

특집논문-08-13-6-05

검색과 분류를 위한 친근도 전파 기반 3차원 모델의 특징적 시점 추출 기법

이수찬^{a)}, 박상현^{a)}, 윤일동^{b)‡}, 이상욱^{a)}

Selecting Representative Views of 3D Objects By Affinity Propagation for Retrieval and Classification

Soochahn Lee^{a)}, Sang Hyun Park^{a)}, Il Dong Yun^{b)‡}, and Sang-Uk Lee^{a)}

요 약

본 논문은 단일 3차원 모델과 모델의 클래스의 특징적인 시점을 추출하여 3차원 모델 검색 및 분류를 수행하는 기법을 제안한다. 제안하는 기법은 3차원 모델을 투영한 2차원 형상 중에 특징적인 형상을 추출하는데, 이때 고르게 샘플(sample)된 형상들을 최근 개발된 친근도 전파 (affinity propagation)^[1] 기법을 이용하여 군집화(clustering)한다. 친근도 전파는 데이터를 군집화하는 동시에 각 클러스터의 대표 값을 계산하므로, 군집화된 형상들로부터 대표 형상이 자연스럽게 지정된다. 제안하는 기법은 친근도 기법을 클래스별로 각 모델의 대표 형상 집합에 재차 적용하여 클래스의 대표 형상을 추출하고, 이를 기반으로 하여 3차원 모델의 분류도 가능하게 한다. 3차원 모델의 검색 뿐 아니라 분류를 가능하게 함으로써, 분류를 검색의 전처리 과정으로 하여 연관된 클래스의 모델 중에서만 검색을 수행할 수 있게 하여 단위가 큰 데이터베이스에서도 효율적인 검색을 가능하게 한다. [16]에 제안된 프린스턴 벤치마크 데이터베이스(Princeton benchmark database)을 이용한 실험을 통해 제안하는 검색 및 분류 기법의 유용함을 보인다.

Abstract

We propose a method to select representative views of single objects and classes of objects for 3D object retrieval and classification. Our method is based on projected 2D shapes, or views, of the 3D objects, where the representative views are selected by applying affinity propagation^[1] to cluster uniformly sampled views. Affinity propagation assigns prototypes to each cluster during the clustering process, thereby providing a natural criterion to select views. We recursively apply affinity propagation to the selected views of objects classified as single classes to obtain representative views of classes of objects. By enabling classification as well as retrieval, effective management of large scale databases for retrieval can be enhanced, since we can avoid exhaustive search over all objects by first classifying the object. We demonstrate the effectiveness of the proposed method for both retrieval and classification by experimental results based on the Princeton benchmark database [16].

Keyword : View Clustering, Affinity Propagation, Retrieval and Classification of 3-D Objects

a) 서울대학교 전기·컴퓨터공학부

School of Electrical Engineering and Computer Science, Seoul National University

b) 한국외국어대학교 용인캠퍼스 디지털정보공학과

School of Digital Information Engineering, Hankuk University of Foreign Studies

‡ 교신저자 : 윤일동(yun@fufs.ac.kr)

1. 소개

3차원 모델은 캐드(CAD, Computer Aided Design), 로봇 비전, 그리고 의료 영상 등의 분야에서 중요한 역할을 한다. 또한, 영화와 방송 등 멀티미디어의 표현 범위를 비약적으

로 확장시키고 있는 다양한 그래픽스 기술은 대부분 3차원 모델을 기반으로 한다. 이에 따라 최근 3차원 모델을 생성하는 기법에 대한 심층적인 연구가 수행되어 다양한 3차원 모델 생성 기법들이 개발되어 모델 생성 기법에 대한 접근이 쉬워졌을 뿐 아니라, 생성된 3차원 모델과 그것들로 이루어진 데이터베이스도 늘어났다. 이러한 흐름에 따라 큰 수의 3차원 모델로 이루어진 데이터베이스를 효과적으로 다루는 기법은 방송을 비롯한 멀티미디어 등 3차원 모델을 응용하는 모든 분야에서 중요성이 증대되고 있으며 그에 대한 연구 또한 점점 큰 관심을 얻고 있다.

3차원 모델로 이루어진 데이터베이스를 기반으로 하는 컴퓨터 비전계의 이슈로 3차원 물체 인식, 물체 분류, 그리고 검색 등이 있다. 이들 이슈는 주어진 데이터의 특성을 추출한 후, 이를 데이터베이스 안의 모델들의 특성과 비교하여 찾고자 하는 결과를 얻는 유사한 구조로 이루어진다. 찾고자 하는 결과는 인식의 경우에 주어진 모델과 일치하

는 데이터베이스 안의 모델, 분류의 경우에는 주어진 모델이 해당하는 클래스, 그리고 검색의 경우 주어진 모델과 유사한 모델들이다. 당연히 데이터베이스로부터 추출하는 정보는 해결하고자 하는 과제에 따라 달라지는데, 인식의 경우 가장 정밀한 정보가 요구되므로 전체적이고 부분적인 정보를 모두 추출해야 하며, 분류의 경우 각 클래스를 이루는 모델들의 공통되는 특성을 추출해야 하고, 검색의 경우 각 모델에 대한 추상적이고 단순한 정보를 추출하게 된다.

본 논문에서 우리는 3차원 모델의 특징적인 시점을 추출하여 검색과 분류의 문제를 다룬다. 제안되는 검색과 분류 기법은 기본적으로 같은 과정에 의해 이루어져서 검색과 분류를 통합하여 다룰 수 있게 해 준다. 기존의 검색 기법들은 유사한 모델을 찾기 위해 모든 모델과의 유사도를 비교하므로, 데이터베이스가 과도하게 커지면 검색 과정이 비효율적이 된다. 검색과 함께 분류 과정을 도입함으로써 주어진 모델과 같은 클래스의 모델들만 고려하면 되므로 검



그림 1. 기존의 검색 기법의 흐름도. 입력 모델과 데이터베이스의 모든 모델 간의 유사도를 계산하므로 데이터베이스의 모델 수가 커질수록 많은 시간이 걸리게 됨
 Fig. 1. Flow chart of traditional retrieval methods. When the number of objects in the database becomes very large, computing the similarity with all the objects causes a computational burden

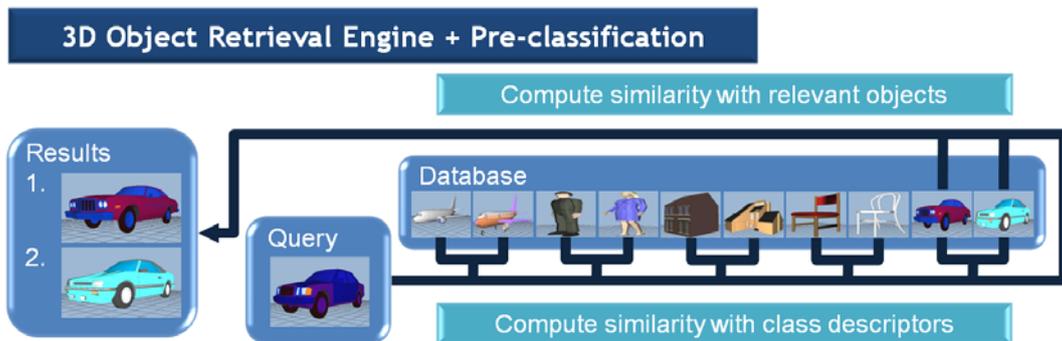


그림 2. 제안하는 검색 기법의 흐름도. 분류를 전처리로 사용함으로써, 입력과 연관이 있는 클래스의 모델만 추출하여 더 효율적인 검색을 수행함
 Fig. 2. By applying a classification as a preprocess, relevant objects can be extracted to enhance efficiency

색 과정을 가속화시킬 수 있게 되는 것이다. 그림 1과 2에 이러한 개념이 나타나 있다. 분류 과정을 도입함으로써 주어진 입력 모델이 해당하는 클래스에 그 모델을 추가함으로써 데이터베이스를 계속적으로 증가시켜 갈 수 있다는 장점 또한 있다.

구체적으로, 제안하는 기법은 고르게 분포된 시점에서의 형상을 샘플한 후 각 형상 간의 유사도를 기반으로 군집화를 하여 각 모델과 각 클래스의 모델 집합의 특징적인 형상을 선정하여 이루어진다. 이때 각 형상은 3차원 모델의 2차원 정사영으로 나타내어지고, 형상 간의 유사도는 2차원 형상 서술자를 이용하여 정의된다. 특징적인 시점들은 최근 제안된 사전 정보를 사용하지 않는 군집화 (unsupervised clustering) 기법의 하나인 친근도 전파 (affinity propagation) 기법^[11]을 통해 이루어진다. 친근도 전파 기법은 샘플된 시점의 형상을 군집화하면서 동시에 각 클러스터의 대표 시점을 선정하게 되어 각 클러스터의 대표 시점을 선정하기 위한 추가적인 과정이 필요하지 않다. 또한, 친근도 전파 기법은 사용자에게 의해 결정되어야 하는 변수가 최소한으로 제한되어 있으며, 각 데이터, 즉 시점 간의 유사성에 의해서 군집화가 결정되어 유클리드 공간의 법칙을 따르지 않는 다양한 종류의 데이터에도 적용이 가능하다는 장점이 있다.

3차원 모델 검색을 위해서는 추출한 특징적인 시점으로부터의 형상의 2차원 서술자를 이어붙임으로써 각 3차원 모델의 서술자를 생성한다. 각 모델의 3차원 서술자로부터 3차원 모델 클래스의 서술자를 생성하는데, 각 모델의 특징적인 시점의 형상들을 친근도 전파 기법을 통해 다시 군집화함으로써 클래스의 특징적인 2차원 형상들을 추출하여 생성하게 된다. 이 과정은 각 모델의 대표 시점 중에서 가장 특징적인 시점의 형상이 그 클래스에 해당하는 모든 모델들의 특성을 잘 반영한다는 가정 하에 이루어진다.

본 논문은 다음과 같이 구성된다. 2장에서는 기존의 3차원 모델 검색 및 분류 기법을 살펴보고, 3장에서는 친근도 전파를 간단하게 재조명한다. 제안하는 시점 기반 3차원 모델 검색 및 분류 기법에 대한 자세한 설명을 4장에서 제시하고, 5장에서는 그에 대한 실험 결과를 제시한다. 마지막으로 6장에서 결론을 짓는다.

II. 연관된 기법

지난 몇 년간 3차원 모델 검색에 대한 상당한 연구가 진행되어 왔다. 대부분의 기법들은 이용되는 주요한 특성에 따라 특징 기반과 시점 기반으로 분류될 수 있다.

대부분의 3차원 모델 검색 기법들은 특징 기반 기법들로, 특징들의 예로는 랜덤한 모델 표면 위의 점의 쌍 간의 거리^[14], 다중해상도 표현에서의 점의 쌍의 절대각(absolute angles)^[13], 반사적인 대칭성^[8], 그리고 특징 분포의 구면상의 조화수(spherical harmonics)^[6, 18, 9]가 있다. 특징 기반 기법은 효율적이고 다양한 형태의 3차원 모델에 적용이 가능한 반면, 모델간의 차이를 극대화 시키는 구성을 찾기 어려우며 서술자로부터 모델의 형태를 추정하기 어렵다.

본 논문에서 제안하는 기법을 비롯한 시점 기반 기법은 직관적이고 융통성이 있으며, 스케치나 영상 등의 형태의 데이터를 입력으로 사용할 수 있는 사용자에게 편리한 인터페이스를 가능하게 한다. 시점 기반 기법들은 모델의 특징적인 시점을 어떻게 선택하는가에 따라 달라진다. Funkhouser 등은 [6]에서 13개의 직교하는 시점 방향으로부터의 모델 형상을 이용하여 서술하는 한편 [4]에서 Cyr와 Kimia는 어스펙트 그래프 (aspect graph) 이론에 따라 시점 구면 (view sphere)의 적도 상의 점을 시점으로 한 형상들 중에 유사한 것들을 영역 성장 기법(region growing method)을 이용하여 묶은 후 각 어스펙트의 대표 시점을 선정한다. 두 기법 모두 성능을 극대화하기 위해서는 3차원 모델들이 같은 점을 기준으로 전후좌우가 맞추어져 있어야, 즉 얼라인 되어 있어야(aligned) 한다. [3]에서 Chen 등은 빛-장 서술자(light-field descriptor)를 제안하였는데, 이 서술자는 시점 구면으로부터 고르게 형상을 샘플한 후 모델 간의 유사성을 대응 형상의 조합을 모두 고려함으로써 얼라인 문제를 해결한다. Lee 등 [10]는 [4]와 [3]의 기법을 결합하여 우선 시점 구면으로 고르게 형상을 샘플한 후 어스펙트뿐 아니라 트랜지션(transition)으로부터도 시점을 뽑는다. 본 논문에서 제안하는 기법은 [4]와 [10]의 기법과 유사하지 만, 다른 군집화 기법을 적용한다.

3차원 모델의 분류에 대해서는 검색에 비해 상대적으로 적은 연구가 이루어졌다. 더욱이 많은 경우에 검색과 분류의

주제에 대한 구분이 명확하게 정의되지 않았다. 이런 상황을 염두에 둔 채 분류만을 다룬 연구에 대한 언급을 하겠다.

[7]에서 Huber 등은 휴리스틱(heuristic)하게 자동차에 관한 모델들을 부분으로 분할한 다음 클래스와 무관하게 전체 모델들의 부분을 지역적인 형상 시그니처(local shape signature)를 이용해서 군집화한 다음, 각 모델에 대해 부분별로 어느 군집에 속하는지를 나타내는 매핑에 따라 분류를 하는 부분 기반 분류 기법을 제안한다. 이 기법은 반드시 각 모델들을 같은 방식을 통해 부분 분할해야 하며 도출된 부분의 수나 구조가 유사해야 하므로 다양한 종류의 모델에 대해 적용하기 어렵다는 문제가 있다. 다른 한편, Donamukkala 등은 [5]에서 각 클래스의 모델들 중에 그 클래스를 가장 잘 대표하는 모델을 선택하는 기법을 제안한다. 이 기법과 본 논문에서 제안하는 기법 모두 클래스 내의 모델들을 이용해서 그 클래스를 설명하는 기법이지만, 본 논문에서 제안하는 기법은 하나의 모델이 아니라 모든 모델들을 집단적으로 사용한다는 차이가 있다. 3차원 모델 검색과 분류에 대한 더욱 세부적이고 자세한 개관은 [2, 17, 20]에 주어져 있다.

친근도 전파^[1]를 이용하는 기법으로는 Xiao 등이 [19]에서 최근에 제안한 기법이 있다. 이 기법은 3차원 거리를 나타내는 데이터를 군집화하는 데에 친근도 전파를 계층적으로 이용하는데, 친근도 전파를 이용하여 모델의 시점별 형상과 클래스 별 모델의 형상을 계층적으로 군집화하는 본 논문의 기법은 이 기법을 참조하였다.

III. 친근도 전파(affinity propagation)

최근 Frey와 Dueck은 친근도 전파(affinity propagation)라는 이름의 메시지 전달(message passing)에 기반을 둔 군집화 기법을 제안하였다^[1]. 데이터 점들 간의 유사도(similarity)를 반영하는 메시지를 점들끼리 주고받음으로써 각 데이터 점마다 자신을 대표하는 점(exemplar)이 정해지게 되고, 같은 대표점을 갖는 데이터 점들끼리 하나의 군집으로 지정되는 것이다. 이때 메시지는 각 데이터 점과 지정된 대표 점들 간의 유사도를 극대화시킬 수 있도록 정의된다.

이름을 통해 알 수 있듯이, 요소 그래프(factor graph)에서 메시지를 주고받는다라는 점에서 친근도 전파는 신뢰도 전파(belief propagation)^[15]와 연관되어 있다. 두 기법의 차이는 메시지의 정의에 있다. 구체적으로, 신뢰도 전파에서의 메시지는 그래프의 노드의 레이블의 가능성(likelihood)을 나타내는 반면, 친근도 전파에서는 각각 데이터 점에 대한 대표 점을 선정하기 위한 두 종류의 척도를 나타내는 책임도(responsibility)와 유효도(availability)라는 메시지가 있다.

두 종류의 메시지는 모두 i 번째와 j 번째의 데이터 점의 유사도를 나타내는 입력 정보 $s(i, j)$ 에 의해 결정된다. $i = k$ 일 경우 $s(k, k)$ 는 k 번째 데이터 점이 대표 점으로 선정될 경향(preference)을 나타내는데, 친근도 전파 과정의 초반에 사용자에게 의해 결정된다. 입력 수치들을 기반으로 하여 책임도 $r(i, k)$ 와 유효도 $a(i, k)$ 는 각각 다음과 같이 정의된다:

$$r(i, k) \leftarrow s(i, k) - \max_{k' \neq k} \{a(i, k') + s(i, k')\}, \quad (1)$$

$$a(i, k) \leftarrow \min \left\{ 0, r(k, k) + \sum_{i' \neq i} \max \{0, r(i', k)\} \right\}. \quad (2)$$

더 자세하게 설명하자면, 책임도 $r(i, k)$ 는 i 번째 데이터 점으로부터 k 번째 데이터 점으로 보내지는 값으로, 데이터 점 k 과 데이터 점 i 간의 유사도 $s(i, k)$ 을 바탕으로 i 의 대표 점 후보로써 k 번째 점이 얼마나 적합한지, i 번째 점의 다른 후보들을 모두 고려하여 나타낸 값이다. 이와 반대로 유효도 $a(i, k)$ 는 k 번째 데이터 점으로부터 i 번째 데이터 점으로 보내지는 값으로, k 번째 데이터 점의 주변 점들이 k 번째 점을 자신들의 대표 점으로 뽑을 가능성을 바탕으로 k 번째 점을 i 번째 데이터 점의 대표 점으로 뽑을 가능성을 나타낸 값이다. $i = k$ 인 경우에는 책임도와 유효도는 각각 자기책임도(self-responsibility) $r(k, k)$ 와 자기유효도(self-availability) $a(k, k)$ 가 된다. 이때, i 의 자리에 k 를 치환하여 계산되는 자기책임도는 사용자에게 의해 입력된 점 k 를 대표 점으로 선정할 경향에서 메시지 전달을 통해 k 번째 점이 다른 점의 대표점으로 선정되는 것이 적합하지 않다는 정도를 뺀 값을 나타낸다. 다른 한편, 다음과 같은 독립적인 식:

$$a(k,k) \leftarrow \sum_{i',t,i' \neq k} \max\{0, r(i',k)\}, \quad (3)$$

에 의해 정의되는 자기유효도는 다른 점들이 자신의 대표 점 후보인 k 번째 점으로 보낸 0보다 큰 책임도들의 합으로, k 번째 점이 대표 점으로 지정될 정도를 나타낸다.

친근도 전파를 통해 군집화를 하는 전체 과정은 초기화, 반복적으로 책임도와 유효도 계산, 그리고 반복 종료로 이루어진다. 초기화 과정은 모든 유효도를 0으로 초기화시키는 것으로 이루어진다. 초기 값들을 바탕으로 반복적으로 책임도와 유효도를 계산한 후, 종료는 미리 정해진 반복 회수를 넘길 때나, 계산되는 값들의 변화가 없을 때 이루어진다. i 번째 점의 대표 점은 $a(i,k) + r(i,k)$ 를 최대로 만들어 주는 k 점으로 결정되는데, 이때 $k=i$ 인 경우 i 번째 점 자체가 대표 점이 된다.

IV. 친근도 전파(affinity propagation)를 이용한 3차원 모델 검색 및 분류

3차원 모델의 각 시점에서의 형상에 친근도 전파를 적용하여 우리는 군집화된 형상들의 대표 형상을 특징적인 시점의 형상으로 추출할 수 있다. 이 과정을 우선 각 모델에 적용하여 모델별 특징적 시점의 형상을 추출한 후, 각 모델의 해당 클래스에 따라 특징적인 시점들을 모으고 이들에 대해 다시 친근도 전파를 적용하여 클래스의 특징적인 시점 형상을 추출하게 된다.

각 세부 과정은 다음과 같다. 3차원 물체의 포즈(pose)에 독립적으로 그 물체를 나타내기 위해 우선 시점 구면상에서 그 물체의 형상을 고르고 뾰뾰하게 샘플해야 한다. 본 논문에서는 Lee 등이 [10]에서 적용한 방식에 따라 정이십면체의 각 삼각형을 네 개의 일정 크기의 삼각형으로 분할한 후 각 점을 구면 위의 점으로 투영하는 과정을 두 번 거친 근사된 정320면체를 생성하고 각 삼각형의 중점을 시점으로 하여 형상을 샘플한다. 각 형상은 그 실루엣을 이진 영상(binary image)으로 나타낸다. 샘플 과정의 모습은 그림 3에 제시된다. 다음으로 각 모델별로 샘플된 각 형상의

집합 V 에 친근도 전파를 적용하여 추출된 대표 형상을 그 모델의 특징적(characteristic) 형상으로 지정하게 된다. 이때 부근의 데이터 점들간만 연결 관계를 형성하는 [19]의 기법과는 달리 모든 형상 간의 유사도를 정의하며, 형상 간의 유사도는 2차원 형상 서술자를 이용한다.

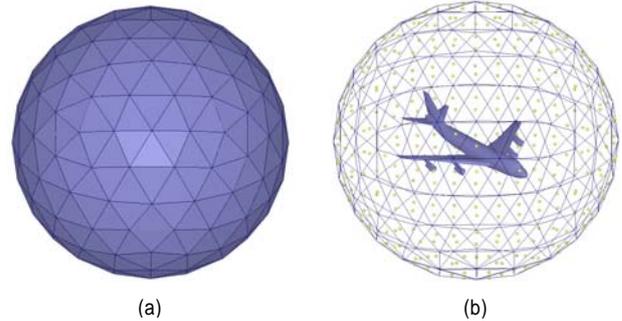


그림 3. [10]에 제시된 시점 샘플 과정. (a) 정이십면체의 각 면을 네 개의 삼각형으로 분할하여 얻은 정320면체. (b) 정320면체의 중점에 위치한 320개의 시점(노란 점으로 표현됨)

Fig. 3. The view sampling process, following that of [10]. Views are sampled from center points of a (a) twice subdivided icosahedron. (b) The viewpoints are represented as yellow points

3차원 모델의 분류를 위해서 데이터베이스에 주어진 클래스들과 각 클래스의 특성을 학습하게 되는데, 이를 위해서 데이터베이스의 각 클래스에 해당하는 모델 집합으로부터 그 클래스의 특성을 가장 잘 반영하는 특징적인 형상들을 추출한다. 즉 클래스별 특징적 형상을 각 클래스에 해당하는 3차원 물체들의 특징적인 형상으로부터 선택하는 것이다. 즉, 각 클래스 별로 해당하는 모든 물체의 추출된 특징적인 형상에 친근도 전파를 재차 적용하고, 각 물체의 특징적인 형상들을 다시 군집화하고 추출된 대표 형상을 그 클래스의 특징적인 형상으로 정의하는 것이다.

검색과 분류 모두 특징적인 형상의 집합을 비교하는 데에 [10] 제시된 변형된 하우스도르프 거리를 사용한다. 구체적으로, 3차원 모델 o_1 과 o_2 의 특징적인 시점의 형상의 집합을 V_{o_1} 과 V_{o_2} 이라고 하였을 때, 형상 집합 사이의 거리는 다음과 같이 정의된다:

$$d(V_{o_1}, V_{o_2}) = \max\{\vec{d}(V_{o_1}, V_{o_2}), \vec{d}(V_{o_2}, V_{o_1})\}, \quad (5)$$

$$\vec{d}(V_{o1}, V_{o2}) = \frac{1}{n} \sum_{v_{o1} \in V_{o1}} \min_{v_{o2} \in V_{o2}} d(v_{o1}, v_{o2}). \quad (6)$$

이때 (6)의 $d(v_{o1}, v_{o2})$ 는 두 시점 v_{o1} 와 v_{o2} 에서의 형상의 형상 기술자들의 L_2 거리(norm)을 의미한다. 또한, 검색은 입력 물체의 특징적인 시점을 추출한 후 각 시점별 형상을 데이터베이스의 모든 물체의 특징적인 시점의 형상들과 비교하여 (5)의 거리가 작은 물체의 순서로 유사함을 정의하고, 분류는 입력 물체의 각 특징적인 시점의 형상을 각 클래스의 특징적인 형상들과 비교하게 된다.

V. 실험 결과

본 장에서는 3차원 모델의 검색과 분류에 대한 실험 결과를 제시한다. 현재까지 생성된 3차원 모델 데이터베이스는 여러 개가 있지만, 본 논문에서는 분류를 위한 실험에 필요한 트레이닝 집합과 테스트 집합을 포함하고 있는 프린스턴 형상 벤치마크 데이터베이스 (Princeton shape benchmark database)^[16]를 이용한다. 프린스턴 데이터베이스는 트레이닝 집합의 907개 모델과 테스트 집합 907개의 모델, 총 1814개의 모델로 이루어져 있으며, 트레이닝 집합은 90개의 클래스, 테스트 집합은 92개의 클래스로, 공통적인 기준에 따라 분류되어 있다.

모든 실험에서는 외곽선을 기반으로 하는 CSS(Curvature Scale Space)^[12] 서술자와, 영역을 기반으로 하는 ART(Angular Radial Transform)^[11] 서술자를 함께 사용한다. 시점 v_i 와 v_j 간의 거리 $d(v_i, v_j)$ 는 CSS 서술자 간의 거리와 ART 서술자 간의 거리의 합으로 정의되며, 각 거리는 VI장에서 언급한 바와 같이 각 서술자의 L_2 거리를 의미한다.

제안하는 검색 기법의 성능을 측정하기 위해서는 테스트 집합만을 이용하는 프린스턴 벤치마크의 구조를 따른다. 907개의 3차원 모델의 서술자는 각 모델의 특징적인 시점의 형상의 2차원 서술자를 이어서 만들었으며, 전체 집합에 대한 검색 성능은 테스트 집합의 각 모델을 입력으로 조회하여 그 모델을 제외한 나머지 모델들에 대한 검색한 결과의 평균으로 이루어진다. 또한, 테스트 집합 O 에 속하는 모델 $o \in O$ 의 형상 집합 V_o 에 대한 친근도 전과 과정에서 입

력하는 대표 경향 $s_o(k, k)$ 은 다음과 같이 정의된다:

$$s_o(k, k) = c \text{mean}_{v_i, v_j \in V_o} S(v_i, v_j), \quad k < N, \quad (4)$$

이때 형상들 간의 유사도 $s(v_i, v_k)$ 은 형상들 거리의 음수 값, 즉 $s(v_i, v_k) = -d(v_i, v_j)$ 이다. 시점의 형상에 대한 입력 경향 $s_o(k, k)$ 는 모든 시점의 형상에 대해 같으며, 이 값은 형상들 간의 유사도 $s(v_i, v_k)$ 의 평균값에 실험적으로 정하는 상수 c 를 곱한 값으로 정의하였다. 이때, [1]에 제시된 바와 같이, c 의 값이 증가할 때, 즉 입력 경향의 값이 감소할 때, 추출되는 대표 형상의 수는 감소하고, c 의 값이 감소할 때, 즉 입력 경향의 값이 증가할 때, 대표 형상의 수는 증가한다. c 의 값이 증가함에 따라 검색 성능이 약간 감소하는데, 이는 추출되는 대표 형상이 감소하기 때문이다. 제시되는 실험 결과에는 검색 성능을 유지하면서도 추출 형상을 줄여서 저장 공간을 절약하는 수치로 $c=1.0$ 을 대입하여 수행한 실험에 대한 결과를 제시한다.

다음으로 우리는 [1]에 제시된 D2 [14], REXT [18], GEDT^[9], SHD^[9], LFD^[3], 그리고 [10]에 제시된 상-변이 서술자 (aspect transition descriptor) 등 기존의 3차원 모델 검색 기법들의 성능과 제안하는 기법의 성능을 비교하였다. 그림 4를 통하여 알 수 있듯이, 제안하는 기법은 [10]에 제

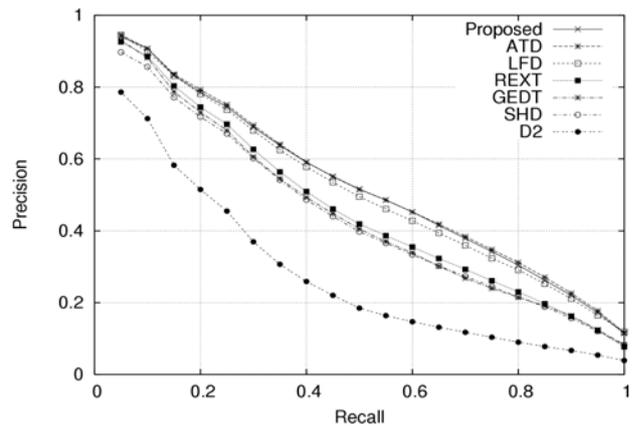


그림 4. 프린스턴 벤치마크 데이터베이스(Princeton benchmark DB)^[16]를 이용하여 제안하는 기법과 기존의 기법들^[14,18,9,3,10]의 검색 성능 비교.
Fig. 4. Precision-recall plots of the proposed method and previous methods^[14,18,9,3,10] tested on the Princeton benchmark database^[16]

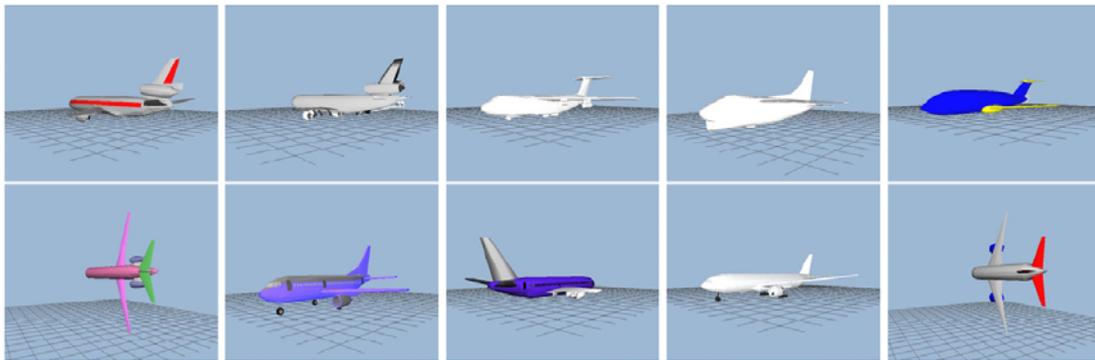
시된 최적의 결과와 비슷한 성능을 보인다. 세부적으로, 제안하는 기법과 상-변이 서술자를 이용한 기법의 프리시전-리콜 곡선(precision-recall curve)이 비슷한 모양을 가진다는 것을 알 수 있는데, 공통되는 형상 샘플 과정이 영향을 미친 것으로 추정된다.

또한, 제안하는 기법을 통한 3차원 모델의 분류의 결과를 제시한다. 위에 언급한 바와 같이 본 논문에서는 트레이닝 집합과 테스트 집합을 사용하는데, 트레이닝 집합의 클래스의 특징적인 시점을 추출한 후, 이를 바탕으로 테스트 집합의 모델들의 클래스를 분류한다. 이때 트레이닝 집합과 테스트 집합의 클래스 분류를 동일하게 하기 위해 두 집합 간에 클래스 분류 체계 최하위 클래스의 이름이 다른 클래스는 제외한다. 이렇게 하여 남은 21개의 클래스의 이름은 표 1에 정리되어 있다.

표 1. 프린스턴 데이터베이스의 트레이닝 집합과 테스트 집합에 공통되는 클래스를 추출한 결과

Table 1. Extracted classes that are common in both the training and test sets of the Princeton benchmark database

class	Training object #	Test object #
aircraft/airplane/biplane	14	14
aircraft/airplane/commercial	10	11
aircraft/airplane/fighter jet	50	50
aircraft/helicopter	17	18
aircraft/spaceship/enterprise like	11	11
animal/biped/human	50	50
animal/biped/human/human arms out	21	20
blade/sword	15	16
body part/face	17	16
body part/head	16	16
bulding/two story home	11	10
city	10	10
furniture/seat/chair/dining chair	11	11
furniture/shelves	13	13
furniture/table/rectangular	26	25
gun/handgun	10	10
liquid container/vase	11	11
plant/potted plane	25	26
plant/tree/barren	11	11
sea vessel/ship	10	11
vehicle/car/sedan	10	10



(a)



(b)

그림 5. 클래스의 대표 형상의 예시. (a) 프린스턴 데이터베이스[16]의 트레이닝 집합에서 10개의 3차원 모델로 이루어진 aircraft/airplane/commercial 클래스의 각 모델의 모습과 (b) $c=8$ 로 하여 추출된 클래스의 특징적인 시점의 형상들

Fig. 5. Example of class representative views. (a) Thumbnails of the 10 3D objects in the aircraft/airplane/commercial class of the training data set [16], and (b) the extracted representative views by the proposed method with $c = 8$

표 2. 입력 경향의 상수 c 를 변화시킬 때의 모델 분류 성능
Table 2. Classification rate with changing preference constant c

c	classification rate(%)
0.8	61.6
1.0	66.5
1.5	68.9
2.0	71.6
3.0	74.3
5.0	75.9
8.0	78.9
10.0	77.6
13.0	75.9

분류 결과 역시 입력 경향 값에 의해 달라지므로, c 의 값을 변화시켜가면서 분류 성능을 비교하였는데, 표 2에 그 결과를 제시하였다. 여기에서, 각 모델은 가장 거리가 작은 클래스로 분류되었는데, 표를 통하여 알 수 있듯이, $c = 8$ 일 때 가장 좋은 분류 성능을 얻을 수 있었다. 그림 5는 클래스의 대표 형상의 예로 비행체/비행기/여객기 클래스의 대표 형상을 나타내는데, 이를 통하여 대표 형상들은 클래스 내의 여러 물체들을 다양한 시점에서 투영한 형상들이 포함되어 있다는 것을 알 수 있다. 분류 성능을 더욱 자세히 살펴보기 위해 각 모델에 따라 모든 클래스와의 거리를 비

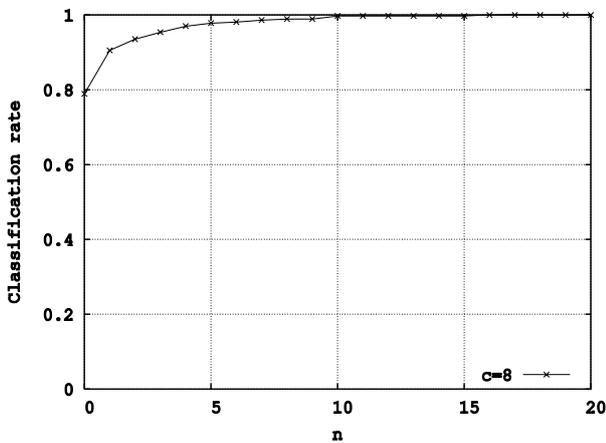


그림 6. 프린스턴 데이터베이스[16]의 트레이닝 집합의 특징적인 형상을 기반으로 테스트 집합의 분류 결과에서 실제 모델의 클래스가 n 번째 이내의 클래스로 뽑히는 비율. ($c = 8$ 로 정의됨)

Fig. 6. The ratio of objects with correct class within the n th class plotted against n tested on the test set of the Princeton benchmark database [16] based on the training set with 21 equivalent classes. Here, the constant used to compute input preference was set to $c = 8$

교하여, 모델의 실제 클래스가 몇 번째인지를 살펴보았는데, 이에 대한 결과를 그림 6에 제시한다. 세부적으로, 클래스들의 대표 형상들과 모델의 대표 형상들 간의 거리를 계산하여 해당 모델의 실제 클래스가 n 번째 클래스로 계산되었을 경우, n 을 증가시키면서 n 번째 이내에 실제 클래스가 속하는 비율을 누적하여 그래프로 나타낸 것이다. 그래프의 곡선이 빠르게 증가할수록 분류 기법의 성능이 좋은 것을 의미하는데, 제시된 결과를 통해 제안하는 기법의 성능이 우수함을 알 수 있다.

아쉽게도 본 논문의 실험에서 사용된 데이터베이스의 크기의 제한으로 인하여 분류 과정을 검색의 전처리 과정으로 적용하였을 때 계산 시간이 얼마나 단축되는지를 비교할 수 없었다. 이런 내용은 추후 연구에서 다룰 예정이다.

VI. 결 론

본 논문에서는 3차원 모델의 검색과 분류를 위하여 각 모델과 클래스의 대표 시점의 형상을 추출하는 기법을 제안한다. 제안하는 기법은 3차원 모델의 2차원 형상에 기반을 두며, 데이터 점을 군집화하는 동시에 각 군집의 대표 점을 추출하는 친근도 전파 [1]를 적용하여 고르게 샘플된 시점의 형상을 군집하고 대표 시점의 형상을 추출하여 이를 모델의 특징적인 형상으로 지정한다. 또한, 반복적으로 친근도 전파를 적용하여 같은 클래스의 여러 모델들의 특징적인 형상을 다시 군집화하여 클래스의 특징적인 형상을 추출한다. 본 논문에서는 프린스턴 벤치마크 데이터베이스 [16]를 이용한 실험 결과를 제시하며, 제시된 실험 결과는 제안하는 기법이 최신 기법 [10]의 결과와 비슷한 검색 성능을 보였다. 트레이닝 집합과 테스트 집합을 이용한 추가적인 실험을 통해 3차원 모델 분류 성능은 21개의 다양한 클래스에 대해 78.9%에 이르는 것으로 나타나 제안하는 기법의 가능성을 보였다.

참 고 문 헌

[1] F.J. Brendan and D. Dueck. Clustering by passing messages be-

- tween data points. *Science*, 315:972 - 976, February 2007.
- [2] R.J. Campbell and P.J. Flynn. A survey of free-form object representation and recognition techniques. *Computer Vision and Image Understanding*, 81(2):166 - 210, 2001.
- [3] D.-Y. Chen, M. Ouhyoung, X.-P. Tian, Y.-T. Shen, and M. Ouhyoung. On visual similarity based 3d model retrieval. In *Eurographics*, pages 223 - 232, 2003.
- [4] C.M. Cyr and B.B. Kimia. A similarity-based aspect-graph approach to 3d object recognition. *International Journal of Computer Vision*, 57(1):5 - 22, 2004.
- [5] R.R. Donamukkala, D. Huber, A. Kapuria, and M. Hebert. Automatic class selection and prototyping for 3-d object classification. In *Proceedings of International Conference on 3-D Digital Imaging and Modeling*, pages 64 - 71, June 2005.
- [6] T. Funkhouser, P. Min, M. Kazhdan, J. Chen, A. Halderman, D. Dobkin, and D. Jacobs. A search engine for 3D models. *ACM Transactions on Graphics*, 22(1):83 - 105, January 2003.
- [7] D. Huber, A. Kapuria, R.R. Donamukkala, and M. Hebert. Parts-based 3d object classification. In *Proceedings of Computer Vision and Pattern Recognition*, June 2004.
- [8] M. Kazhdan, B. Chazelle, D. Dobkin, T. Funkhouser, and S. Rusinkiewicz. A reflective symmetry descriptor for 3D models. *Algorithmica*, 38(1), October 2003.
- [9] M. Kazhdan, T. Funkhouser, and S. Rusinkiewicz. Rotation invariant spherical harmonic representation of 3D shape descriptors. In *Symposium on Geometry Processing*, June 2003.
- [10] S. Lee, S. Yoon, I.D. Yun, D.H. Kim, K.M. Lee, and S.U. Lee. A new 3-d model retrieval system based on spect-transition descriptor. In *Proceedings of European Conference on Computer Vision*, volume 4, pages 543 - 554, 2006.
- [11] B. Manjunath, P. Salembier, and T. Sikora. *Introduction to MPEG-7*. Wiley, 2002.
- [12] F. Mokhtarian and A.K. Mackworth. A theory of multiscale, curvature-based shape representation for planar curves. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(8):789 - 805, 1992.
- [13] R. Ohbuchi, T. Minamitani, and T. Takei. Shape-similarity search of 3d models by using enhanced shape functions. In *International Journal of Computer Applications in Technology*, volume 23, pages 70 - 85, 2005.
- [14] R. Osada, T. Funkhouser, B. Chazelle, and D. Dobkin. Shape distributions. *ACM Transactions on Graphics*, 21(4):807 - 832, October 2002.
- [15] J. Pearl. *Probabilistic Reasoning in Intelligent Systems : Networks of Plausible Inference*. Morgan Kaufmann, 1988.
- [16] Philip Shilane, Patrick Min, Michael Kazhdan, and Thomas Funkhouser. The princeton shape benchmark. In *Shape Modeling International*, June 2004.
- [17] J.W.H. Tangelder and R.C. Veltkamp. A survey of content based 3d shape retrieval methods. *Proceedings of Shape Modeling Applications*, pages 145 - 156, 2004.
- [18] D.V. Vranic. An improvement of rotation invariant 3d-shape based on functions on concentric spheres. In *International Conference on Image Processing*, volume 3, pages 757 - 760, 2003.
- [19] J. Xiao, J. Wang, P. Tan, and L. Quan. Joint affinity propagation for multiple view segmentation. In *Proceedings of International Conference on Computer Vision*, 2007.
- [20] Y. Yubin, L. Hui, and Z. Yao. Content-based 3-d model retrieval: A survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 37(6):1081 - 1098, Nov. 2007.

 저 자 소 개



이 수 찬

- 2004년 : 서울대학교 전기공학부 학사
- 2004년 ~ 현재 : 서울대학교 전기공학부 박사과정
- 주관심분야 : 컴퓨터 비전, 3차원 모델링

저 자 소 개



박 상 현

- 2004년 3월 ~ 2008년 2월 : 연세대학교 전기전자공학부 (공학사)
- 2008년 3월 ~ 현재 : 서울대학교 전기컴퓨터공학부 (공학석사)
- 주관심분야 : 컴퓨터비전



윤 일 동

- 1989년 2월 : 서울대학교 제어계측공학과 공학사
- 1991년 2월 : 서울대학교 제어계측공학과 공학석사
- 1996년 8월 : 서울대학교 제어계측공학과 공학박사
- 1997년 3월 ~ 현재 : 한국외국어대학교 디지털정보공학과 교수
- 주관심분야 : 영상처리, 컴퓨터비전



이 상 욱

- 1973년 : 서울대학교 전기공학부 학사
- 1976년 : 미국 Iowa 주립대 전기공학과 석사
- 1980년 : 미국 Univ. of Southern California, 전기공학과 박사
- 1981년 : General Electric Co. 연구원
- 1983년 : M/A-COM Research Center 선임연구원
- 1983년 ~ 현재 : 서울대학교 전기공학부 정교수
- 주관심분야 : 영상처리, 컴퓨터 비전