

論文95-32B-7-4

# Robust 회귀분석을 이용한 거리영상 분할

## (Range Image Segmentation Using Robust Regression)

李吉茂\*, 朴來弘\*\*

(Kil-Moo Lee and Rae-Hong Park)

### 요 약

본 논문에서는 robust 회귀분석을 이용한 거리영상 분할 알고리즘을 제안하였다. Least median of squares (LMedS)를 일반화하여 least  $k$ th-order square (LKS)를 유도하였고, 기존의 robust 회귀분석과 비교하였다. LKS는 LMedS보다 outlier에 강한 특성을 나타내며, 기존의 residual consensus (RESC)와 비슷한 성능을 나타낸다. LKS는 미리 설정된 비율의 근사화 오차를 이용하는 RESC와는 달리 주어진 관측치에 의해 결정되는 적응적인 파라메타를 이용하는, 선형적 지식이 필요 없는 회귀분석이다. 합성 및 실제 거리영상에 대한 컴퓨터 모의실험을 통해 제안한 알고리즘의 성능이 기존의 알고리즘보다 좋음을 보였다.

### Abstract

In this paper, we propose a range image segmentation algorithm using robust regression. We derive a least  $k$ th-order square (LKS) method by generalizing the least median of squares (LMedS) method and compare it with the conventional robust regressions. The LKS is robust against outliers than the LMedS and shows performance similar to the residual consensus (RESC). The RESC uses the predetermined number of sorted residuals, whereas the LKS uses an adaptive parameter determined by given observations rather than the *a priori* knowledge. Computer simulation with synthetic and real range images shows that the proposed LKS algorithm gives better performance than the conventional ones.

### I. 서 론

거리영상은 3차원 물체의 표면에서 미리 정해진 기준면까지의 수직 거리로 화소값이 구성되며 명암영상과는 달리 광원의 위치나 밝기 및 물체의 반사 성질에 관계없이 3차원 물체의 기하학적 특징을 직접적으로 제공한다. 따라서 명암영상에서 얻을 수 없는 정보를

얻어 고수준 (high level)의 추론없이 3차원 물체 인식이 가능하다. 거리영상을 이용한 3차원 물체 인식의 첫번째 작업은 우선 거리영상을 의미있는 영역들로 분할하는 것이다. 의미있는 영역이란 한 영역 내의 화소값들이 어떤 특징에 대하여 균일한 값을 갖는 것을 의미한다. 명암영상의 경우 한 영역내의 화소값들의 분산이 문턱값보다 작다는 것을 의미하며, 거리영상의 경우에는 화소값이 3차원 물체의 표면을 나타내므로 한 영역내의 화소들이 하나의 함수로 근사화되는 것을 의미한다.

거리영상의 분할은 접근방법에 따라 크게 영역기반 분할과 에지기반 분할로 나눌 수 있다. 영역기반 분할이란 영상내의 균일한 특징을 갖는 화소들을 묶어 나

\* 準會員, \*\* 正會員 西江大學校 電子工學科

(Dept. of Elec. Eng., Sogang Univ.)

※ 본 연구는 제어계측 신기술 연구센터(ERC-ACI)의 연구비 지원에 의해 이루어졌음.

接受日字: 1995年 1月 5日, 수정완료일: 1995年 7月 15日

가는 방법이며 Besl의 방법<sup>[11]</sup>이 대표적이다. Besl은 가우시안 곡률과 평균 곡률의 부호에 따라 곡면을 8가지로 분류하였으며, variable order surface fitting이라는 영역성장법을 이용하여 거리영상을 분할하였다. Besl 방법에는 미분연산의 잡음 증폭성과 그 증폭을 억제하기 위해 사용한 평활화 연산의 에지 손실이라는 상반된 문제가 존재한다. 에지기반 분할은 영상내의 불연속을 추출하여 각 영역의 경계선으로 사용하는 방법이며 Fan 등의 방법이 대표적이다.<sup>[12]</sup> Fan 등은 영상내의 각 화소에서 주곡률을 구한 후, 이 분포를 이용하여 거리영상내의 불연속을 추출하고 거리영상을 분할하였다. Besl의 방법과 마찬가지로 Fan 등의 방법에도 에지검출의 근본 문제인 detection과 localization의 상충관계가 존재한다.<sup>[13]</sup>

미분연산의 잡음 증폭성과 평활화에 의한 에지 손실을 동시에 해결하고자 많은 연구들이 진행되었는데, 비균일적 확산 (anisotropic diffusion)을 이용한 적응 평활화,<sup>[14,5]</sup> 정규화 (regularization)를 이용한 곡면 복원<sup>[6-8]</sup> 및 최근의 통계학 분야에서 도입되어 활발히 연구가 진행중인 robust 회귀분석<sup>[9]</sup> 등이 있다. Robust 회귀분석은 기존의 least squares (LS) 추정에서 발생하는 문제점을 해결하기 위해 LS를 수정하여 보다 잡음에 강한 (robust) 특성을 갖는 회귀분석을 연구하는 분야이다. LS는 평균이 0인 가우시안 잡음에 대해서는 최적의 결과를 나타내지만 다른 잡음 분포에 대해선 강건하지 못한 특성을 나타내는데, 특히 impulse성 잡음이나 서로 다른 두 영역이 만나는 불연속이 많은 컴퓨터 비전 응용에 적합하지 못하다. Robust 회귀분석은 LS의 자승연산을 새로운 함수로 바꾸어 근사화 오차가 크게 나타나는 관측치에 대한 영향을 줄이는 작업에서 시작하였다.<sup>[10]</sup> 이후 Rousseeuw에 의해 least median of squares (LMedS)가 발표되면서 LS의 자승오차의 평균을 중간값으로 대체하는 작업이 이루어졌다.<sup>[11]</sup> 컴퓨터 비전에서는 Meer 등이 처음 LMedS를 도입하면서 robust 회귀분석에 대한 활발한 연구가 진행되었으며,<sup>[12]</sup> Jolion 등의 generalized minimum volume ellipsoid (GMVE),<sup>[13]</sup> Yu 등의 residual consensus (RESC),<sup>[14]</sup> Stewart의 minimize the probability of randomness (MINPRAN)<sup>[15]</sup> 등이 있다.

본 논문에서는 LMedS의 변형인 least  $k$ th-order

square (LKS)를 거리영상 분할에 적용하였다. LKS는 자승오차의 중간값을 최소화하는 LMedS와는 달리  $k$ 번째 자승오차를 최소화함으로써 LMedS보다 outlier에 강한 특성을 나타내며, 관측치의 잡음 정도를 예측하는데 이용되는 inlier 갯수를 고정시킨 RESC와는 달리 주어진 관측치에 따라 가변적인 inlier 갯수를 설정한다. 또한 기존의 robust 회귀분석을 이용한 거리영상 분할 알고리즘에 대해 고찰하고, LKS를 이용한 반복적 거리영상 분할 알고리즘을 제안하였다. 본 논문의 II장에서는 기존의 robust 회귀분석과 LKS를 비교 분석하였으며, III장에서는 기존의 robust 회귀분석을 이용한 거리영상 분할 알고리즘과 제안한 LKS 기반 반복적 거리영상 분할 알고리즘의 성능을 비교 분석하였고, 마지막으로 IV장에서 결론을 맺었다.

## II. Robust 회귀분석

본 장에서는 LMedS의 변형인 LKS를 유도하고 기존의 robust 회귀분석과 비교 분석한다. 1절에서는 기존의 robust 회귀분석에 대해 알아보고, 2절에서 LKS를 유도하며, 3절에서 기존의 robust 회귀분석과 LKS의 성능을 1차원 신호에 대한 모의실험을 통해 비교 분석한다.

### 1. 기존의 robust 회귀분석

$n$ 개의 관측치  $(x_{i,0}, \dots, x_{i,p-1}, y_i)$ 를  $p$ 개의 계수  $\beta_j$ 를 갖는 선형 모델로 기술한다고 하자.<sup>[16]</sup>

$$y_i = \sum_{j=0}^{p-1} \beta_j x_{i,j} + e_i, \quad i = 1, \dots, n \quad (1)$$

여기서  $x_{i,j}$ 는 독립변수,  $y_i$ 는 종속변수,  $\beta_j$ 는 계수이며,  $e_i$ 는 평균이 0이고 표준편차가  $\sigma$ 인 가우시안 잡음이다. 이때 관측치  $(x_{i,1}, \dots, x_{i,n}, y_i)$ 로부터 계수  $\beta_j$ 를 구하는 것을 회귀분석이라고 하며, 주어진 값  $y_i$ 와 복원된 값  $\hat{y}_i$ 와의 차이  $r_i$ 를 오차라고 한다.

대표적인 회귀분석은 LS이며 다음의 목적함수를 최소화한다.

$$\sum_{i=1}^n r_i^2 \quad (2)$$

이 방법은 주어진 관측치에 첨가된 잡음이 평균이 0인 가우시안 분포를 가질 경우 최적의 성능을 나타내

며 구현이 간단하여 컴퓨터 비전의 많은 분야에서 사용되어 왔다. 그러나 첨가된 잡음이 평균이 0인 가우시안 분포가 아닌 경우, 즉 impulse성 잡음이 존재하거나 서로 다른 두 영역이 만나는 곳에서는 잡음에 강건하지 못한 특성을 나타낸다. 이러한 LS의 한계를 극복하고자 최근 통계학 분야에서 도입되어 사용되는 기법이 바로 robust 회귀분석이다. Robust 회귀분석의 성능을 평가하는 기준으로는 breakdown point, relative efficiency, complexity, convergence rate 등이 있다.<sup>[12]</sup> 특히 Hampel에 의해 도입된 breakdown point는 상이한 추정 결과를 유도하는 왜곡된 관측치들이 전체 관측치에서 차지하는 최소비율을 의미하며, 이때 왜곡된 관측치들을 outlier라고 하고 그 반대 개념을 갖는 관측치들을 inlier라고 한다. LS의 경우 모든 관측치의 오차를 최소화하기 때문에 하나의 왜곡된 관측치라도 추정 결과를 상이하게 바꾸어 놓게 되므로 breakdown point가 0이다.

초기에 발표된 robust 회귀분석에는 maximum likelihood type estimation (M-estimation), estimation based on the rank transform (R-estimation), linear combinations of order statistics (L-estimation) 등이 있다.<sup>[10]</sup> M-, R-, L-estimation들은 LS보다 강건한 특성을 갖지만  $1/(\rho+1)$ 이라는 낮은 breakdown point가 단점이다. 이후 발표된 50% breakdown point 회귀분석으로 Siegel의 repeated median (RM)과 Rousseeuw의 LMedS 등이 있으나, RM의 경우 많은 계산량이 단점이며, 두 회귀분석 모두 50%라는 제한된 breakdown point를 갖는다.<sup>[11]</sup>

컴퓨터 비전 분야에서 발표된 최근의 robust 회귀 분석은 대부분 50% 이상의 breakdown point를 나타내고 있으며, Yu 등이 제안한 RESC<sup>[14]</sup>와 Stewart가 발표한 MINPRAN<sup>[15]</sup> 등이 있다. Yu 등은 미리 정해진 갯수의 근사화 오차를 기준으로 압축된 히스토그램을 구성한 후, 이 히스토그램의 power를 목적함수로 이용하여 선형적으로 알려져 있지 않은 inlier의 잡음 분포를 미리 정한 비율의 근사화 오차로 예측하고 inlier와 outlier를 구분하는 기준으로 사용하였다. 또한 근사화 오차만을 기준으로 하던 기존의 목적함수를 수정하여 근사화 오차와 inlier의 갯수 모두를 고려한 아래의 목적함수를 사용하였다.

$$\psi = \sum_{i=1}^q \frac{h_i^\alpha}{|r_i|^\beta} \quad (3)$$

여기에서  $q$ 는 압축된 히스토그램중 inlier로 판정된 bin들의 갯수,  $h_i$ 는  $i$ 번째 bin의 빈도수,  $r_i$ 는 해당 bin의 근사화 오차이고,  $\alpha$ 와  $\beta$ 는 근사화 오차와 inlier 갯수의 비중을 조절하는 파라미터이다. Stewart는 outlier가 균일분포를 갖는다는 가정하에 주어진 관측치의 randomness를 아래의 식으로 평가하고 inlier와 outlier의 판별 기준으로 삼았다.

$$\begin{aligned} F(r, k, n) &= \sum_{i=k}^n \binom{n}{i} \left(\frac{r}{z_0}\right) \left(1 - \frac{r}{z_0}\right)^{n-i} \cdot z_0 \\ &= \frac{z_{\max} - z_{\min}}{2} \end{aligned} \quad (4)$$

여기에서  $F$ 는  $n$ 개의 관측치중 최소  $k$ 개 이상이 inlier일 확률을 의미하며,  $r$ 은 inlier를 구분하는 잡음의 표준편차,  $z_{\min}$ 와  $z_{\max}$ 는 각각 미리 정해진 관측치의 최소값과 최대값이다. MINPRAN은 위의 randomness 함수를 최소화하는 계수  $\beta$ 와  $r, k$ 를 동시에 결정하므로 탐색영역이 기존의 방법에 비해 크다는 단점이 있다.

Jolion 등은 Rousseeuw의 군집화 기법인 MVE를 일반화한 generalized MVE (GMVE)를 제안하였다.<sup>[13]</sup> MVE는 LMedS를 군집화 알고리즘에 적용한 것으로서 최적의 군집을 구하기 위해 정렬된 오차들의 중간값을 최소화한다. 이에 반하여 Jolion 등은 임의의 비율을 최소화하는 GMVE를 사용하여 미리 설정된 여러 비율중 최적의 군집을 형성하는 비율을 선택하였다. 본 논문에서는 Jolion 등의 일반화 과정과 마찬가지로 LMedS의 일반화를 수행하였다.

## 2. Least kth-order square

본 논문에서는 기존의 LMedS 개념을 확장한 least kth-order square (LKS)를 유도하였다. 기존의 LMedS는 자승오차의 중간값을 최소화하는 반면 LKS는  $k$ 번째 자승오차를 최소화하기 때문에 LMedS보다 높은 breakdown point를 갖는다. 통계학에서 Rousseeuw에 의해 처음 제안된 LMedS는 아래의 목적함수를 최소화한다.

$$\text{med}_i r_i^2 \quad (5)$$

위의 목적함수는 분석적인 방법으로 해를 구할 수

없으므로 실제구현시 무작위 추출 (random sampling) 기법을 이용한다.  $p$ 개의 관측치를 무작위로 추출하여  $p$ 개의 계수를 구하고, 구해진 계수를 이용하여 주어진  $n$ 개의 관측치의 자승오차를 계산한다. 이후 자승오차의 중간값을 구하여 그것을 앞에서 구한 계수의 목적함수값으로 사용한다. 위의 작업을  $m$ 번 반복하면서 가장 작은 목적함수값을 갖는 계수를 최종 계수로 선택한다. LMedS를 처음 컴퓨터 버전 분야에 적용한 Meer등은 다차원의 관측치를 1차원에 투영하여 문제를 해결하는 projection pursuit 기법을 이용하여 LMedS를 구현하였다.<sup>[12]</sup>  $p$ 개의 관측치를 무작위로 추출하여 절편 (intercept)에 해당하는 계수 즉 0차 계수를 제외한  $p-1$ 개의 계수를 구하고 주어진  $n$ 개의 관측치에 대한 근사화 오차를 계산한다. 계산된 오차를 정렬하고, 전체 관측치 개수의 반에 해당하는 크기의 윈도우를 이용하여 정렬된 오차에서 최빈값 (mode)을 찾는다. 최빈값 추출시 얻어지는 근사화 오차의 표준편차를 목적함수로 사용하여 위의 작업을 반복하면서 가장 작은 목적함수값을 갖는 계수를 최종 계수로 선택한다.

LKS는 아래의 목적함수를 최소화한다.<sup>[11]</sup>

$$(r^2)_{k;n} \quad (6)$$

여기서 위의 목적함수는 올림차순으로 정렬된 자승오차중  $k$ 번째 자승오차를 의미한다. 위의 목적함수는 Rousseeuw에 의해 언급된 바가 있는 변형된 LMedS로서  $k$ 번째 자승오차를 최소화함으로써 LMedS의 50%보다 큰 breakdown point를 얻을 수 있다. LMedS는  $k$ 가  $[(n+1)/2]$ 일 경우에 해당한다. 여기서  $[\cdot]$ 는 실수를 정수로 내림하는 연산자이다. LKS는 위에서 언급한 projection pursuit 기법에서 윈도우 크기를 정해진  $k$ 에 따라 다시 설정하여 구현한다. LMedS의 경우 중간값 추출을 위해 전체 관측치 개수의 반에 해당하는 크기의 윈도우를 사용하는 반면 LKS는 정해진  $k$ 에 비례한 크기의 윈도우를 사용한다. 예로 전체 관측치 개수의 30%에 해당하는  $k$ 에 대한 LKS의 구현시에는 전체 관측치 개수의 30%에 해당하는 크기의 윈도우를 사용한다. 아래는 LKS 추정과정을 단계별로 설명한 것이다.

$n$ 개의 관측치  $(x_i, y_i)$ 에 대한  $p$ 개의 계수  $\hat{\beta}_i$ 를 구한다고 가정한다.

단계 1. 서로 다른  $p$ 개의 샘플  $(x_i, y_i)$ ,

$i = 0, \dots, p-1$ ,를 추출한다.

단계 2. LS을 이용하여 추출된  $p$ 개 샘플에 대하여 0차 계수를 제외한  $p-1$ 개의 계수  $\hat{\beta}_i, i = 1, \dots, p-1$ 를 계산한다.

단계 3. 구해진  $p-1$ 개의 계수를 이용하여 각 관측치에 대한 오차  $r_i$ 를 계산한다.

$$r_i = y_i - \sum_{j=1}^{p-1} \hat{\beta}_j x_j, i = 0, \dots, n-1 \quad (7)$$

단계 4. 오차  $r_i$ 를 올림차순으로 정렬한다.

단계 5. 크기가  $k$ 인 윈도우를 이용하여  $k$ 만큼 떨어져 있는 오차들간의 차이  $d_i$ 를 구한다.

$$d_i = \frac{r_{i+k} - r_i}{2}, i = 0, \dots, n-1-k \quad (8)$$

단계 6. 구해진 차이  $d_i$ 중 최소인 차이  $d_i$ 를 찾고 최빈값  $\hat{\beta}_0$ 를 구한다.

$$\hat{\beta}_0 = \frac{r_{i+k} + r_i}{2} \quad (9)$$

단계 7. 위의 단계들을 반복하여 구해진  $d_i$ 중 최소인  $\hat{d}_i$ 를 찾고 그것에 해당되는 계수를 최종결과로 구한다.

위에서 구한  $\hat{\beta}_0$ 와 정렬된 오차  $r_i$  및 차이  $d_i$ 은

$$(\hat{\beta}_0 - r_i)^2 \begin{cases} \leq d_l^2, & \text{if } l < i < l+k, \\ = d_l^2, & \text{if } i = l \text{ or } i = l+k, \\ \geq d_l^2, & \text{if } 0 < i < l \text{ or } l+k < i \leq n-1 \end{cases} \quad (10)$$

를 만족한다.<sup>[16]</sup> 또한

$$d_i^2 = (\hat{\beta}_0 - r_i)_{k;n}^2 = \left( \sum_{j=0}^{k-1} \hat{\beta}_j x_j - y_i \right)_{k;n}^2 \quad (11)$$

이 성립되며  $\hat{d}_i$ 에 의해 결정되는 계수는 주어진 관측치에 대한  $k$ 번째 자승오차를 최소화한다.

위의 알고리즘은  $n$ 개의 관측치에서  $p$ 개의 샘플을 추출하므로 모든 경우를 시행할 경우, 반복 횟수는  $nC_p$ 이 된다. 반복 횟수  $nC_p$ 는  $p$ 가 증가함에 따라 급격히 증가하므로, 위의 알고리즘의 실제적인 구현이 불가능해진다. 그러나  $p$ 개의 샘플을 무작위로 추출할 경우, 아래의 조건을 만족하는 반복횟수를 사용하여 계산량을 감축시킬 수 있다. 무작위 추출을  $m$ 회 반복할 경우 1회라도 추출된 샘플  $p$ 개가 모두 inlier일 확률은 다음과 같다.

$$1 - [1 - (1 - \epsilon)^p]^m \leq 1 - Q \quad (12)$$

여기에서  $Q$ 는 추정오류 확률이고  $\epsilon$ 는 전체 관측치에 대한 outlier의 최대점유 비율이다. 예를 들어 주어진  $8 \times 8$  ( $n = 64$ ) 블록을 평면 ( $p = 3$ )으로 근사화할 경우, 모든 경우를 시행하려면 41664번 반복해야 하지만, 5% ( $Q = 0.05$ )의 오류확률과 75% ( $\epsilon = 0.75$ )의 outlier를 가정하고 무작위로 추출할 경우, 190번의 반복만으로 95% ( $= 1 - Q$ )의 신뢰성을 얻을 수 있다.

구해진 계수를 이용하여 주어진 관측치에 첨가된 잡음의 표준편차 (scale)를 예측한다.

$$\hat{s} = c \left( 1 + \frac{5}{(n-p)} \right) \hat{d}_i \quad (13)$$

여기에서  $c$ 는 첨가된 잡음이 가우시안 분포를 갖는다는 가정하에 취해지는 보정인자이며,  $1 + 5/(n-p)$ 는 주어진 관측치의 개수가 작을 경우 잡음의 표준편차가 과소평가 (underestimate)되는 것을 보정하기 위해 Rousseeuw에 의해 권장된 인자이다.

이후 각 관측치에 대한 가중치를 계산한다. 아래의 가중치에 따라 각 관측치를 inlier와 outlier로 구분한다. 즉 아래 식에서 가중치 1을 가지면 inlier로, 0을 가지면 outlier로 간주한다.

$$w_i = \begin{cases} 1, & |r_i| \leq 2.5 \hat{s} \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

위 식에서 사용되는 2.5는 관측치에 첨가된 잡음이 가우시안 분포를 갖는다는 가정하에 최대 분포값의 4.4% 이하로 감소하는 관측치를 outlier로 배제하기 위한 보정인자이다.

위에서 구한 계수들은  $p$ 개의 관측치 샘플에서 구한 값들이므로  $n$ 개의 관측치 모두를 고려한 LS보다 efficiency 측면에서 낮은 성능을 나타낸다. 따라서 주어진 가중치를 이용한 weighted least squares (WLS)을 취하여 LS보다 높은 breakdown point를 가지면서도 efficiency 측면에서 동등한 성능을 갖는 계수값을 얻는다.<sup>[12]</sup>

지금까지 기술한 LKS는 고정된  $k/n$ 를 이용하며, 대부분의 컴퓨터 비전 문제는  $k/n$ 을 0.1 정도로 설정하여 만족스런 결과를 얻을 수 있다. 그러나 전체 관측치에 대한 inlier의 비율은 주어지는 관측치에 따라 다르므로, 주어지는 관측치에 따라 최적의  $k/n$ 를 설정할 필요가 있다. 실제로 1차원 관측치에 대한 실험 결과

에 따르면 실제 inlier의 비율에 비해 작은  $k/n$ 을 설정할 경우 잡음의 표준편차를 과소평가하게 되어 실제보다 적은 inlier를 추출하게 된다. 반대로 실제 inlier의 비율에 비해 큰  $k/n$ 를 설정할 경우 잡음의 표준편차를 과대평가 (overestimate)함은 물론이고 회귀분석 결과 자체를 왜곡시키게 된다. 예로 LMedS ( $k/n$ 이 0.5인 LKS)의 경우 마모된 에지 근처 (inlier 비율이 0.5 이하)에서 LS와 비슷한 왜곡된 추정결과를 가져온다.

MINPRAN<sup>[15]</sup>의 경우 randomness 함수를 이용하여 inlier의 비율을 결정하며, GMVE<sup>[13]</sup>의 경우 Kolmogorov-Smirnov test를 이용한다. LKS의 경우에는 미리 몇개의 비율을 설정하고 각 비율에 의해 구해진 inlier들의 정규화된 절대값 오차의 평균을 평가기준으로 최적의 비율을 선택한다. 따라서 LKS는 다음의 목적함수를 최소화한다.

$$\frac{1}{q_k} \sum_{i=0}^{q_k-1} \frac{|r_{k,i}|}{s_k} \quad (15)$$

여기서  $r_{k,i}$ 는 주어진 비율  $k/n$ 에 따라 추정된 표준편차  $s_k$ 로 구한 inlier들의 근사화오차이며,

$q_k$ 는 inlier의 개수이다. 실제 구현시에는 계산량을 고려하여 0.05 간격으로 0.05부터 0.95까지 19개의 비율을 사용하였으며, 우선 각 비율별로 계수, scale 및 inlier를 구한 후, 19개의 비율에 대한 각각의 절대평균오차를 비교하여 최소의 절대평균오차를 갖는 비율을 선택하였다.

### 3. 1차원 신호에 대한 모의실험 결과

본 절에서는 기존의 robust 회귀분석들과 LKS의 성능을 비교하기 위해 아래 5가지 1차원 신호 ( $x, y$ )에 대한 직선 4근사화 결과에 대해 논한다.

그림 1(a)에 나타나있듯이 신호 1, 2는 하나의 직선으로 구성되어 있으며 신호 1은 기울기가 0이고 신호 2는 기울기가 0이 아니다. 나머지 신호 3, 4, 5는 둘 혹은 세 직선이 혼합되어 있으며 신호 3은 step 에지의 단면, 신호 4는 roof 에지의 단면, 신호 5는 계단형 step 에지의 단면이다. 모든 신호들에 대해 표준편차가 1인 가우시안 잡음을 첨가하여 실험하였다.

#### 1) 여러 robust 회귀분석의 비교실험

앞에서 설명한 LS, LMedS, RESC, MINPRAN, LKS 등의 성능을 비교하였다. RESC의  $\rho$ 값은 0.12




그림 1. Robust 회귀분석들의 성능비교

(a) 입력신호 (b) 신호 1 (c) 신호 2 (d) 신호 3 (e) 신호 4 (f) 신호 5

Fig. 1. Performance comparison of robust regressions.

(a) input signals, (b) signal 1, (c) signal 2, (d) signal 3, (e) signal 4, (f) signal 5.

로, MINPRAN의  $z_0$ 는 50으로 고정하여 실험하였다. LS를 제외한 나머지 회귀분석은 모두 무작위 추출을 이용하므로 신호 1, 2에 대해 1000회 반복실험하였다. 신호 2, 3, 4의 경우 둘 혹은 세 직선으로 구성되어 있으므로 실험을 반복할 때마다 서로 다른 직선을 기준으로 결과가 얻어지므로 반복실험이 아닌 1회 실험

한 결과를 나타내었다.

그림 1(b)는 신호 1에 대한, 그림 1(c)는 신호 2에 대한 반복실험 결과이며, 각 회귀분석마다 반복실험에서 얻어진 계수와 오차를 평균을 취해 나타낸 것이다. 그림 1(b)의 경우 모든 관측치를 고려하는 LS가 가장 작은 오차를 나타내었으며, LKS, LMedS,

MINPRAN, RESC 순으로 작은 오차를 나타내었다. 그림 1(c)의 경우는 LS, LMedS, LKS, MINPRAN, RESC 순으로 작은 오차를 나타내었다. LS가 efficiency 측면에서 가장 우수한 성능을 나타내었으나 앞의 2절에서 언급했듯이 나머지 4개의 회귀분석들은 inlier 추출후 WLS를 이용하여 efficiency의 개선이 가능하다.

그림 1(d), 1(e), 1(f)는 각각 신호 3, 4, 5에 대한 실험 결과이다. 모두 둘 혹은 세 직선으로 구성되어 있으므로 각 회귀분석의 불연속에서의 강건성을 관찰할 수 있다. 신호 3과 신호 4의 경우, 두 직선이 전체 관측치를 50%씩 점유하고 있다. 따라서 하나의 직선의 입장에서 본다면 다른 쪽 직선은 outlier로 고려되므로 어느 직선의 입장에서나 outlier가 50%로 구성되어 있다. 신호 5의 경우 전체 관측치를 40%, 30%, 30%씩 점유하는 직선들이 혼합되어 있으므로 outlier는 최소 60%에서 최대 70%까지이다. 그림 1(d)를 살펴보면 LMedS, RESC, LKS 모두 올바른 결과를 가져왔으나, LS와 MINPRAN의 경우 잘못된 결과를 가져왔다. LS의 경우 모든 관측치를 고려하기 때문에 들중에 하나의 직선에 근사화되지 못하고 두 직선에 걸쳐 근사화되는 현상이 발생한다. 한편 MINPRAN의 경우 관측치의 randomness를 고려하기 때문에 randomness 값이 작은 하나 이상의 관측치 집합이 존재시 위의 결과와 같이 두 집합을 모두 만족시키는 잘못된 결과를 가져온다. Stewart의 논문에 위의 현상에 대한 언급과 그에 대한 heuristic한 개선책이 서술되어 있다.<sup>[15]</sup> 그림 1(e)는 거리영상에서 두드러지게 나타나는 roof 에지의 단면에 대한 실험결과이며, LS를 제외한 모든 회귀분석이 올바른 결과를 나타내고 있다. 그림 1(f)의 경우, LKS와 RESC를 제외한 모든 회귀분석이 잘못된 결과를 나타내었다. LMedS의 경우 50%이상의 outlier가 존재하므로 LS와 비슷한 잘못된 결과를 가져왔다. 첫번째 직선은 세 직선중 가장 큰 비율을 점유하는 반면 세번째 직선은 세 직선중 가장 적은 점유가 첨가되어 있는 직선이다. RESC의 경우 앞 1절의 식 (3)에서처럼 근사화오차와 더불어 inlier의 갯수를 함께 고려하기 때문에 첫번째 직선을 선택하였으며, LKS의 경우 inlier 갯수와는 관계없이 근사화 오차만을 고려하므로 세번째 직선을 선택하였다. RESC에 의해 추정된 첫번째 직선의 근사화 오차의 평균은 0.9654이며, LKS에 의해 추정된 세번째

직선의 근사화 오차의 평균은 0.7860이다.

결론적으로 불연속이 존재하지 않는 경우 LS가 가장 좋은 특성을 나타내었으며, 불연속이 존재하는 경우, LKS와 RESC가 올바른 추정 결과를, 나머지 LMedS, MINPRAN, LS 등은 잘못된 추정 결과를 나타내었다. LMedS의 경우 60%이상의 outlier가 존재하는 신호 5에 대해 잘못된 추정 결과를 나타내었으며, MINPRAN의 경우 50% outlier가 존재하는 신호 3과 60% 이상의 outlier가 존재하는 신호 5에 대해 잘못된 추정 결과를 나타내었다.

2)  $k/n$ 의 변화에 따른 LKS의 성능 비교실험  
0.05에서 0.95까지 19개의  $k/n$ 에 대한 LKS의 성




그림 2.  $k/n$ 에 따른 변화  
(a) 절대평균오차 (b) 당첨비율  
(c) inlier 비율

Fig. 2. Variation as a function of  $k/n$ .  
(a) absolute mean error, (b) vote ratio, (c) inlier ratio.

능을 관찰하였다. 입력신호 5개에 대한 LKS 추정결과를 그림 2에 나타내었다. LKS는 무작위 추출을 이용하여 구현하므로 1000회 반복실험하여 그 결과의 평균을 취하였다. 절대평균오차는 구해진  $q$ 개의 inlier들에 대해

$$\frac{1}{q} \sum_{i=0}^{q-1} |r(x_i)| / \hat{s} = \frac{1}{q} \sum_{i=0}^{q-1} |y(x_i) - \beta_0 - \beta_1 x_i| / \hat{s} \quad (16)$$

와 같이 추정오차  $r(x_i)$ 의 절대값을 scale  $\hat{s}$ 로 정규화 (normalize)하여 평균을 취하였으며, 당첨비

율은 절대평균오차를 평가기준으로 19개의  $k/n$ 중 최적의 결과를 나타내는 비율을 하나씩 골라 당첨비수를 계산할 경우, 1000회 반복실험에 대한 각  $k/n$ 이 선택된 횟수를 %로 나타낸 것이다.

신호 1과 2의 경우 불연속이 존재하지 않으므로 100%가 기대되는 inlier의 비율이다. 그림 2(a)를 살펴보면 신호 1과 2 모두 0.85이 가장 큰 당첨비율을 나타내고 있다(신호 1의 경우 64.0%, 신호 2의 경우 68.0%). 절대평균오차를 평가기준으로 최적의  $k/n$ 을 설정할 경우, 0.85가 신호 1과 2에 대해 각각 100.0%와 97%의 inlier 비율을 나타내어 대부분 관측치를 inlier로 선택하고 있다.

신호 3과 4는 outlier가 50%씩 존재하는 불연속 신호들이다. 신호 3은 원래 50%의 outlier를 가지고 있으나 잡음이 첨가되었기 때문에 안정된 결과를 얻기 위해서  $k/n$ 을 0.45로 설정해야 한다. 왜냐하면  $k/n$ 을 0.45보다 작게 설정할 경우 관측치의 잡음 정도를 과소평가하게 되어 실제보다 적은 inlier를 추출하게 되고 반대로  $k/n$ 을 크게 설정할 경우 LKS의 추정결과 자체가 왜곡되기 때문이다. 신호 4의 경우 roof 에지의 단면으로서 불연속에서 두 직선이 서로 연결되어 있으므로 실제로는 50%보다 적은 outlier를 가지고 있다. 따라서 신호 4에 적합한  $k/n$ 은 0.5이다. 신호 3의 경우 0.45가 97.8%, 신호 4는 0.5가 99.9%로 가장 큰 당첨비율을 나타내고 있으며, 각 비율에 관련된 inlier의 비율 또한 50.0%와 53.1%로서 만족스런 결과를 나타내고 있다. 신호 5의 경우 30%의 inlier를 가지는 불연속 신호이다. 그림 2를 살펴보면 0.3이 99.7%로 가장 큰 당첨비율을 나타내고 있으며, 관련된 inlier의 비율은 34.1%로 나타나고 있다.

결론적으로 절대평균오차를 기준으로 최적의 비율을 선택할 경우 각 신호에 기대되는  $k/n$ 이 1000회 반복

실험을 통해 만족스러운 당첨비율을 가지고 선택됨을 확인할 수 있다.

### III. Robust 회귀분석을 이용한 제안한 거리영상 분할

본 장에서는 robust 회귀분석을 이용한 거리영상 분할에 대하여 논한다. 1절에서는 기존의 robust 회귀 분석을 이용한 거리영상 분할 알고리즘에 대하여, 2절에서는 제안한 LKS를 이용한 반복적 거리영상 분할 알고리즘에 대하여 논하고, 마지막으로 3절에서 각 거리영상 분할 알고리즘에 대한 모의실험 결과를 보였다.

1. 기존의 robust 회귀분석을 이용한 거리영상 분할  
Meer 등은 Rousseeuw가 제안한 LMedS를 거리영상의 분할에 적용하였다.<sup>112</sup> 그들은 LMedS의 step 에지와 roof 에지에 대한 모의실험을 통해 올바른 결과의 추출을 위해서는 화소단위 추출만으로는 충분한 결과를 얻을 수 없으며 인접한 화소간의 상관성을 이용해야 한다고 주장하였다. Meer 등의 알고리즘은 두 단계로 이루어져 있으며, 첫번째 단계에서는 크기가 작은 윈도우를 이용하여 잡음을 제거하고 화소단위로 계수 및 scale을 추출하였다. 두번째 단계에서는 전체 영상을 크기가 같은 블럭으로 나누고 첫번째 단계에서 각 화소별로 구해진 계수중 최적의 계수를 그 블럭의 계수로 결정하였다. 이후 각 블럭의 inlier와 outlier를 구하고 인접 영역간의 병합을 시도하여 최종적으로 거리영상을 분할하였다.

Jolion 등은 Rousseeuw가 제안한 MVE를 일반화하여 GMVE를 제안하고, GMVE에 기반한 군집화로 거리영상을 분할하였다.<sup>113</sup> 계산량의 감축을 위해 거리영상을 서로 겹치는 블럭들로 나눈 후 각 블럭에 대해 M-estimation으로 계수를 추정하였다. 이후 구해진 계수들을 GMVE의 입력 관측치로 사용하여 반복적으로 최적의 군집을 찾았다. 이후 찾어진 군집들을 거리영상내의 각 화소에 대응시켜 씨앗영역을 추출하고 영역성장법을 이용하여 최종적으로 거리영상을 분할하였다. Rousseeuw가 처음 제안한 MVE와 달리 GMVE는 군집화의 해상도를 결정하는  $h$ 값을 0.5가 아닌 0.05에서 0.5까지 변화시켜 개선된 결과를 가져왔다. 그러나 군집화 단계에서 추출된 영역들은 영역성장의 씨앗영역 역할만 하고 있으며, 대부분의 영역경계



는 영역성장에 의존하고 있는 문제점이 있다.

Yu 등은 근사화 자승오차의 압축된 히스토그램에 기반한 RESC 알고리즘을 이용하여 거리영상을 분할하였다.<sup>[14]</sup> 우선 전처리로서 거리영상내의 step 에지를 찾아 분리된 각 영역별로 RESC 알고리즘을 적용하였다. 주어진 영역에 대해 무작위 추출을 반복하면서 각 시도별로 근사화 자승오차 히스토그램을 압축하고 그것의 power를 구하여 가장 큰 power를 갖는 히스토그램의 계수를 선택하였다. 또한 히스토그램의 첫째 bin을 이용하여 관측치에 첨가된 잡음의 분산을 추정하고 inlier와 outlier를 구분하였다. 이후 구해진 inlier 부분에 번호를 할당하고, 고립된 outlier 부분을 인접한 inlier 영역에 병합하였다. 이 작업을 전처리에서 분리된 각 영역에 대해 번호할당이 되지 않은 화소가 문턱값보다 작아질 때까지 반복하여 거리영상을 분할하였다. 또한 무작위 추출의 성능개선을 위해 유전자 알고리즘 (genetic algorithm)을 적용하였다. Yu 등의 방법은 빠르면서 올바른 결과를 나타내지만 사용자가 결정하는 파라미터가 많다는 단점이 있다.

## 2. LKS를 이용한 제안한 반복적 거리영상 분할

본 논문에서는 LKS를 이용한 반복적 거리영상 분할 알고리즘을 제안하였다. LKS는 LMedS와 다른 달리 breakdown point가 50%로 한정되어 있지 않으므로 기존의 LMedS를 이용한 거리영상 분할 알고리즘처럼 전체 영상을 인위적으로 분할하지 않고, 전체 영상을 하나의 탐색영역으로 간주하여 분할 알고리즘을 실행시킨다.

단계 1. 전체 영상  $I$ 에서 아직 영역 할당이 이루어지지 않은 부분들중 가장 큰 부분을 찾아 탐색영역  $S$ 로 결정한다.

단계 2. 주어진 탐색영역  $S$ 에 대해 LKS 알고리즘을  $m$ 번 반복하여 계수  $\beta$ 와 잡음의 표준편차  $\sigma$ 를 구하고 inlier와 outlier 부분을 구분한다.

단계 3. 구해진 inlier 부분중 가장 큰 부분을 찾아 영역번호를 할당하고 나머지 부분은 outlier로 간주한다.

단계 4. 단계 3에서 구해진 inlier 영역에 대해 WLS 추정을 수행한다. 계수  $\beta$ 와 잡음의 표준편차  $\sigma$ 를 갱신하고, 탐색영역  $S$ 를 inlier와 outlier 부분으로 다시 구분한다.

단계 5. 구해진 inlier 부분에 영역번호를 할당하고 추정된 계수  $\beta$ 와 잡음의 표준편차  $\sigma$ 를 저장한다.

단계 6. 단계 5에서 구해진 outlier중 inlier 영역에 의해 고립된 부분들을 찾아 인접한 inlier 영역으로 병합한다.

단계 7. 단계 1부터 6까지 반복하면서 영역 할당이 이루어지지 않은 부분이 문턱값  $\mu$ 보다 작아지면 본 알고리즘을 마친다.

본 알고리즘은 1단계에서 탐색이전에 탐색영역을 제한하므로 반복횟수가 증가함에 따라 탐색영역이 줄어들게 된다. 따라서 LKS 추정에서의 무작위 추출 횟수를 50으로 고정하였다. 서로 다른 물체가 비슷한 거리값을 가질 경우 하나의 영역으로 추출되는 것을 방지하기 위해 단계 2에서 추출된 inlier중 가장 큰 영역만을 단계 3에서 추출하였다. 앞에서 언급했듯이 LKS는 무작위 추출에 기반을 두기 때문에 LS보다 efficiency가 떨어지므로 단계 4에서 WLS 추정을 적용하여 efficiency를 개선하였다. 단계 6에서는 고립된 outlier를 인접한 inlier 영역에 병합하였다. 단계 7의 문턱값  $\mu$ 가 너무 작으면 불필요한 영역까지 추출되며 너무 크면 의미있는 영역을 추출하지 못하게 된다. 따라서  $\mu$ 를 100으로 고정하여 실험하였다.

본 알고리즘에서는 모든 거리영상을 1차 다항식으로 근사화하였다. 고차 다항식은 서로 다른 영역을 하나의 영역으로 잘못 추출할 수 있기 때문이다. 또한 고차 다항식은 LKS의 무작위 추출 횟수의 급격한 증가를 요구한다. 예로 1차 다항식의 경우 무작위 추출 50회 정도로 만족할 만한 결과를 얻을 수 있으나 3차 다항식의 경우 무작위 추출 1만회 이상으로도 올바른 결과를 얻지 못한다. 고차 곡면으로 이루어진 거리영상의 경우 본 알고리즘을 적용하면 하나의 곡면이 여러 개의 평면으로 나누어지게 된다. 따라서 낮은 차수에 의해 나누어진 영역들을 고차 다항식으로 병합하는 과정이 필요하다. 영역 병합은 주어진 두 영역에 대한 LS 추정에서 얻어지는 inlier 분포를 이용한다. 두 영역을 하나의 영역으로 간주하여 계수와 scale을 추정하고 scale의 크기로 병합 여부를 결정할 경우 불연속이 포함되어 잘못된 결과를 나타낸다. 따라서 인접한 두 영역에 대해 두 영역의 크기를 비교하고 크기가 큰 영역으로 병합 영역의 계수와 scale을 추정 후 크기가 작은 영역의 inlier 비율로 병합여부를 결정하였다.

## 3. 합성 및 실제 거리영상에 대한 모의실험 결과

본 장에서는 기존의 거리영상 분할 알고리즘과 제안




그림 3. 합성 거리영상의 그레이 레벨 표현

- (a) 합성 거리영상 1 (b) 합성 거리영상 2 (c) 합성 거리영상 3
- (d) 합성 거리영상 4 (e) 합성 거리영상 5 (f) 합성 거리영상 6

Fig. 3. Gray level representation of synthetic range images.

- (a) synthetic range image 1. (b) synthetic range image 2. (c) synthetic range image 3.
- (d) synthetic range image 4. (e) synthetic range image 5. (f) synthetic range image 6.

한 거리영상 분할 알고리즘에 대한 성능을 평가하기 위하여 수행한 합성 및 실제 거리영상에 대한 모의실험 결과에 대해 논한다.

1) 입력 거리영상에 대한 설명

합성 거리영상은 컴퓨터 그래픽에서 쓰이는 ray tracing 알고리즘을 이용하여 제작하였으며 해상도는  $256 \times 256$ 이고 화소값은 실수로 이루어져 있다.<sup>[17]</sup> 그림 3은 모의실험에 사용한 합성 거리영상의 그레이 레벨 표현이다. 그림 3에서 어두운 화소가 거리값이 크고 밝은 화소가 거리값이 작다. 그림 3(a)와 3(b)는 평면만으로 이루어진 거리영상이며, 그림 3(c), 3(d), 3(e), 3(f) 등은 곡면과 평면이 혼합된 거리영상이다. 그림 3(a)는 다양한 구조물로 이루어진 합성 거리영상이며 III-3절에서 기존의 알고리즘과 제안한 알고리즘

을 비교하기 위해 사용하였다. 그림 3(b)는 정육면체 하나로 이루어진 간단한 구조의 합성 거리영상이며, 그림 3(c)는 제안한 LKS를 이용한 반복적 알고리즘의 고차 곡면에 대한 분할결과를 분석하기 위해 사용하였다. 나머지 그림 3(d), 3(e), 3(f) 등은 평면과 곡면이 혼합된 복잡한 구조를 가진 합성 거리영상이며 제안한 LKS를 이용한 반복적 알고리즘의 성능을 평가하기 위해 사용하였다.

실제 거리영상은 서울대학교 제어계측 신기술 연구센터 (ERC-ACI)에서 레이저 거리 측정기를 이용하여 실제 3차원 물체에 대한 거리값을 취득한 것이다.<sup>[18]</sup> 거리영상의 해상도는  $256 \times 256$ 이며 각 화소의 위치 (x, y)와 거리값 z의 정밀도는 0.1mm이다. 그림 4는 실제 거리영상에 대한 그레이 레벨 표현이다. 그림




그림 4. 실제 거리영상의 그레이 레벨 표현

(a) 실제 거리영상 1 (b) 실제 거리영상 2 (c) 실제 거리영상 3  
 (d) 실제 거리영상 4 (e) 실제 거리영상 5 (f) 실제 거리영상 6

Fig. 4. Gray level representation of real range images.

(a) real range image 1. (b) real range image 2. (c) real range image 3.  
 (d) real range image 4. (e) real range image 5. (f) real range image 6.




그림 5. 합성 거리영상에 대한 분할 결과 ( $\sigma = 0.1$ )

(a) 합성 거리영상 2 (b) 합성 거리영상 4  
 (c) 합성 거리영상 5 (d) 합성 거리영상 6

Fig. 5. Segmentation results for synthetic range images ( $\sigma = 0.1$ ).

(a) synthetic range image 2. (b) synthetic range image 4,  
 (c) synthetic range image 5, (d) synthetic range image 6.

4(a)와 4(b)는 하나의 물체로 이루어진 구조가 간단한 영상이며, 그림 4(c)와 4(d)의 경우 두 물체가 겹쳐 있는 영상이고, 그림 4(e)와 그림 4(f)는 꼭면으로 이루어진 영상이다.

2) LKS를 이용한 제한한 반복적 거리영상 분할  
 그림 5는 제한한 LKS를 이용한 반복적 거리영상




그림 6. 근사화 차수에 따른 분할 결과 ( $\sigma = 0.1$ )  
 (a) 1차 (b) 3차  
 Fig. 6. Segmentation results depending on the order of approximation polynomials ( $\sigma = 0.1$ ).  
 (a) first order, (b) third order.

분할 알고리즘을 여러 합성 거리영상에 적용한 실

과이다. 그림 3(b), 3(d), 3(e), 3(f)에 표준편차가 0.1인 가우시안을 첨가하고 실험을 수행하였다. 평면으로 이루어진 부분들은 올바르게 하나의 영역으로 분할되었으며, 곡면으로 이루어진 부분은 1차 다항식으로 근사화하였기 때문에 여러 개의 영역으로 나누어졌다.

그림 6은 그림 3(c)의 합성 거리영상에 대해 LKS 추정에서 이용되는 다항식의 차수를 1차와 3차로 바꾸어 가며 분할 알고리즘을 적용한 결과이다. 첨가된 가우시안 잡음의 표준편차는 0.1이다. 차수가 증가함에 따라 불연속 부분을 구분하지 못하고 서로 다른 영역들을 하나의 영역으로 추출하는 분할 결과를 나타내고 있다.

그림 7은 그림 4의 실제 거리영상을 제한한 LKS를 이용한 반복적 분할 알고리즘으로 분할한 결과이며 기




그림 7. 실제거리 영상에 대한 분할 결과

- (a) 실제 거리영상 1 (b) 실제 거리영상 2 (c) 실제 거리영상 3
- (d) 실제 거리영상 4 (e) 실제 거리영상 5 (f) 실제 거리영상 6

Fig. 7. Segmentation results for real range images.

- (a) real range image 1, (b) real range image 2, (c) real range image 3,
- (d) real range image 4, (e) real range image 5, (f) real range image 6.




그림 8. 거리영상 분할 알고리즘의 성능비교 ( $\sigma = 0.5$ )  
 (a) LMedS (b) GMVE (c) RESC (d) LKS  
 Fig. 8. Performance comparison of range image segmentation methods.  
 (a) LMedS, (b) GMVE, (c) RESC, (d) LKS.

재된 숫자는 각 영역에 할당된 영역번호이다. 병합에 사용된 다항식의 차수는 3차이며 두 영역 병합의 병합 여부를 결정하는 작은 영역의 inlier의 비율은 0.25이다. 전체적으로 만족스러운 분할 결과를 나타내었지만 그림 7(c)와 7(e)의 경우 아직도 병합이 이루어지지 못한 영역이 있으므로 고차 곡면의 병합을 위한 개선된 알고리즘이 요구된다.

### 3) 기존의 거리영상 분할 알고리즘과의 비교

그림 8은 기존의 거리영상 분할 알고리즘과 제안한 거리영상 분할 알고리즘의 모의실험 결과를 비교한 것이다. 그림 3(a)의 합성 거리영상에 표준편차가 0.5인 가우시안 잡음을 첨가하여 각 알고리즘을 적용하였다. 그림 8(a)는 Meer 등의 알고리즘으로 분할한 결과이며 병합이 이루어지지 못한 작은 영역들이 나타나 있다. 그림 8(b)는 GMVE 알고리즘으로 분할한 결과이며 기울기가 0인 영역들은 올바르게 추출되었으나 roof 에지로 연결된 기울어진 평면들에서 잘못된 결과가 나타나 있다. 그림 8(c), 8(d)는 각각 RESC 알고리즘, 제안한 LKS 알고리즘으로 분할한 결과이며 두




그림 9. RESC와 LKS의 비교  
 (a) RESC ( $\sigma = 1$ ) (b) LKS ( $\sigma = 1$ )  
 (c) RESC ( $\sigma = 3$ ) (d) LKS ( $\sigma = 3$ )  
 Fig. 9. Performance comparison of the RESC and LKS.  
 (a) RESC ( $\sigma = 1$ ), (b) LKS ( $\sigma = 1$ ),  
 (c) RESC ( $\sigma = 3$ ), (d) LKS ( $\sigma = 3$ ).

알고리즘 모두 올바른 분할 결과를 나타내고 있다.

그림 9는 가우시안 잡음의 표준편차가 1일 경우와 3일 경우에 RESC와 제안한 LKS 알고리즘의 분할결과를 비교한 것이며 기재된 숫자는 각 영역에 할당된 영역번호이다. 잡음의 표준편차가 커짐에 따라 roof 에지로 연결된 부분에서 왜곡현상이 일어남을 알 수 있으며, RESC와 제안한 알고리즘이 비슷한 결과를 나타내고 있다.

표 1은 그림 9에 나타난 RESC와 제안한 LKS 방법의 분할결과에 대한 근사화 오차를 나타낸 것이다. LKS 알고리즘은 LKS 추정이후 efficiency 개선을 위해 WLS 추정을 수행하였기 때문에 RESC 알고리즘보다 작은 근사화 오차를 나타내고 있다. 그러나  $256 \times 256$  거리영상에 대해 80 MIPS 워크스테이션에서 실행시, RESC가 약 30초, LKS가 약 2분을 나타내어 제안한 LKS 알고리즘의 속도 개선이 요구된다.

결론적으로 제안한 split-merge 거리영상 분할 알고리즘이 Meer 등의 알고리즘과 GMVE 알고리즘보다 잡음에 강함을 확인할 수 있으며, LKS 알고리즘의

경우 RESC 알고리즘과는 비슷한 성능을, 나머지 거리 영상 분할 알고리즘보다는 우수한 성능을 나타냄을 확인할 수 있다.

#### IV. 결 론

본 논문에서는 robust 회귀분석을 이용한 거리영상

표 1. RESC와 LKS 거리영상 분할 알고리즘의 성능비교 (a)  $\sigma = 1$  (b)  $\sigma = 3$   
 Table 1. Performance comparison of the RESC and LKS. (a)  $\sigma = 1$ . (b)  $\sigma = 3$ .

영역번호	RESC		LKS	
	영역크기	평균오차	영역크기	평균오차
1	36229	0.968539	36226	0.785601
2	7060	1.224064	7027	0.759138
3	4957	0.965713	4964	0.764084
4	3905	0.926840	3870	0.774490
5	1890	0.865013	1796	0.761450
6	1588	0.962402	1655	1.058829
7	2763	0.771695	2767	0.747723
8	1212	0.839956	1191	0.761938
9	1847	0.774325	1958	0.928484
10	1457	0.762593	1404	0.750978
11	1177	0.905971	1265	0.827543
12	826	0.799917	828	0.783963
합계	64911	0.966233	64951	0.789033

(a)

영역번호	RESC		LKS	
	영역크기	평균오차	영역크기	평균오차
1	36518	2.972449	36869	2.415640
2	7014	2.330880	7027	2.290321
3	4973	2.424451	4967	2.353284
4	3871	2.563503	3867	2.317951
5	1951	2.625197	1956	3.428179
6	1285	2.428862	1918	3.490272
7	2781	2.693371	2773	2.336793
8	1232	3.411916	960	2.213775
9	1607	2.297907	1483	2.293055
10	1771	3.121432	1133	2.262766
11	965	2.350337	1271	3.421824
12	829	2.349792	827	2.299636
합계	64797	2.781769	65051	2.460052

(b)

분할 알고리즘을 제안하였다. LMedS를 일반화하여 LKS를 유도하였으며 LKS를 이용한 반복적 거리영상 분할 알고리즘을 제안하였다. 합성 및 실제 거리영상에 대한 모의실험을 통해 기존의 Meer 등의 알고리즘과 GMVE 알고리즘보다 우수한 성능을 나타냄을 보였으며, RESC와는 비슷한 성능을 가짐을 확인하였다. 그러나 RESC의 경우 설정되는 파라미터의 갯수가 많고 근본적으로 관측치에 첨가된 잡음의 표준편차를 미리 정해진 비율의 근사화 오차를 이용하여 예측한다는 측면에서 제한조건이 설정된 회귀분석이지만 제안한 LKS의 경우 여러 비율에 의해 구해진 inlier의 평균 오차를 평가하여 최적의 비율을 선택하는, 제한조건이 설정되지 않은 회귀분석이다. 앞으로 제안한 거리영상 분할 알고리즘의 속도 개선을 위한 연구와 고차 곡면의 적용에 대한 연구가 필요하다.

#### 감사의 글

실험영상을 제공해 주신 서울대학교 제어계측공학과 신호처리 연구실의 이상욱 교수님, 윤일동씨, 구자성씨에게 감사드립니다.

#### 참 고 문 헌

- [1] P. J. Besl, *Surfaces in Range Image Understanding*. New York: Springer-Verlag, 1988.
- [2] T. J. Fan, G. Medioni, and R. Nevatia, "Segmented descriptions of 3-D surfaces," *IEEE Journ. Robotics and Automation*, vol. RA-3, no. 6, pp. 527-538, Dec. 1987.
- [3] J. Canny, "A computational approach to edge detection," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-8, no. 6, pp. 679-698, Nov. 1986.
- [4] P. Perona and J. Malik, "Scale-space and edge detection using anisotropic diffusion," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-12, no. 7, pp. 629-639, July 1990.
- [5] P. Saint-Marc, J. S. Chen, and G. Medioni, "Adaptive smoothing: A general

- tool for early vision," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-13, no. 6, pp. 514-529, June 1991.
- [6] D. Terzopoulos, "The computation of visible-surface representations," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-10, no. 4, pp. 417-438, July 1988.
- [7] A. Blake and A. Zisserman, *Visual Reconstruction*, Cambridge, MA: MIT Press, 1987.
- [8] R. M. Bolle and B. C. Vemuri, "On three-dimensional surface reconstruction methods," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-13, no. 1, pp. 1-13, Jan. 1991.
- [9] P. Meer, D. Mintz, D. Y. Kim, and A. Rosenfeld, "Robust regression methods for computer vision: A review," *Int. Journ. Computer Vision*, vol. 6, no. 1, pp. 59-70, Apr. 1991.
- [10] P. J. Besl, J. B. Birch, and L. T. Watson, "Robust window operators," in *Proc. Second Int. Conf. Computer Vision*, Tampa, FL, pp. 591-600, Dec. 1988.
- [11] P. J. Rousseeuw, "Least median of squares regression," *Journ. American Statistical Association*, vol. 79, no. 388, pp. 871-879, Dec. 1984.
- [12] P. Meer, D. Mintz, and A. Rosenfeld, "Least median of squares based robust analysis of image structure," *CAR-TR-490*, Center for Automation Research, University of Maryland, College Park, Mar. 1990.
- [13] J. M. Jolion, P. Meer, and S. Bataouche, "Robust clustering with applications in computer vision," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-13, no. 8, pp. 791-802, Aug. 1991.
- [14] X. Yu, T. D. Bui, and A. Krzyzak, "Robust estimation for range image segmentation and reconstruction," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-16, no. 5, pp. 530-538, May 1994.
- [15] C. V. Stewart, "A new robust operator for computer vision: Theoretical analysis," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, pp. 1-8, Seattle, WA, June 1994.
- [16] P. J. Rousseeuw and A. M. Leroy, *Robust Regression and Outlier Detection*, New York: John Wiley and Sons, 1987.
- [17] J. D. Foley, A. van Dam, S. K. Feiner, and J. F. Hughes, *Computer Graphics: Principles and Practice*, Addison-Wesley Pub. Co., 1992.
- [18] R. Jarvis, "Range sensing for computer vision," in *Three-Dimensional Object Recognition Systems*, A. K. Jain and P. J. Flynn, Eds., Amsterdam, Elsevier Science Publishers B. V., 1993.

## 저 자 소 개



李吉茂(準會員)

1969年 8月 4日生. 1993年 2月  
서강대학교 전자공학과 졸업(공  
학사). 1995年 2月 서강대학교  
대학원 전자공학과 졸업(공학석  
사). 현재 삼성전자 근무. 주관  
심 분야는 영상처리 등임.

朴來弘(正會員) 第23卷 第6號 參照

현재 서강대학교 공과대학 전자공학  
과 교수