



특집논문 (Special Paper)

방송공학회논문지 제30권 제2호, 2025년 3월 (JBE Vol.30, No.2, March 2025)

<https://doi.org/10.5909/JBE.2025.30.2.159>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

삼중항 샘플링 전략과 HNSW 알고리즘을 이용한 딥러닝 기반의 유사 이미지 검색 기법

소신^{a)}, 고민수^{b)}, 전백찬^{a)}, 강경헌^{a)}, 김정래^{a)†}, 김영길^{a)†}

Deep Learning-Based Similar Image Retrieval Method Using Triplet Sampling Strategy and HNSW Algorithm

Shin So^{a)}, Min-Soo Ko^{b)}, Baek-Chan Jeon^{a)}, Kyung-Heon Kang^{a)}, Jeong-Rae Kim^{a)†}, and Young-Gil Kim^{a)†}

요약

본 논문에서는 삼중항(triplet) 샘플링 전략과 ANN(Approximate Nearest Neighbor)을 이용한 유사 이미지 검색 방법을 제안한다. 삼중항 손실(triplet loss)을 이용하는 이미지 검색 모델의 학습 과정은 샘플링 전략에 따라 학습 효율 및 성능이 크게 달라진다. 제안하는 논문에서는 클래스 정보를 이용하여 in-class negative 샘플과 out-of-class negative 샘플을 나누어 샘플링하고 이를 효율적으로 배치해 학습의 효율과 검색 성능을 높인다. 또한 검색 대상의 수에 비례하여 늘어나는 유사도 계산의 복잡도를 ANN 방법을 적용하여 감소시켰으며, 다양한 ANN 중 최적의 알고리즘을 선별하기 위해 정확도, 메모리, 소요 시간 측면에서 실험을 진행하였다. 실험을 통해 제안하는 방법이 기존의 유사 이미지 검색 방법에 비해 높은 검색 성능과 빠른 속도를 보이는 것을 확인하였으며, t-SNE를 통해 해당 샘플링 방법이 미치는 영향력을 직관적으로 보였다.

Abstract

In this paper, we introduce a method of similar image retrieval by using triplet sampling strategy and ANN (Approximate Nearest Neighbor). In training image retrieval model by using triplet loss, the sampling strategy for training the model with triplet loss makes a lot of difference in training efficiency and accuracy. For this reason, we choose in-class negative samples and out-of-class negative samples divided by class information. Also, we reduced computational complexity by ANN algorithm and inspected accuracy, memory, spent time for selecting an optimal ANN algorithm. We verify that our method has higher search accuracy and speed than existing methods. Finally, we show that our sampling method has fine resolution for image retrieval by t-SNE.

Keyword : Deep Learning, Image Retrieval, Triplet Loss, Sampling Strategy, ANN Algorithm

Copyright © 2025 Korean Institute of Broadcast and Media Engineers. All rights reserved.

“This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered.”

I. 서론

온라인 쇼핑의 발전으로 소비자들은 원하는 상품을 온라인 검색을 통해 찾을 수 있다. 기존의 상품 검색 방법은 입력한 텍스트 정보를 데이터베이스에 미리 저장된 상품명, 카테고리, 기타 속성 등과 같은 상품 정보 텍스트와 비교하여 유사한 상품을 찾는다. 이러한 텍스트 입력 기반의 방법은 소비자가 원하는 상품의 상품명, 상품 범주와 같은 정보를 알지 못할 때 검색이 어려운 단점이 있다.

텍스트 입력 기반 검색 방법의 한계를 극복하기 위해 이미지 간의 유사도를 이용하는 검색 방법이 연구되고 있다. 딥러닝 모델 개발 이전에 이미지 검색 방법 중 자주 사용된 **bag of words** 기법은 이미지의 시각적 특징을 부분별로 추출하고 이를 코드 북 형태로 구성하여 이에 대한 히스토그램을 비교하여 이미지 간의 유사성을 계산하는 방식이다^[1]. 그러나 이러한 방법으로 추출하는 특징은 저차원의 형태여서 이미지의 복잡한 특징을 충분히 반영하지 못하는 한계가 있다. 최근에는 딥러닝 모델을 이용하여 이미지로부터 생성된 고차원의 임베딩 벡터를 이용하는 방법이 연구되고 있다^[2]. 딥러닝 모델의 중간 임베딩 벡터의 각 값을 특징의 히스토그램값으로 바라볼 수 있으므로 이를 비교하여 이미지 간의 유사성을 계산할 수 있다.

대표적인 딥러닝을 통해 이미지의 고차원 임베딩 벡터를 배우는 방법은 분류 문제를 학습하는 것이다. 이미지의 클래스를 구분하도록 학습함으로써 주어진 이미지의 복잡한 특징을 추출하도록 한다. 하지만 이는 임베딩 벡터 간 분포를 직접적으로 학습하는 것이 아니기 때문에 이미지 검색에 큰 성능의 효과를 보이지는 못한다.

삼중항 손실^[3]을 이용한 학습 방법은 각 데이터에 대응하

는 임베딩 벡터의 거리를 직접적으로 학습하기 때문에 이미지 검색에 있어서 효과적인 결과를 보여주고 있다. 또한, 해당 방법론을 사전에 대규모 데이터 세트를 학습한 모델로부터 다양한 데이터 세트에 전이 학습에 적용할 수도 있다. 삼중항 손실을 이용하는 방법은 삼중항을 구성하는 방법에 따라 학습의 효율과 검색 성능이 크게 달라지기 때문에 성능의 향상을 위해서는 효과적인 삼중항 샘플링 전략이 필요하다.

학습된 모델로부터 추출한 임베딩 벡터를 이용하여 유사한 이미지를 찾는 가장 기본적인 형태는 **brute force KNN**으로 모든 후보 벡터와의 유사도를 비교하여 가장 가까운 순서대로 정렬하는 방식이다. 이러한 방식에는 검색 대상의 규모가 커질수록 비교하는 시간이 데이터의 규모에 비례하여 기하급수적으로 늘어나기 때문에 실제 시스템에 적용하기 위한 제약이 따른다. 이를 개선하기 위해 근사적으로 근접 이웃을 계산하는 **ANN(Approximate Nearest Neighbor)** 방법들이 연구되고 있다. ANN 방법을 사용하여 검색 속도를 많이 줄일 수 있으나, 국소 해(**local optima**)를 찾을 가능성이 있다는 단점이 있으므로 주어진 환경에 따르는 적절한 선택이 필요하다.

본 논문에서는 클래스 정보를 이용한 삼중항 샘플링 전략을 사용해 검색 성능을 향상시키고 ANN 방법 중 최적의 알고리즘을 찾아내어 검색 시간을 감소시킨 유사 이미지 검색 방법을 제안한다.

II. 관련 연구

1. 삼중항 손실

샘플 간의 거리를 이용해 유사도를 학습하기 위해 대조 손실(**contrastive loss**)과 삼중항 손실을 이용하는 방법이 있다. 대조 손실은 두 샘플 간의 유사성을 고려하여 **positive** 샘플과의 거리는 최소화하고 **negative** 샘플과의 거리를 최대화하는 방법으로 학습한다. 그러나 대조 손실은 한 번에 두 개의 샘플만을 고려하므로, 삼중 관계를 이용해 상대적 거리를 학습하는 삼중항 손실보다 학습하기 어렵다. 삼중항 손실은 임베딩 공간에서 **anchor** 샘플에 대하여 **positive** 샘플, **negative** 샘플과의 거리를 동시에 고려해 **negative** 샘플이 **positive** 샘플보다 **anchor** 샘플에 대해 멀어지게 한다. 그림 1은 삼중항 손실을 이용한 학습의 동작 방식이다.

a) 서울시립대학교(University of Seoul)

b) 한국전자기술연구원(Korea Electronics Technology Institute)

* Corresponding Author : 김정래(Jeong-Rae Kim)

김영길(Young-Gil Kim)

E-mail: jrkim@uos.ac.kr, ygkim72@uos.ac.kr

Tel: +82-2-6490-2616, +82-2-6490-2340

ORCID: <https://orcid.org/0000-0002-3261-7238>

<https://orcid.org/0000-0001-7066-0555>

※ 본 논문은 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 첨단 분야 혁신융합대학사업(차세대통신)의 연구 결과입니다.

※ 이 논문의 연구 결과 중 일부는 한국방송·미디어공학회 2024년 추계 학술대회에서 발표한 바 있음.

· Manuscript February 17, 2025; Revised February 21, 2025; Accepted February 21, 2025.




그림 1. 삼중항 손실 기반의 학습 동작
Fig. 1. Training mechanism based on triplet loss

삼중항 손실은 임베딩 벡터 사이의 상대적 거리 정보를 직접적으로 학습한다. 삼중항은 anchor, positive, negative 세 개의 샘플로 구성된다. 학습은 anchor와 positive 샘플 사이의 거리는 최소화되고 anchor와 negative 샘플 사이의 거리는 최대화되는 방향으로 진행된다. 삼중항 손실 함수는 식 (1)과 같다.

$$L(A, P, N) = \max\{0, d(A, P) - d(A, N) + \alpha\} \quad (1)$$

여기서 $L(A, P, N)$ 은 삼중항 손실을 나타내며 $d(A, P)$ 은 anchor와 positive 샘플 사이의 거리를 의미하고 $d(A, N)$ 은 anchor와 negative 샘플 사이의 거리를 의미한다. 또한 α 는 positive 샘플과 negative 샘플 사이의 margin을 의미한다. 임의의 α 를 설정하여 positive 샘플과 negative 샘플이 일정 거리 이상을 유지하며 멀어지도록 학습한다.

삼중항 손실을 이용해 적절한 임베딩 벡터를 만들어내기 위한 여러 연구가 진행되어왔다. 특히, Hard mining, Easy mining을 통해 positive 중 가장 가까운 샘플 이외의 데이터의 상대적 거리를 멀도록 학습하는 방법이 연구되었다^[4]. 그러나 해당 방법은 positive 샘플에 대한 상대적 거리를 집중적으로 연구하였으며, class 정보를 적극적으로 활용하여 negative 샘플을 구성하지 않은 한계점을 갖고 있다.

2. ANN

임베딩 벡터를 이용하여 유사한 이미지를 찾는 가장 기본적인 형태인 brute force KNN은 모든 후보 벡터와의 유사도를 비교하여 가장 가까운 순서대로 정렬하는 방식이다. 이러한 방식은 검색 대상의 규모에 비례하여 유사도를 비교하는 시간이 늘어나는 단점이 있다. 근사적으로 근접 이

웃을 계산하는 ANN의 방법을 이용하여 이러한 문제를 해결할 수 있다.

ANNOY^[5](Approximate Nearest Neighbor Oh Yeah) 방법은 전체 샘플을 이진 트리 형태의 부분들로 나누어 구성하고 트리 탐색 방식으로 특정 샘플이 속하는 구역을 찾은 후 이 구역 안의 샘플 중에서 가장 유사한 샘플을 추출한다.

HNSW^[6](Hierarchical Navigable Small World) 방법은 검색 대상의 수를 계층적으로 늘려가면서 인접 위치를 계산한다. 그림 2와 같이 가장 처음 계층에서 랜덤하게 초기 위치를 설정하고, Greedy Search 알고리즘을 통해 query와 가장 가까운 벡터를 찾아낸다. 해당 벡터의 위치를 더 많은




그림 2. 각 알고리즘의 검색 방법. query(빨간색)와 가장 인접한 노드(노란색)를 찾기 위한 과정. Brute force KNN은 모든 노드를 비교하는 반면, ANNOY는 이진 트리의 형식으로 계층마다 구역을 계속해서 나누며 query와 가까운 구역을 좁혀 인접한 노드를 찾고, HNSW는 첫 계층에서 랜덤한 초기 노드부터 greedy하게 인접한 노드를 찾고 점차 밀집된 임베딩 공간을 갖는 다음 계층의 초기 노드로 두어 인접한 노드를 찾아가는 방법이다.

Fig. 2. Search method for each algorithm. Processes of finding the node (yellow) closest to the query (red). Brute force KNN compares all nodes, while ANNOY continuously divides sections in each layer in the form of a binary tree and narrows down the section close to the query to find adjacent nodes. HNSW greedily searches for adjacent nodes starting from a random initial node in the first layer and sets them as initial nodes in the next layer with a gradually denser embedding space to find adjacent nodes.

샘플이 있는 계층에서의 초기 위치로 사용하고 마찬가지로 가장 가까운 벡터를 찾아낸다. 이러한 반복 과정을 통해 전체 샘플과의 비교 없이 인접한 위치와 주변 샘플들을 추출한다.

III. 방법

1. 이미지 인코더

유사 이미지 검색 방법은 입력 이미지의 임베딩 벡터와 가장 가까운 벡터에 대응하는 이미지를 찾아내는 것을 목표로 한다. 이를 위해 이미지를 임베딩 벡터로 변환하기 위한 이미지 인코더가 필요하다. 제안하는 방법에서는 Swin Transformer v2-B^[7] 구조를 적용한 이미지 인코더를 사용한다. Swin Transformer v2는 지역적인 self-attention 메커니즘을 도입하여 연산 효율성과 개선된 성능을 갖는 모델로 기존의 CNN 모델 대비 더 풍부한 특징 표현을 제공할 수 있다. 효율적인 학습을 위해 ImageNet 데이터로 사전 학습된 모델로부터 학습을 진행하고 임베딩 벡터의 크기는 2048을 사용한다.

2. 삼중항 샘플링 전략

삼중항 손실을 효율적으로 적용하기 위해서는 삼중항을 구성하는 방법이 중요하다. 일반적인 삼중항 샘플링의 경

우에 anchor와 동일한 class에 속하는 이미지는 positive 샘플로, 그 외의 class에 속하는 이미지는 negative 샘플로 구성한다. 이러한 삼중항 샘플링은 학습이 진행됨에 따라 이미 상대적 거리가 조정된 결과가 출력되어 학습에 도움이 되지 못하는 문제가 발생한다. 따라서 차이를 구분하기 어려운 샘플이 어느 정도 비율에 따라 구성되어야 한다.

제안하는 방법에서는 어려운 샘플을 구성하기 위해 클래스 정보를 이용한다. 클래스 내부의 이미지 간의 비교는 더 정교한 차이를 학습해야 하므로 클래스 외부 이미지 간의 비교보다는 상대적으로 어렵다. 그래서 삼중항 샘플링을 적용할 때, anchor와 같은 상품 이미지를 positive 샘플로, anchor가 속한 class의 다른 이미지를 negative 샘플로 사용하는 in-class negative 샘플링과 기존과 같이 클래스 외부 이




그림 3. 클래스 정보를 이용한 삼중항 샘플링 예시
Fig. 3. Examples of triplet sampling by using class information




그림 4. Swin Transformer v2 인코더를 통해 생성된 임베딩 벡터가 상대적 위치를 학습하는 과정. Negative sample을 in-class에서 선택할 확률과 out-of-class에서 선택할 확률의 비율 4:6으로 달리하여 삼중항 샘플링을 진행한다.

Fig. 4. The process of learning the relative position of an embedding vector generated through the Swin Transformer v2 encoder. Triplet sampling is performed by varying the ratio of the probability of selecting a negative sample in-class and out-of-class at 4:6.

미지를 사용하는 out-of-class negative 샘플링으로 구분하고 각 배치를 4:6 비율로 구성되도록 한다. 이러한 샘플링 전략을 통해 모델에게 더 어려운 구분 문제를 제시하여 학습 효율을 높일 수 있다. 그림 3은 구성되는 샘플링 형태에 따른 삼중항 샘플링의 예시를 보여준다. 그림 4에서 해당 샘플링 방법을 이용해 학습을 진행하였을 때, 각 상품 이미지의 임베딩 벡터가 변화하는 결과를 시각적으로 표현하였다.

3. HNSW 알고리즘

HNSW 알고리즘은 brute force KNN에 비해 훨씬 적은 시간복잡도를 지닌다. 이는 IV장의 실험 결과를 통해 확인할 수 있다. 본 논문에서는 학습이 완료된 Swin Transformer v2 모델을 이용해 SOP 데이터 세트를 임베딩 벡터로 변환한 매트릭스를 저장하고, 새로운 query 이미지를 입력으로 받아 임베딩 벡터로 변환한 후 HNSW 알고리즘을 통해 유사한 이미지 K개의 인덱스를 추출하고 이에 해당하는 상품 이미지를 출력한다. 전체적인 알고리즘의 적용 과정은 그림 5를 통해 확인할 수 있다.

IV. 실험

1. 데이터 세트

제안하는 방법의 성능을 평가하기 위해 SOP(Stanford

Online Products) 데이터 세트를 이용한다^[8]. SOP 데이터 세트는 12개의 상품 클래스와 22,634개의 상품으로 구성된다. 상품별로 다른 각도에서 촬영한 여러 장의 이미지로 이루어져 총 120,053장의 상품 이미지로 구성된다. 쇼핑물의 데이터 형태와 비슷한 구조로 되어 있어 이미지 검색 성능 평가에 적합하다.

2. 모델 평가 지표

모델의 성능 평가는 Recall@K 지표를 사용한다. 각 query 이미지로 검색한 K개의 유사 이미지 안에 query와 같은 제품의 이미지가 검색되는 경우 매칭된 것으로 판단한다. 매칭되는 이미지가 하나라도 있는 경우를 1, 어떠한 이미지도 매칭되지 않았을 경우를 0으로 측정한다. 본 논문에서는 전체 query에 대해 해당 점수의 평균을 낸 평균 Recall@K을 통해 유사도 이미지 검색 성능을 평가한다^[4].

3. 모델 학습 파라미터 및 실험 환경

실험은 NVIDIA V100 그래픽 카드를 사용하여 진행하고, 50 epoch 학습을 진행한다. 학습 파라미터는 다음과 같이 설정한다.

- Image Size : 256
- Optimizer : AdamW
- LR Scheduler : Cosine Annealing




그림 5. 제안하는 방법에서 사용하는 이미지 검색 과정
Fig. 5. Image retrieval process in our method

- Learning Rate : 0.001
- Triplet Size : 15
- Margin(α) : 0.5

4. 유사 이미지 검색 성능

성능 평가를 위해 ImageNet 데이터 세트로 사전 학습된 pre-trained 모델, out-of-class만 사용하는 기존의 랜덤 삼중항 샘플링을 학습한 모델, 제안하는 방법의 삼중항 샘플링 기법을 적용한 모델의 성능을 비교한다. 표 1은 제안하는 방법의 유사 이미지 검색 성능을 나타낸다. 실험 결과를 통해 제안하는 방법의 성능이 모든 Recall@K 지표에서 높게 나온 것을 확인할 수 있다. 이는 모델이 더 어려운 구분 문제를 학습함으로써 임베딩 공간에서의 구분 능력이 더 높아진 것으로 판단된다.

표 1. Brute force KNN 알고리즘을 이용한 각 방법의 유사 이미지 검색 성능 비교

Table 1. Performance of the proposed method with brute force KNN

Recall@K	Pre-trained	Random Sampling	Proposed Method
5	58.15%	83.46%	91.03%
10	64.99%	87.24%	93.66%
20	71.07%	90.29%	95.43%
50	78.38%	93.64%	97.16%
100	83.59%	95.63%	97.95%

앞선 3.2절에서 구별이 쉬운 데이터만을 사용해 학습에 사용할 때, 상대적 거리를 모델이 빠르게 학습하여 더 이상

훈련이 진행되지 않는 문제가 발생하므로 구별이 더욱 어려운 데이터를 학습시키는 것이 성능의 향상에 영향을 미칠 것이라 가정하였다. 그림 6은 학습을 진행하며 삼중항 손실을 출력한 값이다. 랜덤하게 샘플링한 기존의 방법론의 경우 모델이 더 빠르게 수렴하고 또한 손실값이 더욱 낮다. 하지만, 삼중항 샘플의 구성이 더욱 쉬우므로 이러한 현상이 발생한 것이며, 표 1에서 확인한 바와 같이 제안한 샘플링 방법론을 사용해 학습할 때 더욱 높은 일반화 성능을 기대할 수 있다.

최적의 샘플링 비율을 찾기 위해 표 2와 같이 샘플링 비율(in-class : out-of-class)을 달리하였을 때, 성능지표가 어떻게 변화하는지 brute force KNN 알고리즘을 통해 비교하였다. 0:10은 모든 negative 샘플이 out-of-class인 랜덤 샘플링에 해당한다. 이에 비교하여 점차 어려운 데이터의 비율이 증가할수록 성능이 향상하였고, in-class negative와 out-of-class negative 샘플의 비율이 4:6 혹은 5:5일 때 가장 좋은 성능을 보였다.

표 2. Brute force KNN 알고리즘을 이용한 샘플링 비율(in-class : out-of-class)에 따른 성능 비교

Table 2. Performance comparison according to sampling ratio (in-class: out-of-class) using brute force KNN algorithm

Recall@K	0:10	1:9	2:8	3:7	4:6	5:5
5	83.46%	89.76%	90.39%	90.73%	91.03%	91.08%
10	87.24%	92.65%	93.17%	93.37%	93.66%	93.70%
20	90.29%	94.62%	95.01%	95.24%	95.43%	95.47%
50	93.64%	96.61%	96.87%	97.04%	97.16%	97.14%
100	95.63%	97.69%	97.86%	97.90%	97.95%	97.94%




그림 6. 학습 중 삼중항 손실값
Fig. 6. Triplet loss in training




그림 7. 두 가지 방법(좌: random sampling, 우: 제안한 방법)에 동일한 데이터(bicycle_final 데이터 세트의 5종류 상품 데이터)를 적용하여 얻은 결과의 t-SNE 시각화

Fig. 7. Visualization of 5 products from the bicycle_final dataset using t-SNE for random sampling method (left) and ours (right)



그림 8. Random sampling을 이용한 학습 결과 매우 유사하다고 잘못 판별한 두 이미지

Fig. 8. The random sampling model reasoned that these two images was very similar, but it's not

그림 7은 기존의 샘플링 방법과 제안한 샘플링 방법으로 학습한 모델에 대하여 같은 클래스인 bicycle 내에서 동일한 상품은 같은 색으로 표현해 5개의 상품을 t-SNE^[9]로 시각화한 결과이다. 붉은 원으로 표시한 내부를 살펴보면 기존의 랜덤하게 샘플링한 방법으로 학습한 모델(좌)은 서로 다른 상품임에도 가장 근접한 임베딩 벡터로 변환하였다. 이에 반하여 클래스 정보를 주어 학습한 모델은 해당 이미지를 적절하게 변환하였다. 그림 8은 그림 7에서 붉은 원으로 감싼 두 임베딩 벡터의 실제 데이터이다. 서로 다른 상품이지만, 자전거의 체인에 해당하는 특징에 집중하여 비슷

한 이미지라고 판단하였다고 볼 수 있다. 따라서 클래스에 따라 샘플링하는 본 논문의 전략은 상품 이미지 검색 모델을 학습하는 데에 있어 핵심이 되는 기술이다.

5. 검색 알고리즘 간 성능 비교

각 유사 이미지 검색 알고리즘 간 속도, 정확도, 메모리 요구량을 측정하였다. 학습을 완료한 유사도 검색 모델을 사용하였으며 brute force KNN, ANNOY, HNSW를 적용하여 성능을 비교하였다. 아래의 표 3과 표 4는 총 60,502장

의 테스트 데이터 세트에 대해, 제안하는 방법을 이용해 검색할 때 소요되는 시간과 정확도를 나타낸다.

표 3. 검색 알고리즘 간 유사 이미지 검색 속도 비교

Table 3. Comparison of speed between ANN algorithms

Method	Test set	Test set (x10)
Brute Force KNN	116.54ms	14,664.91ms
ANNOY	3.25ms	10.32ms
HNSW	0.52ms	6.51ms

표 4. 검색 알고리즘 간 유사 이미지 검색 정확도 비교

Table 4. Comparison of accuracy between ANN algorithms

Recall@K	Brute Force KNN	ANNOY	HNSW
5	91.03%	85.65%	89.02%
10	93.66%	87.90%	91.42%
20	95.43%	89.49%	94.51%
50	97.16%	90.96%	96.88%
100	97.95%	92.06%	97.84%

실험 결과를 통해 제안하는 방법이 가장 빠른 검색 속도를 보이는 것을 확인할 수 있다. Brute force KNN 기법은 특별히 605,020장의 데이터 세트에 대하여 10초 이상의 검색 시간이 소요되었다. 구글 리서치의 조사자료에 따르면, 웹사이트의 로딩 시간이 1초에서 10초로 늘어날 경우, 사용자가 해당 페이지를 이탈할 확률이 123% 증가한다고 한다^[10]. 즉, brute force KNN 기법은 실제 온라인 쇼핑 서비스에 적용하기에 큰 어려움이 예상된다. 이에 비해 HNSW 알고리즘을 적용하면 약 224배 빠른 검색 속도를 보였으며, 실제 서비스 구현에도 크게 영향을 끼치지 않는 수치에 해당한다. 다만, 전체적인 Recall@K 값은 HNSW 알고리즘이 brute force KNN에 비해 다소 감소하였음을 확인할 수 있다. 이는 HNSW 알고리즘의 검색 방식으로 인해 local

optima를 찾아냈기 때문이다. 그 이유는 첫째로, 각 계층에서 query와 가장 가까운 데이터를 greedy 알고리즘으로 근사적으로 찾는 과정에서 발생한다. 둘째로, 계층적으로 찾아가는 방법에서도 발생한다. 이전 계층에서 최적의 노드를 놓치면, 이후의 층에서도 최적의 노드를 찾지 못하고 잘못된 경로로 탐색이 이어질 가능성이 높아진다. 마지막으로, 시작점이 랜덤하게 초기화되기 때문에 결과 역시 이에 따라 달라질 수 있다.

실제 서비스에 이용하기 위해 메모리 요구량은 매우 중요한 지표이다. 표 5는 각 알고리즘을 사용하였을 때의 메모리 사용량을 비교한 결과이다. 각 원소는 float32를 기준으로 하였다. brute force KNN는 기존의 임베딩 매트릭스를 이용해 dot product method로 계산하므로 메모리의 크기는 임베딩 매트릭스 전체에 해당한다. 따라서 주어진 데이터의 개수를 이용해 계산할 수 있다. 각 원소가 4바이트에 해당하며 임베딩 벡터의 크기는 2048이므로 이를 통해 간단하게 필요한 메모리의 양을 MB 단위로 계산할 수 있다. HNSW 알고리즘은 이에 더해 인덱스를 생성하고 저장하기 위한 메모리가 요구된다. 이는 주요 파라미터 중 하나인 M의 값에 따라 달라지는데, 각 노드당 M개의 양방향 연결을 통해 그래프를 생성하기 때문이다. 따라서 HNSW 알고리즘의 경우 각 벡터당 $2048 \times 4 + M \times 2 \times 4$ 으로 계산할 수 있다. 표 5는 직접 계산을 통해 요구되는 메모리를 나타내었고, 가장 오른쪽의 열은 파이썬의 psutil 라이브러리를 통해 실제로 인덱스 생성 후 증가하는 메모리를 측정한 결과이다. 1,000,000장의 데이터에 대해 약 8GB에 해당하는 메모리가 필요함을 알 수 있다.

그림 9는 HNSW 알고리즘의 두 파라미터인 ef(검색 시 저장하는 dynamic list의 크기), M(인덱스 생성 시 사용하는 link의 수)에 따라 변화하는 정확도(Recall@1), 메모리

표 5. 검색 알고리즘 간 메모리 사용량 비교

Table 5. Comparison of memory usage comparison between ANN algorithms

Dataset size	Brute Force KNN	HNSW (M=8)	HNSW (M=16)	HNSW (M=32)	HNSW (M=64)	HNSW(psutil) (M=64)
1,000	7.81 MB	7.87 MB	7.93 MB	8.06 MB	8.30 MB	11.05 MB
10,000	78.03 MB	78.75 MB	79.30 MB	80.64 MB	83.00 MB	85.80 MB
100,000	781.25 MB	787.50 MB	793.00 MB	806.40 MB	830.00 MB	827.52 MB
1,000,000	7,812.50 MB	7,875.00 MB	7,930.00 MB	8,064.00 MB	8,300.00 MB	8,254.91 MB




그림 9. 하이퍼파라미터(ef, M)에 따른 HNSW 알고리즘의 정확도, 메모리, 소요 시간 측면 성능 지표
Fig. 9. Performance of HNSW algorithm according to hyperparameters

요구량, 소요 시간을 측정된 결과이다. ef가 400, M가 64일 때 가장 성능이 좋으며 메모리와 속도 측면에서 준수한 수치를 기록하므로 해당 방법론을 최종적으로 채택하였다.

표 6은 각 샘플링 비율(in-class : out-of-class)에 따라 학습을 완료한 임베딩 벡터에 대해 HNSW 알고리즘을 적용하였을 때 이미지 검색 정확도를 비교한 결과이다. 샘플링 비율이 4:6일 때, 모든 K 값에 대하여 가장 좋은 성능을 보인다. 그러므로 본 논문에서는 제안한 모델의 성능을 비교하기 위하여 샘플링 비율로 4:6을 사용하였다. 표 7은 기존의 삼중항 학습을 사용하여 가장 높은 성능을 보인 방법^[4]과 비교한 결과이다. 그 결과 본 논문에서 제안하는 방법론이 모든 지표에서 좋은 성능을 보인다.

표 6. HNSW 알고리즘을 이용한 샘플링 비율(in-class : out-of-class)에 따른 유사 이미지 검색 정확도 비교

Table 6. Comparison of accuracy between sampling ratios (in-class : out-of-class) with HNSW algorithm

Recall@K	1:9	2:8	3:7	4:6	5:5
1	80.14%	81.08%	81.70%	82.76%	82.63%
10	90.32%	90.78%	91.26%	91.42%	91.36%
100	97.58%	97.74%	97.81%	97.84%	97.83%

표 7. 기존 방법론과의 성능 비교

Table 7. Comparison of performance between current method

Methods	Recall@1	Recall@10	Recall@100
EPSHN	78.3%	90.7%	96.3%
Ours	82.8%	91.4%	97.8%

V. 결 론

본 논문에서는 삼중항 샘플링 전략과 ANN을 이용한 유사 이미지 검색 방법을 제안하였다. 실험을 통해 제안하는 방법의 유사 이미지 검색 성능이 기존 방법들에 비해 우수함을 확인하였다. 특히 클래스 정보를 이용한 삼중항 샘플링 방식을 도입하여 학습 효율을 높이고 Swin Transformer v2 모델의 활용으로 학습되는 임베딩 벡터의 품질을 향상했다. 또한, HNSW 방법을 적용하여 대용량 데이터 세트에서도 빠른 검색 속도를 확보하였다. 고속 방법을 활용함으로써 검색 시간이 크게 단축되었으며 실제 서비스에 적용할 수 있음을 보였으나, 약간의 정확도 감소가 있었다. 이는 실제 응용에서 검색 속도와 정확도 간의 trade-off를 고려해야 함을 시사한다. SOP 데이터 세트에 대한 연구 외에 다른 대규모 데이터 세트를 이용한 추가 실험과 다양한 손실 함수와의 조합을 통해 검색 성능을 더욱 향상하는 연구를 진행할 예정이다. 또한, CLIP 등의 자기 지도 학습(self-supervised learning)을 적용하여 레이블이 없는 대용량의 데이터를 사전 학습해 유사 이미지 검색 성능을 향상하는 방안을 모색하고자 한다.

참 고 문 헌 (References)

- [1] L. Fei-Fei and P. Perona, "A Bayesian Hierarchical Model for Learning Natural Scene Categories", IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp.524-531, 2005.
doi: <https://doi.org/10.1109/CVPR.2005.16>

- [2] A. Babenko, A. Slesarev, A. Chigorin, and V. Lempitsky, "Neural Codes for Image Retrieval", European Conference on Computer Vision in proceeding, pp.584-599, 2014.
doi: https://doi.org/10.1007/978-3-319-10590-1_38
- [3] E. Hoffer, and N. Ailon, "Deep Metric Learning using Triplet Network", Similarity-based Pattern Recognition, pp.84-92, 2015.
doi: https://doi.org/10.1007/978-3-319-24261-3_7
- [4] H. Xuan, A. Stylianou, R. Pless, "Improved embeddings with easy positive triplet mining", The IEEE Winter Conference on Applications of Computer Vision (WACV), pp.2474-2482, 2020.
doi: <https://doi.org/10.1109/WACV45572.2020.9093432>
- [5] W. Li, Y. Zhang, Y. Sun, W. Wang, M. Li, W. Zhang, and X. Lin, "Approximate nearest neighbor search on high dimensional data — experiments, analyses, and improvement", IEEE Transactions on Knowledge and Data Engineering, Vol. 32, No.8, pp.1475-1488.
doi: <https://doi.org/10.1109/TKDE.2019.2909204>
- [6] Y. A. Malkov, and D. A. Yashunin, "Efficient and Robust Approximate Nearest Neighbor Search using Hierarchical Navigable Small World Graphs", IEEE transactions on Pattern Analysis and Machine Intelligence, Vol.42, No.4, pp.824-836, 2018.
doi: <https://doi.org/10.1109/TPAMI.2018.2889473>
- [7] Z. Liu, et al., "Swin transformer v2: Scaling up capacity and resolution". Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp.12009-12019, 2022.
doi: <https://doi.org/10.1109/CVPR52688.2022.01170>
- [8] H. O. Song, Y. Xiang, S. Jegelka, and S. Savarese, "Deep Metric Learning via Lifted Structured Feature Embedding", IEEE Conference on Computer Vision and Pattern Recognition, pp.4004-4012, 2016.
doi: <https://doi.org/10.1109/CVPR.2016.434>
- [9] L. der Maaten,; G. Hinton, "Visualizing Data Using T-SNE", Journal of machine learning research, Vol.9, No.86, pp.2579—2605, 2008.
- [10] D. An, "Find out how you stack up to new industry benchmarks for mobile page speed", Think with Google-Mobile, Data & Measurement, p.24, 2018.

— 저 자 소 개 —

소 신



- 2019년 ~ 현재 : 서울시립대학교 수학과 재학
- ORCID : <https://orcid.org/0009-0009-2516-8524>
- 주관심분야 : 컴퓨터 비전, 딥러닝, 생성모델

고 민 수



- 2010년 2월 : 광운대학교 전자공학과 학사
- 2012년 2월 : 광운대학교 전자공학과 석사
- 2016년 2월 : 광운대학교 전자공학과 박사
- 2015년 12월 ~ 현재 : 한국전자기술연구원 책임연구원
- ORCID : <https://orcid.org/0000-0003-0675-1756>
- 주관심분야 : 컴퓨터 비전, 영상처리, 인공지능

전 백 찬



- 2024년 ~ 현재 : 서울시립대학교 도시공학과 석·박사 통합과정 재학
- ORCID : <https://orcid.org/0009-0006-5681-3416>
- 주관심분야 : 도시 공학, 머신러닝, 데이터 사이언스, 인공지능

저 자 소 개



강 경 현

- 2025년 2월 : 서울시립대학교 수학과 학사
- 2025년 ~ 현재 : 한양대학교 인공지능학과 석사과정
- ORCID : <https://orcid.org/0009-0008-5520-7224>
- 주관심분야 : 인공지능, 컴퓨터 비전, 자기지도학습



김 정 래

- 2004년 8월 : 서울대학교 수리과학부 박사
- 2005년 ~ 2007년 : 서울대학교 생명공학공동연구원(Bio-MAX Institute) 선임연구원
- 2007년 ~ 2010년 : KAIST 바이오및뇌공학과 연구교수
- 2010년 ~ 현재 : 서울시립대학교 수학과 교수
- ORCID : <https://orcid.org/0000-0002-3261-7238>
- 주관심분야 : 수치해석, 시스템생물학, 머신러닝



김 영 길

- 2001년 8월 : 한국과학기술원 전자공학 박사
- 2001년 ~ 2003년 : SK 하이닉스
- 2003년 ~ 현재 : 서울시립대학교 전자전기컴퓨터공학부 교수
- ORCID : <https://orcid.org/0000-0001-7066-0555>
- 주관심분야 : 이동통신, 신호처리