

고유벡터 접근방법에 기반한 물체 인식 기법

정회원 박 상 호*, 이 경 무**

An Object Recognition Technique based on Eigenvector Approach

Sang Ho Park*, Kyung Mu Lee** *Regular Members*

요 약

본 논문에서는 고유벡터에 기반하여 물체의 이동, 회전, 그리고 크기 변화에 불변한 특성을 가지는 직선 특징 정합 알고리듬을 제안한다. 먼저, 기준 모델을 이루는 특징들의 관계와 입력 영상에서 추출한 특징들의 관계의 유사도를 기반으로 정합 가능한 직선 성분들을 제한함으로써 기준 모델에 대응 가능성이 있는 후보 모델을 구하고 고유벡터 접근방법을 이용하여 후보 모델과 기준 모델을 정량적으로 비교하게 된다. 후보 모델을 구하는 전처리 과정을 통하여 고유벡터 접근방법을 적용할 때의 해결하기 어려운 문제점인 벡터의 순서와 대응관계를 해결할 수 있다. 그리고 기준 모델과 후보 모델에 대하여 근접 행렬을 생성함으로써 물체의 구조적 묘사를 간결히 나타낼 수 있으며, 두 물체를 근접 행렬의 고유벡터가 이루는 특정 공간으로 변환시켜 비교함으로써 상이도 척도를 통한 정량적 비교를 가능하게 해 준다.

합성 영상과 실 영상에 대한 실험 결과는 제안하는 알고리듬이 릴렉세이션 기법에 비하여 직선 성분들 사이의 정합을 빠르고 효율적으로 수행함을 보여주며, 두 물체의 상이도를 정량적으로 나타낼 수 있음을 보여준다.

ABSTRACT

In this paper, we propose a new eigenvector-based linear feature matching algorithm, which is invariant to the rotation, translation and scale. First, in order to reduce the number of possible matches, we use a preliminary correspondence test that generates a set of finite candidate models, by restricting combinations of linear features in the input image. This approach resolves an inherent problem relating to ordering and correspondence in eigenvector/modal approach. Secondly, we employ the *modal analysis*, in which the Gaussian weighted proximity matrices for reference and candidate models are constructed to record the relative distance and angle information between linear features for each model. Then, the *modes* of the proximity matrices of the two models are compared to yield the *dissimilarity measure*, which describes the quantitative degree of the difference between the two models.

Experimental results on synthetic and real images show that the proposed algorithm performs matching of the linear features with affine variation fast and efficiently compared to a relaxation technique and provides the degree of dissimilarity in a quantitative way.

I. 서 론

컴퓨터 시각의 주된 목적은 입력 영상 데이터로부터 필요한 정보를 추출하여 영상 내의 물체들을 인식하고 이해하는 데 있다. 이를 위해서는 일반적으로 저

수준 처리 과정 (low-level processing)을 통해서 입력 영상에 존재하는 특징적인 성분들을 구하고, 모델과의 정합 (matching)을 통해 인식을 수행하게 된다[1]. 가장 간단한 예는 영역들간의 상관관계 (correlation)를 이용하여 화소별로 정합을 수행하는 것이다. 그러나 이

* LG전자 디지털 미디어 연구소(sharkie@lge.co.kr) 정회원, ** 홍익대학교 전파공학과(kmlee@wow.hongik.ac.kr) 정회원
논문번호 : 98257-0619, 접수일자 : 1998년 6월 19일

러한 기법은 주변 환경의 변화 등에 기인한 화소의 특성 변화에 상당히 민감하며, 모델과 정합 대상의 위치 변화와 크기 변화, 방향 변화를 반영하기 위해서는 먼저 이를 추정하는 기법을 필요로 한다[2]. 이와는 대조적으로 모델과 대상 물체의 고수준 묘사 (high-level description)를 이용하여 영상들간의 정합을 수행할 수도 있다. 보다 높은 수준에서 정합을 수행할수록 영상 취득 조건의 변화에 상관 없이 비교적 견실한 정합을 수행할 수 있으나, 복잡한 입력 영상으로부터 고수준 설명을 추출하기에는 여러가지 어려운 문제점이 따르게 된다. 그러므로 고수준 정합을 위한 안정적인 특징 추출 및 설명이 필수적이며, 이에 대한 연구가 국내외적으로 아주 활발하다.

이러한 문제들을 해결하면서 영상들에 존재하는 물체들간의 정합을 수행하기 위해서는 물체들을 적절히 표현하는 과정이 필요하다. 물체를 표현하는 기법 중의 하나인 구조적 묘사 (structural description)란 물체를 표현하는 데 있어 물체를 이루는 부분과 그것들의 특성, 그리고 부분들이 이루는 관계로 나타내는 것이다[3]. 구조적 묘사를 다루는데 있어서 가장 어려운 문제 중의 하나는 본 논문에서 다루고자 하는 바인 여러 물체들의 구조적 묘사들을 최적으로 정합하는 것이다. 이 문제는 영상 분석이나 컴퓨터 시각 등의 분야에서 인식을 수행하기 위하여 필수적이며, 이를 위한 여러가지 기법들이 제안되었다. 이중에서 대표적인 것이 비선형 최적화 기법중의 하나인 릴렉세이션 기법이며, 이 기법은 특징들간의 상관 관계를 이용하여 라벨이 모델에 할당될 확률을 반복적으로 갱신한다[4, 5, 6]. 릴렉세이션 기법은 안정적인 수렴성을 보장하지만, 초기 확률 설정의 어려움과 초기치에 따른 국부 최소로의 수렴 가능성과 같은 문제점을 존재한다.

본 논문에서는 이러한 문제점을 극복하기 위하여 고유벡터 (eigenvector)를 이용한 정합 기법을 제안한다. 고유벡터를 이용하여 물체를 나타내는 방법은 물체 자체의 일반화된 대칭축을 이용하여 물체를 고유모양 (eigenshape)으로 표현 가능하게 한다. 이러한 모양 기술은 물체를 구성하는 특징들 사이의 관계를 나타내는 근접 행렬 (proximity matrix)의 고유벡터에 의해 선형 결합으로 분해될 수 있으며 Scott와 Longuet-Higgins는 이 행렬의 고유벡터를 이용하여 두 영상에 존재하는 점들의 패턴을 대응시키는 알고리듬을 제안하였다 [7]. 이 접근 방법은 영상 내에서 물체의 이동에 불변한 장점을 가지고 있으며 비반복적으로 패턴의 정합이 가능하다. 그러나 물체의 회전 이동과 크기 변화에는 성능이 상당히 저하된다는 문제점을 가지고 있다.

Shapiro와 Brady는 영상 내에서 점들이 이루는 관계에 기반하여 각각의 영상에서 근접 행렬을 생성하고, 근접 행렬의 고유벡터로 이루어지는 형태 행렬 (modal matrix)를 구하였다[8]. 각각의 물체를 나타내는 형태 행렬을 구하고, 형태 행렬의 상관 관계를 나타내는 관계 행렬 (association matrix)을 구하면 점들간의 대응 관계를 간단하게 구현할 수 있다. 이 방법은 Scott와 Longuet-Higgins의 방법과는 달리 한 영상 내에서 근접 행렬을 구하므로 물체의 회전 이동에는 완전히 불변한 성질을 가지고 있으나, 크기 변화에는 역시 유연히 대처하지 못한다는 문제점을 가지고 있다. 그리고 이보다 더 큰 문제점은 패턴을 구성하는 점의 개수가 차이가 날 때에는 적용이 힘들다는 점이다. 비슷한 방법이 Umeyama에 의하여 그래프 정합 문제에 적용되었으나[9], 역시 두 그래프의 크기가 일치할 경우에만 대응하는 노드 (node)를 찾을 수 있기 때문에 그 적용 범위가 매우 제한적이라 할 수 있다.

Sclaroff는 유한 요소 해석법 (finite element method)을 적용하여 물체를 나타내고 고유벡터를 이용하여 물체를 정합하거나 인식할 수 있음을 보였다[10]. 유한 요소 해석법을 적용함으로써 표본화와 인자화에 따른 문제점을 해결할 수 있고 하나의 물체를 유일하게 나타낼 수 있다. 또한 각각의 고유벡터에 물리적 의미를 부여할 수 있고, 두 물체를 나타내는 고유벡터 사이의 변형을 참조하여 물체를 인식을 수행할 수 있다. 그러나 계산 과정이 너무 복잡하고 두 물체의 유사도를 비교하기에 적합하지 않으므로 일반적인 정합 및 인식 문제에는 적용이 용이하지 않다.

그리고 고유 영상을 이용하여 영상을 정합하는 기법들이 연구되었는데 영상의 화소 값에 적절적으로 고유 묘사 (eigen-description)를 적용하는 기법이 고유 영상의 개념이며 모델 데이터베이스 구축을 통한 영상 정합 [11], 얼굴 인식 [12, 13], 자동차 인식 [14] 분야에 적용되어 왔다.

그러나 기존의 기법들은 직선 성분들간의 정합에는 적절치 못하며 대응점의 개수가 비슷할 경우에만 적용 가능하다. 그러므로, 입력 영상에 존재하는 특징들의 개수가 훨씬 많은 물체 인식 (object recognition) 문제에서는 이 기법을 바로 적용하기가 불가능하다. 그러므로 고유벡터를 이용하여 직선 기반의 목표물 인식을 수행하기 위해서는 직선 특징들간의 차이를 기술할 수 있는 적절한 척도 (measure)가 필요하며, 특징들 사이의 상관관계를 제한 조건으로 사용하여 가능한 조합을 제한하는 과정이 필요하다.

본 논문의 구성은 다음과 같다. 2 장에서는 특징들

사이의 상관관계를 제한 조건으로 사용하여 제안하는 후보 집합 선정 기법에 대해 서술하고, 3 장에서는 고유벡터 접근 방법을 이용한 정합 및 인식 기법에 대하여 설명한다. 그리고 합성 영상 및 실영상에 제안하는 접근 방법을 적용시킨 실험 결과를 4 장에 보이고, 마지막으로 5 장에 결론을 제시한다.

II. 상관 관계를 이용한 후보 집합의 설정

목표물을 찾기 위하여 고유벡터를 이용한 정합 방법을 적용시키는 데 따르는 가장 큰 문제점은 기준 모델을 구성하는 특징의 개수와 입력 영상에서 추출한 특징의 개수가 다르다는 점이다. 그러므로, 기준 모델의 형태 행렬과 입력 영상의 특징에 대한 형태 행렬은 크기가 다를 뿐만 아니라, 고유벡터로 구성되는 특징 공간에서의 모양도 달라지게 되므로 직접 비교하는 것이 불가능하다. 이와 같은 문제점을 극복하기 위하여, 먼저 기준 모델의 상관 관계와 입력 영상에서의 특징이 이루는 상관 관계의 유사도를 계산하여 기준 모델에 정합 가능한 대상을 감축시키는 과정이 필요하다. 이를 위해서는 직선 성분 사이의 관계를 정량적으로 나타낼 수 있는 적절한 척도 (measure)가 필요하며, 입력 특징으로부터 모델 특징과 대응 순서가 일치하는 정합 가능성이 있는 후보 모델 (candidate model)의 집합을 구성하면 정합 성능과 속도를 크게 향상시킬 수 있다.

먼저, 본 논문에서 사용하는 용어 및 표기를 간단히 정리하면 다음과 같다.

- 기준 모델 (reference model) : 주어진 모델
- 기준 특징 (reference feature) : 모델을 이루는 특징
- 라벨 영상 (label image) : 입력 영상에서 추출한 특징으로 구성된 영상
- 라벨 특징 (label feature) : 입력 영상에서 추출한 특징
- Q_r : 기준 모델을 이루는 특징들의 집합
- Q_c : 입력 영상에서 추출한 특징들의 집합
- M : 기준 모델의 특징 개수
- N : 라벨 영상의 특징 개수

제안하는 정합 기법의 전체적인 과정을 그림 1에 나타내었다. 이 과정을 간단히 살펴보면 기준 특징과 라벨 특징이 형성하는 상관관계의 유사도를 비교하여 후보 집합과 후보 모델을 구하고 기준 모델과 후보 모델을 특징 공간으로 변환시켜 상이도를 비교한다.

여러 후보 모델 중에서 가장 상이도가 작은 값을 가지는 후보 모델을 최종 정합 결과로 선택한다.

2.1 직선 특징을 위한 이진 관계의 설정

기준 모델에서의 특징의 개수와 입력 영상에서 추출한 특징의 개수가 각각 M, N 개일 때, 이를 임의의 순서대로 나열하여 식 (1)과 같은 순서화된 집합 (ordered set) Q_r 과 Q_c 를 얻을 수 있다.

$$\begin{aligned} Q_r &= \{a_1, a_2, \dots, a_M\} \\ Q_c &= \{a_1, a_2, \dots, a_M, \dots, a_N\} \end{aligned} \quad (1)$$

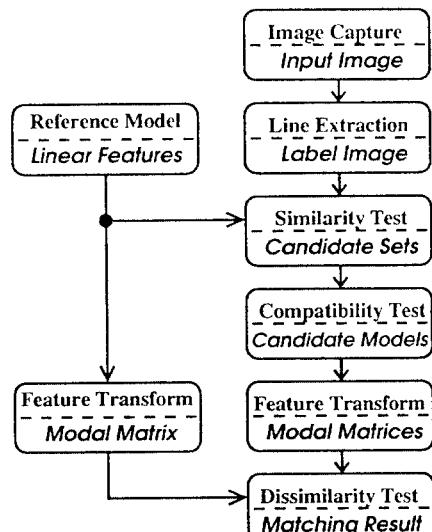


그림 1. 제안하는 정합 기법

$$\begin{aligned} r(a_m, a_n) &= \{r_i(a_m, a_n) | a_m, a_n \in Q_r\}, \quad i = 1, \dots, N_r, \\ r(a_r, a_s) &= \{r_i(a_r, a_s) | a_r, a_s \in Q_c\}, \quad i = 1, \dots, N_c \end{aligned} \quad (2)$$

여기서 a_m 과 a_n 은 각각 기준 특징과 라벨 특징에서 i 번째 특징을 나타내며 라벨 특징들을 또한 라벨이라 부른다. 두 직선 특징이 이루는 관계들의 집합을 r 이라 하면, 기준 특징들 사이의 이진 관계 $r(a_m, a_n)$ 과 영상 특징들 사이의 이진 관계 $r(a_r, a_s)$ 를 식 (2)와 같이 나타낼 수 있다. 여기서 N_r 은 사용된 이진 관계의 개수를 나타낸다.

두 직선 사이의 상관관계를 특징화하기 위하여 그

그림 2에 나타난 바와 같이 4 개의 다른 척도 ($N_r = 4$)를 사용하였다.

$$\begin{aligned} r_1(x_1, x_2) &= \theta_1, \\ r_2(x_1, x_2) &= \theta_2, \\ r_3(x_1, x_2) &= \overline{AB}/\overline{CD} \\ r_4(x_1, x_2) &= (\overline{AB} + \overline{CD})/d, \end{aligned} \quad (3)$$

where $d = (\overline{AC} + \overline{AD} + \overline{BC} + \overline{BD})/4$

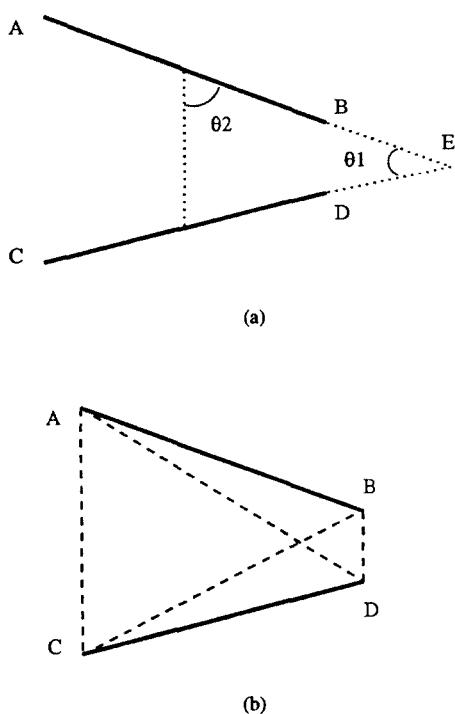


그림 2. 두 직선간의 상관관계

그림 2에서 r_1 은 두 선분 또는 두 선분의 연장선이 이루는 각도를 나타내며, r_2 는 두 선분의 중점을 연결하는 선분과 한 직선이 이루는 각도를 나타낸다. r_3 는 두 선분의 길이의 비를 나타내며, r_4 는 두 선분의 길이의 합에 대한 두 선분의 끝점 사이의 평균거리의 비를 나타낸다. r_1 과 r_2 는 두 선분이 이루는 상대적인 방향과 위치 정보를 반영하며 r_3 와 r_4 는 두 선분의 상대적인 길이와 거리를 특징짓는다. r_1 이 0도에서

180 도 사이의 값을 가질 수 있도록 그림 2(a)의 삼각형 ACE에서 코사인 제 2 법칙을 사용하여 θ_1 을 계산하였다. 각각의 r_i 는 기준 모델과 라벨의 회전 이동 (rotation), 위치 변화 (translation), 그리고 크기 변화 (scale changes)에 불변하도록 설정되었기 때문에, 이러한 변환에 존재하는 다양한 경우에 대하여 적용이 가능하다.

식 (3)에서 규정한 상관관계를 기반으로 하여 기준 특징 (a_m, a_n)과 라벨 (a_r, a_s)의 양립성 척도 (compatibility measure)를 정의하면 식 (4)와 같다. 이 식의 값은 기준 특징들 사이의 상관 관계와 라벨들 사이의 상관 관계가 얼마나 유사한지를 나타내며 a_m 에 a_r 에 해당할 때, a_n 이 a_s 에 대응하는 것이 얼마나 타당한지를 나타내는 척도로 사용된다.

$$S(a_m, a_n; a_r, a_s) = \sum_{i=1}^{N_r} 1/(1 + \frac{|r_i(a_m, a_n) - r_i(a_r, a_s)|}{w_i}) \quad (4)$$

여기서 w_i 는 각 이진 상관관계에 대한 가중치를 나타내며, 각 상관관계가 양립성 척도에 미치는 효과를 비슷하게 하기 위하여 실험적으로 $w_1 = w_2 = \pi/4$, $w_3 = w_4 = 8.0$ 으로 설정하여 사용하였다. 양립성 척도 $S(a_m, a_n; a_r, a_s)$ 는 항상 양의 값을 가지며, 기준 특징 쌍과 라벨 쌍이 이루는 관계가 완전히 동일할 때, N_r 의 최대값을 가지고 이 관계가 차이가 날수록 단조 감소하는 값을 가지게 된다.

2.2 라벨 영상에서 후보 모델의 구성

2.2.1 양립 행렬의 구성

본 절에서는 고유벡터를 이용한 정합 방법을 적용하기 전에 후보 집합을 구성하는 새로운 알고리듬에 대하여 제시하였다. 이러한 과정을 통하여, 정합을 위한 탐색 영역을 대폭적으로 감축할 수 있을 뿐 아니라, 고유벡터 정합을 위한 특징의 순서와 개수를 미리 정할 수 있으므로 정합 과정이 상당히 간단해진다.

먼저, 각각의 기준 특징 쌍 (a_m, a_n)에 대하여 다음과 같은 양립 행렬 R_{mn} 을 생성할 수 있다.

$$R_{mn} = \begin{bmatrix} g_{mn}^T(1) \\ g_{mn}^T(2) \\ \vdots \\ g_{mn}^T(N) \end{bmatrix}_{N \times N}, \quad 1 \leq m, n \leq M \quad (5)$$

여기서 각 행렬의 성분은 다음과 같이 정의된다.

$$[\mathbf{R}_{mn}] = [\mathbf{g}_{mn}^T(i)], \quad (6)$$

$$= \begin{cases} S(a_m, a_n; \alpha_i, \alpha_j) & \text{if } S(a_m, a_n; \alpha_i, \alpha_j) > x \\ 0 & \text{otherwise} \end{cases}$$

양립 행렬 \mathbf{R}_{mn} 은 기준 특징 쌍 (a_m, a_n) 에 대응 가능한 모든 라벨들의 조합을 나타내며 기 정의된 상수 x 를 문턱치로 하여 상관관계가 비슷하지 않은 경우는 배제하게 된다. 즉, $S(a_m, a_n; \alpha_i, \alpha_j)$ 가 x 보다 크면 기준 특징 쌍 (a_m, a_n) 과 라벨 쌍 (α_i, α_j) 사이의 상관관계가 유사하다고 간주한다.

2.2.2 후보 집합의 구성

다음 단계로는 기준 특징 a_m 에 대해서 ψ_m 과 ϕ_m 을 다음과 같이 정의할 수 있다.

$$\psi_m = \begin{bmatrix} u_m(1) \\ u_m(2) \\ \vdots \\ u_m(N) \end{bmatrix}, \quad \phi_m = \begin{bmatrix} v_m(1) \\ v_m(2) \\ \vdots \\ v_m(N) \end{bmatrix}, \quad 1 \leq m \leq M,$$

여기서 $u_m(i)$ 와 $v_m(i)$ 는 다음과 같다.

$$u_m(i) = \begin{cases} 1 & \text{if all } \mathbf{g}_{mn}(i) \neq 0, n = 1, \dots, M \\ 0 & \text{otherwise} \end{cases}$$

$$v_m(i) = \begin{cases} \sum_{n=1}^M \|\mathbf{g}_{mn}(i)\|_\infty & \text{if all } \mathbf{g}_{mn}(i) \neq 0, n = 1, \dots, M \\ 0 & \text{otherwise} \end{cases}$$

여기서 $u_m(i)$ 는 i 번째 라벨 α_i 가 m 번째 기준 특징 a_m 에 정합될 가능성이 있는 경우 1의 값을 가지고, 그렇지 않을 경우에는 0의 값을 가지게 되며, $v_m(i)$ 는 그 정합 정도를 나타낸다. 그러면, 각각의 기준 특징 a_m 에 대해서 할당 가능한 라벨들의 집합을 ψ_m 에서 0이 아닌 원소를 택함으로써 구할 수 있다. 그리고, 0이 아닌 ψ_m 에 해당하는 ϕ_m 의 값의 큰 순서에 따라 정렬함으로써 순서화된 지수 집합 (ordered index set) $I_m (m = 1, \dots, M)$ 을 구할 수 있다.

$$I_m = \{\gamma_{mi} | 1 \leq i \leq t_m, u_m(\gamma_{mi}) \neq 0, v_m(\gamma_{mi}) \geq v_m(\gamma_{m(i+1)})\} \quad (7)$$

여기서 t_m 은 ψ_m 에 존재하는 0 아닌 원소의 개수가 된다. 이 지수 집합으로부터 기준 모델 특징 a_m 에 대한 후보 집합 A_{am} 을 구할 수 있으며 이와 같이 각각의 기준 모델 특징에 대하여 구한 후보 집합들은 각각의 기준 특징에 할당 가능한 모든 라벨들을 식 (8)과 같이 그 지지도인 $v_m(\gamma_{mi})$ 의 크기 순으로 정렬하여 가지고 있다.

$$A_{am} = \{\alpha_{\gamma m 1}, \alpha_{\gamma m 2}, \dots, \alpha_{\gamma m t_m}\}, \quad m = 1, \dots, M \quad (8)$$

후보 집합 $(A_{a1}, A_{a2}, \dots, A_{aM})$ 을 구하면, 각각의 후보 집합에서 한 원소씩을 선택함으로써 식 (9)와 같이 여러 개의 후보 모델 (candidate model)을 구할 수 있다.

$$\mathcal{A} = \{(\tilde{\alpha}_1, \tilde{\alpha}_2, \dots, \tilde{\alpha}_M) | \tilde{\alpha}_1 \in A_{a1}, \dots, \tilde{\alpha}_M \in A_{aM}\} \quad (9)$$

후보 모델에서의 라벨의 개수와 순서는 기준 모델과 동일하므로 라벨의 대응 관계는 이미 설정되었다고 볼 수 있으며, 여러 개의 후보 모델 중에서 기준 모델과 가장 유사한 집합을 정합 결과로서 선택할 수 있다.

III. 고유 벡터를 이용한 정합 기법

영상 라벨에서 후보 모델이 구해지면, 이 모델들을 기준 모델과 비교해야 한다. 앞 절에서 사용한 이진 관계는 단지 부분적인 정보만을 제공하기 때문에 각 이진 관계들의 유사도를 나타내는 $S(a_m, a_n; \alpha_r, \alpha_s)$ 의 단순합은 두 모델이 비슷한지를 어느 정도 지시하는 척도가 되지만 전체적인 관계를 고려하고 있지는 않기 때문에 정확한 전역 척도로 사용하기에는 부적합하다. 그러므로 본 논문에서는 모델을 구성하는 특징들을 전체적인 정보를 내포하는 특징 공간으로 변환시키는 형태 분석 (modal analysis) 기법을 이용한다.

3.1 특징 공간에서 상관 관계의 표현

고유벡터에 기반한 형태 분석 기법을 위하여 먼저 M 개의 특징으로 구성된 $x_i, i = 1, 2, \dots, M$ 에 대하여, 특징들간의 상호 관계를 표현하는 형태 행렬을 구성하는 과정을 살펴보면 다음과 같다.

3.1.1 근접 행렬의 생성

먼저 각각의 이진 상관관계 r_k 에 대해서 $M \times M$ 크기의 정방 행렬 (square matrix)인 거리 행렬 (metric matrix) P_k 를 구성한다. 거리 행렬의 각 성분은 식 (10)을 이용하여 구할 수 있다.

$$[P_k]_{ij} = r_k(x_i, x_j) \quad (10)$$

각 이진 관계의 거리 행렬로부터 가우시안 가중치를 이용하여 식 (11)의 근접 행렬 (proximity matrix) $H_{M \times M}$ 를 구할 수 있다.

$$[H]_{ij} = \exp\left\{-\sum_{k=1}^{Nr} [P_k]_{ij}^2 / 2\sigma_k^2\right\} \quad (10)$$

여기서 가우시안 가중치 σ_k 는 영상 내에서 이진 상관관계들 사이의 상호 작용을 조절하는 역할을 하게 되며 물체의 크기 변화에 따른 거리 행렬 값의 변화를 보상해 줄 수 있다. 즉, 모델의 크기가 클 경우 큰 값의 σ 를 사용하고 모델의 크기가 작을 경우 작은 값의 σ 를 사용하면 물체의 크기 변화에 의한 영향을 상쇄 할 수 있다.

3.1.2 형태 행렬의 생성

근접 행렬이 대칭 행렬일 경우, 이 행렬의 고유값은 항상 다른 실수값을 가지게 되므로 그 특성이 간단해지며 이후의 분석이 상당히 용이하게 된다. 그러므로, 근접 행렬을 대칭 행렬로 만들기 위하여 식 (3)에서 사용한 여러 이진 상관관계 중에서 교환 법칙을 만족시키는 r_1 과 r_4 만을 사용하여 거리 행렬을 구성 한다.

근접 행렬 H 의 i 번째 고유값과 이에 해당하는 고유벡터를 각각 λ_i , e_i 라 하면 식 (12)를 만족시키게 된다. 여기서 λ_i 에 해당하는 유일한 고유벡터를 구하기 위하여 고유벡터의 크기를 $\|e_i\| = 1$ 이 되도록 정규화하여 사용한다. 그러나 e_i 의 부호가 바뀌어도 식 (12)를 만족하게 된다.

$$H e_i = \lambda_i e_i, \quad i = 1, \dots, M \quad (12)$$

그리고 이를 행렬 모양으로 다시 쓰면 다음과 같이 나타낼 수 있다.

$$H = V D V^T \quad (13)$$

여기서 V 는 직교 (orthogonal) 형태 행렬 (modal matrix)이 되며, 각 고유벡터를 형태 행렬의 열 (column)로서 가지게 된다. D 는 양의 고유값을 크기 순서대로 가지는 대각 행렬이 되며, 식 (14)와 같은 형태로 나타낼 수 있다.

$$V = [e_1, e_2, \dots, e_M], \quad (14)$$

$$D = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_M \end{bmatrix}, \quad \lambda_i > \lambda_{i+1}$$

형태 행렬의 각 열을 모드 (mode)라고 칭하는데, 각 모드는 주파수 순서대로 정렬된 모델의 특징을 반영하게 되며 저주파에 해당하는 모드는 전체적인 변형을, 고주파에 해당하는 모드는 국부적인 변형을 나타내게 된다.

3.2 가우시안 가중치를 이용한 크기의 정규화

기준 모델과 후보 모델의 근접 행렬을 구하는 과정에서는 각 모델 내에 존재하는 특징간의 관계를 이용하기 때문에, 영상 내에서 물체의 회전 이동 (rotational shift)이나 병진 이동 (translational shift)에 불변한 근접 행렬을 구할 수 있다. 그러나 근접 행렬이 물체의 크기 변화에 대해서는 일반적으로 불변하지 않기 때문에 Shapiro가 사용한 방법과 같이 고정된 가우시안 가중치를 사용하면 크기 변화에 불변한 근접 행렬을 구할 수 없다. 그리고 사용하는 상관 관계의 종류에 따라서 거리 행렬의 값이 차이가 많이나기 때문에 미리 가우시안 가중치를 설정해서 사용하는 것이 불가능하다. 이러한 문제점을 해결하기 위하여 본 논문에서는 가우시안 가중치를 적응적으로 설정할 수 있는 새로운 방법을 제안하였다.

식 (11)에서 σ_1 의 값은 두 선분의 연장선이 이루는 각도를 나타내므로 크기 변화에 상관없이 상수를 사용할 수 있다. σ_1 의 값을 상수로 사용하기 위해서는 미리 적절한 크기의 값을 실험적으로 설정해 주어야 한다. 그러나 P_4 를 구할 때 사용되는 σ_4 의 값은 크기의 변화를 고려하여 설정되어야 한다. P_4 의 각 성분들은 모델을 이루는 특징들의 크기에 비례하는 값을 가지기 때문에 식 (15)와 같이 각 성분의 평균을 사용함으로써 정규화할 수 있다.

$$\sigma_k = \begin{cases} \frac{\pi}{4} & \text{for } k=1 \\ \frac{1}{(M-1)(M-1)} & \text{for } k=4 \end{cases} \quad (15)$$

이러한 적응적인 가우시안 가중치를 사용하는 방법은 거리 행렬의 값들의 크기를 전혀 예측할 수 없을 경우에도 가장 적절한 값을 가우시안 가중치로서 사용할 수 있게 해 주는 장점이 있다. 즉, 거리 행렬의 값에 비례하는 값을 가지게 되므로 특징들이 이루는 상관 관계의 차이가 클 경우에는 큰 값을 가질 수 있고, 상관 관계의 차이가 작을 경우에는 작은 값을 가질 수 있게 된다.

3.3 각 모드의 부호 정렬

기존의 고유벡터 접근법은 주로 유사한 모양을 가지는 두 모델이 주어졌을 때, 두 모델을 이루는 점(point)들 사이의 대응 관계를 구하기 위하여 사용되었지만, 본 논문에서는 두 모델 사이의 유사도를 평가하기 위하여 고유벡터 접근법을 사용한다. 그러나 이 방법을 유사도를 평가하는 정합에 이용하는 데에는 다음과 같은 문제점이 존재한다. 먼저 각 모드 - 형태 행렬의 각 열 - 가 특징들의 순서에 불변하지 않다는 점이다. 모델을 이루는 특징들의 순서가 변하게 되면 모드가 상당히 변하게 되고 특징의 순서가 변하기 전의 모드와는 상당히 다른 값을 가지게 된다. 그러므로 비교하고자 하는 두 모델의 특징들을 일대일 대응이 되지 않을 경우에는 모드의 비교가 의미가 없게 된다.

후보 집합을 구하는 과정에서 후보 집합 A_{a_m} 의 원소들은 기준 특징 a_m 에 모두 대응하기 때문에 기준 모델 Q_r 과 후보 집합에서 한 원소씩을 선택하여 형성한 후보 모델 \mathbf{A} 는 각 원소들이 순서대로 일대일 대응을 이루고 있기 때문에 별도로 순서를 정렬할 필요가 없다. 그러므로 기준 모델 Q_r 과 Q_c 의 부분 집합인 후보 모델 \mathbf{A} 의 근접 행렬과 형태 행렬을 구해 시 각 모드의 차이를 비교함으로써 유사도를 평가할 수 있다.

Q_r 의 근접 행렬을 \mathbf{H}_r 이라 하고 \mathbf{A} 의 근접 행렬을 \mathbf{H}_c 라 하면 각각 식 (16)과 같이 나타낼 수 있다.

$$\begin{aligned} \mathbf{H}_r &= \mathbf{V}_r \mathbf{D}_r \mathbf{V}_r^T \\ \mathbf{H}_c &= \mathbf{V}_c \mathbf{D}_c \mathbf{V}_c^T \end{aligned} \quad (16)$$

이와 같이 순서가 일치하는 근접 행렬과 이에 대응하는 형태 행렬을 구하면 \mathbf{V}_r 과 \mathbf{V}_c 의 각 열, 즉 각 모드를 비교함으로써 정합이 가능하다. 그러나 각 모드를 비교하기 전에 각 열의 부호(sign)를 일치시켜야 한다는 문제점이 존재한다. \mathbf{e}_i 가 \mathbf{V} 의 고유벡터이면 $-\mathbf{e}_i$ 역시 \mathbf{V} 의 고유벡터이므로, 식 (12)를 만족하는 고유벡터가 유일하게 존재하지 않는다. 그러므로 \mathbf{V}_r 의 모드와 이에 해당하는 \mathbf{V}_c 의 모드의 부호를 일치시키지 않는다면 \mathbf{e}_n 와 \mathbf{e}_c 를 직접 비교하는 것이 의미가 없게 된다. 즉, \mathbf{V}_r 의 i 번째 모드인 \mathbf{e}_n 와의 차이를 계산할 \mathbf{V}_c 의 i 번째 모드가 \mathbf{e}_c 와 $-\mathbf{e}_c$ 중에서 어느 것이 타당한지를 미리 결정해 주어야 한다.

부호를 일치시키는 구체적인 과정은 다음과 같다. \mathbf{V}_r 을 기준 형태 행렬이라 하고 \mathbf{V}_c 의 각 모드를 기준 형태 행렬의 모드와 일치하도록 부호를 조정해 준다. 두 특징들의 순서가 일치하지 않을 경우에는 이러한 부호 조정 과정이 상당히 복잡하지만 본 논문에서는 두 특징들의 순서를 미리 일치시켰기 때문에 식 (17)과 같이 간단히 한번의 계산으로 부호 일치가 가능해진다.

$$\hat{\mathbf{e}}_c = \begin{cases} \mathbf{e}_c & \text{if } \|\mathbf{e}_n + \mathbf{e}_c\| > \|\mathbf{e}_n - \mathbf{e}_c\| \\ -\mathbf{e}_c & \text{otherwise} \end{cases} \quad (17)$$

여기서 이 식이 가지는 물리적 의미는 두 벡터가 이루는 방향이 같으면 부호를 바꾸지 않고, 서로 반대 방향을 가르킬 경우에는 부호를 바꾸어서 부호를 일치시키는 것이다.

3.4 모드 비교를 이용한 정합

직선 성분으로 이루어진 기준 모델과 후보 모델의 구조적 묘사는 근접 행렬의 모드에 이미 내포되어 있다. 그러므로 두 구조적 묘사의 유사성을 비교하는 기준의 알고리듬과는 달리 각 근접 행렬의 모드를 비교함으로써 매우 간단하게 기준 모델과 후보 모델의 유사도를 평가할 수 있다. 앞 절에서와 같이 두 모드의 부호를 일치시킨 후에는 식 (18)과 같이 각 고유벡터의 차이를 계산하여 두 후보 모델의 유사 정도를 성량적으로 나타낼 수 있다. 여기서 \mathcal{D} 는 두 모델의 차이에 비례하여 큰 값을 가지므로 “상이도 척도 (dissim-

ilarity measure)"라고 부르기로 한다.

$$\mathcal{D}(\mathbf{V}_r; \mathbf{V}_c) = \sum_{j=1}^M \|\mathbf{e}_{rj} - \hat{\mathbf{e}}_{cj}\|^2. \quad (18)$$

그러나 각 모드의 중요도는 해당하는 고유값에 비례하므로 모든 모드의 차이를 계산할 필요는 없다. 큰 고유값에 해당하는 고유벡터는 전체적인 모양을 나타내고, 작은 고유값에 해당하는 고유벡터는 지역적인 모양 변화나 잡음의 영향에 의한 결과를 나타낸다. 그러므로 식 (19)와 같이 주요한 k 개의 모드만을 이용하여 식 (18)에서 M 대신 k 를 사용하여 계산하는 방법이 이용되고 있다 [11, 15]. T_s 는 1 보다 약간 작은 양수로서 모델이 가지고 있는 전체 에너지 중에서 계산에 이용하는 에너지의 비율을 나타낸다. T_s 를 1.0으로 선택하면 $k = M$ 이 되므로 모든 모드를 비교하는 것이며, 0.99 이상의 값을 선택하여 사용하면 계산시 소실되는 에너지가 거의 없이도 단지 몇 개의 모드만 비교하면 되므로 상당한 계산량의 감축을 얻을 수 있다.

$$W_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^N \lambda_i} \geq T_s \quad (19)$$

이와 같은 계산량 감축에도 불구하고 이와 같은 계산 방법은 각각의 모드를 동일하게 취급하는 문제점이 존재한다. 본 논문에서는 이와 같은 문제점을 해결하기 위하여 식 (20)을 사용하여 각각의 모드를 해당하는 고유값으로 가중치를 주는 방법을 사용한다.

$$\mathcal{D}(\mathbf{V}_r; \mathbf{V}_c) = \sum_{j=1}^k \|\lambda_{rj} \mathbf{e}_{rj} - \lambda_{cj} \hat{\mathbf{e}}_{cj}\|^2. \quad (20)$$

이 방법은 모델이 가지고 있는 에너지에 비례하는 값을 가지는 고유값을 가중치로 사용하기 있기 때문에 잡음이나 국부적인 모양의 변화에 상당히 견실한 정합을 수행할 수 있다.

이 방법을 적용시키는데 있어서 만약 λ_{rj} 와 λ_{cj} 의 값이 크기가 차이가 난다면 문제가 될 수 있다. 즉 $\mathbf{e}_{rj} = \mathbf{e}_{cj}$ 일 경우에도 $\|\lambda_{rj} \mathbf{e}_{rj}\|$ 와 $\|\lambda_{cj} \hat{\mathbf{e}}_{cj}\|$ 의 차이가 커질 수 있다. 그 결과 $\|\lambda_{rj} \mathbf{e}_{rj} - \lambda_{cj} \hat{\mathbf{e}}_{cj}\|^2$ 의 값과 상이도 척도인 $\mathcal{D}(\mathbf{V}_r; \mathbf{V}_c) = \sum_{j=1}^k \|\lambda_{rj} \mathbf{e}_{rj} - \lambda_{cj} \hat{\mathbf{e}}_{cj}\|^2$ 의 값이 두 모델간의 차이를 제대로 반영하지 못하게

된다. 그러나 σ_k 의 값이 적응적으로 결정되었고, 각 모드는 λ_{rj} 와 λ_{cj} 의 값에 따라 순서대로 정렬되었기 때문에 비슷한 모양을 가지는 물체의 모델에 대해서는 해당하는 고유값이 비슷한 값을 가지게 된다. 그러므로 비교하는 기준 모델과 후보 모델이 비슷하면 각 모드와 대응하는 고유값은 값이 유사해지므로, 상이도 척도인 $\mathcal{D}(\mathbf{V}_r; \mathbf{V}_c)$ 는 작은 값을 가지게 된다. 반면에 비교하는 두 모델의 차이가 커질수록 모드의 차이도 커지고 해당하는 고유값도 크기가 차이가 나기 때문에 $\mathcal{D}(\mathbf{V}_r; \mathbf{V}_c)$ 는 더 큰 값을 가지게 된다.

IV. 실험 결과

제안하는 고유벡터에 기반한 정합 알고리듬의 성능 평가를 위하여, 직선 성분으로 구성한 합성 영상에 대하여 정합 결과를 정량적으로 살펴보고 실 영상에서 추출한 직선 성분에 대한 모의 실험을 수행하였다. 그리고 대표적인 정합 알고리듬인 텔렉세이션 기법과 성능을 비교하였다.

4.1 합성 영상에 대한 실험 결과

먼저 직선 성분으로 구성한 합성 영상에 대한 정합 성능을 살펴보면 다음과 같다. 두 직선 성분의 상호 관계로는 직선이 이루는 각도와 직선의 두 끝점이 이루는 거리의 평균을 이용하였으며, 크기 변화에 따라 직선의 길이와 거리가 변할 수 있기 때문에 거리의 평균에 대해서는 적응적 가우시안 가중치를 사용하였다. 크기가 변할 경우에도 각도는 변하지 않으므로 각도에 대해서는 일정한 값을 사용해도 무방하다.

그림 3 (a)에는 6 개의 직선 성분으로 구성된 기준 모델을 도시하였다.

이것은 한글의 “간”을 고딕체로 나타낸 것이다, 그림 3 (b)에는 직선 성분으로 구성된 라벨 영상을 도시하였다. 라벨 영상에는 모델과 동일한 크기와 모양, 상관 관계를 가지는 직선 성분 뿐만 아니라, 크기와 길이, 상관 관계가 약간씩 다른 직선 성분을 포함하는 80 개의 선분이 나타나 있다. 그러므로 이 경우에 $N = 80$ 이 된다. 그림 3 (c)는 기준 모델을 두 배로 확대한 후보 모델이며, 그림 3 (d)에서 (j)는 그림 3 (b)에서 추출한 후보 모델을 나타낸다.

본 논문에서 제안한 고유벡터를 이용한 정합 기법의 성능을 평가하기 위하여 이전 상관 관계의 양립성을 나타내는 식 (4)에서 정의한 $S(a_m, a_n; a_k, a_l)$ 의

최대값을 1로 정규화시켜 \bar{S} 로 나타내었다. 그리고, 정규화된 지지도의 합을 이용하여 $\sum \bar{S}$ 로서 “유사도”를 정의하고 “상이도”와의 값을 비교하였다. 유사도의 최대값은 자신을 제외한 다른 성분으로부터 받는 지지도가 최대일 경우 1의 값을 가지기 때문에 그림 3과 같이 $M=6$ 인 경우에는 기준 모델과 후보 모델이 완전히 동일한 경우 $M-1=5$ 의 값을 최대값으로 가지게 된다. 이와는 반대로 상이도의 값은 두 모델이 완전히 동일한 경우에 0의 값을 가지게 되고 기준 모델과 후보 모델의 차이가 심할수록 점차 증가하는 값을 가지게 된다. 그림 3의 (c)에서 (j) 까지의 8 가지 경우에 대하여 유사도와 상이도 값을 그림 4에 나타내었다. 본 논문에서 사용한 척도들은 크기 변화와 회전 이동에 완전히 불변하므로, 그림 3 (c), (d)의 경우에는 유사도 값으로서 0.0000을 가지게 되고, 이진 상관 관계를 이용해서 계산하면 기준 모델과 후보 모델과의 상관 관계가 완전히 일치하므로 5.0000의 값을 가지게 된다.

그림 4의 다른 값을 살펴보면 한 직선 성분이 기준 모델과 상당히 다른 경우 유사도 값은 이를 제대로

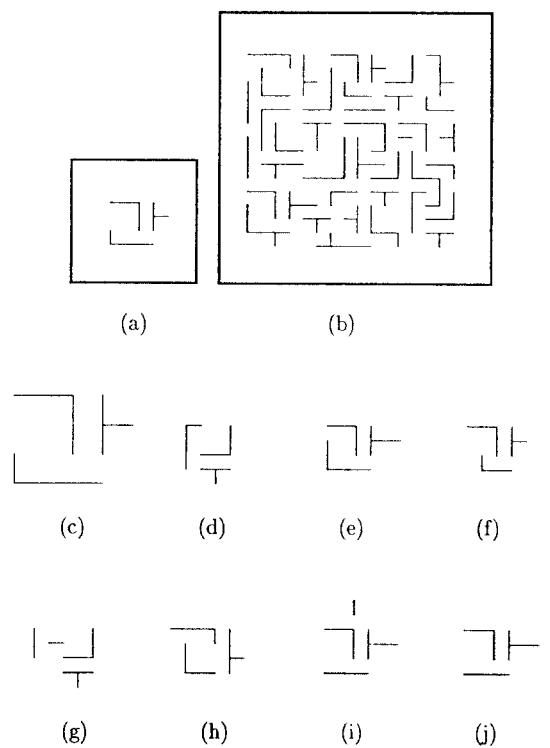


그림 3. “간” 영상의 기준 모델, 라벨 영상, 후보 모델

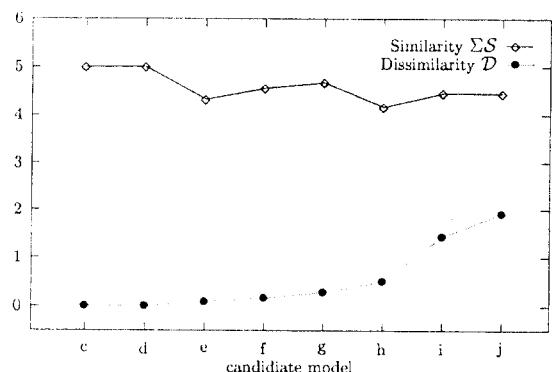


그림 4. “간” 모델에 대한 유사도와 상이도

반영하지 못하고 있다. 즉, 한 직선 성분에 관련된 값만 작아지기 때문에 유사도 값은 전체적으로 크게 영향을 받지 않는다. 그러나 고유벡터를 이용하여 계산한 상이도 값은 한 직선 성분이 기준 모델과 상당히다를 경우에는 고유벡터의 값이 전체적으로 영향을 받아 달라지므로 상이도 값이 큰 차이를 보이게 된다. 이와 같은 결과를 보이는 이유는 고유 벡터를 구성할 때, 형태 행렬의 각 열에 모든 직선 성분들간의 관계가 내포되어 있으므로 정합 하고자 하는 물체의 한 직선 성분이 모델과 많은 차이를 가질 경우, 이 직선 성분이 후보 모델을 나타내는 형태 행렬의 각 열에 모두 영향을 미치게 된다. 그러므로 전체적인 특정 공간에서의 형태가 달라지므로 비교적 큰 차이를 나타내게 된다. 그러나 이진 상관 관계의 합을 정합 척도로 이용할 경우에는 한 직선 성분이 모델과 큰 차이를 보이더라도, 각 성분이 가지는 이진 상관 관계 중에서 하나의 값에만 영향을 미치게 된다. 그림 4의 상이도 값에서 알 수 있듯이 고유벡터를 이용한 정합 기법은 특정 성분의 지역적인 변화에는 비교적 불변하면서도 전체적인 변화를 잘 반영할 수 있으므로 지역적인 상관 관계만을 이용하는 다른 접근 방법에 비해 보다 안정적인 정합 성능을 나타낼 수 있다.

4.2 실 영상에 대한 실험 결과

실 영상에 대한 정합 성능을 평가하기 위하여 먼저 280×240 의 크기를 가지는 그림 5 (a), (b)와 같이 동일한 장면에 대하여 시점이 다른 두 항공 영상을 입력 영상으로서 사용하여 정합 성능을 평가하였다.

그림 5에서 직선 성분을 추출하기 위하여 Nevatia-Babu의 직선 추출기 (line extractor)를 사용하였으며

[16], 그림 5 (a)에서 추출한 삼각형 모양의 인공 구조물을 기준 모델로 설정하면 $M = 3$ 이 되며 그림 6 (a)에 기준 모델을 나타내었다. 그림 5 (b)에서 추출한 직선 성분은 135 개이므로 $N = 135$ 가 되며 이에 해당하는 라벨 영상을 그림 6 (b)에 나타내었다.

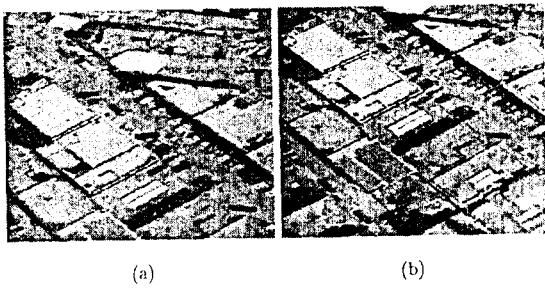


그림 5. 입력 항공 영상

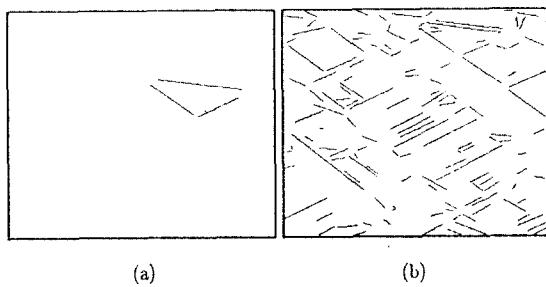


그림 6. 항공 영상의 기준 모델과 라벨 영상

그림 7에는 후보 합집합에서 추출한 여러 조합 중에서 4 가지의 후보 모델을 도시하였으며 각각의 유사도 함수 값은 (a) 0.6391, (b) 0.5148, (c) 0.2935, (d) 0.0095로 가장 작은 값을 가지는 (d)가 정합될 후보 모델임을 쉽게 알 수 있다.

제안하는 정합 기법은 기준 모델을 고정시키지 않고, 정합된 물체를 기준 모델로 간주함으로써 연속 영상에서의 물체 추적에 응용할 수 있다. 즉, n 번째 영상에서 기준 모델과 대응하는 물체를 찾고 이 물체를 $n+1$ 번째 영상의 기준 모델로 사용하는 과정을 반복함으로써 그림 8에 나타난 바와 같이 물체의 모양이 변화하는 경우에도 효율적인 추적 결과를 얻을 수 있다.

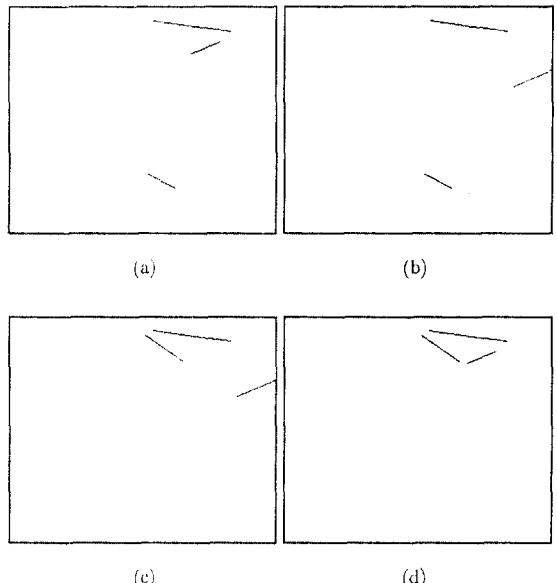


그림 7. 항공 영상에서 추출한 후보 모델

4.3 릴렉세이션 기법과 복잡도 비교

본 논문에서 제안하는 기법의 성능을 기존의 정합 기법과 비교하기 위하여 $M = 4$, $N = 84$ 인 경우에 대하여 릴렉세이션 기법을 적용하여 정합을 수행하였다.

릴렉세이션 기법을 적용시키기 위해서는 각 기준 특징에 각각의 라벨 특징이 대응될 초기 확률을 미리 설정해 주어야 한다. 그리고 이 초기 확률을 시작점으로 하여 기준 특징과 라벨 특징 사이의 양립성과 지지도를 계산하고, 반복적으로 확률을 갱신해 나간다. 초기 확률을 설정하는 방법은 여러 가지가 있으나 본 논문에서는 일정한 확률 (uniform probability)을 초기 확률로 사용하였다. 기준 특징 a_i 에 대하여 라벨 특징 a_j 가 대응될 확률을 p_{ij} 라고 할 때, p_{ij} 는 식 (21)과 같이 확률 벡터를 형성한다.

$$\mathbf{p} = (p_{i1}, p_{i2}, \dots, p_{iN}), \quad i = 1, 2, \dots, M \quad (21)$$

$$\sum_j p_{ij} = 1$$

초기에는 N 개의 라벨 특징이 모두 a_i 에 대응될 확률이 같다고 간주하여 식 (22)와 같이 $p_{ij} = 1/N$ 으로 확률 벡터를 형성한다.



그림 8. 연속 영상에서의 물체 추적 결과

$$\mathbf{p} = \left(\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N} \right), \quad (22)$$

릴렉세이션 기법에서는 이 확률을 반복적으로 생
신하여 최종적으로는 p_{ij} 가 특정한 j 값에 대해서만
1의 값을 가지고 다른 j 값에 대해서는 0의 값을 가
지게 함으로써 정합 라벨을 찾을 수 있다. 릴렉세이
션 기법의 문제점은 앞에서도 언급한 바와 같이 초기
확률 값에 전체적인 성능이 좌우된다는 것이며, 라벨

특징의 개수인 N 이 큰 값을 가지는 경우에는 너무 낮은 초기 확률로 인하여 수렴하지 않거나 잘못된 정합 결과를 얻기가 쉽다. 이러한 초기 확률 설정 문제를 해결하기 위하여 여러 가지 연구가 진행되어 왔으며, 보다 제한적인 초기 확률을 설정함으로써 릴렉세이션 기법의 전반적인 성능을 향상시킬 수 있음을 보이고 있다. 본 논문에서는 초기 확률을 설정하기 위하여 기존의 복잡한 알고리듬을 적용하고 않고 후보 집합의 원소만을 이용하여 초기 확률을 설정하도록 하였다.

즉, a_i 에 대응 가능한 후보 집합 Λ_{ai} 의 원소의 개수가 L 개라 하면, 식 (23)과 같이 초기 확률을 설정 한다.

$$p_{ij} = \begin{cases} \frac{1}{L} & \text{if } j \in \Lambda_{ai} \\ 0, & \text{otherwise} \end{cases} \quad (23)$$

일반적으로 $L \ll N$ 또는 $L < N$ 의 관계가 성립하므로 후보 집합을 이용할 경우 계산 시간 뿐만 아니라 수렴성에 있어서도 상당한 성능 향상을 보일 수 있다. 266MHz의 펜티엄 프로세서를 사용하여 이와 같이 후보 집합을 이용한 경우의 릴렉세이션 기법과 고유 벡터를 이용한 정합 기법의 계산 시간을 표 1에 나타내었다.

표 1. 릴렉세이션 기법과 계산 시간의 비교

case	I	II	III
process	candidate sets	relaxation operation	modal approach
time (ms)	$t_1 = 202$	$t_2 = 18,027$	$t_3 = 170$

표 1에서 t_1 은 후보 집합을 구하는데 소요되는 시간이며, t_2 는 후보 집합을 이용하여 초기 확률을 구했을 경우 릴렉세이션 기법이 수렴하는데 걸리는 시간이다. 그리고 t_3 는 후보 집합에서 구한 하나의 후보 모델과 기준 모델을 고유벡터 접근법을 이용하여 계산하는데 걸리는 시간이다. 릴렉세이션 기법을 적용하여 정합 대상을 찾는데 걸리는 시간 T_{relax} 는 식 (24)와 같이 나타낼 수 있다. 후보 집합에서 구한 후보 모델의 전체 개수를 n_c 라고 할 때 제안하는 알고리듬을 적용하여 정합 대상을 찾는데 걸리는 시간 T_{modal} 은 식 (24)와 같다. T_{modal} 은 후보 집합의 개수에 상당히 좌우되므로 후보 집합의 개수를 적절히 제한해야 계산량 면에서 보다 큰 이득을 얻을 수 있다.

$$\begin{cases} T_{relax} = t_1 + t_2 \\ T_{modal} = t_1 + n_c \cdot t_3 \end{cases} \quad (24)$$

V. 결 론

본 논문에서는 고유벡터 접근 방법을 이용하여 복

잡한 영상에서 표적을 인식하는 효율적 정합 알고리듬을 제안하였다. 제안하는 정합 알고리듬은 물체의 이동, 회전 및 크기 변화에 불변한 속도를 사용하여 상관관계를 평가하므로 물체를 나타내는 기하학적 특징이 바뀔 경우에도 안정적인 적용이 가능하다. 그리고 정합 속도의 향상 및 고유벡터 접근 방법의 문제점을 극복하기 위하여 먼저 대응 가능한 라벨을 제한시킨 후보 집합과 후보 모델을 생성하는 기법을 제안하였다. 기준 모델과 후보 모델을 비교하기 위하여 이들의 구조적 묘사를 나타내는 근접 행렬을 구하고 각각의 고유벡터를 고유값으로 가중치를 주어 차이를 계산함으로써 정량적인 비교가 가능하다.

본 논문에서 제안한 방법은 반복을 통해 확률적 값을 쟁신하지 않고 정합 가능한 조합에서 정량적 비교를 통하여 가장 유사한 조합을 찾기 때문에 릴렉세이션 기법에서의 문제점인 국부 최소로 수렴하는 등의 문제점을 해결할 수 있으며, 중요한 기저에 대한 가중치 설정으로 잡음이나 물체 모양의 부분적인 변형에 안정적인 정합을 수행할 수 있다.

합성 영상 및 실 영상에 대한 실험 결과는 제안하는 기법이 기준 모델과 비슷한 물체가 여러 개 있을 경우에도 성능의 저하 없이 우수한 정합 성능을 보여주며, 계산량의 측면에서 대폭적인 감축을 나타낸다.

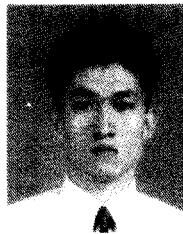
그리고 기하학적 왜곡이 존재하는 실 영상에서도 우수한 정합 성능을 보여주며 연속 영상에서 물체의 모양이 계속적으로 변화하는 경우에도 안정적인 추적을 수행할 수 있다.

참 고 문 헌

- R. Duda and P. Hart, *Pattern Classification and Scene Analysis*. New York: Wiley, 1973.
- A. Sakai, Y. Nomura, and Y. Mitsuya, "Matching for affine transformed pictures using Hough planes," in *MVA96*, (Tokyo, Japan), pp. 381-384, 1996.
- R. Schalkoff, *Pattern Recognition: Statistical, Structural and Neural Approaches*. New York: John Wiley & Sons Inc., 1992.
- A. Rosenfeld, R. Hummel, and S. Zucker, "Scene labeling by relaxation operations," *IEEE Trans. Systems, Man, and Cybernetics*, vol. SMC-6, pp. 420-433, June 1976.
- R. Hummel and S. W. Zucker, "On the foundations of relaxation labeling processes," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 5, pp. 267-287,

May 1983.

6. G. Medioni and R. Nevatia, "Matching images using linear features," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 6, pp. 675-685, Nov. 1984.
7. G. Scott and H. Longuet-Higgins, "An algorithm for associating the features of two patterns," in *Proc. of the Royal Society of London B244*, pp. 21-26, 1991.
8. L. Shapiro and J. Brady, "Feature-based correspondence: an eigenvector approach," *Image and Vision Computing*, vol. 10, pp. 283-288, Oct. 1992.
9. S. Umeyama, "An eigendecomposition approach to weighted graph matching problems," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 10, pp. 696-703, Sep. 1988.
10. S. Sclaroff and P. Pentland, "Modal matching for correspondence and recognition," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 17, pp. 545-561, June 1995.
11. K. Ohba and K. Ikeuchi, "Detectability, uniqueness, and reliability of eigen windows for stable verification of partially occluded objects," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 19, pp. 1043-1048, Sept. 1997.
12. M. Kirby and L. Sirovich, "Application of the Karhunen-Loeve procedure for the characterization of human faces," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 12, pp. 103-108, Jan. 1990.
13. M. Turk and A. Pentland, "Face recognition using eigenfaces," in *CVPR91*, (Lahaina, Maui, HI, USA), pp. 586-591, June 1991.
14. H. Murase and S. Nayar, "Visual learning and recognition of 3-d objects from appearance," *International Journal of Computer Vision*, vol. 14, pp. 5-24, Jan. 1995.
15. M. Uenohara and T. Kanade, "Use of Fourier and Karhunen-Loeve decomposition for fast pattern matching with a large set of templates," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 19, pp. 891-898, Aug. 1997.
16. R. Nevatia and K. Babu, "Linear feature extraction and description," *Comp. Graph. Image Proc.*, vol. 13, pp. 257-269, 1980.



박 상 호(Sang Ho Park) 정회원
1991년 2월: 서울대학교 제이계측
 공학과(학사)
1993년 2월: 서울대학교 제어계측
 공학과(석사)
1998년 8월: 서울대학교 전기공학
 부(박사)
1998년 9월 ~ 현재: LG전자(주) 근
 무

현재: LG전자 디지털 미디어 연구소
<연구분야> 칼라 영상 처리, 물체 인식 및 추적, 영
 상 통신



이 경 무(Kyung Mu Lee) 정회원
1984년: 서울대학교 제어계측공학
 과 학사
1986년: 서울대학교 제어계측공학
 과 석사
1993년: Univ. of Southern California
 전기공학과 박사
1993년 ~ 1994년: Signal & Image
 processing Institute, USC, Research Fellow
1994년 ~ 1995년: 삼성전자 자동화연구소 선임연구원
1995년 ~ 현재: 홍익대학교 전자전기공학부 조교수
<연구분야> 컴퓨터비전, 영상처리 및 멀티미디어응용