEVIER Infrared Physics & Technology* Vol 55, Issue 4, pp. 263-269, July 2012.
- [9] D. Scribner, K. Sarkady, M. Kruer, J. Calfield, J. Hunt, M. Colbert, and M. Descour, "Adaptive nonuniformity correction for IR focal plane arrays using neural networks," *Proc. SPIE* 1541, pp. 100-109, 1991.
- [10] Chao Zuo, Yuzhen Zhang, Qian Chen, Guohua Gu, Weixian Qian, Xiubao Sui and Jianle Ren, "A two-frame approach for scene-based nonuniformity correction in array sensors," *ELSEVIER Infrared Physics & Technology* Vol 60, pp. 190-196, Sep 2013.
- [11] Yohann Tendero, Stephane Landeau and Jerome Gilles, "Non-uniformity Correction of Infrared Images by Midway Equalization," *Image Processing On Line*, pp. 134-146, Jan 2012.
- [12] Lee Jonhho, Ra Jongbeom, "Improvement on a optimization algorithm for non-uniformity correction of infrared videos," *Master Thesis, KAIST, Department of Electrical Engineering*, 2013.
- [13] Kim Seongmin, Bae Yoonsung, Jang Jaeho, and Ra Jongbeom, "Fixed Pattern Noise Reduction in Infrared Videos Based on Joint Correction of Gain and Offset," *The Institute of Electronics and Information Engineers*, Vol. 49, SP. 2, pp. 35-44, 2012.
- [14] Gun-hyo No, Yong-hee Hong, Jin-ho Park, Ho-jin Jhee, "Scene-based Nonuniformity Correction for Neural Network Complemented by Reducing Lense Vignetting Effect and Adaptive Learning rate," *Journal of The Korea Society of Computer and Information*, Vol. 23 No. 7, pp. 81-90, July 2018.
- [15] Yong-hee Hong, Keun-Jae Lee, Hong-Rak Kim, Ho-Jin

Jhee, "Scene-based Nonuniformity Correction Complemented by Block Reweighting and Global Offset Initialization," Journal of The Korea Society of Computer and Information, Vol. 22 No. 8, pp. 15-23, August 2017.

- [16] D. L. Perry and E. L. Dereniak, "Linear theory of nonuniformity correction in infrared staring sensors," Opt. Eng. 32, pp. 1854-1859, 1993.



Chan-Won Jun received the B.S. degree in Mechanical Engineering from KOREA Aerospace University, Seoul, Korea, in 1989 and the Ph.D degree in Department of Informations & Communications Engineering from PAI CHAI University,

Daejeon, Korea, in 2005. He is Principal research engineer at ADD in Korea. His research interests include image processing and applications of machine vision domain.



Ho-jin Jhee received the B.S. degree in Electronics Engineering from Dongguk University, Seoul, Korea, in 1997 and the Ph.D degree in Electrical Engineering from University of Florida, Gainesville, Florida, U.S.A in 2010. He is currently research

engineer at LIG Nex1 in Korea. His research interests include statistical signal processing, image processing and applications of machine vision domain.

Authors




Yong-Hee Hong received the B.S., M.S. degrees in Computer Science and Engineering from Soongsil University, Seoul, Korea, in 2009 and 2011, respectively. Mr. Hong joined LIG Nex1 company in 2011. He is currently working

on infrared camera. He is interested in image processing, developing infrared camera.



Nam-Hun Song received the B.S., M.S. degrees in Computer engineering from Kwangwoon University, Seoul, Korea, in 2011 and 2013, respectively. Mr. Song is currently research engineer at LIG Nex1 in Korea. His research interests include

analog and digital signal processing by using logic in fpga and embedded system design.



Dae-Hyeon Kim received the B.S., M.S. degrees in Electrical Engineering and Computer from Kyungpook National University, Daegu, Korea, in 2008 and 2010, respectively. Mr. Kim currently research engineer at LIG Nex1 in Korea. His research

interests include image signal processing, embedded system and infrared sensor tracking systems.