

회전한 상표 이미지의 진위 결정을 위한 기계 학습 데이터 확장 방법

¹구본근

Machine Learning Data Extension Way for Confirming Genuine of Trademark Image which is Rotated

¹Bongen Gu

요약

상표권 보호를 위한 상표 이미지의 진위 결정에 심층 신경망인 합성곱 신경망을 이용할 수 있다. 이를 위해, 상표로 등록되어 있는 한 장의 상표 이미지를 반복적으로 학습하는 것은 기계학습의 성능을 감소시키는 원인이 된다. 따라서, 이러한 응용에서 학습 데이터는 다양한 방법으로 생성된다. 하지만 대상 이미지가 회전되어 있으면 원본이라 하더라도 인식하지 못하거나 위조 상표로 분류되기도 한다. 본 논문에서는 회전한 상표 이미지의 진위 결정을 위한 기계학습 데이터의 확장 방법을 제안한다. 본 논문에서 제안하는 학습 데이터 확장 방법은 기울어진 이미지를 생성하고 이를 학습 데이터로 사용하는 것이다. 본 논문에서 제안하는 학습 데이터 확장 방법의 유효성 검증을 위해 대학의 로고를 대상으로 학습 데이터를 생성하였으며, 이를 활용하여 합성곱 신경망을 학습시킨 후 검증용 데이터를 이용하여 정확도를 평가하였다. 정확도 평가 결과에 따르면 본 논문에서 제안한 방법으로 생성한 학습 데이터를 활용하면 회전한 상표를 대상으로 한 진위 여부 결정에 합성곱 신경망을 활용할 수 있다.

Abstract

For protecting copyright for trademark, convolutional neural network can be used to confirm genuine of trademark image. For this, repeated training one trademark image degrades the performance of machine learning because of overfitting problem. Therefore, this type of machine learning application generates training data in various way. But if genuine trademark image is rotated, this image is classified as not genuine trademark. In this paper, we propose the way for extending training data to confirm genuine of trademark image which is rotated. Our proposed way generates rotated image from genuine trademark image as training data. To show effectiveness of our proposed way, we use CNN machine learning model, and evaluate the accuracy with test image. From evaluation result, our way can be used to generate training data for machine learning application which confirms genuine of rotated trademark image.

Keywords: Machine Learning, Rotated, trademark, CNN, training data, ConvNN

¹ 한국교통대학교 컴퓨터공학과 교수(bggoo@ut.ac.kr)

I. 서론

서비스와 제품 품질의 상향 평준화는 브랜드 가치를 소비자의 선택에 많은 영향을 주는 요인으로 만들고 있다. 따라서 최근에서는 업종을 불문하고 기업, 서비스, 상품의 브랜드 가치를 관리하기 위해 다수의 기업들은 그들이 소유하고 있는 브랜드를 전략적으로 관리하고 있다[1]. 상표(trademark) 관리는 전략적 브랜드 관리 요소 중 하나이다. 상표는 기업, 서비스, 상품을 표현할 수 있는 주요한 지적 재산권이므로 기업은 우리나라의 특허청과 같은 기관에 상표를 등록함으로써 그것을 배타적으로 사용할 수 있는 권한인 상표권(trademark rights)을 소유한다.

브랜드 가치가 낮거나 알려 지지 않은 소규모 개인, 기업이 그들의 제품, 서비스 판매 확대를 위한 방법으로 유명 브랜드의 상표와 유사한 상표를 사용함으로써 상표권을 소유한 기업은 무형의 피해를 입고 있다. 특히, 인터넷 및 모바일 장치를 기반으로 한 다양한 거래 형태의 출현과 이를 기반으로 한 거래 규모 및 건수는 폭발적으로 증가와 더불어 유사 상표로 인한 상표권 침해도 증가하고 있다[2].

유사 상표로 인한 피해는 상표권을 소유하고 있는 기업 및 소비자에게 발생한다. 특히, 상표권을 소유하고 있는 기업의 브랜드 가치를 기반으로 제품 또는 서비스를 선택한 소비자는 유사 상표로 인한 피해를 보상받기 쉽지 않다. 따라서 상표권으로 보호되는 지적재산권의 범위에 저촉되지 않도록 조작된 유사 상표에 대해 소비자가 그 진위 여부를 판단할 수 있는 방법은 유사 상표로 인한 소비자의 피해를 최소화할 수 있다.

각종 매체에 노출되는 상표의 진위를 결정하기 위한 방법으로는 상표권으로 보호받는 상표 이미지를 학습한 후 입력 상표 이미지의 진위 여부를 판별하는 기계학습 기술을 이용하는 것이다[1,3]. 상표의 진위를 결정하기 위한 기계학습 모델의 정확도는 학습 데이터의 양에 종속적이다. 즉, 학습 모델의 구성과 학습 데이터의 양이 기계학습을 활용한 응용 시스템의 성능을 결정한다. 특히, 이미지 처리를 위한 기계학습은 학습에 사용할 관련 이미지 확보가 매우 중요하다. 객체 인식을 위한 기계학습을 위해 다양한 객체 이미지를 데이터베이스화 하여 공개하고 있는 CIFAR-10[4] 등은 동물, 물체 등 다양한 이미지를 포함하고 있어 이를 기계학습에 활용할 경우에 학습 데이터 수집 문제를 해소할 수 있다.

객체 인식 등에 사용되는 고양이, 비행기, 기타 물건 등은 다양한 형태의 이미지가 존재하지만 등록된 이미지만 상표권으로 보호받는 상표는 상표 이미지의 진위 판별을 위해 사용하는 학습 데이터의 양이 제한적일수 밖에 없다. 특허청 등에 등록된 제한된 수의 상표 이미지를 반복적으로 학습을 하는 기계학습은 과 적합(over fitting) 상태에 이르러 그 성능이 감소된다[5-7]. 따라서 기계학습을 활용한 상표 진위 여부 판별 응용과 같이 학습 데이터가 제한적인 경우에 적절한 량의 학습 데이터 확장 방안이 필요하다.

학습 데이터 확장을 위한 기존의 방법은 상표 이미지에 무작위로 임의의 선을 삽입하거나[1], 임의 크기의 원판을 삽입[3]하는 등이 있다. 이러한 방법은 상표 진위를 판별하는 기계학습 응용을 위한 학습 데이터를 충분히 생성할 수 있어 상표 진위 결정의 정확도를 높일 수 있다. 하지만 이러한 확장 방법은 정위치에 있는 상표 이미지를 이용하여 학습 데이터를 생성하기 때문에 진위 판별 대상 상표 이미지가 임의의 각도로 기울어져 있는 경우에 기계학습의 정확도가 감소되는 문제점을 갖고 있다.

이러한 문제점을 해결하기 위해 본 논문에서는 기울어져 있는 상표 이미지의 진위 결정을 위한 기계학습용 데이터 확장 방법을 제안한다. 본 논문에서 제안하는 방법은 정위치에 있는 상표 이미지에 임의의 선을 삽입하고, 임의의 각도로 회전시켜 학습 데이터를 생성하는 것이다. 본 논문에서 제안한 학습 데이터 생성 방법의 유효성 검증을 위해 한 대학이 등록한 상표 이미지를 이용하여 제안한 확장 방법에 따라 학습 데이터를 생성하고, 이를 합성곱 신경망(CNN, Convolutional Neural Network) 모델[8] 학습에 사용하였다. 학습이 완료된 모델이 검증용 데이터를 대상으로 한 진위 결정 결과를 기반으로 정확도를 계산하고, 이를 기반으로 하여 본 논문에서 제안하는 학습 데이터 확장 방법이 유효함을 보인다.

본 논문의 구성은 다음과 같다. 제 2 장에서는 상표 진위 판별을 위한 기존의 연구를 소개한다. 제 3 장에서는 본 논문에서 제안하는 회전한 상표 이미지의 진위를 결정할 수 있는 기계학습

데이터 확장 방법에 대해 기술하며, 제 4 장에서는 본 논문에서 제안한 학습 데이터 확장 방법의 유효성을 한 대학의 등록 상표를 이용하여 검증한다. 제 5 장에서는 결론 및 향후 연구 내용을 소개한다.

II. 기존 연구

합성곱 신경망을 이용한 유사 상표 검색과 관련된 최근의 연구는 특허청에서 운영하고 있는 특허정보 검색서비스(KIPRIS)에 등록되어 있는 상표를 수집한 후 여백 제거, 해상도 조절, 데이터 증폭—본 논문에서는 ‘데이터 확장’이라고 표기함— 등의 과정을 거쳐 학습 데이터를 생성하고, 이를 기계학습에 사용하였다[1]. 이 연구에서 적은 양의 학습 데이터로 인한 과 적합 문제를 해결하기 위해 사용한 학습 데이터 증폭 방법은 상표 이미지에 임의의 선을 무작위로 삽입하여 한 개의 상표 이미지 당 백 개의 학습 이미지 데이터를 생성하였다.

이 연구에서 사용한 학습 모델은 GooLeNet, VGG-Net, ResNet 이며, 학습 데이터에 포함된 데이터의 일부를 검정 데이터로 사용한 경우에 유사 상표 검색의 정확도는 0.904, 0.939, 0.991 로 평가되었다. 반면, 학습 데이터에 포함되지 않은 테스트 데이터를 각 학습 모델에 적용한 경우에 정확도는 각각 0.649, 0.676, 0.77 로 평가되었다.

상표의 일종인 기관 로고의 진위 판별을 위해 기계학습 모델 연구는 다소 복잡한 이미지를 포함하고 있는 기관의 로고의 오사용 방지를 위한 것으로 하나의 로고 이미지에 대한 학습 데이터를 확장하고 있다[3]. 이 연구에서 사용한 학습 데이터 확장은 로고 이미지를 300x300 픽셀의 크기로 크기 재설정을 한 후 회색 이미지로 변환하였다. 변환된 회색 이미지에 10 과 50 사이 임의 값으로 지름을 갖는 검은색 원반을 임의 위치에 삽입하는 방법을 사용하였다.

기관 로고의 진위 판별을 위해 사용한 학습 모델은 합성곱 계층과 풀링 계층으로 구성된 4 단계의 합성곱 신경망과 두 단계의 완전 연결 신경망(FC, Fully Connected Neural Network)으로 구성되어 있다[3]. 4 개의 합성곱 계층은 5x5 크기의 커널을 사용했으며, 풀링 계층은 최대값 풀링(max pooling)을 사용했다. 완전 연결 신경망은 합성곱 신경망의 출력을 입력으로 하여 기관 로고의 진위 여부를 결정할 수 있도록 분류한다.

이 연구에서는 앞서 기술한 학습모델을 위해 진짜 로고로 분류되는 600 개의 학습 데이터와 위조 또는 모조로 분류되는 600 개의 학습 데이터 등 모두 1,200 개의 학습 데이터를 생성하여 로고 진위 결정의 정확도를 평가하였다. 생성한 1,200 개의 학습 데이터 중 검증용 데이터는 임의로 결정된 100 개의 로고 이미지를 사용하였다. 이 연구에서 수행한 정확도는 학습 데이터를 확장하지 않은 경우에 평균 78.8%, 학습 데이터 확장을 한 경우에 평균 99.3%를 보여 본 논문에서 제안한 확장 방법이 유효함을 보였다.

III. 회전한 상표 이미지를 위한 학습 데이터 확장 방법

3.1 회전한 상표 이미지 정의

본 논문에서 사용하는 용어인 ‘회전한 상표 이미지(rotated trademark image)’는 등록된 상표 이미지를 기준으로 진위 여부를 결정할 대상 이미지를 캡처하는 과정에서 이미지의 중심을 기준으로 시계 방향 또는 반시계 방향으로 회전한 것을 의미한다. 그림 1은 한국교통대학교의 공식 상표(로고) 이미지와 회전한 이미지를 나타낸 것이다. 그림 1(a)는 공식 상표 이미지를 나타낸 것으로 중앙에 표시한 가상의 수직선을 기준으로 캡처 과정에서 발생할 수 있는 이미지의 회전 여부를 나타낸다. 그림 1(b)는 회전한 상표 이미지의 예를 나타낸 것으로 가상의 수직선을 기준으로 상표 이미지가 반시계 방향으로 임의의 각도 만큼 회전을 한 것이다. 따라서, 그림 1(b)에 나타낸 것과 같은 이미지가 회전한 상표 이미지이다.

상표를 구성하고 있는 각 요소의 방향성과 무관하게 특허청 등에 등록된 상표 이미지가 회전하지 않은 바른 방향이며, 캡처한 상표 이미지의 회전 유무는 이것을 기준으로 결정된다. 진위 여부 결정의 대상이 되는 상표 이미지는 인터넷으로부터 다운로드, 스마트폰 등 스마트

기기를 활용한 사진 촬영 등 다양한 방법으로 캡처가 되지만 사용자의 의도와 무관하게 상표권으로 등록된 상표 이미지와 같이 정방향으로 정렬된 대상 이미지를 얻는 것은 쉽지 않다.




Figure 1. Example of Normal and Rotated Trademark Image

3.2 학습 데이터 확장 방법

앞서 기술한 바와 같이 이미지 또는 영상 속의 객체는 다양한 형태를 갖고 있다. 예를 들어, ‘강아지’로 분류되는 다양한 이미지는 견종, 취하고 있는 자세, 색깔, 생김새 등과 무관하게 분류되어야 하기 때문에 다양한 ‘강아지’ 이미지가 학습 데이터로 사용된다. 하지만 상표 이미지는 상표권으로 등록된 소수의 이미지만 존재하기 때문에 이를 이용하여 학습에 사용하는 것은 과적합 문제의 원인이 된다. 소량 학습 데이터로 인한 과적합 문제 해결을 위해 학습 데이터 확장 즉, 학습 데이터의 양을 증가시키는 다양한 방법이 제안되었지만 상표 이미지의 중심을 기준으로 회전한 이미지를 대상으로 한 인식 또는 진위 결정에 대한 것은 현재까지 없는 것으로 파악된다.

기존 연구에서 제안된 데이터 확장 방법으로 생성된 학습 데이터를 이용하여 학습한 학습 모델은 그림 1(a)에 나타난 이미지를 진짜 상표로 분류를 하지만, 그림 1(b)에 나타난 상표는 진짜 상표임에도 불구하고 모방 또는 위조 상표 이미지로 분류할 수 있다. 이것은 그림 1(b)의 상표 이미지가 회전되어 있어 학습한 이미지와 다른 것으로 판단할 가능성이 있다.

회전한 상표 이미지의 진위를 결정하기 위한 기계학습용 학습 데이터 확장 방법으로 본 논문에서 제안하는 방법은 상표로 등록된 상표 이미지를 기반으로 하여 시계 방향 또는 반시계 방향으로 회전을 시키는 것이다. 그림 2(b)는 그림 2(a)에 표시한 등록된 상표 이미지를 임의 각도와 방향으로 회전시켜 생성한 이미지를 나타내고 있다. 회전시킨 학습 데이터 생성에 사용할 최대 각도는 응용에 따라 다르게 결정될 수 있다.

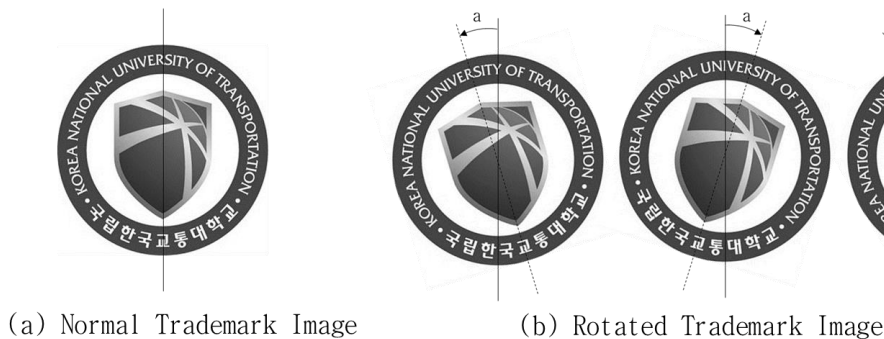


Figure 2. Examples of generating Training Data via rotating

IV. 기계학습 모델 및 성능 평가

4.1 학습 데이터 생성

본 논문에서 제안한 학습 데이터 확장 방법의 유효성 검증을 위해 한국교통대학교 공식 상표를 대상으로 학습 데이터를 생성하여, 기계학습 모델을 훈련하였다. 본 논문에서 제안한 방법으로 생성하여 기계학습에 사용한 학습 데이터는 표 1 에 보이는 것과 같다. 표 1 의 ‘Genuine Trademark’ 열은 그림 2(a)에 나타난 등록된 상표 이미지를 기반으로 각 방법에 따라 생성한 학습 데이터의 수를 나타낸 것이며, ‘Non-Genuine Trademark’은 모조 또는 위조된 상표 이미지의 수를 의미한다.

Table 1. Generated Training Data

Way	Number of Generated Data	
	Genuine Trademark	Non-Genuine Trademark
Scale	1,000	645
Rotate	1,000	645
Scale-Rotate	1,000	645
Scale-Rotate-Line	1,000	645

등록된 상표 이미지를 위한 1,000 개의 학습 데이터 생성 방법은 기존에 제안된 방법 중 해상도 조절(Scale), 임의 선 삽입(Line)과 본 논문에서 제안하는 회전(Rotate)을 조합하여 네 가지를 사용하였다. 해상도 조절 방법은 원본 상표 이미지의 해상도를 임의의 비율로 감소시킨 후 다시 원래 이미지 해상도로 복구하여 생성하였으며, 각 학습 데이터 생성시 0.1 과 1.0 사이의 실수 난수 값을 해상도 조절 비율로 사용하였다. 회전 방법은 원본 상표 이미지를 반시계 방향으로 설정된 각도만큼 회전시켜 생성하였다. 본 논문에서 사용한 회전 각도는 0 도, 5 도, 10 도, 15 도이며, 각각의 회전에 대해 200 개의 학습 데이터를 생성하였다. 해상도 조절과 회전 조합 방법(Scale-Rotate)는 앞서 기술한 해상도 조절 방법과 회전 방법을 조합한 것으로 해상도 조절 비율은 0.1 과 1.0 사이의 난수, 회전 각도는 각각 0 도, 5 도, 10 도, 15 도로 하여 학습 데이터를 생성하였다. 해상도 조절, 회전 조합, 임의 선 삽입 방법을 조합한 방법(Scale-Rotate-Line)은 앞의 해상도 조절과 회전 조합 방법과 동일한 방법으로 학습 데이터를 생성하여 임의 길이의 선을 임의 위치에 추가하였다.

4.2 학습 모델

본 논문에서 사용한 학습 모델은 이미지, 영상 분석 및 처리에 효과적인 것으로 알려진 합성곱 신경망(Convolutional Neural Network, CNN)과 완전 연결 신경망(Full-Connected Neural network, FC)을 사용하였다. 합성곱 신경망은 이미지, 영상 프레임에서 객체 분석, 인식을 위한 분야에 효과적인 것으로 알려져 있는 것으로 최근에는 이미지, 영상 처리와 더불어 다양한 분야에서 활용되고 있다. 완전 연결 신경망은 합성곱 신경망의 출력을 이용하여 분류 등을 수행한다.

앞의 절에서 기술한 방법으로 생성한 학습 데이터를 학습하기 위해 본 논문에서 구성한 학습 모델은 그림 3 과 같다. 이 학습 모델은 240x240 크기의 상표 이미지를 입력하며, Conv 로 표기된 세 개의 합성곱 계층으로 구성되어 있다. 각 합성곱 계층은 각각 32, 32, 64 개의 3x3 커널로 구성된다. 합성곱 계층의 출력을 위한 활성화 함수는 간단한 계산과 기계학습에 높은 성능을 보이는 ReLU 함수를 사용하였다. Max 로 표시된 풀링 계층은 2x2 크기의 윈도를 사용하였으며, 과적합을 감소시키기 위해 세 개 계층의 드롭아웃(Dropout)을 사용하였으며, 그 비율은 각각 0.25, 0.25, 0.5 를 사용하였다. 입력된 상표 이미지의 진위를 결정하기 위해 두 단계의 완전 연결 신경망을 사용하였으며, 각각 512 개와 2 개의 뉴런으로 구성된다.

기계 학습을 하는 동안에 모델에서 출력된 결과와 학습 데이터와 함께 제공된 레이블의 오차를 최소화하기 위해 Adam 최적화 알고리즘을 사용하였으며, 학습 데이터의 80%에 해당하는 데이터를 학습에 사용하고, 나머지 20%의 데이터는 모델 검증을 위해 사용하였다.

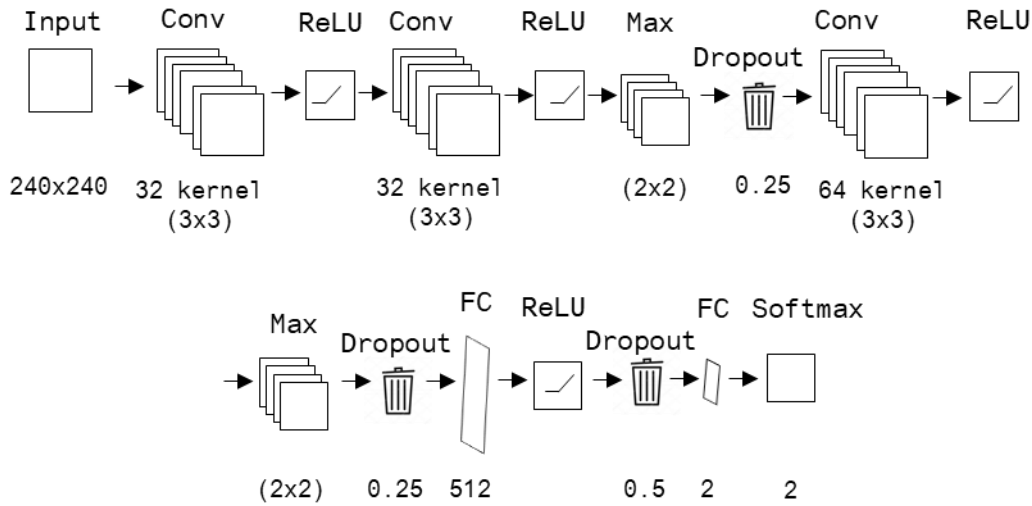


Figure 3. Configuration of Machine Learning Model

4.3 실험 환경 및 결과

본 논문에서 제안한 학습 데이터 확장 방법의 유효성 검정을 위해 학습이 완료된 모델에 시험용 데이터에 대한 상표 이미지 진위 결정의 정확도를 평가하였다. 기계학습은 그림 3에 보인 학습 모델에 본 논문에서 제안한 학습 데이터 확장 방법에 따라 생성된 학습 데이터를 입력으로 하여 실시하였다. 기계학습 모델의 구현은 Tensorflow 기반의 Keras 를 이용하였다. Tensorflow 와 Keras 는 다양한 운영환경을 지원하고 있기 때문에 본 논문에서 사용한 시스템의 환경(Intel Xeon E5-2640, 2 CPU, 32GB, Quadro P2000 GPU, Ubuntu 18.04)과 무관하게 적용할 수 있다.

시험용 데이터는 그림 2(a)에 나타낸 등록된 상표 이미지와 유사 상표 이미지에 대해 해상도 조절, 임의의 선 추가와 함께 0도, 7도, 14도, 21도 회전시켜 생성하였다. 각 회전 각도에 각각 100개의 데이터를 생성하여 모두 800개의 시험용 데이터를 생성하였으며, 학습이 완료된 학습 모델에 입력으로 제공되기 전에 시험용 데이터의 순서를 무작위로 변경하였다. 학습 데이터와 다른 각도로 생성하였기 때문에 시험용 데이터는 학습 데이터에 포함되지 않았다.

표 2는 학습이 완료된 학습 모델에 시험용 데이터를 입력으로 하여 상표 이미지의 진위를 결정한 결과에 대한 정확도를 나타낸 것이다. 표 2의 첫번째 열(Trained Learning Model)은 모델이 학습한 데이터의 종류를 나타낸 것으로 각각 해상도 조절, 회전, 해상도 및 회전 조합, 해상도, 회전 및 선 삽입 방법으로 생성한 데이터를 학습한 것을 의미한다. 표 2의 두번째 열은 등록된 상표 이미지만을 포함하고 있는 시험용 데이터를 대상으로 진위 결정의 정확도를 나타낸 것이며, 세번째 열은 등록된 상표 이미지와 기타 다른 상표 이미지를 포함하고 있는 시험용 데이터를 대상으로 한 진위 결정 정확도를 나타낸 것이다.

Table 2. Accuracy for Test Data

Trained Learning Model	Data set included Only Genuine Trademark	Data set included Genuine and Imitation Trademark
Scale	0.117	0.559
Rotate	0.35	0.675
Scale-Rotate	0.75	0.875
Scale-Rotate-Line	0.75	0.875

정확도 결과에 따르면 상표 이미지의 캡처 방법과 환경에 따라 상표 이미지가 임의의 각도로 회전된 경우에 상표 이미지의 진위 결정을 위한 학습 데이터 생성에 이미지를 회전시키는 방법이 해상도를 변경하는 것보다는 나은 성능을 보였다. 그러나 등록된 상표 이미지를 대상으로 회전시키는 방법, 해상도에 변화를 주는 방법을 단독으로 사용하기 보다는 회전과 해상도 변화를 함께 적용하는 것이 더 나은 성능을 보였다. 반면 본 논문의 도메인이라고 할 수 있는 상표 이미지 진위 결정 분야에서 학습 데이터 생성에 선을 임의 위치에 삽입하는 것은 큰 효과가 없는 것으로 판단된다.

V. 결론

기관 또는 개인이 소유한 상표권 보호를 위해 기계학습을 활용하여 상표 이미지의 진위 결정을 하고자 할 경우에 대량의 학습 데이터가 필요하다. 객체 인식, 분석 분야에 사용되는 기계학습은 다양한 형태의 학습 데이터가 존재하며, 일부 연구팀들은 그들이 구축한 대용량의 이미지 데이터베이스를 공개를 하고 있다. 보통의 객체들과 달리 상표는 특허청 등에 등록된 소량의 이미지만 존재하기 때문에 기계학습을 활용하여 대상 이미지의 진위를 결정하고자 할 경우에 학습 데이터의 부족으로 인한 과적합이 발생할 수 있다.

본 논문에서 상표 이미지 등과 같이 소량의 데이터를 이용하여 학습 데이터의 수와 양을 증가시키는 학습 데이터 확장 방법을 제안하였다. 특히 본 논문에서는 다양한 방법과 환경에서 캡처한 대상 이미지가 등록된 상표 이미지와 동일한 방향이 아닌 회전되어 있는 경우를 고려한 학습 데이터 생성 방법을 제안하였다. 즉, 제안한 방법은 상표 이미지의 중심을 기준으로 시계방향 또는 반시계방향으로 회전을 시켜 학습 데이터를 생성하였다.

본 논문에서 제안한 방법의 유효성 확인을 위해 한 대학의 등록 상표를 대상으로 학습 데이터를 생성하였으며, 심층 신경망의 한 종류인 합성곱 신경망과 완전연결 신경망을 이용하여 상표 이미지 진위 결정의 정확도를 평가하였다. 정확도 평가 결과에 의하면 상표 이미지 진위 결정을 위한 기계학습용 학습 데이터 생성시 기존의 방법인 해상도 변경 방법과 함께 본 논문에서 제안한 회전 방법을 조합하여 학습 데이터를 생성하는 것이 효과적이었다.

추후 연구과제로는 본 논문에서 제안한 방법으로 여러 상표 이미지를 위한 학습 데이터를 생성하고, 이를 활용하여 상표 이미지의 진위 결정할 뿐만 아니라 상표 이미지를 상표권을 소유한 기관별로 분류하는 시스템을 구축하는 것이다. 또한, 등록된 상표 이미지를 학습하여 예상되는 유사 상표를 생성하는 모델을 개발하는 것이다.

VI. 감사의 글

2019년 한국교통대학교 지원을 받아 수행하였음.

VII. 참고문헌

- [1] J. Yun, "A Study on Similar Trademark Search Model Using Convolutional Neural Networks," MS. dissertation, Graduate School, KwangWoon Univ., Seoul, Korea, 2018.
- [2] S. Bae, J. Park, S. Oh, T. Jung, and H. Choi, "A Survey and Analysis of the trademark management activity in the Domestic Companies," Korea Intellectual Property Office, Dec. 2013.
- [3] H. Park, S. Moon, M. Lee, M. Lee and B. Gu, "Training Data Extension Way for Machine Learning Classifying Original and Imitation Logo," in Proc. Of the Fall Conference on ICT Platform(PTL), Seoul, 2019, pp. 17-19.
- [4] A. Krizhevsky, "The CIFAR-10 & CIFAR-100," <https://www.cs.toronto.edu/~kriz/cifar.html>
- [5] A. Krizhevsky, I. Sutskever, and G. Hinton, "Imagenet classification with deep convolutional neural networks," In Advances in Neural Information Processing Systems 25(NIPS 2012), 2012,

- pp.1097-1105.
- [6] G. Szegedy, W. Liu, P. Sermanet, S. Reed, D. Anguelov, and A. Rabinovich, "Going deeper with Convolutions," In Proc. Of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2015, pp.1-9.
 - [7] J. Fadaee, A. Bisazza and C. Monz, "Data augmentation for low-resource neural machine translation," arXiv:1705.00440, May. 2017.
 - [8] Y. LeCun and Y Bengio, "Convolutional networks for images, speech, and time series," The handbook of brain theory and neural networks, MIT Press, MA, USA, 1998, pp.255-258

저자 소개



구본근(*Bongen Gu*)

1998년 4월 ~ 한국교통대학교 컴퓨터공학과 교수

관심분야: 컴퓨터구조, 기계학습, 저장장치, 네트워크 보안
