Journal of Korean Institute of Intelligent Systems, Vol. 24, No. 1, February 2014, pp. 007-015
http://dx.doi.org/10.5391/JKIIS.2014.24.1.007

두 영상검색 시스템의 협력적 이용을 통한 재순위화

Re-ranking the Results from Two Image Retrieval System in Cooperative Manner

황중원* · 김현우** · 김준모*†
Joong-won Hwang*, Hyunwoo Kim**, and Junmo Kim*†

*한국과학기술원 전기 및 전자공학부, **다음 커뮤니케이션
† Department of Electrical Engineering, KAIST
**Daum Communication Corp.

요 약

영상검색은 컴퓨터 비전과 데이터 마이닝 분야의 주요한 주제 중 하나이다. 현재 상용화된 영상 검색 시스템이 놀라운 성능을 보여주고 있음에도 불구하고, 폭발적으로 증가하는 웹상의 영상정보를 효율적으로 검색하기 위하여, 영상 검색 기술의 성능향상이 꾸준히 요구되고 있다. 재순위화는, 이런 요구를 만족시키기 위한 방법 중 하나로서, 영상 검색 시스템이 도출한 초기 결과를, 독자적인 알고리즘을 통해 연관도를 한 번 더 계산하고, 그에 따라 검색 결과의 성능을 향상시키는 방법이다. 지금까지 제안된 많은 재순위화 알고리즘이, 영상 검색 시스템이 영상의 시각적 정보를 사용하지 않는다는 가정하에 개발되어 왔지만, 현재 Google 과 Baidu 등 많은 상업적 영상 검색 시스템이 영상의 시각적 패턴에 대한 정보를 사용하기 시작함에 따라 이러한 가정이 어긋나고 있다. 또한, 영상 검색 시스템들이 독자적인 환경에서 개발되었기 때문에, 다수의 영상 검색 시스템의 협력으로 성능을 향상시킬 수 있을 것이라 예측되는 상황에도 불구하고, 이에 대한 연구가 부족했다. 본 논문에서는 이 두 가지 문제를 해결하기 위하여, 두 영상 검색 시스템이 사용하는 시각적 특징을 바탕으로, 두 시스템의 상보적인 정보를 이용하는 방법에 대하여 제안한다. 성능에 대한 평가는 가상 모형에서 이루어졌으며, 제안된 방법을 통하여 성능향상이 가능하다는 것을 보여준다.

키워드 : 영상 검색, 재순위화 알고리즘, 협력 모델, 정보 융합

Abstract

Image retrieval has become a huge part of computer vision and data mining. Although commercial image retrieval systems such as Google show great performances, the improvement on the performances are constantly on demand because of the rapid growth of data on web space. To satisfy the demand, many re-ranking methods, which enhance the performances by reordering retrieved results with independent algorithms, has been proposed. Conventional re-ranking algorithms are based on the assumption that visual patterns are not used on initial image retrieval stage. However, image search engines in present have begun to use the visual and the assumption is required to be reconsidered. Also, though it is possible to suspect that integration of multiple retrieval systems can improve the overall performance, the research on the topic has not been done sufficiently. In this paper, we made the condition that other manner than cooperation cannot improve the ranking result. We evaluate the algorithm on toy model and show that propose module can improve the retrieval results.

Key Words : Image Retrieval, Re-ranking Algorithm, Cooperative Model, Information Fusion

1. 서 론

영상 검색(Image Retrieval) 기술은 현재 컴퓨터 비전과 데이터마이닝 분야의 중대한 분야 중 하나이다. 현재 상용화 된 영상검색 시스템은 대표적으로 Google Image Search, Flickr, Bing, Baidu Image Search 등이 있다. 이러한 영상검색 시스템이 보여주는 놀랄만한 성능에도 불구하고, 웹 상에 존재하는 데이터들의 수가 폭발적으로 늘어남에 따라, 영상검색기술의 성능에 대한 개선이 꾸준히 요구되는 상황이다. 이러한 요구사항을 만족시키기 위해 개발되는 방법 중에 가장 보편화 된 방법 중 한 가지는 재순위화(Re-ranking)이다. 재순위화는 초기 영상 시스템이 검색의 결과를 내놓았을 때, 별도의 알고리즘을 통해 각 영상과 질의(Query)와의 연관도를 다시 한 번 계산하고 그에 따라 영상들을 재정렬하는 과정이다. 기존의 재순위화 알고리즘

접수일자: 2014년 2월 7일
심사(수정)일자: 2014년 2월 17일
게재확정일자 : 2014년 2월 17일
† Corresponding author
This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

은 주로 영상 내적인 정보, 즉 시각적 정보를 새로운 연관도를 계산하는 과정에 사용하였다. 이는 과거의 영상 검색 시스템이 오로지 주변의 텍스트, 캡션 등 영상 외적인 정보들을 통해 영상 검색을 수행하였다는 사실에 바탕을 둔, 초기 검색 결과의 순위가, 시각적 정보를 반영하지 않았다는 가정에 기초한다[1-6]. 그러나 현재 Google Image Search 나 Baidu Image Search 는 영상 외적인 정보뿐만 아니라 시각적인 정보를 통하여도 영상을 검색한다[7]. 또한 Google 의 연구기관 내에서는, 영상 내적인 정보와 외적인 정보를 복합적으로 사용하는 방법에 대한 연구 또한 이뤄지고 있으며[8][9] 내용기반 영상검색(Contents Based Image Retrieval) 기술도 학계에서 꾸준히 이뤄지고 있는 추세이다[10]. 그렇기 때문에 내용 기반 영상 검색 시스템(Contents Based Image Retrieval System)과, 그에 관련된 기술이 발전함에 따라 시각정보가 초기 검색에 사용되지 않는다는 가정에서 벗어나는 상황이 많아질 것으로 전망되며, 이 가정을 재고해 볼 필요가 있다.

또한 기존의 재순위화 알고리즘은 단일 검색 시스템의 결과를 개선하는 방법에 집중하였으며, 여러 개의 검색결과가 있을 때, 그들의 결과를 통합하는 방법에 대해서는 연구가 많이 이뤄지지 않은 상태이다. 현재 영상검색 시스템들은 독자적인 환경에서 개발되어 비공개 이용허락(Closed License)로 운영되고 있기 때문에, 상이한 알고리즘과 특징(Feature) 들을 사용하고 있을 가능성이 크다. 따라서 각각의 영상 검색 시스템이 질의와의 연관도를 판단하는 기준을 통합하여 보다 나은 결과를 도출할 수 있을 가능성이 있다.

현재까지 제안된 알고리즘으로서 다수의 영상검색 시스템을 사용하여 재순위화 하는 알고리즘으로는 Crowdreranking[4]이 있다. 하지만 Crowdreranking에서는 다수의 영상 검색 시스템으로부터의 검색 결과를, 단순히 보다 많은 수의 학습 데이터를 마련하기 위해 사용한다. 상기 논문에서는 다수의 영상 검색 시스템의 검색 결과들로부터 Bag of Visual Words 의 방법을 사용하기 위한 dictionary를 구성한다. 이 때 모든 영상이 순위와 관계없이 하나의 학습 데이터로 취급되기 때문에, 각각의 영상 검색 시스템들의 순위 리스트에 관한 정보가 소실된다. 이런 상황에서 복수의 시스템을 사용하는 행위가 의미를 얻기 위해서는, 각각의 영상 검색 시스템이 상이한 시각적 패턴을 띈 영상을 검출 결과로 내놓음으로서, 모든 영상 검색 시스템의 결과가, 특정의 단일 영상 검색 시스템으로부터의 결과보다 더 다양한 시각적 패턴을 보여야 한다. 그러나 영상 검색 시스템이 시각적 정보뿐만 아니라, 텍스트 정보 또한 사용하기 때문에, 단일 영상 검색 시스템으로부터 나온 결과 영상의 시각적 패턴이, 다수의 영상 검색시스템으로부터 나온 결과 영상보다 더 단조로운 시각적 패턴을 보일 것이라는 보장은 없다. 따라서 다수의 영상 검색 시스템을 사용하는 효과가, 믿을 수 있는 양성 학습 데이터의 양이 증가한다는 사실 이외에는 모호하다.

이러한 문제를 해결하기 위하여 본 논문은, 영상검색 시스템이 검색과정에서 영상 내적인 정보를 사용한다는 가정하에서, 두 개의 영상 검색 시스템의 결과를 협력하는 방법에 대해 제안한다. 제 2 장에서는 제안하는 방법에 대하여 두 절에 걸쳐 설명한다. 제 2.1 절에서는 기존의 재순위화 알고리즘과 제안된 알고리즘의 접근법의 차이점을 그래프 모델을 통하여 설명한다. 제 2.2 절에서는 2.1 절에서 설명한 내용을 바탕으로 본 논문에서 제시하는 재순위화 방법에 대하여 설명한다. 제 3 장에서는 제안된 알고리즘을 가상 모형에서 실험하고 그 성능에 대하여 논의하며, 제 4 장에서는 결론 및 향후 연구 방향에 대하여 제시한다.

2. 제안한 재순위화 방법

2.1 접근법

재순위화 알고리즘은, 영상 검색 시스템의 내부적인 구조를 직접 고치는 대신, 검색된 결과에서 질의와의 연관도를 독립적으로 계산하여, 검색 결과의 성능을 높이는 방식이다. 재순위화 알고리즘은 영상 검색 시스템의 내부 구조에 대해 자세히 알 필요가 없다는 점과, 기존의 시스템을 고치지 않은 채로 추가적인 알고리즘을 덧붙여 사용할 수 있다는 점 때문에, 재순위화 알고리즘은 개발적인 측면에 장점을 가지고 있다.

재순위화 알고리즘은 그 기원을 잠정적 적합 피드백(Pseudo Relevance Feedback) 에 두고 있다. 잠정적 적합 피드백은 일반적인 적합성 피드백(Relevance Feedback)과 달리, 인간이 결과에 따라 지도학습(Supervised Learning) 방식으로 피드백을 주지 않고, 자율학습(Unsupervised Learning) 의 방식으로 피드백을 주는 방식이다. 이 자율학습은 주로 재순위화 단계에서 사용할 수 있는 특징인, 초기 영상 검색의 순위리스트에 대한 정보와, 결과로 나온 영상들의 시각적 정보를 사용하여 이루어진다.

잠정적 적합 피드백은 두 가지 가정을 기초로, 앞서 언급한 두 가지 정보를 사용한다[11]. 첫 번째는 초기 영상검색이 어느 정도 합리적인 연관도의 근거를 제시한다는 가정이다. 이 가정은 자율학습에서, 재순위화 이후의 순위 리스트가, 이미 알려진 순위 리스트에서 최소한으로 변화된 결과를 얻도록 한다. 두 번째는 시각적으로 서로 비슷한 영상은 비슷한 영상은 의미상(Semantic Meaning)으로도 비슷하고, 이에 따라 질의로부터 서로 비슷한 연관도를 가진다는 가정이다. 영상검색에서 영상에 할당되는 순위는, 질의와의 연관도를 나타내는 지표이기 때문에 두 번째 가정은 시각적으로 비슷한 영상이 비슷한 순위를 갖도록 한다. 일부의 재순위화 알고리즘[2][4][6] 에서는 두 번째 가정을 직접적으로 사용하는 대신, 첫 번째와 두 번째 가정이 융합된 형태로 변경된 가정을 사용하기도 한다. 이 융합된 형태의 가정은, 검색 순위가 높은 곳에서 반복적으로 나타나는 패턴을 가진 영상은, 질의와 연관된 영상일 확률이 높다는 것이다. 두 번째 가정을 어떠한 형태로 사용하던, 이 두 가지 가정은, 각각 두 가지 정보를 어떠한 방식으로 사용할지에 대한 단서를 제공한다. 이 두 가정을 본 논문에서는 잠정적 피드백의 기본적인 가정이라고 부르도록 한다.

Tian[3]이 제안한 Bayesian Reranking은 이러한 잠정적 피드백의 기본적인 가정이 잘 반영되어 있는데, 이 알고리즘에서는 시각적인 정보를 바탕으로 각 영상이 질의와 관련 있을 사전확률(Prior probability)을 계산하고, 초기 검색 순위를 우도(Likelihood)를 구하는 데에 사용하여 각 영상의 사후확률(Posteriori Probability)를 계산하는 방식을 취하였다. 우도는, 수식에서 시각적 정보를 조건으로 하여야 하지만, 초기 검색 순위가 시각적인 정보를 사용하지 않는다는 가정을 하여, 초기 순위 리스트와, 재순위화 후의 순위 리스트만의 함수로 표현되었다. 이에 따라 Bayesian Reranking은 다음과 같은 에너지 함수를 최소화 시키는 것

을 목적함수로 갖는다.

$$E(\boldsymbol{r}) = \Sigma_{i,j} w_{ij} (r_i - r_j) + \lambda \mathrm{dist}(\boldsymbol{r}, \bar{\boldsymbol{r}}) \qquad (1)$$

식 (1)의 에너지 함수는 사후 확률에 로그를 취한 것이다. w_{ij} 는 영상의 시각적인 패턴의 유사성과 관계된 비중으로, 영상 i와 영상 j가 시각적으로 유사할수록 높은 값을 갖는다. r_i와 r_j는 각각 영상 i와 영상 j의 순위가 되며, $\bar{\boldsymbol{r}}$ 과 $\boldsymbol{r}$은 각각 초기 영상 검색의 결과로 나온 순위 리스트와, 재순위화 후의 순위 리스트이다. λ는 양의 값을 갖는 상수이다. 식 (1)의 우변에서 첫 번째 항은 잠정적 적합 피드백의 두 번째 가정과 연결되며, 두 번째 항은 첫 번째 가정과 연결된다.

Bayesian Reranking에서 주목해야하는 점은 초기 순위 리스트가 제공하는 연관도에 대한 정보와, 시각적 특징이 제공하는 정보가 독립적이라는 가정을 하였고, 이를 평행적으로 사용하였다는 것이다. Bayesian Reranking의 경우, 재순위화 하고자 하는 영상의 순위가, 시각정보를 반영하지 않는다고 가정하였기 때문에 시각 정보와 순위 리스트가 독립적이 된다. 하나의 원인, 즉 영상으로부터 나왔을 때, 두 개의 독립적인 정보가 나왔을 때, 이 두 정보는 공통성을 설명하는 방향으로 연결하는 것이 자연스럽다. 그렇기에, 초기 영상검색에서 시각적 정보를 사용하지 않을 것을 상종하는 기존의 재순위화 알고리즘은 모두 이러한 연결 방식을 따른다. 그림 1. (a) 은 이러한 상황을 도시하고 있다. 본 논문에서 각 문자가 표기하는 바는 표 1 에 나타나 있으며, 그림 내의 위첨자(Superscript) i는 영상 i에서 추출한 패턴임을 나타낸다. 본 논문에서 제 3자는, 초기 영상검색 시스템인 Sys_1과 Sys_2의 내부구조에 대한 직접적인 지식이 없는 상황을 가정한, 일반적인 재순위화 알고리즘의 주체를 지칭한다.

표 1. 본 논문에서 사용되는 표기
Table 1. The notation in this paper

Sys_1	Image retrieval system 1
Sys_2	Image retrieval system 2
$\boldsymbol{\alpha}$	The set of features that are observed by 3rd party on re-ranking step
$\boldsymbol{\beta}$	The set of features that are used on Sys_1 and not observed by third party
$\boldsymbol{\gamma}$	The set of features that are used on Sys_2 and not observed by third party
$\boldsymbol{Rank_1}$	Initial rank list from Sys_1
$\boldsymbol{Rank_2}$	Initial rank list from Sys_2

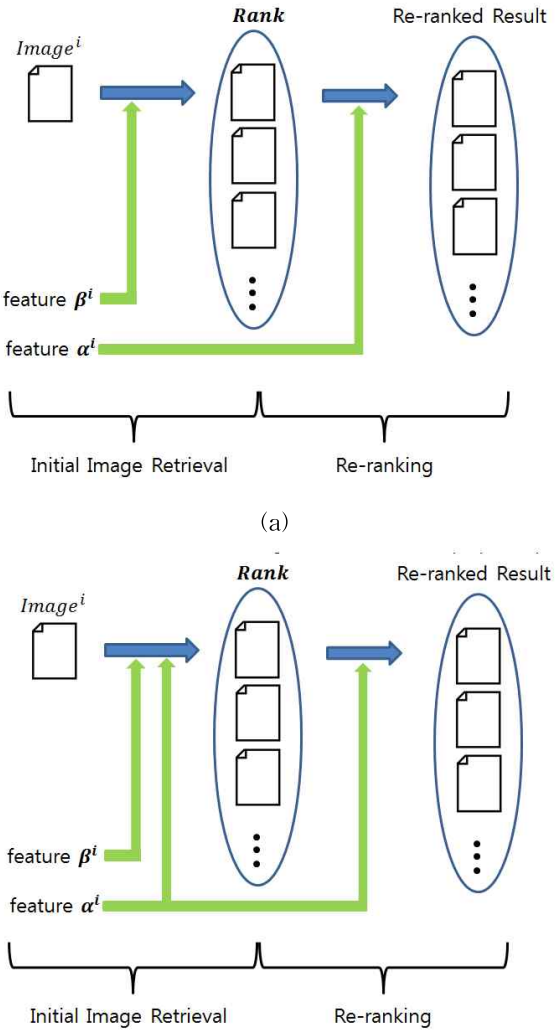

그림 1. 재순위화 알고리즘에서 가정하는 특징의 사용 (a) 기존의 재순위화 알고리즘에서는 초기 영상 검색 시스템에서 시각적 정보를 사용하지 않을 것을 가정한다. (b) 본 논문에서 제안된 알고리즘에서는 재순위화 단계에서 관측한 특징이 초기 영상검색에서 사용되었을 것을 가정한다.
Fig. 1. Models of feature usage that are assumed in re-ranking algorithms: (a) conventional re-ranking algorithms are based on the assumption that visual features, which are used on re-ranking stage, are not used on initial retrieval stage; (b) proposed re-ranking algorithm is based on the assumption that the feature used on re-ranking stage are already used on initial retrieval stage.

그림 1. (a) 에서는 영상 i의 특징 중 비 시각적인 특징, 즉 재순위화 단계에서 관측하지 않는 특징 $\boldsymbol{\beta^i}$만이 초기 순위 리스트에 영향을 미치며, 따라서 순위 리스트 $\boldsymbol{Rank}$가 제공하는 정보는, 영상의 $\boldsymbol{\alpha^i}$와 다른 특징, $\boldsymbol{\beta^i}$의 정보라고 볼 수 있다. 두 특징 $\boldsymbol{\alpha^i}$, $\boldsymbol{\beta^i}$가 하나의 영상을 원인으로 삼고 있되 각각 다른 측면을 나타내기 때문에, 이들의 정보를 통

합하여 사용하는 식(1) 과 같은 방식이 합리적이라고 할 수 있다.

하지만 서론에서 언급한 대로, 현재 영상검색 시스템들은 점점 영상 내적인 정보, 즉 시각적인 정보를 점점 많이 사용하는 추세이다. 이러한 이유로 앞으로는 재순위화 단계에서 관측한 시각정보가 추가적인 정보를 제공할 수 있을 경우가 보다 줄어들 것으로 예측된다. 따라서 초기 순위 리스트로부터 얻는 정보가, 시각적인 특징으로부터 얻는 정보와 별개의 측면을 나타내는 것이라는 가정이 깨어지고 있으며, 새로운 종속관계에 대한 탐구가 필요하다.

그림 1. (b)는, 이렇게 시각적인 정보가 순위 리스트에 영향을 주고 있는 상황을 도시한다. 제 3자가 사용한 시각적인 정보 $\boldsymbol{\alpha^i}$가 순위 리스트를 도출할 때 사용되었다고 하면, 더 이상 순위 리스트에서 얻는 정보와 시각적인 정보를 별개의 정보라고 생각하고, 이를 취합하는 방식이 합리적이지 않게 된다. 만일 그렇다면, $\boldsymbol{Rank}$에서 이미 사용한 정보를 다시 한 번 중복되게 사용하는 것이기 때문이다. 이는 기존의 순위 리스트를, 관측한 특징 $\boldsymbol{\alpha^i}$에 더 비중을 두어 연관도를 측정하겠다는 의미가 되며, 재순위화가 성능을 향상시킬 것이라는 근거를 잃게 된다. 이 경우에는 오히려 영상 검색 시스템이 더 많은 특징을 사용하였기 때문에, $\boldsymbol{\alpha^i}$ 만을 관측하여 연관도를 검색한 것 보다 신뢰성 있다고 보는 것이 합리적이다. 이에 따라서 $\boldsymbol{\alpha^i}$외의 특징, $\boldsymbol{\beta^i}$가 연관도에 어떠한 정보를 제공하는지에 대하여 예측하는 것이 합리적이다. 이런 점에 있어서, $\boldsymbol{\beta^i}$는 기존의 영상 검색 시스템이 내린 영상의 연관도에 대한 판단에 있어서, $\boldsymbol{\alpha^i}$가 제공하지 못하는 정보를 제공한다고 볼 수 있고 따라서, $\boldsymbol{\alpha^i}$에 대하여 상보적인 정보를 제공한다고 할 수 있다.

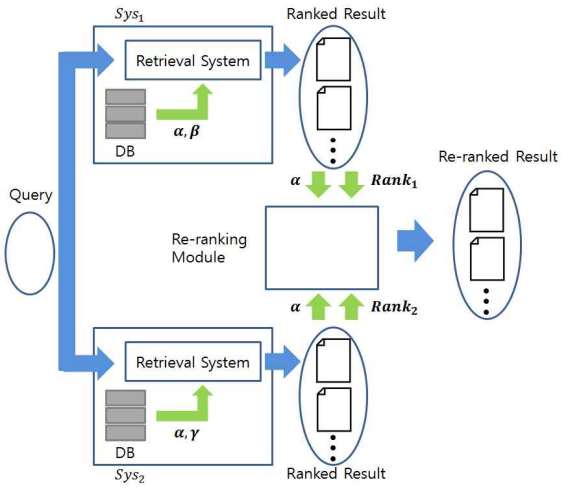

그림 2. 두 영상 검색 시스템의 협력적인 사용
Fig. 2. Cooperative usage of two retrieval systems

본 논문은 이러한 상보적인 정보 $\boldsymbol{\beta^i}$를 여러 개의 영상 검색 시스템으로부터 구하여, 통합하는 방식을 제안한다. 그림 2. 는 이런 협력적인 상황을 도시한다. 두 영상 검색기가 사용하지만 제 3자가 관측하지 않은 특징은 각각 $\boldsymbol{\beta}$와 $\boldsymbol{\gamma}$가 되고, 만약 $\boldsymbol{Rank_1}$과 $\boldsymbol{Rank_2}$과 다르다면, $\boldsymbol{\alpha}$와 $\boldsymbol{\beta}$, $\boldsymbol{\alpha}$와 $\boldsymbol{\gamma}$가 각각 Sys_1과 Sys_2이 사용하는 특징의 전체 집합이 되도록 정의되었기 때문에, $\boldsymbol{\beta}$와 $\boldsymbol{\gamma}$가 연관도에 대하여 서로 다른 설명을 한다고 생각할 수 있다. 본 논문에서 제안하는 협력의 방식은, 이러한 $\boldsymbol{\alpha}$,$\boldsymbol{\beta}$, 그리고 $\boldsymbol{\gamma}$의 정보를 통합하여 영상 검색의 성능을 높이는 것이다. 일반적인 논문에서는 시각적 외적인 정보에서 나온 초기 검색결과를, 시각적인 정보를 통하여 보강시켜 검색 결과의 성능을 이룬다면, 본 논문에서는 여러 가지 영상검색기가 사용하는 상보적인 특성을 활용하여 영상 검색의 성능을 높인다.

2.2 상보적인 특징의 정보를 이용한 재순위화

현재 상용화 된 영상 검색 시스템에서 시각적인 정보를 통하여 영상검색을 시키는 것으로 알려진 것으로는 Google의 연구그룹이 발표한 Visuarank[8] 가 있다. Visualrank는 검색의 이용자가 한 웹페이지를 방문한 후, 관련된 웹페이지에 역시 관심을 갖고 연속적으로 방문할 것이라는 Pagerank[12]의 모델을 따른다. 이 때 관련된 웹페이지는 영상 검색이라는 적용 분야에 맞춰져 관련된 영상으로 대체되며, 관련된 웹페이지는 시각적으로 비슷한 영상으로 대체된다. 즉 Visualrank는 앞서 언급된 잠정적 적합 피드백에 대한 가정 중 융합된 형태의 두 번째에 충실한 방법이다.

구체적으로 Visualrank는, 무수히 많은 이용자가 앞서 언급한대로 연속적인 방문을 하는 상황을 가정했을 때, 각 영상을 방문하고 있는 이용자 수를 통하여 영상들의 질의와의 연관도를 측정한다. 이러한 모델은 각 노드가 영상을 나타내는 그래프 위에서 이루어지는 랜덤워크를 통하여 설명할 수 있다. 랜덤워크가 이루어지는 그래프는, i번째 영상과 j번째 영상의 쌍별 유사성이 i,j번째 원소가 되는 유사성 행렬(Similarity Matrix)이나, i번째 영상을 방문한 이용자가, j번째 영상을 방문하는 확률이 i,j번째 원소가 되는 인접성 행렬(Adjacency Matrix)로 정의된다. 이 때, 인접성 행렬은, 유사성 행렬을 열별 정규화 시킨 결과와 동일하다 이렇게 구성된 그래프에서 랜덤워크를 수행하였을 때, 프로세스가 포화되었을 시 유저가 각 노드를 방문하고 있을 확률 값은 인접성 행렬의 고유 벡터로 구할 수 있다. 다음 식은 영상 검색에서 Visualrank를 구하는 방식이다.

$$\boldsymbol{p} = \boldsymbol{Ap} \tag{2}$$

식 (2)에서 $\boldsymbol{A}$는 인접성 행렬이고 $\boldsymbol{p}$는 연관도 점수(Relevance Score) 벡터이다. 고유 벡터 $\boldsymbol{p}$의 i번째 원소는, i번째 영상을 방문하고 있을 확률이다. 랜덤워크의 특성상, 이 확률 값이 높게 나오는 영상은, 반복적으로 나타나는 시각적 패턴을 많이 포함하는 영상이 된다. 만약 잠정적 적합 피드백에 대한 두 번째 가정에 의하여, 시각적인 유사성이 비슷한 의미를 뜻한다면, 이는 이용자들이 많이 방문하고 있는 영상이 되며, 결과적으로 연관도가 많은 영상이라는 결론을 내릴 수 있다.

본 논문에서는 협력의 대상이 되는 영상 검색 시스템이 Visualrank를 응용한 방식으로 시각적인 정보를 이용한다고 가정한다. 뿐만 아니라 $\boldsymbol{\beta}$와 $\boldsymbol{\gamma}$가 각각 $\boldsymbol{Rank_1}$과 $\boldsymbol{Rank_2}$에 주는 영향과 효력 상 동등한 특징인 $\hat{\boldsymbol{\beta}}$와 $\hat{\boldsymbol{\gamma}}$를 생성하는 방식을 제안한다. $\hat{\boldsymbol{\beta}}$와 $\hat{\boldsymbol{\gamma}}$가 연관도에 대해 정보를 제시하는 방식 또한 Visualrank를 응용한 방식으로 이루어진다고 가정한다. Visualrank를 응용한 방식이라 함은, 연관도 점수 벡터로 인접성 행렬의 고유벡터가 아닌, 유사성 행렬의 고유벡터를 사용하는 것으로 변경된 방식을 말한다.

제 3자의 경우 Sys_1과 Sys_2가 사용하는 특징 중 β와 γ가 무엇인지 구체적으로 알지 못할 뿐 아니라, 시스템이 사용하는 알고리즘 또한 알 수 없기 때문에 β와 γ를 직접 사용하는 방식은 사용할 수 없다. 또한 초기 영상 검색 시스템인 Sys_1과 Sys_2에서 β와 γ를 사용하는 방식은 연관도를 구하기 위한 하나의 자체적인 알고리즘일 뿐이다. 중요한 것은 이것이 최종적으로 연관도 점수 벡터, 혹은 순위 리스트의 형태로 해석된 정보이다. 그렇기 때문에 β와 γ가 구체적으로 무엇인지보다, 연관도에 어떠한 영향을 끼치는지가 중요하다.

이 때, α와 β, α와 γ로부터 정보를 얻어 계산된, 영상들의 연관도에 대한 정보는 이미 $\boldsymbol{Rank}_1$과 $\boldsymbol{Rank}_2$의 형태로 주어진 상황이다. 따라서 $\hat{\beta}$와 $\hat{\gamma}$는, Visualrank를 응용한 방식을 통하여 영상들의 연관도가 구하여질 경우, α가 설명하지 못하는 부분을 설명할 수 있는 형태의 특징이 된다. 다른 말로 하자면, 순위 리스트 $\boldsymbol{Rank}_1$과 $\boldsymbol{Rank}_2$와 일치하는 연관도 점수 벡터 $\boldsymbol{p}_1$, $\boldsymbol{p}_2$를 고유벡터로 하는 유사성 행렬 $\boldsymbol{S}_1$과 유사성 행렬 $\boldsymbol{S}_2$가 있으며, α를 통하여 계산된 유사성 행렬 $\boldsymbol{S}_\alpha$가 있을 때, $\boldsymbol{S}_1$과 $\boldsymbol{S}_\alpha$, $\boldsymbol{S}_2$와 $\boldsymbol{S}_\alpha$의 괴리를 $\hat{\beta}$와 $\hat{\gamma}$가 채워주게 된다. 그렇기 때문에, $\hat{\beta}$와 $\hat{\gamma}$를 구하는 과정은, $\boldsymbol{S}_1$와 $\boldsymbol{S}_2$를 구하는데 있어서, 연관도 점수 벡터에서 유사성 행렬을 구하는 방식이며, Visualrank의 역문제라고 생각할 수 있다.

고유벡터를 구하는 데에 있어서, 본래의 Visualrank가 사용한 인접성 행렬을 사용하는 대신, 유사성 행렬을 사용한 이유는, 대칭적인 거리 측정체계(Distance Metric)를 사용하였을 경우 그 제한조건이 더 단순한 형태를 보이기 때문이다. 본 논문에서 제시하는 방식이 고유벡터에서 행렬을 구하는 문제이기 때문에, 제한조건의 복잡도는 제안하는 알고리즘의 복잡도와 직접적으로 연관된다. 먼저 인접성 행렬과 유사성 행렬 모두, 비음수성과 삼각부등식을 만족시키기 위해, 각 행렬의 각 원소가 0보다 커야 하며, 각 행렬의 고유값들이 모두 0보다 커야 한다. 이는 각 행렬을 양반정치행렬(Positive Semidefinite Matrix)으로 구성함으로서 해결할 수 있다. 다만 양반정치행렬이 유사성 행렬이 되기 위해서는, 대칭행렬이 되며 대각행렬이 모두 동일하면 된다. 하지만 인접성 행렬이 되기 위해서는 같은 행에 있는 원소들의 합이 1이 되어야 하며, 대각성분으로 그 성분이 포함하는 행을 나누었을 경우, 유사성 행렬의 형태가 되어야 한다. 이 때, 유사성 행렬과 인접성 행렬의 고유 벡터를 통해 얻는 순위 리스트는, 다수의 영상의 패턴의 분포가 하나의 덩어리로 존재할 경우(Homogeneous), 거의 동등하다는 사실을 실험적으로 확인할 수 있었다. 한 쌍의 영상의 패턴간의 유사성을 측정하기 위한 거리 측정체계로는 가우시안 거리를 사용하였다.

$\boldsymbol{S}_1$과 $\boldsymbol{S}_2$를 구하는데 있어서, 유일성이 보장되지 않는 부분이 두 군데 있는데, 첫 번째는 $\boldsymbol{Rank}_1$과 $\boldsymbol{Rank}_2$와 일관성 있는 연관도 점수 벡터 $\boldsymbol{p}_1$, $\boldsymbol{p}_2$를 구하는 과정이다. 순위 리스트라는 것은 확률로 존재하는 연관도 점수 벡터를 양자화한 값이기 때문에, 순위에서 연관도 점수 벡터를 구하는 과정은 유일하지 않다. 두 번째는 이러한 연관도 점수 벡터 $\boldsymbol{p}_1$, $\boldsymbol{p}_2$로부터 유사성 행렬 $\boldsymbol{S}_1$과 $\boldsymbol{S}_2$을 구하는 과정이다. $n \times n$ 대칭행렬의 형태를 지닌 유사성 행렬의 경우, n개의 직교하는 고유 벡터를 지니기 때문에, 연관성 점수 벡터를 구한 후에도 총 $n-1$ 차원의 자유도를 갖는다. 이 두 문제를 해결하기 위하여 잠정적 적합 피드백의 첫 번째 가정에 알맞은 방식을 사용하였다. α만을 사용하여 구한 유사성 행렬 $\boldsymbol{S}_\alpha$과 연관도 점수 벡터 $\boldsymbol{p}_\alpha$가, α와 β 혹은 α와 γ를 통해 구한 유사성 행렬 $\boldsymbol{S}_1$과 $\boldsymbol{S}_2$와 연관도 점수 벡터 $\boldsymbol{p}_1$, $\boldsymbol{p}_2$에 어느 정도 합리적인 근거를 제시한다고 볼 수 있다. 따라서 $\boldsymbol{S}_\alpha$와 $\boldsymbol{S}_1$ 혹은 $\boldsymbol{S}_2$, $\boldsymbol{p}_\alpha$와 $\boldsymbol{p}_1$ 혹은 $\boldsymbol{p}_2$는 최소한의 변화를 갖도록, 다른 말로는 최대한 유사하도록 연관도 점수 벡터와 유사도 행렬을 정하였다. 이 유사성을 정하는 과정에서는 코사인 유사도를 사용하였다.

가우시안 거리를 통하여 유사성 행렬을 구성하였을 경우, 전체 특징에서 유사성 행렬은 각 특징에서 유사성 행렬의 원소별 곱이 된다. 이렇게 전체 특징에서 구해진 유사성 행렬의 고유 값은, 전체 특징을 고려하였을 경우의 연관도 점수 벡터가 된다.

3. 실험 결과

제안된 알고리즘은 두 영상검색 시스템이 기존에 사용하고 있었던 특징을 사용하여 영상들과 질의와의 연관성에 대해 내린 결론을 협력적으로 사용하는 방법이다. 현재 상용화된 영상검색 시스템인 Google 과 같은 시스템에서는 아직 구체적으로 어떠한 특징을 사용하고 있는지 확인할 수 없고, 이에 따라 α의 추론에 문제가 생긴다. 또한 내용 기반 영상검색 시스템을 직접 구성하더라도, 영상 내적인 정보가 의미상 괴리(Semantic Gap)를 일으킬 수 있으며 이에 따라 성능이 저하될 수 있다. 의미상 괴리에 의한 성능의 저하는 영상 검색 시스템 자체의 성능과 관련된 바이기 때문에 본 논문의 논지를 벗어난다. 논문의 논지인 두 영상검색 시스템의 협력에 의한 성능현화를 직관적으로 확인하기 위하여 다음과 같은 가상 모형(Toy Model)을 구성하고 성능측정을 하였다. 가상 모형은 두 영상 검색 시스템으로부터 받는 순위리스트 $\boldsymbol{Rank}_1$과 $\boldsymbol{Rank}_2$가 의미상 괴리에 의한 오차를 적게 보인다고 가정하며, 이들이 사용하는 모든 특징, 즉 α, β와 γ를 사용하였을 경우 더 정교한 결과를 얻을 수 있다는 상황을 가정하고 성능을 평가한 것이다. 실환경에서 이러한 가정을 만족시키는 환경이라면, 같은 정도의 성능 개선을 기대할 수 있다.

3.1 가상 모형의 구성

가상 모형은 다음과 같이 구성되었다. 본 실험은 총 30장의 영상을 재순위화 하는 상황을 가정하였다. 특징벡터의 길이는 쌍별 유사성에서 이행(Transitivity)적인 성질이 나타나는 것을 막기 위해 영상의 수보다 많거나 같아야 한다. 이에 따라 각 영상이 30차원의 특징 벡터를 갖고 있다고 가정하였다. 이 때, 특징 벡터에서 α, β와 γ에 각각 10개씩 원소를 배정하였다. 즉 i 번째의 가상적인 영상의 특징 벡터 $\boldsymbol{x}^i$의 첫 번째부터 열 번째까지 원소는 α에 해당하는 특징으로, 열한 번째에서 스무 번째까지의 원소는 β에 해당하는 특징으로, 스물한 번째부터 서른 번째 원소는 γ 에 해당하는 원소로 삼았다. 특징 벡터의 각 원소는 기본적으로는 평균값 0의 정규분포를 생성 확률밀도함수로 하는 확률변수의 실현 값으로 생성하였다. 생성 확률밀도함수의 표준편차 값은, 각 실험마다 목적에 맞게 정하였다. 이는 질의의

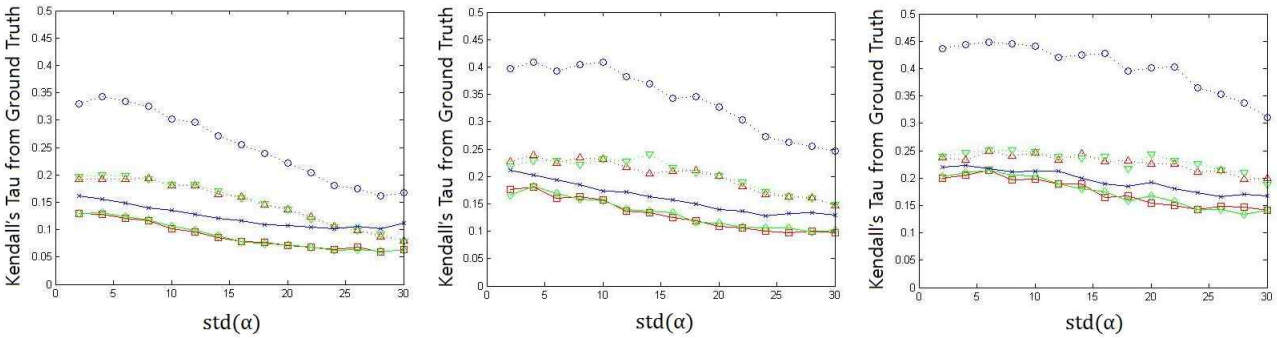

그림 3. 고정된 β, γ의 원소별 표준편차에 대해 α의 원소별 표준편차의 변화에 따른 실험. std(f)는 특징 f에 해당하는 원소들의 원소별 표준편차. (a) std(β) = std(γ) = 15, (b) std(β) = std(γ) = 21.2, (c) std(β) = std(γ) = 30

Fig. 3. Experiment on the varying entitywise standard deviation of α while entitywise standard deviation of β, γ are fixed. std(f) is standard deviation of entity that belongs to feature set f. (a) std(β) = std(γ) = 15, (b) std(β) = std(γ) = 21.2, (c) std(β) = std(γ) = 30

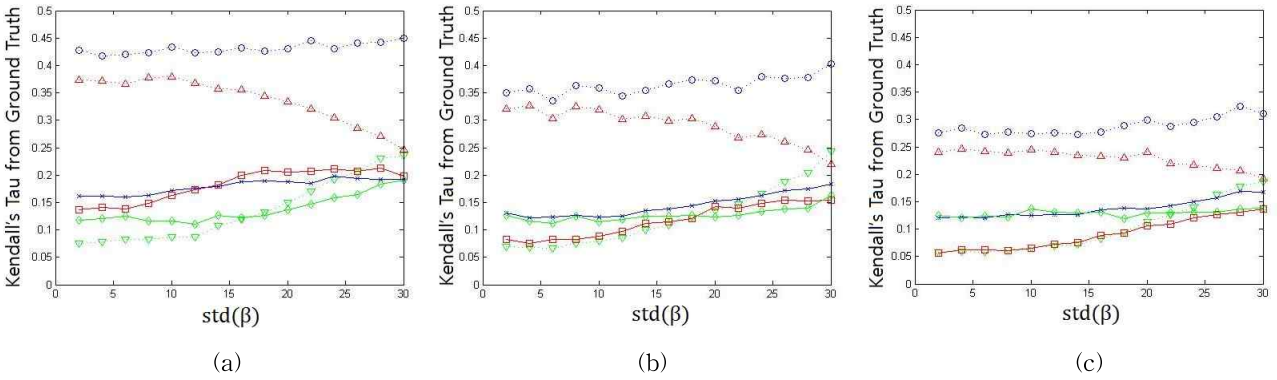

그림 4. 고정된 α, γ 의 원소별 표준편차에 대해 β 의 원소별 표준편차의 변화에 따른 실험. std(γ) = 30로 고정, (a) std(α) = 15, (b) std(α) = 21.2, (c) std(α) = 30

Fig. 3. Experiment on the varying entitywise standard deviation of β while entitywise standard deviation of α, γ are fixed. std(γ) are fixed to 30. (a) std(α) = 15, (b) std(α) = 21.2, (c) std(α) = 30

표 3. 상보적인 정보에 의한 성능향상을 관측하기 위한 여섯 개의 알고리즘의 내용과 그래프 내의 표기 방법

Table 3. Six algorithms modeled to observe performance change by using complementary information

Re-ranking Subject	Complementary Information	Information used on re-ranking	Method to measure relevance to query	Marker on graph (line)
Third person	unused	α	Eigenvector of S_α	Blue circle (dashed)
Sys_1	unused	α,β	Euclidean distance from ground truth mean	Red triangle(dashed)
Sys_2	unused	α,γ	Euclidean distance from ground truth mean	Green inverted triangle (dashed)
Third person	used	α,$Rank_1$,$Rank_2$	Eigenvector of $S_{\alpha\hat{\beta}\hat{\gamma}}$	Blue cross (solid)
Sys_1	used	α,β,$Rank_2$	Eigenvector of $S_{\alpha\beta\hat{\gamma}}$	Red square (solid)
Sys_2	used	α,γ,$Rank_1$	Eigenvector of $S_{\alpha\hat{\beta}\gamma}$	Green diamond (solid)

특징벡터가 원점에 존재하며, 나머지 영상들이 질의를 중심으로 분포하고 있는 상황을 모델링 한 것이다.

지상 검증 자료(Ground Truth) 는 생성된 특징벡터 전체를 바탕으로, 생성확률 분포의 평균값인 원점으로부터의 유클리디언 거리로 삼았다. 협력의 주체가 되는 영상 검색 시스템 Sys_1과 Sys_2는 각각 특징벡터에서 α와 β에 해당하는 원소들로 이루어진 좌표와, α와 γ에 해당하는 원소들로 이루어진 좌표의 원점으로 부터의 유클리디언 거리로 연

관성에 대한 초기 순위 리스트 $Rank_1$와 $Rank_2$를 만들도록 하였다. 또한, α의 유사성 행렬의 고유 벡터만으로 순위 리스트를 만들었다. 이 세 가지 순위 리스트는 상보적인 특징을 사용하여 재순위화 하지 않은 상태의 결과가 된다.

제안된 알고리즘을 통하여 영상 검색 결과의 성능향상을 확인하기 위한 순위 리스트는 총 세 가지 방식에 의하여 구해졌다. 첫 번째 방식은 제 3자가 $Rank_1$, $Rank_2$로부터 $\hat{\beta}$와 $\hat{\gamma}$를 생성하여 재순위화를 이룬 것이다. 이 경우 연관도는 α, $\hat{\beta}$, $\hat{\gamma}$를 통하여 이루어진다. 나머지 두 방식은 Sys_1과 Sys_2 각각에 대해 아는 입장에서의 입장에서, 각각 $Rank_2$로부터 $\hat{\gamma}$를, 혹은$Rank_1$ 로부터 $\hat{\beta}$를 생성하여 연관도를 다시 계산한 것이다. 이 경우 연관도는 각각 α, β, $\hat{\gamma}$와 α, $\hat{\beta}$, γ를 통하여 계산되어진다. 지금까지 언급된 총 여섯 가지 알고리즘의 내용과 그래프에서의 표기방식이 표 3에 정리되어 있다.

특징 벡터간의 유사성을 측정하기 위한 가우시안 거리의 분산 값은, 즉 식 (3) 의 σ^2 은, 실험적인 관측을 통하여 3000 으로 잡았다. 성능을 판단하는 지표로는 앞서 설명된 여섯 개의 알고리즘이 도출한 순위 리스트와 지상 검증 자료간의 Kendall's tau를 사용하였다. 따라서 각 알고리즘의 성능을 표시하는 선이 그래프 내의 아래쪽에 위치할수록 지상 검증 자료에 가깝고, 높은 성능을 보인다고 할 수 있다.

실제 영상 검색 시스템에서 성능개선은

3.2 α의 원소별 표준편차의 변화에 따른 실험

첫 번째 실험은, 관측되지 않은 특징의 원소별 표준편차가 일정할 경우, 관측한 특징에 해당하는 원소별 표준편차의 변화에 따른 성능개선의 정도를 비교한 것이다. 특징벡터를 구성하는 한 원소의 분산은, 그 원소가 영상간의 거리에, 혹은 원점으로부터 한 영상까지의 거리에 얼마나 영향을 주는지를 나타낸다. 3.1 절에서 언급한 방법대로, 가우시안 분포에 따라 특징 벡터의 각 원소를 생성하였을 경우, 두 특징벡터간의 유클리디언 거리의 제곱은 일반화된 Chi-square 분포를 갖는다. 이는 원점으로부터의 거리의 제곱 역시 마찬가지이다. Chi-square 분포의 평균값은 합쳐진 가우시안 분포의 분산들의 합이다. 따라서 각 원소를 생성할 때 확률밀도함수의 분산과 표준편차는, 해당 원소가 유클리디언 거리에 얼마만큼 영향을 주는지를 정하게 된다. 본 실험에서는 β와 γ에 해당하는 원소 하나하나의 표준편차 값을 각각 15, 21.2, 30를 고정시킨 상태에서, α에 해당하는 원소 하나하나의 표준편차 값을 $[0,30]$의 범위로 조절하며 성능을 관찰하였다. 이 때, β와 γ의 분산은 α의 분산이 측정 범위 내의 최대치를 가질 때와 비교하여 25%, 50%, 100% 가 된다.

따라서 첫 번째 실험은, 관측된 특징 α가 영상의 질의로부터의 연관도에 미치는 영향력의 변화에 따라, 상보적인 특징의 정보가 어느 정도의 성능향상을 보일 수 있는지 여부를 확인한 실험이다. 본 실험의 결과는 그림 2 에 도시되어 있다. 실험의 결과는, 모든 결과에서 상보적인 특징을 사용한 경우에서, 그것을 사용하지 않았을 때와 비교하여, 성능향상이 이루어진다는 사실을 보여준다.

또한 대부분의 상황에서, 붉은색으로 도시된, 다른 영상검색 시스템의 정보를 전혀 사용하지 않은 상황에 비해, 제 3 자가 상보적인 특징의 정보를 추출하여 재순위한 것의 성능이 더 좋다는 것을 알 수 있었다. 성능 개선이 이루어지지 않은 상황은, Sys_1과 Sys_2이 각각 사용하는 특징의 영향력에 비하여 상보적인 특징의 영향력이 거의 없을 경우, 즉 협력이 별로 필요하지 않은 경우이다. 이러한 경우, 잠정적 적합 피드백의 가정을 사용하여 생성한 $\hat{\beta}$와 $\hat{\gamma}$, 두 개를 사용하는 것 보다, 정확한 정보 β 혹은 γ 중 하나를 사용하는 것이 더 지상 검증 자료에 더 가까운 결과를 얻을 수 있다는 사실을 알 수 있다.

3.2 β의 원소별 표준편차의 변화에 따른 실험

두 번째 실험은 각 영상 검색 시스템이 지상 검증 자료에 대하여 알고 있는 정도가 다를 경우의 실험이다. 본 실험은 γ 에 해당하는 특징벡터의 원소별 표준편차는 30 이고 α에 해당하는 원소별 표준편차가 각각 15, 21.2, 30 일 경우, β의 표준편차에 따라 성능 개선이 어떻게 이루어지는지 관찰하였다. β에 해당하는 원소별 표준편차가 $[0,30]$의 범위 내에 있을 경우의 성능이 측정되었다. 즉 각 그래프의 최우측에서 Sys_1과 Sys_2가 관측하는 특징의 연관도에 미치는 영향력이 같아지며, 그 좌측에서는 Sys_2가 관측하는 특징이 영향력이 더 강하다고 할 수 있다.

실험 결과에서 두 가지 사실을 알 수 있다. 먼저 β에 해당하는 원소의 표준편차가 작을 때, 제 3자가 상보적인 특징의 정보를 추출하여 재순위화를 이루었을 경우의 성능은, Sys_1과 Sys_2가 상보적인 특징의 정보를 사용하지 않았을 경우의 사이에 존재하였다. 이는 첫 번째 실험에서 성능개선이 이루어지지 않는 상황과 마찬가지로, Sys_2가 관측하는 특징이 지상 검증 자료가 되는 특징의 대부분을 알고 있기 때문에, 지상 검증 자료에 가까운 성능을 보이고 있고, 잠정적 적합 피드백의 가정을 사용하여 생성한 특징을 통해 얻은 정보로는 그 성능을 뛰어넘기 어려운 상황이다. 하지만 이러한 상황에서 제 3자의 상보적인 특징의 정보를 이용한 재순위화의 결과는, Sys_1보다 Sys_2의 성능에 더 가까운 형태를 보인다. 이 사실은 중요하다. 왜냐하면 어떠한 사전지식을 제 3자에게 주지 않았음에도 불구하고, 재순위화가 더 좋은 성능의 영상 검색 시스템의 결과를 따라가는 모습을 보여주는 것이기 때문이다. 만약 추후에 사용할 영상 검색 시스템 두 개가, 즉 모든 질의에 대한 평균 성능은 비슷하지만 특정한 질의에 따라 우열이 바뀔 수 있다고 가정해보자. 이러한 경우, 본 논문에서 제시한 재순위화 알고리즘은 항상 더 좋은 쪽의 결과에 더 가까운 성능을 보이기 때문에, 모든 질의에 대한 평균 성능은 단일 영상 검색 시스템보다 더 높을 것을 예측할 수 있다.

다음으로, Sys_1과 Sys_2가 상보적인 특징을 사용하여 재순위화를 하였을 경우 성능이 어떻게 변하는지에 관하여 알 수 있다. 보다 불리한 상황인 Sys_1에서 $Rank_2$를 바탕으로 $\hat{\gamma}$의 정보를 얻어 재순위화를 할 경우, 성능이 많이 향상 되었지만, 유리한 상황인 Sys_2가 $Rank_1$을 바탕으로 $\hat{\beta}$를 구하여 재순위화를 할 경우, 오히려 성능이 약간 떨어지는 모습을 보였다. 이는 열등한 정보를 가진 시스템의 협력이 오히려 우월한 정보를 가진 시스템의 성능의 열화를 가져올 수도 있다는 사실을 시사한다. 하지만 Sys_1이 개선되는 정도와 Sys_2가 열화되는 정도를 비교하였을 경우, 항상 Sys_1이 개선되는 정도가 더 크다는 사실을 관찰할 수 있었다. 이는 앞서 언급했던 바와 마찬가지로, 두 시스템의 모든 질의에 대한 평균 성능이 비슷하고, 질의에 따라 우열이 갈리

는 상황에서 다른 영상 검색 시스템으로부터 상보적인 정보를 얻으면, 그렇지 않았을 때에 비해 평균적으로 더 좋은 성능을 얻을 것이란 사실을 유추할 수 있게 한다.

4. 결론 및 향후 연구

본 논문에서는 여러 개의 영상 검색 시스템이 시각적인 특징을 사용한다는 가정을 바탕으로, 순위 리스트에서 관측된 특징과 상보적인 정보를 가진 특징을 생성한 후, 이들을 합쳐서 전체적인 성능을 향상시키는 방법에 대하여 제안하였다. 구체적으로는, 가우시안 유사성을 바탕으로 유사성 행렬을 구성한 후, Visualrank의 역문제를 풀어서 특징을 추출한 후, 추출된 특징들을 결합한 유사성 행렬을 구하였다. 이렇게 구한 유사성 행렬로부터 다시 한 번 연관성 점수 벡터를 구하는 방식으로 재순위화를 이루었다. 실험 결과는, 본 논문에서 가정한 상황에서, 두 영상 검색 시스템의 협력이 가능하며 제안한 방법을 통하여 검색 결과의 성능향상을 이룰 수 있다는 사실을 보여준다.

향후 연구는 크게 두 가지 문제를 해결하기 위한 연구가 필요할 것으로 보인다. 첫 번째는, 어떠한 특징을 기존의 영상 검색시스템에서 사용하고 있는가에 대해 알아낼 수 있는 방법이다. 관측된 특징이 기존의 영상 검색 시스템에서 사용되고 있는지 여부에 따라, 그림 1.(a) 의 종속관계 추론을 사용하여 일반적인 재순위화 알고리즘을 적용시킬지, 아니면 그림 1.(b) 의 종속관계 추론을 사용하여 상보적인 특징을 추출한 후, 협력을 통해 성능향상을 이루어낼지 확실히 정할 수가 있게 된다. 이는 실제 영상 검색 시스템의 성능을 향상시키기 위한 필수적인 조건이다.

두 번째는, 제한조건을 간단히 만들기 위하여 Visualrank에서 인접성 행렬을 사용하던 부분을 유사성 행렬로 바꾼 부분에 대한 개선이다. 본 논문에서 제안된 알고리즘은 이 때문에, 전체 특징 공간에서 다수의 영상의 패턴의 분포가 하나의 덩어리로 존재할 경우에는 좋은 성능을 보이지만, 여러 개의 덩어리로 존재할 경우에는(Heterogeneous) 성능이 떨어지게 된다. 이러한 문제를 해결하기 위해 보다 복잡한 제한 조건을 갖는 행렬을 생성할 수 있는 방법, 혹은 보다 나은 영상 검색 알고리즘의 역문제를 푸는 방법에 대한 연구가 요구된다.

References

[1] R. Yan, A. Hauptmann, and R. Jin, "Multimedia search with pseudo-relevance feedback," *Proceedings of the 2nd international conference on Image and video retrieval*, vol. 2728, pp. 238-247, 2003.

[2] W. H. Hsu, L. S. Kennedy, and S.-F. Chang, "Video search reranking via information bottleneck principle," *Proceedings of the 14th annual ACM international conference on Multimedia*, pp. 35-44, 2006.

[3] X. Tian, L. Yang, J.Wang, Y. Yang, X. Wu, and X.-S. Hua, "Bayesian video search reranking," *Proceedings of the 16th ACM international conference on Multimedia*, pp. 131-140, 2008.

[4] Y. Liu , T. Mei and X. S. Hua, "CrowdReranking: Exploring multiple search engines for visual searchreranking," *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval*, pp.500-507, Mar. 2009

[5] X. Tian, D. Tao, X.-S. Hua, and X. Wu, "Active reranking for web image search," *IEEE Transactions on Image Processing*, vol. 19, no. 3, pp. 805-820, 2010.

[6] L. Duan, W. Li, I. W. Tsang, and D. Xu, "Improving web image search by bag-based reranking," *IEEE Transactions on Image Processing*, vol. 20, no. 11, pp. 3280 - 3290, Nov. 2011.

[7] Wikipedia. "List of CBIR Engines" Available: http://en.wikipedia.org/wiki/List_of_CBIR_engines, 2013, [Accessed: December, 22, 2013]

[8] Y. Jing and S. Baluja, "VisualRank: Applying pagerank to large-scale image search," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, no. 11, pp. 1877-1890, Nov, 2008.

[9] J. Liu, R. Hu, M. Wang, Y. Wang, and E. Y. Chang, "Web-scale image annotation," *Proceedings of the 9th Pacific Rim Conference on Multimedia*, pp.663-674. 2008

[10] GiRyong Choi, Hye-Wuk Jung, and Jee-Hyoung Lee "Image-based Image Retrieval System Using Duplicated Point of PCA-SIFT", *Journal of the Korean Institute of Intelligent System* vol23. pp 190-279, 2013

[11] M. Wang , H. Li , D. Tao , K. Lu and X. Wu, "Multimodal graph-based reranking for Web image search", *IEEE Transactions on Image Processing*, vol. 21, no. 11, pp.4649 -4661 2012

[12] L. Page, S. Brin, R. Motwani, and T. Winograd, "The PageRank citation ranking: Bringing order to the web." *Technical report, Stanford Digital Library Technologies Project*, 1998.

저 자 소 개

황중원(Joong-won Hwang)

2009년 : 서울대학교 전기전자공학부(공학사)
2012년~현재 : 한국과학기술원 전자전기공학부 석사과정

관심분야 : Image Retrieval, Computer Vision
Phone : +82-42-350-8088
E-mail : feather0011@naver.com

김현우(Hyunwoo Kim)

1994 : 한양대학교 전자통신공학과(공학사)
1996 : 포스텍 전자전기공학과(공학석사)
2001 : 포스텍 전자전기공학과(공학박사)
2001～2007 : 삼성종합기술원/삼성전자 책임연구원
2007～2008 : KGIT 책임연구원
2009～2011 : KGIT 조교수
2011～현재 : (주)다음 커뮤니케이션 연구원

관심분야 : 영상검색, 컴퓨터 비전
Phone : +82-2-6718-0193
E-mail : eugene.hwkim@gmail.com

김준모(Junmo Kim)

1998 : 서울대학교 전기공학부 학사.
2000 : MIT EECS 석사.
2005 : MIT EECS 박사.
2005~2009 : 삼성전자종합기술원 전문연구원.
2009~현재 : 한국과학기술원 전기 및 전자공학과 조교수.

관심분야 : 통계적 신호처리, 영상처리 및 컴퓨터비전, 정보이론
Phone : +82-42-350-3488
E-mail : junmo@ee.kaist.ac.kr