

유사 이미지 분류를 위한 딥 러닝 성능 향상 기법 연구

Research on Deep Learning Performance Improvement for Similar Image Classification

임동진*, 김태홍**

NHN 다이퀘스트 AI R&D그룹*, 한국한의학연구원 미래의학부**

Dong-Jin Lim(glow14795@gmail.com)*, Taehong Kim(thkim@kiom.re.kr)**

요약

딥 러닝을 활용한 컴퓨터 비전 연구는 여전히 대규모의 학습 데이터와 컴퓨팅 파워가 필수적이며, 최적의 네트워크 구조를 도출하기 위해 많은 시행착오가 수반된다. 본 연구에서는 네트워크 최적화나 데이터를 보강하는 것과 무관하게 데이터 자체의 특성만을 고려한 CR(Confusion Rate)기반의 유사 이미지 분류 성능 향상 기법을 제안한다. 제안 방법은 유사한 이미지 데이터를 정확히 분류하기 위해 CR을 산출하고 이를 손실 함수의 가중치에 반영함으로써 딥 러닝 모델의 성능을 향상시키는 기법을 제안한다. 제안 방법은 네트워크 최적화 결과와 독립적으로 이미지 분류 성능의 향상을 가져올 수 있으며, 클래스 간의 유사성을 고려해 유사도가 높은 이미지 식별에 적합하다. 제안 방법의 평가결과 HanDB에서는 0.22%, Animal-10N에서는 3.38%의 성능향상을 보였다. 제안한 방법은 다양한 Noisy Labeled 데이터를 활용한 인공지능 연구에 기반이 될 것을 기대한다.

■ 중심어 : | 분류 | 딥 러닝 | 유사 이미지 | 컨볼루션 뉴럴 네트워크 | 혼동률 |

Abstract

Deep learning in computer vision has made accelerated improvement over a short period but large-scale learning data and computing power are still essential that required time-consuming trial and error tasks are involved to derive an optimal network model. In this study, we propose a similar image classification performance improvement method based on CR (Confusion Rate) that considers only the characteristics of the data itself regardless of network optimization or data reinforcement. The proposed method is a technique that improves the performance of the deep learning model by calculating the CRs for images in a dataset with similar characteristics and reflecting it in the weight of the Loss Function. Also, the CR-based recognition method is advantageous for image identification with high similarity because it enables image recognition in consideration of similarity between classes. As a result of applying the proposed method to the Resnet18 model, it showed a performance improvement of 0.22% in HanDB and 3.38% in Animal-10N. The proposed method is expected to be the basis for artificial intelligence research using noisy labeled data accompanying large-scale learning data.

■ keyword : | Classification | Deep Learning | Similar Image | CNN | Confusion Rate |

* 본 연구는 한국한의학연구원 'AI 한의사 개발을 위한 임상 빅데이터 수집 및 서비스 플랫폼 구축(KSN2013110)'과제의 지원을 받아 수행되었습니다.

접수일자 : 2021년 04월 14일

수정일자 : 2021년 05월 11일

심사완료일 : 2021년 05월 19일

교신저자 : 김태홍, e-mail : thkim@kiom.re.kr

I. 서론

최근 지속적으로 주목받고 있는 딥 러닝 알고리즘은 이미지 분류에서 더 나아가 음성 인식, 번역, 객체 탐지 문제와 같이 다양한 영역으로 확장 적용되고 있으며 기존 알고리즘 대비 뛰어난 성능을 보이며 많은 연구가 수행되고 있다. 특히, 이미지넷으로 잘 알려진 1,000개의 이미지 분류 문제를 겨루는 알고리즘 대회인 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서는 합성곱 신경망 모델들의 정확도가 사람의 정확도를 뛰어넘으며, 5%이하의 낮은 오류율을 보이고 있으며, Resnet[1]의 경우 3.6%의 인식 오류율을 보였다. 합성곱 신경망의 성능 향상은 주로 네트워크 구조를 변경하거나 데이터를 보강하며 이루어진다. 그러나 다수의 학습 데이터가 필수적인 딥 러닝 알고리즘은 여전히 다양한 데이터 자체의 문제, 특히 데이터 내 클래스 불균형 문제[2][3], 학습 데이터의 오류(Noisy Labeled Data)[4][5], 시각적으로 매우 유사한 특징을 가진 혼동 이미지 데이터[6][7] 등은 이미지 분류 모델의 성능 향상을 위해 극복해야하는 문제로 남아 있다.

본 논문에서는 학습 모델의 종류나 데이터셋의 크기와 무관한 혼동 이미지셋(시각적으로 유사한 특징을 가진 클래스)을 이용한 분류 성능 향상 기법을 제안한다. 제안 방법은 딥 러닝 모델의 학습 과정에서 발생하는 모델의 예측값과 데이터의 정답값의 차이를 이용하여 CM(Confusion Matrix)을 만들고, CM으로부터 두 클래스 간 차이 대한 비율 CR(Confusion Rate)을 새롭게 정의한다. CR 값은 손실 함수에 가중치를 더해 모델의 학습을 보정한다.

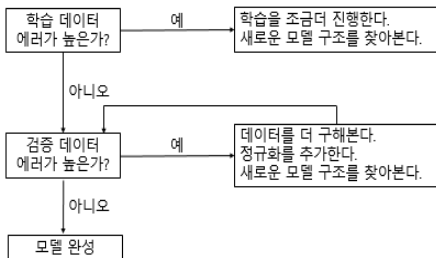


그림 1. 딥 러닝 모델 구현 과정

본 논문의 구성은 서론에 이어, 2장에서 유사 이미지 인식 분야의 관련 연구를 서술하며, 3장에서는 실험에 사용한 데이터셋의 특징에 대해 기술한다. 4장에서는 유사 클래스의 선정 방법 및 학습 방법에 대해 상세히 설명하고 5장에서 제안 방법을 적용한 실험 결과 및 분석에 대해 논하고자 한다. 마지막 6장에서는 결론 및 고찰과 함께 향후 연구 의의 및 한계점에 대해 기술한다.

II. 관련 연구

최근 딥 러닝 연구는 향상된 컴퓨팅 자원과 알고리즘을 기반으로 다수의 레이어를 구성하는 것이 가능해짐으로서 보다 복잡도가 높은 모델을 활용하여 다양한 문제를 해결하고 있다. [그림 1]은 딥 러닝 모델의 구현 과정을 나타낸 것으로, 일반적으로 딥 러닝 모델의 학습을 수행하면서 학습 데이터의 오류가 높다면 모델 학습을 더 진행하거나 새로운 모델 구조를 고안해야 한다. 학습된 모델이 검증 데이터에서 에러가 높다면 학습데이터에 과적합되었을 가능성이 높으므로 학습 데이터를 추가하거나 딥 러닝 모델에 정규화 과정을 추가하게 된다. [그림 1]의 과정을 통해 모델을 구현한 딥 러닝 모델은 일반적으로 성능 향상을 위해 깊은 구조를 갖게 되고, 깊은 구조의 딥 러닝 네트워크는 적게는 수백만 개부터 많게는 수천만 개에 이르는 파라미터를 갖고 있으며, 이러한 네트워크를 과적합 없이 안정적으로 학습하기 위해 많은 양의 데이터가 필요하다[8].

많은 양의 데이터를 손쉽게 확보하기 위해 주로 전통적인 데이터 확장 기법이 사용되며, 이미지를 회전, 반전 또는 확대시켜 변환하면 데이터가 확장되는 효과가 있다. 최근에는 GAN(Generative Adversarial Network) 모델을 이용하여 데이터를 새롭게 생성하는 방법을 동시에 적용하고 있다[9][10]. 그러나 GAN을 이용한 데이터 확장 기법은 데이터를 새롭게 생성하기 위해 별도의 네트워크가 필요하며 학습 시간이 늘어나는 문제점과 전통적인 데이터 확장 기법은 시각적으로 유사한 클래스간의 관계를 고려하기 어렵다는 문제점을 갖고 있다.



그림 2. HanDB와 Animal-10N 데이터셋 및 버섯과 한약재의 유사 이미지 샘플(순서대로)

임동진[11], 김정연[12]은 시각적으로 매우 유사한 클래스의 분류 성능 향상을 위해 계층 구조의 딥 러닝 모델을 만드는 방법을 시도하였다. [11]에서는 한글 손글씨 데이터셋 중 하나인 SERI95a를 사용하였으며, 딥 러닝 모델로부터 상호 혼동 쌍을 추출하고, 추출된 정보를 이용하여 계층적 딥 러닝 구조를 설계하여 실험을 진행하였다.

[12]에서도 한글 손글씨 데이터셋 중 하나인 PE92 데이터셋을 사용했으며, SOM(Self-Organizing Map)을 이용하여 사전에 유사 클래스들을 클러스터링 하였다. 클러스터링된 클래스들은 개별적으로 딥 러닝 모델을 만들고 학습에 이용하였다. 네트워크 구조를 변경하는 방법은 시각적으로 매우 유사 클래스 분류 성능 향상에 유의미한 결과를 보였으나 두 개 이상의 모델을 학습시켜야 하는 한계가 있다.

앞선 문제를 해결하기 위해 Chopra[6]와 Dubey[7]는 데이터 확장 기법이나 모델의 구조를 변경시키지 않고 시각적으로 유사한 클래스의 분류 성능을 높이는 Pairwise Learning을 제안했다. Pairwise Learning은 두 이미지 사이의 관계를 KL-Divergence 등을 통해 새롭게 정의하고, 정의된 관계를 Pairwise Confusion Loss 라는 새로운 학습 가중치로 손실 함수를 대체하여 모델의 학습에 사용하여 유사 클래스들을 잘 구분할 수 있도록 하였다.

Pairwise Learning은 유사한 이미지의 관계를 데이터로부터 찾는 데이터 중심적인 방법으로, 두 클래스가 갖는 이미지가 실제로 유사하더라도 딥 러닝 모델은 두 이미지가 유사하다고 판단하지 않을 수 있다[13].

따라서 본 논문에서는 [6][7]에서와 같이 데이터 확장 기법이나 모델의 구조를 변경시키지 않고 손실 함수를 조절하는 방법을 사용하지만 [13]의 문제점을 해결하기 위해 데이터셋에 사용하는 딥 러닝 모델을 이용하여 모델로부터 두 이미지의 유사 관계를 찾아 손실 함수에 가중치를 더해 모델의 학습을 보정한다.

III. 데이터

제안 방법의 평가를 위해서 [그림 2]와 같이 유사한 이미지를 다수 포함하고 있는 데이터셋을 선정하였다. 그 중 특정 데이터셋에 과적합되는 문제를 회피하기 위해 데이터 특성이 이질적인 한글 필기체와 동물이미지 데이터셋인 HanDB[14]와 Animal-10N[15]데이터를 활용하여 실험을 수행하였다. HanDB는 SERI95a와 PE92를 합친 데이터셋으로 한글의 특성으로 인하여 (강, 감), (귀, 키, 커) 등과 같은 유사글자가 많이 나타나며, 2,350개의 클래스가 학습데이터 665,890장, 검증데이터 75,186장으로 구성되어 있다. Animal-10N 데이터셋은 (고양이, 시라소니), (재규어, 치타)등과 같이 유사한 동물들 10종의 사진을 모은 데이터셋으로, 학습데이터 50,000장과 검증데이터 5,000장으로 이루어져 있다. 각각의 데이터는 본 연구의 목적에 맞게 잘 알려진 Resnet34, Resnet18, VGG13[16] 모델을 네트워크 구조 변화 없이 제안 방법만을 적용하여 비교 평가를 수행하였다.

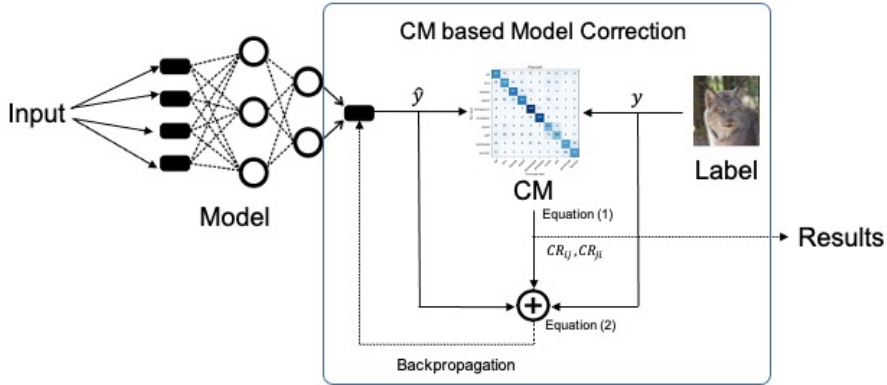


그림 3. 제안 프로세스 개념도

	cat	lynx	cheetah	jaguer	chimpanzee	orangutan	coyote	wolf	guinea pig	hamster
cat	1826	495	131	251	408	223	355	676	457	644
lynx	445	1792	212	429	93	93	693	701	48	102
cheetah	134	218	3210	755	239	30	181	138	18	58
jaguer	286	386	902	2477	102	40	428	160	41	91
chimpanzee	181	44	93	41	4146	306	68	251	146	46
orangutan	157	50	28	24	317	3976	89	30	162	166
coyote	407	614	108	310	189	141	1761	1013	130	168
wolf	505	456	105	149	327	74	929	2171	158	217
guinea pig	465	31	27	29	204	242	115	162	2332	1202
hamster	536	50	35	78	94	216	200	229	1016	2516
True label	cat	lynx	cheetah	jaguer	chimpanzee	orangutan	coyote	wolf	guinea pig	hamster
Predicted label	cat	lynx	cheetah	jaguer	chimpanzee	orangutan	coyote	wolf	guinea pig	hamster

그림 4. Confusion Matrix 예시

$$\begin{cases} CR_{ij} = \frac{CM_{ij}}{CM_{ij} + CM_{ji}} (i \neq j) \\ CR_{ij} = 0 (i = j) \end{cases} \quad (1)$$

CM의 행과 열은 각각 정답값과 예측값을 의미하며 i 와 j 는 학습할 때 클래스에 부여된 번호를 뜻한다. [그림 3]은 제안 방법의 전체적인 프로세스를 나타낸 것으로 먼저 입력 이미지에 대한 모델의 예측값 \hat{y} 와 정답값 y 를 이용하여 CM을 만든다. 그 후 만들어진 CM으로부터 식(1)을 이용하여 CR_{ij}, CR_{ji} 을 산출한뒤 기존의 손실 함수에 가중치를 더해 역전파를 진행하게 된다. 산출된 CR_{ij}, CR_{ji} 값은 각각 0.5일 때 두 클래스 간에 가장 많이 서로를 혼동하고 있는 경우이다. 예를 들어, [그림 4]의 오랑우탄과 침팬지의 경우 서로 잘못 예측한 623장의 이미지 중 오랑우탄을 침팬지로 317장 잘못 예측 했고, 침팬지는 오랑우탄으로 306장 잘못 예측 했다. 즉 오랑우탄이나 침팬지의 이미지가 들어올 때 50%의 확률로 한번은 오랑우탄 한번은 침팬지로 예측하고 있다는 의미로 서로를 가장 많이 혼동하는 상태로 볼 수 있다. 따라서 식 (1)에 의해 두 CR_{ij}, CR_{ji} 의 값이 0.5일 때 최대값을 산출하는 정보 엔트로피를 적용하여 Loss에 가중치를 더해주게 된다. k 는 상수 값으로 정보 엔트로피를 통해 구한 Loss를 얼마만큼 반영할 것인지 정하게 된다.

$$L = L + k \times L \times Entropy(CR_{ij}, CR_{ji}) \quad (2)$$

IV. 제안 방법

딥 러닝 모델은 모델이 완전히 학습되기 전에는 모델의 예측값이 일관되지 않는 변화를 보인다. 또한 딥 러닝 모델은 학습데이터의 정답을 암기하는 경향을 갖고 있으며, 전체 학습 데이터셋의 정답을 모두 암기하기에 충분한 저장 공간을 갖고 있다[17][18]. 본 논문에서는 위의 특성을 이용하여 모델이 학습 데이터를 완전히 암기하기 전 단계의 예측값과 정답을 이용하여 CM(Confusion Matrix)을 만든 뒤 CR을 산출하여 학습에 이용한다.

본 연구에서는 Optimizer로 SGD를 사용하였으며, Learning rate 0.01, Momentum 0.9 와 Batch Size 는 512로 설정하였다. HanDB에서는 이미지를 60x60 으로 변환 한 후 GrayScale과 Zero Padding을 적용 하여 1x64x64로 학습을 진행하였고, Animal-10N에 서는 3x64x64의 크기로 학습을 진행하였다.

표 1. CR 기반 Loss 보정 알고리즘

Algorithm 1 Loss Correction Algorithm	
CM	Confusion Matrix,
CR	Confusion Matrix of Rate, L : list of loss,
y	label number, \hat{y} : prediction number
for $n = 0$ to epochs do	
$CM^t \leftarrow$ initialize the confusion matrix to 0	
$CR^t \leftarrow$ make rate matrix from CM^{t-1}	
for $m = 0$ to mini_batch do	
$CM^{t_{min}} = CM^{t_{min}} + 1$	
if $n > 1$ then	
for $i = 0$ to mini_batch do	
if $y_i \neq \hat{y}_i$ then	
$L_i = L_i + k * L_i * Entropy(CR_{y\hat{y}}^t, CR_{\hat{y}y}^t)$	
update network parameter	

V. 실험 결과 및 분석

본 논문에서는 제안 방법을 여러 도메인에 적용 해보 기 위해 이질적인 두 종류의 데이터셋을 실험에 사용하 였다. HanDB는 한글 필기체 데이터 셋으로, 한글의 특 성에 따라 다수의 유사 이미지를 포함하고 있으며 총 2,350개의 클래스, 학습데이터 665,890장, 검증데이터 75,186장으로 이루어져 있다. Animal-10N 데이터셋 은 총 10개의 클래스로 학습데이터 50,000장과 검증데 이터 5,000장으로 구성되어 있어 있으며 이미지 유사 도가 높은 동물 10종의 사진을 모은 데이터셋이다. 또 한 네트워크 구조 변경 없이 동일한 조건에서 실험을 진행하기 위해 Optimizer와 Batch_Size등 모든 하이 퍼 파라미터를 고정하고 학습을 진행하였으며 Animal-10N은 Resnet18, Resnet34, VGG13 모델 을 100 epochs 반복하였고, HanDB는 50 epochs 반 복하였다.

본 연구에서는 먼저 식(2)에서 k 값에 따른 학습 변화 를 알아보기 위해 VGG13 네트워크와 Animal-10N 데이터셋으로 실험을 진행하였다. [그림 7]과 같이 k 의 값이 3 일 때 결과가 가장 좋았으며, 값이 커질수록 과 적합 등의 이유로 성능이 감소하는 모습을 보였다.




그림 5. Resnet18 Animal-10N 정확도 변화

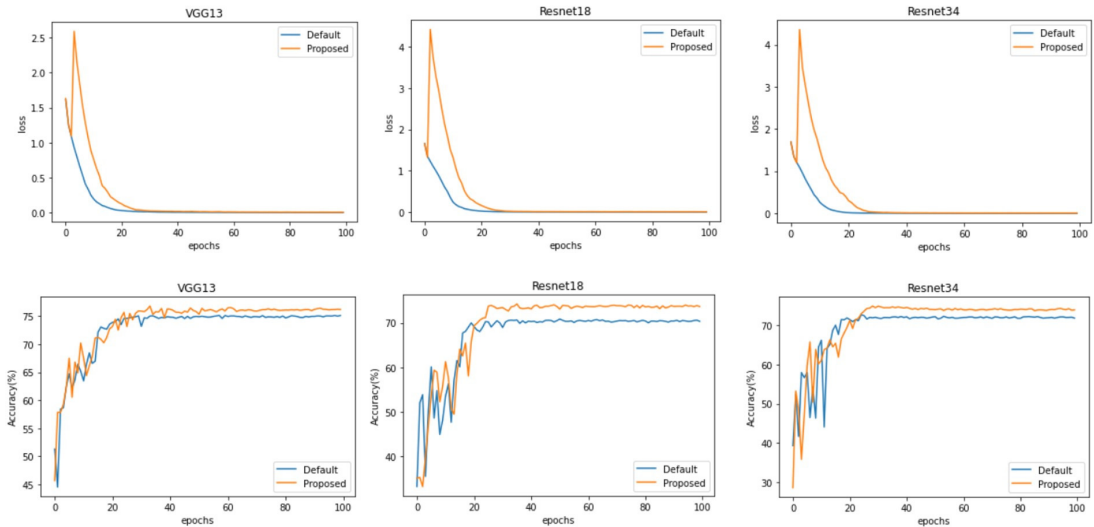


그림 6. Animal-10N 데이터셋 기준 모델과 제안 모델 학습 및 검증 변화




그림 7. VGG13 네트워크에서 k값 변화에 따른 정확도 변화

따라서 이후 모든 실험은 k를 3으로 고정하고 실험을 진행하였다.

제안 방법이 다양한 네트워크에서도 활용 가능성을 보이기 위해 VGG13, Resnet18, Resnet34에 Animal-10N 데이터셋을 적용한 결과 [그림 6]의 결과와 같이 모든 네트워크에서 성능향상을 보였으며, VGG13에서 1.68%, Resnet18에서 3.38%, Resnet34에서 2.24%의 성능 향상을 확인할 수 있었다. 그러나 Resnet18에서 정확도 변화를 확인한 결과 3.38%의 성능 향상에도 불구하고 [표 2]에서와 같이 오랑우탄의 정확도가 떨어졌으며, [그림 5]에서와 같이 코요테와 늑

대의 CR 값이 0.53에서 0.5로 상승하는 모습을 확인할 수 있었다.

표 2. Resnet18에서의 정확도 변화(%)

Class	Default	Proposed (k=3)
Cat	59.96	65.17
Lynx	65.98	68.87
Cheetah	76.42	78.98
Jaguer	74.23	75.57
Chimpanzee	87.74	90.16
Orangutan	90.48	89.77
Coyote	54.39	63.41
Wolf	52.48	56.74
Guinea pig	65.89	68.84
Hamster	68.86	74.77

본 연구에서는 제안 방법이 도메인이 다른 데이터셋에도 효과가 있음을 확인하기 위해 HanDB 데이터셋에 VGG13, Resnet18, Resnet34 모델을 적용하여 실험을 진행하였다.

[표 3]과 같이 실험 결과 모델의 정확도 향상은 Resnet34 모델에 대해 Animal-10N에서와는 달리 HanDB에서는 98.40%에서 98.50%로 유의미한 성능

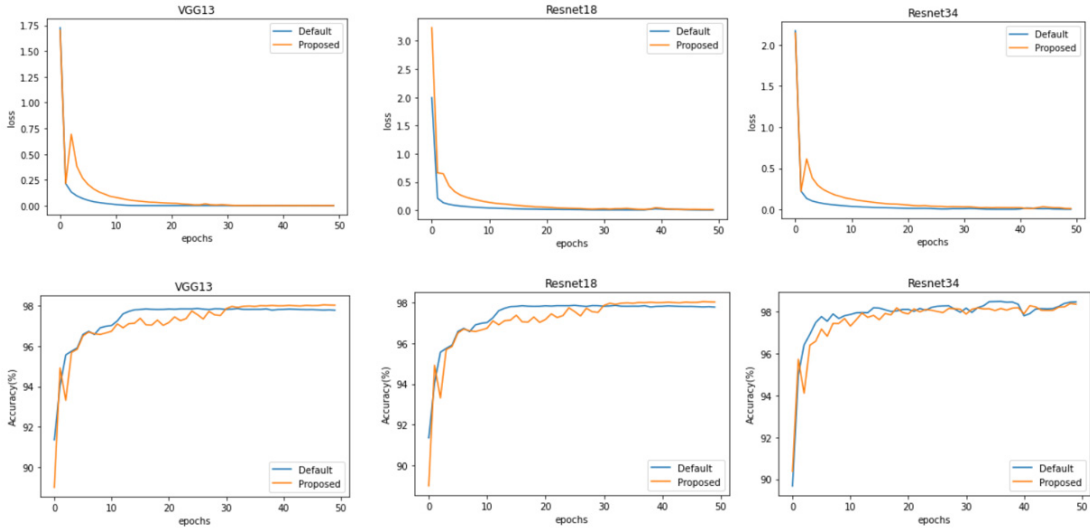


그림 8. HanDB 데이터셋 기존 모델과 제안 모델 학습 및 검증 변화

향상을 보이지 못하였는데, [그림 8]에서 HanDB는 Animal-10N에서와 달리 학습 초기에 Loss가 0으로 빠르게 수렴하는 모습을 볼 수 있었다.

표 3. 제안 모델 정확도(%): Animal-10N

Method	VGG13	Resnet18	Resnet34
Animal-10N			
Default	75.14	70.82	72.70
Proposed (k=3)	76.82	74.20	74.94
HanDB			
Default	97.86	98.22	98.40
Proposed (k=3)	98.04	98.44	98.50

제안 방법은 2 epoch부터 매 epoch마다 모델의 예측값을 기반으로 CM을 만들고 CR을 산출하여 학습에 이용하게 되는데, HanDB에서와 같이 모델의 학습이 빠르게 수렴한다면 CM은 대각행렬 모양을 띄게 되고 결국 CR의 값은 0이 된다. 이는 기존의 손실 함수에 아무런 가중치를 추가하지 않은 것과 같기 때문에 실질적 보정효과를 가져올 수 없는 결과를 보여줬다.

VI. 결론 및 고찰

본 논문에서는 네트워크의 최적화나 데이터를 보강하는 과정을 거칠 필요 없이 모델과 데이터 자체의 특성만을 고려한 CR을 이용하여 딥 러닝 모델의 성능을 향상 하도록 하는 방법을 제안하였다. CR은 딥 러닝 모델 학습 과정에서 산출되며 Pairwise Learning 방법 처럼 기존의 손실 함수에 가중치로 추가하여 모델의 학습에 이용한다. 제안 방법을 다양한 네트워크에 적용한 결과 네트워크의 구조 변화나 추가적인 데이터 보강 없이 모든 네트워크에서 유사 이미지 분류 성능이 향상 되었다. Animal-10N의 경우 최대 3.38%의 성능향상을 보였으며, HanDB에서는 0.22%의 성능향상을 보였다. 그러나 Animal-10N 데이터셋의 (코요테, 늑대)의 경우 제안 방법에서 오히려 CR 값이 증가하고, 오랑우탄의 경우 정확도가 떨어지는 것을 확인할 수 있었는데, 이에 대한 분석이 필요하다. 또한 Animal-10N 데이터셋과 달리 HanDB에서는 유의미한 성능향상을 보여주지 못했는데, 딥 러닝 모델이 유사 이미지와 상관 없이 빠르게 최적점에 수렴하기 때문이다. 학습이 빠르게 최적점에 수렴하면 학습 과정 중 오답이 발생하지 않게 되고, 결과적으로 [그림 3]의 CM 으로부터 산출되는 값 식 (2)의 $k \times L \times Entropy(CR_{ij}, CR_{ji})$ 부분

이 0 이 되어 제안 방법을 적용하지 않은 것과 같은 값이 역전파 된다.

두 개의 데이터셋의 특징을 고려해보면, HanDB는 배경이미지가 없는 한글 필기체 데이터셋이고, Animal-10N은 상대적으로 배경이 복잡한 동물 데이터셋이기 때문에, 학습 수렴의 속도차이의 차이로 인해 Animal-10N 데이터셋에서 제안한 방법의 유사 이미지 분류 보정 효과가 높은 것으로 확인되었다. 이러한 특성으로 인해 제안 방법은 추가적인 보안을 통해 실제계의 비식용버섯, 독성 약재 이미지와 같은 복잡한 데이터 분류에 보다 효과적인 것으로 예상되며. 또한 최근 대용량 데이터의 주요 수집처인 웹기반의 수집 이미지셋과 같이 Noisy Label이 포함된 데이터셋에 대한 처리 방안 연구 등에도 활용할 수 있을 것으로 기대한다.

참 고 문 헌

- [1] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," Proceedings of the IEEE conference on computer vision and pattern recognition, pp.770-778, 2016.
- [2] Johnson, M. Justin, and M. Taghi, "Survey on deep learning with class imbalance," Journal of Big Data, Vol.6, No.1, pp.1-54, 2019.
- [3] Buda, Mateusz, Atsuto Maki, and A Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," Neural Networks, Vol.106, pp.249-259, 2018.
- [4] T. Xiao, T. Xia, Y. Yang, C. Huang, and X. Wang, "Learning from massive noisy labeled data for image classification," Proceedings of the IEEE conference on computer vision and pattern recognition, pp.2691-2699, 2015.
- [5] H. J. Song, M. S. Kim, and J. G. Lee, "Selfie: Refurbishing unclean samples for robust deep learning," International Conference on Machine Learning, pp.5096-5915, 2019.
- [6] S. Chopra, R. Hadsell, and Y. LeCun, "Learning a similarity metric discriminatively, with application to face verification," CVPR, pp.539-546, 2005.
- [7] A. Dubey, O. Gupta, P. Guo, R. Raskar, R. Farrell, and N. Naik, *Training with confusion for fine-grained visual classification*, CoRR, 2017.
- [8] Mikołajczyk, Agnieszka, and Michał Grochowski, "Data augmentation for improving deep learning in image classification problem," 2018 international interdisciplinary PhD workshop (IIPhDW), IEEE, pp.117-122, 2018.
- [9] J. G. Ian, P. Jean, M. Mehdi, X. Bing, W. David, O. Sherjil, C. Aaron, and B. Yoshua, *Generative adversarial networks*. 2014.
- [10] M. Frid-Adar, E. Klang, M. Amitai, J. Goldberger, and H. Greenspan, "Synthetic data augmentation using GAN for improved liver lesion classification," 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018), IEEE, pp.289-293, 2018.
- [11] 임동진, *AI 성능 향상을 위한 상호 혼동 쌍 선정 및 답 러닝 모델 연구*, 과학기술연합대학원대학교, 석사 학위논문, 2020.
- [12] 김정연, *다중 열 답러닝 구조와 자기 구성 지도를 이용한 한글 필기체 인식 연구*, 숭실대학교, 석사학위논문, 2018.
- [13] Moravec, Hans, "When will computer hardware match the human brain," Journal of evolution and technology Vol.1, pp.10-22, 1998.
- [14] <https://github.com/callee2006/HangulDB>
- [15] <https://dm.kaist.ac.kr/datasets/animal-10n>
- [16] Simonyan, Karen, and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
- [17] D. Arpit, S. Jastrzębski, N. Ballas, D. Krueger, E. Bengio, and M. S. Kanwal, "A closer look at memorization in deep networks," International Conference on Machine Learning, PMLR, pp.233-242, 2017.
- [18] C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals, "Understanding deep learning requires rethinking generalization," Communications of the ACM, Vol.64, No.3, pp.107-115, 2021.

저 자 소 개

임 동 진(Dong-Jin Lim)

정회원



- 2018년 2월 : 강원대학교 컴퓨터정보통신공학(공학사)
- 2020년 2월 : 과학기술연합대학원대학교 빅데이터과학(공학석사)
- 2020년 7월 ~ 현재 : NHN 다이퀘스트

〈관심분야〉 : 빅데이터, 영상 처리

김 태 흥(Taehong Kim)

정회원



- 2014년 2월 : 과학기술연합대학원대학교 응용정보과학(공학박사)
- 2014년 3월 ~ 2018년 7월 : 한국과학기술정보연구원 선임연구원
- 2018년 7월 ~ 현재 : 한국한의학연구원 선임연구원

〈관심분야〉 : 빅데이터, IoT, 인공지능