

# 적응적 가중치 함수를 이용한 모션 벡터의 필터링 (Filtering Motion Vectors using an Adaptive Weight Function)

장석우<sup>†</sup> 김진욱<sup>\*\*</sup> 이근수<sup>\*\*\*</sup> 김계영<sup>\*\*\*\*</sup>  
(Seok-Woo Jang) (Jin-Uk Kim) (Geun-Soo Lee) (Gye-Young Kim)

**요약** 본 논문에서는 적응적 가중치 함수를 이용하여 블록 단위의 모션 벡터를 필터링하는 방법을 제안한다. 제안하는 방법에서는 먼저 인접한 영상을 받아 들여 가변적 크기의 블록 정합 방법을 이용하여 모션 벡터를 추출한다. 그리고 추출된 모션 벡터를 강건 예측에 적용하여 아웃라이어(outlier)를 제거함으로써 강건 예측에서 사용하는 동작 모델에 근접한 모션 벡터만을 추출한다. 제안된 적응적 강건 예측은 연속적인 시그모이드 가중치 함수를 사용하여 정상 자료와 아웃라이어의 소속 정도를 보다 효과적으로 표현한다. 또한, 최소화 기법의 반복 단계에서 잔여에러가 감소함에 따라 점진적으로 시그모이드 가중치 함수를 조율함으로써 정상 자료와 아웃라이어를 보다 유연하게 분리한다. 실험에서는 카메라의 동작이 포함된 비디오 데이터를 입력 받아 성능을 비교 분석함으로써 제안한 방법의 우수함을 보인다.

**키워드** : 모션 벡터, 적응적 가중치 함수, 최소화 기법, 강건 예측

**Abstract** In this paper, we propose an approach for extracting and filtering block motion vectors using an adaptive weight function. We first extract motion vectors from a sequence of images by using size-varibale block matching and then process them by adaptive robust estimation to filter out outliers (motion vectors out of concern). The proposed adaptive robust estimation defines a continuous sigmoid weight function. It then adaptively tunes the sigmoid function to its hard-limit as the residual errors between the model and input data are decreased, so that we can effectively separate non-outliers (motion vectors of concern) from outliers with the finally tuned hard-limit of the weight function. The experimental results show that the suggested approach is very effective in filtering block motion vectors.

**Key words** : Motion vectors, adaptive weight function, minimization method, robust estimation

## 1. 서론

컴퓨터 비전 및 디지털 비디오 처리 기술이 발달함에 따라 동영상을 분석하여 동작 정보를 추출하는 연구가 활발히 진행되고 있다. 특히, 블록 단위의 모션 벡터를 추출하고 필터링하는 기법은 기본적인면서도 매우 중요한 연구 분야로서 파노라마 영상 제작, 모델 기반의 비디오 코딩, 그리고 카메라 교정 등의 여러 응용 분야에

서 많이 사용될 수 있다[1-3]. 모션 벡터를 필터링하기 위해 여러 가지 기법들이 사용되고 있지만 이 중 최근에는 강건 예측을 이용한 방법이 우수한 결과를 산출한다고 알려져 있다[4].

일반적으로, 강건 예측 기법은 아웃라이어(outlier)가 포함될 경우 모델을 최적화시키는 인수가 올바르게 수렴하지 못하므로 입력 자료의 통계적인 분포를 고려하여 아웃라이어를 제거하고 정상 자료(non-outlier)만으로 모델의 인수를 구하는 통계적인 방법으로 잘 알려져 있다[5]. 강건 예측에서는 입력 자료, 그리고 일련의 인수를 가지는 모델 사이의 적합도를 측정하는 목적 함수(object function)가 정의된다. 그런 다음, 최소화 기법을 적용하여 목적 함수가 최적화되도록 조정함으로써 모델의 인수를 구한다. 강건 예측에서 다차원 최소화 문제로 일반적으로 많이 사용되는 기법 중의 하나는 Levenberg-Marquardt(LM) 방법으로, 이 방법은 표준적인 비선형 최소 제곱 적합 방법으로 잘 알려져 있다

· 본 연구는 첨단정보기술연구원(AiTrc)을 통하여 한국과학재단의 지원을 받았다

† 비 회 원 : 한국건설기술연구원 건설CALIS연구원 연구원  
swjang@kict.re.kr

\*\* 정 회 원 : 한국건설기술연구원 건설CALIS연구원 연구원  
jukim@kict.re.kr

\*\*\* 비 회 원 : 한경대학교 컴퓨터공학과 교수  
kslee@hnu.hankyong.ac.kr

\*\*\*\* 중신회원 : 숭실대학교 컴퓨터학부 교수  
gykim@computing.ssu.ac.kr

논문접수 : 2003년 1월 23일

심사완료 : 2004년 8월 31일

[6]. 이 방법은 역 헤시안(inverse Hessian) 방법과 steepest descent 방법을 훌륭하게 결합한 방법으로 최소화 기법의 반복 단계에서 목적 함수가 지역적인 2차원 함수로 올바르게 근사될 경우에는 역 헤시안 방법을 적용하고, 그렇지 않을 경우에는 기울기 강하 방법을 적용한다.

그러나, LM 방법은 효과적으로 제어되지 못하면 목적 함수가 올바르게 수렴하지 않는다고 알려져 있다 [7]. 또한, 본 논문에서는 다음과 같은 강건 예측의 문제점을 발견하였다. 기존의 강건 예측은 정상 자료와 아웃라이어를 구분하기 어려운 최소화 기법의 초기 단계에서도 임계치를 이용하는 이진 가중치 함수를 사용하여 정상 자료와 아웃라이어를 분리한다. 따라서 정상 자료와 아웃라이어의 부정확한 분리로 최소화 기법의 단계가 반복됨에 따라 모델의 인수가 잘못 갱신된다.

따라서 본 논문에서는 이런 문제점을 개선한 통계적인 적용적 강건 예측 기법을 소개하고, 이를 통해 모션 벡터를 필터링하는 방법을 제안한다. 제안하는 방법에서는 먼저 인접한 영상을 받아 들어 블록 정합 기법을 이용하여 모션 벡터를 추출한다. 그리고 추출된 모션 벡터를 적용적 강건 예측에 적용하여 아웃라이어를 제거함으로써 모션 벡터를 필터링한다. 제안된 적용적 강건 예측은 연속적인 시그모이드 가중치 함수를 사용하여 정상 자료와 아웃라이어의 소속 정도를 보다 효과적으로 표현한다. 또한, 최소화 기법의 반복 단계에서 잔여에러(residual error)가 감소함에 따라 점진적으로 시그모이드 가중치 함수를 조율함으로써 정상 자료와 아웃라이어를 보다 유연하게 분리하고, 이를 통해 보다 정확하게 모션 벡터를 필터링 할 수 있다. 그림 1은 본 논문에서 제안한 모션 벡터 필터링 방법의 전체적인 구조를 보여준다.

그림 1에서 보는 바와 같이 제안된 모션 벡터 필터링

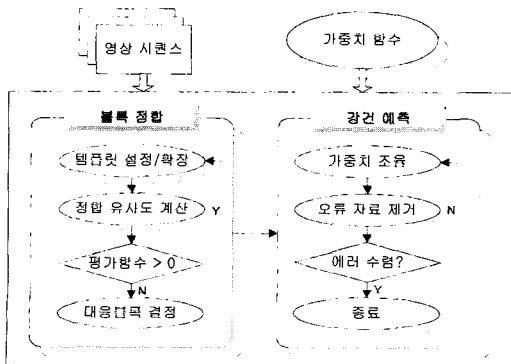


그림 1 모션 벡터 필터링의 전체 구조

은 크게 블록 정합 단계와 적용적 강건 예측 단계로 구성된다. 블록 정합 단계에서는 분별력 있는 최대 정합 유사도를 추출할 때까지 정합 템플릿의 크기를 확장하면서 블록 사이의 정합을 반복적으로 수행하는 가변적 블록 정합을 소개한다. 소개된 블록 정합 방법은 정합의 반복 여부를 평가 함수를 통해 결정하며, 평가 함수는 현재의 탐색 영역에서 구한 정합 유사도 분포 중 최대 정합 유사도를 가지는 블록의 정합 분별력 유무를 판단하여 블록 정합의 반복 여부를 결정한다. 적용적 강건 예측 단계에서는 블록 정합으로부터 구한 모션 벡터를 받아 들인 후 최소화 기법을 통해 오류 모션 벡터를 제거한다. 그리고, 최적화 기법의 반복 과정에서 연속적인 시그모이드 가중치 함수를 조율하여 유연하게 아웃라이어를 제거함으로써 모션 벡터를 보다 정확하게 필터링한다.

1장에서는 연구 동기와 모션 벡터 필터링의 전체적인 개요를 설명하였다. 2장에서는 블록 정합을 이용하여 모션 벡터를 추출하는 방법에 대해 설명하고, 3장에서는 통계적인 적용적 강건 예측에 대해 설명한다. 4장에서는 실험 결과 및 결론을 기술한다.

## 2. 모션 벡터 추출

본 장에서는 보다 정확하게 모션 벡터를 추출하기 위해 가변적인 블록 정합을 소개한다. 블록 정합은 영상을 모양과 크기가 동일한 사각형의 블록으로 분할한 후 블록 단위의 특징을 정의하고, 정의된 특징에 의해 구성되는 정합 척도를 일정한 탐색 영역 내의 블록들에 적용하여 가장 높은 정합 척도를 가지는 블록을 찾는다. 그리고 기준 블록과 정합된 블록 사이의 중심 위치의 변위를 모션 벡터로 정의한다.

블록 단위의 모션 벡터를 추출하기 위해서 많은 기법들, 예를 들어 전역 탐색에 의한 방법, 3 단계 탐색에 의한 방법, 4 단계 탐색에 의한 방법 등이 문헌에 소개되었다[8-10]. 그러나 이런 방법들은 모션 벡터의 정확도를 개선하기 보다는 시간적인 복잡도만을 줄이는 데 치중한 나머지 블록 정합 내부의 문제인 국부적 최소(local minimum)에 빠지는 경향이 있다. 그리고 정합을 수행하는 영상 내부에 에지가 존재하거나 영역의 명암 값이 유사할 경우에는 정합의 분별력이 저하되므로 오정합이 발생할 확률이 매우 높다. 본 논문에서는 이런 문제점을 해결하기 위해 분별력 있는 최대 정합 유사도를 추출할 때까지 정합 템플릿의 크기를 확장하면서 블록 사이의 정합을 반복적으로 수행하는 가변적 블록 정합을 소개한다. 그림 2는 가변적 블록 정합 방법의 전체 구조를 보여준다. 그림 2에서 확인할 수 있듯이 평가 함수가 양의 값을 가질 경우에는 정합 템플릿을 확장하면

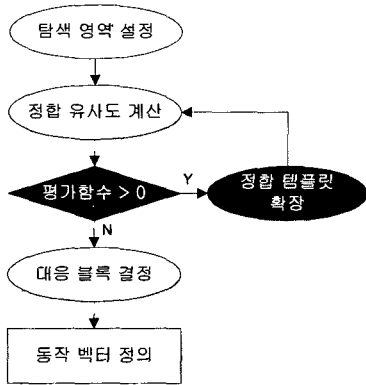


그림 2 가변적인 블록 정합의 구조

서 블록 정합을 반복하고, 평가 함수가 음의 값을 가질 경우에는 정합된 대응 블록을 이용하여 모션 벡터를 결정한다.

블록 사이의 정합 유사도로는 여러 가지 척도가 사용될 수 있다[11]. 본 논문에서는 정합 유사도의 한 방법인 DBS(displaced block similarity)를 식 (1)과 같이 정의하여 사용한다.

$$DBS(i, j; u, v) =$$

$$\left( 1 - \frac{1}{n^2} \sum_{y=0}^{n-1} \sum_{x=0}^{n-1} \left| \frac{I_n(i+x, j+y) - I_{n-1}(i+u+x, j+v+y)}{I_{max}} \right| \right) \times 100 \quad (1)$$

식 (1)에서  $n$ 은 블록의 크기를 의미하고,  $(i, j)$ 는 영상의  $i, j$ 에 위치하는 블록의 시작 좌표를 의미하며,  $(u, v)$ 는 기준 블록과 정합되는 블록 사이의 변위를 의미한다. 그리고  $I_n$ 과  $I_{n-1}$ 은 현재 시점과 이전 시점 영상의 명암 값을 의미하고,  $I_{max}$ 는 명암값의 최대값 255를 의미한다. 그리고 정합 유사 함수  $DBS$ 는 0에서 100사이의 범위를 갖도록 정규화된다.

제안하는 가변적 블록 정합은 분별력 있는 최대 정합 유사도를 추출할 때까지 정합 템플릿의 크기를 확장하면서 블록 사이의 정합을 반복적으로 수행한다. 이를 위해서 본 논문에서는 실험적인 결과를 통해 구한 두 가지 평가 기준을 설정하여 사용한다. 첫째, 정합 템플릿의 확장 여부에 대한 기준을 설정한다. 즉, 정해진 탐색 영역에서 추출한 정합 유사도의 분포 중 최대 정합 유사도가 분별력이 있는가를 평가한다. 이는 최대 정합 유사도  $DBS_{max}$ 를 가지는 블록의 위치를 중심으로 인접 블록과의  $DBS$ 의 차이를 비교하여 평가한다. 즉,  $DBS_{max}$ 를 가지는 블록과 인접 블록의  $DBS$ 의 차이 중 최소값을 경사도(slope)로 정의하고, 경사도가 임계치  $TH$  이하일 경우에만 블록을 확장한다. 둘째, 정합 템플

릿의 크기를 확장하면서 정합 유사도를 반복적으로 계산할 경우 정합 템플릿의 확장 지속 여부에 대한 기준을 설정한다. 다시 말해, 정합 템플릿을 확장함에 따라 경사도의 1차 미분값이 +에서 -로 변하는 변곡점을 발견할 때까지 블록 정합을 반복한다.

위에서 기술한 두 가지 평가 기준을 바탕으로 평가 함수를 수식으로 정의하면 식 (2)와 같다. 식 (2)에서  $(x(n), y(n))$ 은 정합 템플릿의 크기가  $n \times n$ 일 때의 최대 정합 유사도  $DBS_{max}$ 를 가지는 블록의 중심 위치를 의미하고,  $i^*$ 와  $j^*$ 는 위치가  $(x(n), y(n))$ 인 블록의 인접 블록의 중심 위치를 의미한다.

$$\Phi(x(n), y(n)) = \max \left[ \begin{array}{l} e_1 + TH(x(n), y(n)) \\ e_2 + GD(x(n), y(n)) \end{array} \right] \times \frac{e_1 + TH(x(n), y(n))}{e_2 + GD(x(n), y(n))} \quad (2)$$

$$TH(x(n), y(n)) = T_{SL} - SL(x(n), y(n))$$

$$GD(x(n), y(n)) = SL(x(n), y(n)) - SL(x(n-1), y(n-1))$$

$$SL(x(n), y(n)) = \min_{-1 \leq i^*, j^* \leq 1} [DBS(x(n), y(n)) - DBS(x(n+i^*), y(n+j^*))]$$

$$\text{where } \begin{cases} e_1 : \text{infinitesimal positive number} \\ e_2 : \text{infinitesimal negative number} \\ T_{SL} : \text{threshold value of slope} \end{cases}$$

그리고  $SL$ 은 정의한 정합 유사 함수의 경사도를 의미하고,  $GD$ 는 경사도의 1차 미분값을 의미한다.  $GD$ 와  $TH$  값의 범위에 따른 평가 함수  $\Phi(x(n), y(n))$ 값의 범위는 표 1과 같다.

표 1 평가 함수  $\Phi(x(n), y(n))$ 의 값의 범위

$\Phi(x(n), y(n))$		$TH(x(n), y(n))$		
		$TH > 0$	$TH = 0$	$TH < 0$
$GD(x(n), y(n))$	$GD > 0$	+	+	-
	$GD = 0$	-	-	-
	$GD < 0$	-	-	-

그림 3은  $SL$ 의 값의 변화에 따른 최적의 정합 템플릿의 크기  $n_{opt}$ 를 보여주며, 그림 4는  $GD$ 의 값의 변화에 따른  $n_{opt}$ 를 보여준다. 그림 3과 그림 4에서 확인할 수 있듯이  $SL$ 의 일차 미분값인  $GD$ 가 0에 도달할 때에 최적의 정합 템플릿의 크기를 구할 수 있다. 본 논문에서는 정합 유사도에 적용하는 임계치와 경사도를 결합하여 평가 함수를 정의함으로써 간편하게 정합 템플릿의 확장 여부를 결정하면서 블록 정합을 반복할 수 있다.

위에서 기술한 가변적 블록 정합 알고리즘에 대한 보다 세부적인 내용은 참고문헌 [12]에서 확인할 수 있다.




그림 3 SL과  $n_{opt}$ 와의 관계




그림 4 GD와  $n_{opt}$ 와의 관계

### 3. 모션 벡터 필터링

본 논문에서는 모션 벡터를 필터링하기 위해 통계적인 적용적 강건 예측을 제안한다. 적용적 강건 예측의 입력으로는 연속적인 입력 영상으로부터 가변적 블록 정함으로 구한 모션 벡터를 사용한다. 따라서 제안된 강건 예측에서 의미하는 정상 자료는 순수하게 카메라의 동작만을 포함하고 있는 배경 영역의 모션 벡터를 의미하고, 아웃라이어는 배경 영역의 모션 벡터를 제외한 모션 벡터를 의미한다. 즉, 아웃라이어는 지역적인 물체의 이동으로 인해 형성된 모션 벡터나 조명이나 그 외의 잡음으로 인해 형성된 모션 벡터를 의미한다.

일반적으로, 강건 예측은 크게 두 단계로 구성된다. 첫째, 입력 자료로부터 아웃라이어를 제거하는 단계이다. 아웃라이어가 포함될 경우 모델을 최적화시키는 인수가 올바르게 수렴하지 못하므로 입력 자료의 통계적인 분포를 분석하여 아웃라이어를 제거한다. 둘째, 아웃라이어를 제거한 정상 자료만을 이용하여 모델의 인수를 구한다. 모델의 인수를 구하는 과정에서는 최소화 기법을 사용한다. 본 논문에서는 최소화 기법 중 실제 문

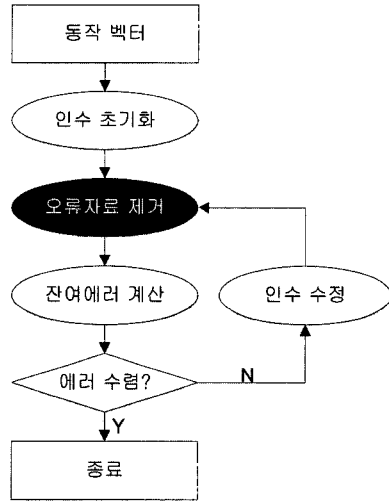


그림 5 강건 예측의 구조

제에 적용할 경우 매우 잘 동작한다고 알려져 있어 많이 사용되고 있는 LM 방법을 사용한다. 강건 예측은 그림 5와 같이 모델과 입력 자료 사이의 잔여예러가 수렴할 때까지 모델의 인수를 갱신하면서 전체 단계를 반복한다.

제안된 적용적 강건 예측에서 사용하는 측정 모델은 식 (3)과 같다. 일반적으로, 식 (3)은 어파인(affine) 모델이라고 불린다.

$$\Omega(x, y, \mathbf{a}) = \begin{bmatrix} u(x, y, \mathbf{a}) \\ v(x, y, \mathbf{a}) \end{bmatrix} = \begin{bmatrix} a_1x + a_2y + a_3 \\ a_4x + a_5y + a_6 \end{bmatrix} \quad (3)$$

식 (3)에서 인수 벡터  $\mathbf{a}$ 는 어파인 모델의 인수를 나타내고,  $u(x, y, \mathbf{a})$ 와  $v(x, y, \mathbf{a})$ 는 적용적 강건 예측의 입력으로 사용되는 모션 벡터의 수평 성분과 수직 성분을 의미한다. 식 (3)의 측정 모델을 기초로 목적 함수(object function)를 정의하면 식 (4)와 같다.

$$\begin{aligned} \chi^2(\mathbf{a}) &= \sum_{i=1}^N w_i \left[ \frac{P_{x_i, y_i} - \Omega(x_i, y_i, \mathbf{a})}{\sigma_i} \right]^2 \\ &= \sum_{i=1}^N w_i \left[ \frac{(P_{x_i} - u(x_i, y_i, \mathbf{a}))^2}{\sigma_{x_i}^2} + \frac{(P_{y_i} - v(x_i, y_i, \mathbf{a}))^2}{\sigma_{y_i}^2} \right] \\ &= \sum_{i=1}^N w_i \| \mathbf{r}_i \|^2 \end{aligned} \quad (4)$$

식 (4)에서  $w_i$ 는  $i$ 번째로 입력되는 자료의 가중치를 의미하고,  $P_{x_i}$ 와  $P_{y_i}$ 는  $i$ 번째 입력 자료의 수평 성분과 수직 성분을 의미한다. 그리고  $N$ 은 입력 자료의 전체 개수, 즉 동작벡터의 총수를 의미한다.

제안하는 적용적 강건 예측은 이진 가중치 함수를 사용하는 기존의 강건 예측과는 다르게 연속적인 가중치 함수를 사용한다. 연속적인 가중치 함수로는 시그모이드

함수(sigmoid function)를 이용한다. 본 논문에서 사용하는 시그모이드 가중치 함수는 이진 가중치 함수보다 정상 자료와 아웃라이어의 소속 정도를 보다 효과적으로 표현하므로 최소화 기법의 반복 초기 단계에서 범할 수 있는 잔여에러를 최소화할 수 있다. 식 (5)는 시그모이드 가중치 함수를 정의한다.

$$\mathbf{W}^k = (w_1^k, w_2^k, \dots, w_j^k, \dots, w_N^k) \quad (5)$$

$$w_j^k = \alpha \cdot w_j^{k-1} + \beta \cdot (1 - \text{sig}^k(x = j; a^k, c^k))$$

$$\text{sig}^k(x; a^k, c^k) = \frac{1}{1 + e^{-a^k(x-c^k)}}$$

where  $0 \leq \alpha, \beta \leq 1, \alpha + \beta = 1$

식 (5)에서  $\mathbf{W}^k$ 는 최소화 단계의  $k$ 번째 반복에서 사용하는 가중치 벡터로서  $w_i^k$ 는 0에서 1사이의 범위를 가지는  $i$ 번째 입력 자료의 가중치를 나타낸다. 그리고  $x$ 는 시그모이드 함수의 입력 벡터를 나타내고,  $c^k$ 는 시그모이드 함수를 수평축을 기준으로 이동시키는 바이어스(bias)를 나타내며,  $a^k$ 는  $x=c$  위치에서 시그모이드 함수의 기울기를 조절하는 역할을 수행한다. 본 논문에서는 입력 자료의 잔여에러들을 오름차순으로 정렬하고, 이 잔여에러들의 누적 잔여에러(accumulated residual errors)들을 기반으로 가중치를 적용하기 위해 일반적인 시그모이드 함수를 사용하지 않고  $x=c$  위치에서  $y$ 축을 중심으로 회전 이동한 시그모이드 함수를 가중치 함수로 사용한다.

적응적 강건 예측은 최소화 기법의 반복 과정에서 현재 단계의 가중치를 계산할 때 이전 단계의 가중치를 반영하도록 정의된다. 또한, 최소화 기법이 반복되면서 잔여에러가 감소함에 따라 시그모이드 함수를 조율함으로써 정상 자료와 아웃라이어를 보다 유연하게 분리한다. 가중치 조율은 시그모이드 함수의 두 인수  $c^k$ 와  $a^k$ 를 조율하여 수행한다. 먼저, 인수  $c^k$ 의 조율은 그림 6과 같이 정렬된 잔여에러의 누적 그래프에서 값의 변화가 가장 급격한 부분에 해당하는  $x$ 축 좌표를 이용하여 수행한다. 그림 6에서  $x$ 축은 정렬된 잔여에러의 순서를 나타내는 인덱스이고,  $y$ 축은 정렬된 잔여에러의 누적 잔여에러를 나타낸다.

그림 6에서와 같이 정렬된 잔여에러의 누적 그래프에서 1번째 누적 잔여에러와  $N$ (입력자료의 총수)번째 누적 잔여에러의  $y$ 축 좌표를 연결하여 직선을 생성한 후 이 직선으로부터 가장 멀리 떨어진 지점의  $x$ 축 좌표를 계산한다. 인수  $c^k$ 의 조율은 식 (6)과 같이 정의된다.

$$c^k = a \cdot c^{k-1} + \beta \cdot \left( \arg \max_j \{D_j\} \right) \quad (6)$$

$$D_j = \frac{\left| \left( \frac{E^k(N) - E^k(1)}{N-1} \right) \cdot j - E^k(j) + \left( \frac{N \cdot E^k(1) - (1 \cdot E^k(N))}{N-1} \right) \right|}{\sqrt{\left( \frac{E^k(N) - E^k(1)}{N-1} \right)^2 + (-1)^2}}$$




그림 6 인수  $c^k$ 의 조율




그림 7 인수  $a^k$ 의 조율

$$E^k(j) = \sum_{i=1}^j w_i^{k-1} \|r_i^k\|$$

식 (6)에서  $E^k(j)$ 는 정렬된 잔여에러의 누적 잔여에러를 의미하며,  $D_j$ 는 1번째 누적 잔여에러와  $N$ 번째 누적 잔여에러의  $y$ 축 좌표를 연결하여 생성한 직선과 누적 잔여에러 사이의 거리를 나타낸다. 그림 7은 인수  $a^k$ 의 조율 방법을 보여준다. 그림 7에서  $x$ 축은 정렬된 잔여에러의 순서를 나타내는 인덱스이고,  $y$ 축은 정렬된 잔여에러의 누적 잔여에러를 나타낸다. 본 논문에서 인수  $a^k$ 의 조율은 그림 7과 같이 정렬된 잔여에러의 누적 그래프에서  $E^k(c)$ 와  $E^k(N)$  사이의 비율을 활용하여 수행한다. 즉, 최소화 기법의 반복이 진행함에 따라 모델을 구성하는 인수가 입력 자료의 분포에 맞게 적합되고 모델과 입력 자료 사이의 잔여에러는 최소화되므로 정렬된 잔여에러의 누적 그래프에서  $E^k(c)$ 는 점점 감소하다가 어느 시점에서 수렴하게 된다. 결국, 최소화 기법의 반복이 진행될수록  $E^k(c)$ 와  $E^k(N)$  사이의 차이는 점점 증가한다. 본 논문에서는 이런 사실을 이용하여 최소화 기법의 반복 초기에는  $a^k$ 를 낮은 값으로 설정하고 최소

화 기법의 반복이 진행됨에 따라  $a^k$ 를 점점 높은 값으로 설정하다가 잔여에러가 수렴될 경우에는  $a^k$ 를 제한하는 형태를 갖도록 설정할 수 있다.

$E^k(c)$ 와  $E^k(N)$  사이의 비율을 이용하여 최소화 기법의 반복에 따라 인수  $a^k$ 를 조율하는 식은 다음과 같이 정의된다.

$$a^k = a^{k-1} \times \frac{\left( \frac{E^{k-1}(c)}{E^{k-1}(N)} \right)}{\left( \frac{E^k(c)}{E^k(N)} \right)} \quad (7)$$

적응적 강건 예측에서는 연속적인 시그모이드 가중치 함수를 사용하여 자동적으로 정상 자료와 아웃라이어를 유연하게 분리함으로써 기존의 강건 예측에서 사용해야만 했던 임계치를 제거하는 효과를 얻을 수 있다.

4. 실험 결과 및 결론

본 장에서는 제안된 블록 단위의 모션 벡터 필터링 방법을 비디오 데이터에 적용하여 실험한 결과 및 결론에 대해 기술한다. 실험을 위해 사용한 컴퓨터는 AMD사의 Athlon 800MHz이고, 운영 체제로는 마이크로소프트의 윈도우 2000을 사용하였으며, 컴파일러로는 마이크로소프트의 비주얼 C++ 6.0을 사용하였다. 실험에서는 여러 가지 카메라의 동작이 포함된 실내 공간에서 촬영된 입력 영상을 이용하였다. 그림 8은 카메라가 2도/frame의 속도로 시계 방향으로 회전되는 입력 영상의 예를 보여준다.

그림 9는 그림 8의 입력 영상으로부터 기존의 블록 정합 알고리즘인 전역 탐색에 의한 방법, 3단계 탐색에 의한 방법, 그리고 4단계 탐색에 의한 방법과 본 논문에서 제안한 가변적 블록 정합 알고리즘을 이용하여 추출한 모션 벡터를 시각적으로 보여주고 있다. 그림 9에서 확인할 수 있듯이 회전된 영상으로부터 추출된 모션 벡터는 영상의 중심 위치를 기준으로 동심원 모양을 형성

한다. 그리고, 제안한 방법으로 추출한 모션 벡터가 보다 정확함을 시각적으로 확인할 수 있다.

그림 10은 가변적 블록 정합으로 추출한 모션 벡터를 받아 들여 기존의 고정적인 임계치를 이용하는 강건 예측[5]과 적응적 강건 예측을 수행하여 아웃라이어를 제거한 후의 모션 벡터를 보여준다. 그림 10(a)에서와 같이 기존의 강건 예측으로 필터링된 모션 벡터는 여전히 많은 잡음 모션 벡터를 포함하고 있다. 이는 최소화 과정에서 잔여에러의 수렴 여부에 무관하게 일정한 값의 임계치를 할당함으로써 기인된다. 이에 비해 그림 10(b)에서와 같이 제안된 강건 예측으로 필터링된 모션 벡터는 잡음 모션 벡터를 거의 포함하고 있지 않다. 이는 고정적인 임계값을 사용하는 대신 연속적인 가중치 함수를 정의하고, 잔여에러가 감소함에 따라 가중치를 조율함으로써 유연하게 잡음 모션 벡터를 제거할 수 있기 때문이다.

그림 11과 그림 12는 강건 예측과 적응적 강건 예측으로 추출한 최종적인 누적 잔여에러를 그래프로 보여준다. 적응적 강건 예측으로 구한 최종적인 잔여에러가 보다 크게 수렴하고 있다는 것을 확인할 수 있다.

본 논문에서는 적응적 강건 예측을 이용하여 블록 단위의 모션 벡터를 필터링하는 방법을 제안하였다. 이를 위해, 먼저 가변적 블록 정합 방법을 이용하여 연속적인 입력 영상으로부터 모션 벡터를 추출한다. 통계적인 적응적 강건 예측에서는 추출된 모션 벡터를 필터링한다. 제안된 강건 예측에서는 연속적인 시그모이드 가중치 함수를 사용하여 정상 자료와 아웃라이어의 소속 정도를 보다 효과적으로 표현한다. 그리고, 최소화 기법의 반복에서 잔여에러가 감소함에 따라 점진적으로 시그모이드 가중치 함수를 조율함으로써 정상 자료와 아웃라이어를 보다 유연하게 분리하고, 이를 통해 보다 효과적으로 모션 벡터를 필터링할 수 있다. 향후에는 보다 다양한 입력 영상 및 서로 다른 측정 모델을 사용하여




(a) 입력 영상 t




(b) 입력 영상 t+Δt


그림 8 카메라의 회전 동작을 포함한 입력 영상




(a) 전역 탐색에 의한 방법



(b) 3단계 탐색에 의한 방법




(c) 4단계 탐색에 의한 방법




(d) 제안한 방법

그림 9 모션 벡터의 추출 결과



(a) 필터링된 모션 벡터 (기존)



(b) 필터링된 모션 벡터 (제안)

그림 10 필터링된 모션 벡터

실험을 할 예정이다. 또한, 측정 모델이 입력된 데이터에 미치는 스무딩(smoothing) 효과에 대한 분석을 수행할 것이다.

### 참고문헌

[1] James Davis, "Mosaics of Scenes with Moving Objects," Proceedings of Computer Vision and




그림 11 강건 예측의 최종 잔여에러




그림 12 적응적 강건 예측의 최종 잔여에러

Pattern Recognition, Santa Barbara, CA, pp. 354-360, June 1998.

[2] Jong-Il Park, Nobuyuki Yagi, Kazumasa Enami, Kiyoharu Aizawa, "Estimating of Camera Parameters from Image Sequence for Model-Based Video Coding," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 4, No. 3, pp. 288-296, June 1994.

[3] Eduardo Bayro-Corrochano, Bodo Rosenhahn, "A Geometric Approach for the Analysis and Computation of the Intrinsic Camera Parameters," *Pattern Recognition*, Vol. 35, No. 1, pp. 169-186, January 2002.

[4] Jong-Il Park, Choong-Woong Lee, "Robust Estimation of Camera Parameters from Image Sequence for Video Composition," *Signal Processing: Image Communication*, Vol. 9, No. 1, pp. 43-53, November 1996.

[5] William H. Press, Saul A. Teukolsky, William T. Vetterling, Brian P. Flannery, *Numerical Recipes in C : The Art of Scientific Computing*, Second Edition, Cambridge University Press, 제15장 : Modeling of Data, pp. 656-706, 1992.

[6] Simon Moss, Edwin R. Hancock, "Registration Incomplete Radar Images Using the EM Algorithm," *Image and Vision Computing*, Vol. 15, No. 8, pp. 637-648, August 1997.

[7] Stan Sclaroff, John Isidoro, "Active Blobs," *Proceedings of International Conference on Computer Vision*, Mumbai, India, pp. 1146-1153, 1998.

[8] B. Liu, A. Zaccarin, "New Fast Algorithms for the Estimation of Block Motion Vectors," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 3, No. 2, pp. 438-441, 1994.

[9] R. Li, B. Zeng, M. L. Liou, "A New Three-Step Search Algorithm for Block Motion Estimation," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 4, No. 4, pp. 438-441,

1994.

[10] Lai-Man Po, Wing-Chung Ma, "A Novel Four-Step Algorithm for Fast Block Motion Estimation," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 6, No. 3, pp. 313-317, 1996.

[11] Ramesh Jain, Rangachar Kasturi, Brian G. Schunck, *Machine Vision*, McGraw-Hill, New York, 1995.

[12] Seok-Woo Jang, Hyung-Il Choi, "A Strategy of Matching Blocks at Multi-Levels," *International Journal of Intelligent Systems*, Vol. 17, No. 10, pp. 965-975, 2002.



장 석 우

1995년 2월 숭실대학교 전자계산학과 졸업(공학사). 1997년 2월 숭실대학교 대학원 전자계산학과 졸업(공학석사). 2000년 8월 숭실대학교 대학원 컴퓨터학과 졸업(공학박사). 2003년 10월~현재 한국건설기술연구원 건설CALS연구센터 선임연구원. 관심분야는 컴퓨터 비전, 영상 처리, 동작 이해, 비디오 검색 등



김 진 옥

1988년 2월 충남대학교 계산통계학과 졸업(이학사). 1991년 2월 충남대학교 대학원 계산통계학과 졸업(이학석사). 1999년 2월 충남대학교 대학원 컴퓨터학과 박사 수료. 1991년 10월~현재 한국건설기술연구원 건설CALS연구센터 선임연구원. 관심분야는 정보검색, 데이터베이스, 정보시스템 등





이 근 수

1983년 숭실대학교 전자계산학과 공학사  
1988년 숭실대학교 전자계산학과 공학석  
사. 1993년 숭실대학교 전자계산학과 공  
학박사. 1992년 9월~1993년 8월 군산대  
학교 컴퓨터과학과 교환교수. 2003년 3  
월~2004년 2월 미국 George Mason  
University, 전자계산학과 객원교수. 1989년~현재 한경대  
학교 컴퓨터공학과 교수. 관심분야는 패턴인식, 퍼지이론,  
컴퓨터비전, 지식기반 시스템, 동작이해, 비디오검색 등임

김 계 영

정보과학회논문지 : 소프트웨어 및 응용  
제 31 권 제 8 호 참조