

마이크로스코프 이미지의 딥러닝 기반 이상검출⁺

(Abnormal Detection with Microscope through Deep Learning)

정희용^{1,2,3)*}, 고정원⁴⁾, 신춘성^{5)*}

(Hieyong Jeong, Jeongwon Go, and Choonsung Shin)

요약 흡연자 중에서 담배가 인체에 유해하다는 사실을 모르는 사람은 없을 것임에도 불구하고, 정작 금연 성공률은 높지 않다. 금연을 위한 의지를 지속적으로 굳건하게 다지기 위하여 병원에서 실시하는 건강검진과 PET(positron emission tomography) 이미지를 통한 암 검사의 결과가 도움이 되지만, 일상생활 중에 간단히 실시할 수 있는 방법이 아니다. 본 연구에서는 일상생활 중에 관찰 가능한 흡연자의 신체 부위를 딥러닝 기반 마이크로스코프 이미지 측정 및 분석을 통하여 흡연자와 비흡연자의 차이를 검출할 수 있는 비침습적 방법을 제안하였다. 우선, 관찰 부위를 흡연시 직접적인 접촉을 하는 혀바닥 표면으로 설정하였다. 다음으로, 마이크로스코프로 혀바닥 표면(410배 확대)을 흡연자 10명과 비흡연자 10명의 실험 참가자를 통하여 데이터 셋(총 1,000장)을 구축하여 그 중 80%를 딥러닝 모델의 학습에 사용하였고, 나머지 20%는 예측에 사용하였다. 딥러닝 모델을 스케일링하는 방법(width scaling, depth scaling, resolution scaling) 중 한 가지 방법만 적용하는 VGG, ResNet, DenseNet과 세 가지를 모두 적용하여 스케일링하는 EfficientNet의 성능을 비교하여 모세혈관 이미지 처리에 EfficientNet의 우수성을 확인해 볼 수 있었다.

핵심주제어: 딥러닝, 마이크로스코프, 이상검출, 흡연, 혀바닥

Abstract The success rate of the no-smoking campaign has been low, although everybody knows that cigarettes are harmful to the human health. The results of both regular health and cancer checks in the hospital are useful for strengthening the human intention for quitting the smoking, however, those methods are difficult to use in daily life because of the use of large-scaled particular devices such as PET(positron emission tomography). Thus, this study proposed a non-invasive method that detects the difference between smokers and non-smokers through deep-learning-based analysis. At first, observing parts were decided to the tongue surface. Then, a data set(total 1,000) was made through the experiment to measure the tongue surface(410 times magnification) with the participants of 10 smokers and 10 non-smokers. The 80% ratio of data set was used for the train, and the left 20% was for the prediction. As a result, it was found that the classification through EfficientNet with the compound scaling including three scaling methods of width scaling, depth scaling and resolution scaling was much better than other models including VGG, ResNet, and DenseNet with the only one scaling.

Keywords: abnormal detection, deep learning, microscope, tongue surface, smoke

* Corresponding Author: h.jeong@jnu.ac.kr

+ 이 논문은 2020년 전남대학교 국립대육성사업비 교내 신진 학술연구비와 한국산업기술평가관리원 연구비의 지원에 의해 연구되었음.

Manuscript received January 06, 2021 / revised April 02, 2021 / accepted April 06, 2021

1) 전남대학교 AI융합대학 IoT인공지능융합전공, 제1저자

2) 전남대학교 대학원 인공지능융합학과, 교신저자

3) 전남대학교 소프트웨어공학과, 교신저자

4) 전남대학교 AI융합대학 IoT인공지능융합전공, 공동저자

5) 전남대학교 문화전문대학원 미디어예술공학전공, 교신저자

1. 서 론

흡연이 인체에 유해하다는 사실을 모르는 사람은 없다. 주요 지표로서 대한민국의 사망원인 1위는 암이고, 2위는 뇌혈관질환, 3위는 심장질환으로, 흡연은 이들 사망원인 1, 2, 3위에 공통된 주요 위험 인자로 분류된다 (WHO, 1983, Ayanian et al, 1999, Frank et al, 2002). 따라서 국민의 건강 문제를 논의할 때 흡연 문제가 빠질 수가 없다.

흡연자들 중에 아직도 담배가 인체에 해롭다는 것을 모르는 사람은 없을 것이다. 하지만 정작 담배의 유해성에 관한 질문을 하게 되면, 폐암이나 후두암의 발병과 관련이 있다는 정도이고, 그 이상 상세히 대답을 할 수 있는 사람은 드물다. 물론, 흡연 지식수준에 따라 흡연 형태(흡연율, 흡연량)의 차이를 조사한 연구 결과의 보고는 있지만 (Chen et al, 2001, Sargent et al, 2001, Hakeem et al, 2001, Carosella et al, 2002, Geckova et al, 2002, Torabi et al, 2002, Woo et al, 2003), 흡연자의 흡연 지식 점수가 평균 34.8점이고, 비흡연자의 점수가 평균 36.8점으로 통계적으로 유의성($P=0.003$)이 있다고 하더라도 두 그룹 간에 평균 점수 차이가 크지 않기 때문에 거의 유사한 데이터 분포를 가지고 있다. 금연을 위하여 더 많은 지식을 전달한다고 하더라도, 지식의 양이 늘어나게 되면 금연에 대한 생각은 고조되었지만 직접적으로 “나의 문제”라는 인식으로 받아들이기까지는 힘들어 보인다.

흡연자의 금연 결심 원인과 금연에 대한 동기 부여 간에 관련성 여부에서 동기부여의 기술 통계량을 살펴보면, 1위가 치과 치료, 2위가 폐암 사진으로 나타났다 (Frank et al, 2002, Geckova et al, 2002, Torabi et al, 2002). 그 외에도 담배 값 인상, 금연 구역지정 등이 있기는 하지만, 금연 결심의 가장 큰 동기 부여는 흡연으로 인하여 자신의 건강이 점차 중증 질환의 발병 가능성이 높아지고 있다는 사실에 대한 염려라고 간주할 수 있다. 그래서 대부분의 흡연자들은 정기건강검진 때 흡연으로 인한 심각한 건강 문제가 발생하였거나, 실제로 암과 같은 중증 질환이 발견되어서 수술 날짜를 검토하게 될 때 비

로써 자기 자신 본인의 심각한 문제로 인식을 하게 된다. 그렇다고 일상생활 가운데 혈액 검사나 PET (positron emission tomography)검사 등으로 매번 자신의 건강을 체크해 본다는 것은 고가 장비의 수급 문제 등으로 거의 불가능한 일로 여겨진다. 그래서 흡연으로 인하여 자신의 건강이 점점 악화되고 있다는 것을 좀 더 간편하게 파악할 수 있는 방안이 필요하다. 검사 결과로 인하여 흡연으로 인한 건강 악화가 자기 자신의 문제로 강하게 인식하게 되면서 금연 의지를 더욱 굳건하게 할 수 있지 않을까라는 가설을 세워 조사하게 되었다.

종래의 흡연이 인체에 미치는 영향은 코호트 자료 분석을 통하여 흡연자의 사망률이 비흡연자보다 2~3배 높다는 것과 21개의 질병과의 연관성을 통계 기반으로 역학 조사한 연구가 가장 많다 (Geckova et al, 2002, Woo et al, 2003). 또한 치과에서는 흡연이 치아와 잇몸 건강에 미치는 영향을 살펴보기 위해 의사의 육안이나 저장한 이미지를 사용하여 평가하는 연구도 있다 (Hakeem et al, 2001, Sargent et al, 2001). 한편 흡연으로 인한 미각 손상을 조사하기 위해 혀바닥에 직접적으로 전기자극을 가하여 미각 기능을 측정하여 보고한 연구도 있다 (Woo et al, 2003). 본 저자의 조사 결과를 볼 때, 흡연자 본인이 직접 흡연으로 인한 인체의 변화를 관찰할 수 있는 간이 방법은 아직까지 존재하지 않는 것처럼 보인다.

따라서 흡연 행위를 바탕으로 흡연자의 인체 상태를 직접 파악할 수 있는 연구를 제안하였다. 제안한 방법은 흡연자의 상태를 직접 파악하기 위해 흡연 시 담배 연기를 흡입할 때 혀바닥 표면 상태를 확대 영상으로 측정하여 분석하는 방법이다. 이를 위해 흡연자와 비흡연자에 대한 혀바닥 표면 상태를 마이크로스코프를 이용하여 이미지를 획득하여 데이터 셋 (총 1,000장)을 구축하여, 딥러닝 모델을 기반으로 흡연자와 비흡연자 간에 차이 검출에 유효한지 어떤지를 살펴보았다. 다양한 딥러닝 모델 가운데 혀바닥 표면의 상태를 측정할 마이크로스코프 이미지에 적용하기 적합한 모델을 찾은 후 학습 파라미터 수와 정확도의 관계를 통하여 하이퍼파라미터를 세팅하는 방법을 살펴보도록 하겠다.

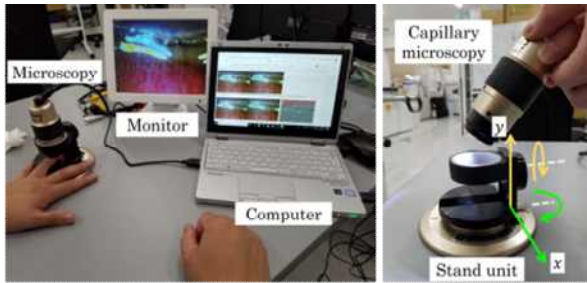


Figure 1. A description of the microscope with the low and high magnification.



Figure 2. An explanation to measure the tongue surface.

2. 실험 방법

2.1 실험 시스템 구성

Fig. 1은 저배율 ($\times 100$)/고배율 ($\times 410$) 확대 기능을 가진 마이크로스코프와 전체 실험 시스템의 구성을 보여주고 있다. 실험 참가자는 피부 표면의 상태를 측정하기 위해 측정 부위를 스탠드와 마이크로스코프의 결합부분에 위치시켜 측정하면 된다. 실험 운영자는 실시간으로 컴퓨터 모니터에서 측정 부위의 상태를 확인할 수 있고, 필요한 이미지는 컴퓨터에 바로 저장할 수 있다.

실험에 사용한 마이크로스코프는 (주) GOKO의 Bscan-Z (GOKO Imaging Devices, Kanagawa, Japan, Suga et al, 2019)로서 실린더 형태의 몸체로 컴팩트한 사이즈 (diameter \times length = $\phi 45 \times 106\text{mm}$)의 외형이다. 렌즈가 달린 몸체의 무게는 150g이고, 스탠드의 무게는 250g이다. 스탠드에는 렌즈가 부착된 몸체 부분을 x축과 y축 방향으로 각각 10mm 범위 내에서 측정 부위를 조절할 수 있지만, z축 방향으로 조절할 수 있는 기능을 갖추고 있지는 않다. 하지만 z축 방향 조절이 필요할 때는 실험 참가자가 실시간으로 측정 상태를 컴퓨터 모니터로 확인하면서 실험 운영자의 지시에 따라 수동으로 조절할 수 있기 때문에 본 연구의 실험 결과에 미치는 악영향은 없었다. 렌즈가 교환 작업이 따로 필요 없이 저/고배율 확대 기능을 사용할 수 있도록 설계되었다. NTSC-USB 2.0 컨버터를 통

하여 30 frame per 1s로 실시간으로 컴퓨터에 이미지를 나타낼 수 있다.

본 실험의 측정 부위인 혀바닥을 측정할 경우에는 Fig. 2와 같이 렌즈가 달린 몸체만 스탠드와 분리하여 실험 참가자 본인이 자신의 혀바닥 표면을 왼쪽부터 오른쪽으로 이동해 가면서 측정을 하면 된다. 이때 위생 및 감염 문제와 렌즈 표면에 침과 같은 이물질과 접촉되는 것을 예방하기 위하여 렌즈와 혀바닥 표면의 접촉 부분을 투명 랩으로 감싸서 실험을 진행하였다.

2.2 EfficientNet 모델

일반적으로 ConvNet (합성곱 신경망)의 정확도를 높일 때 잘 짜여진 모델 자체를 찾는 방법도 있겠지만, 기존 모델을 바탕으로 복잡도 (Complexity)를 높이는 방법도 많이 사용한다. Fig. 3은 이미 존재하는 모델의 사이즈를 키워주는 여러 방법들을 보여주고 있다. 대표적으로 필터의 개수, 즉 채널의 개수를 늘리는 width scaling과 layer의 개수를 늘리는 depth scaling과 input image의 해상도를 높이는 resolution scaling이 자주 사용된다. ResNet이 depth scaling을 통해 모델의 사이즈를 조절하는 대표적인 모델이며 (Zagoruyko et al, 2016, Howard et al, 2017, He et al, 2018), MobileNet, ShuffleNet 등이 width scaling을 통해 모델의 사이즈를 조절하는 대표적인 모델로 알려져 있다 (Lu et al, 2018, Sharir et al, 2018, Tan et al, 2019). 하지만 기존 방식들에서는 위 세 가

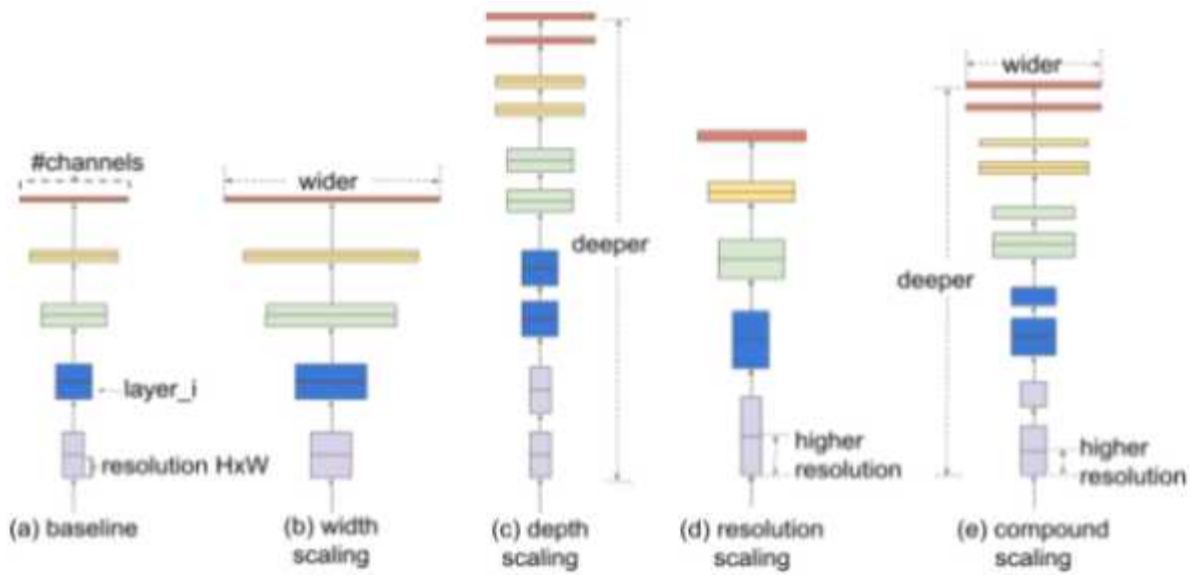


Figure 3. Model scaling. (a) is a baseline network example; (b)~(d) are conventional scaling that only increases one dimension of network width, depth, or resolution. (e) is the compound scaling method that uniformly scales all three dimension with a fixed ratio (Tan et al, 2019).

지 scaling을 동시에 고려하는 경우가 거의 없다. 또한 세 가지 scaling 기법 중에 어떤 기법을 사용할지에 대한 가이드라인이 존재하지 않아서 시행착오가 필요하다는 어려움이 존재한다 (Krizhevsky et al, 2012, Szegedy et al, 2015, He et al, 2016, Hu et al, 2018, Huang et al, 2018, Kornblith et al, 2019).

이에 반해 네트워크 모델을 고정하고 depth (d), width (w), resolution (r) 세 가지를 동시에 조절할 수 있는 방법에 대하여 살펴보자 (Tan et al, 2019). 우선, 고정 모델을 좋은 모델로 선정하는 것이 중요하다. 아무리 scaling factor를 조절하더라도 초기 모델 자체의 성능이 낮으면 임계 성능도 낮기 때문이다. 그래서 MnasNet와 거의 동일한 search space 조건에서 AutoML을 통해 모델을 탐색하였고 이 과정을 통하여 찾은 모델 EfficientNet-B0를 사용한다.

다음으로, 이 모델을 기점으로 세 가지 scaling factor를 동시에 조절하는 compound scaling은 아래와 같이 구현할 수 있다.

$$\begin{aligned}
 \text{depth} : d &= \alpha^\Phi & (1) \\
 \text{width} : w &= \beta^\Phi \\
 \text{resolution} : r &= \gamma^\Phi \\
 \text{s.t. } \alpha \cdot \beta^2 \cdot \gamma^2 &\approx 2 \\
 \alpha \geq 1, \beta \geq 1, \gamma &\geq 1
 \end{aligned}$$

우선 수식 (1)에서와 같이 depth, width, resolution은 각각 α, β, γ 로 나타내며, 각각의 비율은 $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$ 라는 조건을 만족시켜야 한다. 이때 width와 resolution에 제곱이 들어간 이유는 depth는 2배 키워주면 FLOPS도 비례해서 2배 증가하지만, width와 resolution은 가로와 세로가 각각 곱해지기 때문에 제곱 배 증가하기 때문에 제곱을 곱해서 계산을 한다.

그 후 전체 모델의 사이즈는 α, β, γ 에 똑같은 Φ 만큼 제곱하여 조절을 하면 된다. EfficientNet의 α, β, γ 값을 간단히 grid search를 통해 구하는 방식을 채택하고 있으며 처음 단계에서는 Φ 를 1로 고정한 뒤 사용한 데이터 셋에서 좋은 성능을 나타내는 α, β, γ 값을 찾으면 된다.

본 논문에서 $\alpha = 1.2, \beta = 1.1, \gamma = 1.15$ 를 사용하였고 세 개의 scaling factor는 고정한 후 Φ 를 증가시켜가면서 모델의 사이즈를 키워다.




Figure 4. An example of dataset used for this study.

2.3 데이터 셋 구축

본 논문의 실험 방안은 저자의 검색한 결과에 따르면 아직까지 국내외에서 수행된 적이 없다. 따라서 공개된 사용가능한 데이터 셋이 없기 때문에 직접 측정을 통하여 이미지 데이터를 수집하여 딥러닝 모델에 훈련 가능한 데이터 셋을 구축하여야만 한다. 이에 우선 실험 참가자인 20대 중후반의 건강한 남성 중 흡연자 10명과 비흡연자 10명을 대상으로 각각 측정하여 이미지를 수집한 뒤, 부족한 데이터를 Keras의 Image Data Generator 함수를 사용하여 이미지 데이터를 증식시켜서 총 1,000장으로 그 중 80%를 훈련과 검증에 사용하였고, 나머지 20%를 test에 사용하였다.

본 실험은 Helsinki 선언 기반 의료 연구윤리를 준수하여 실험을 시작하기 전에 충분히 실험 참가자에게 실험 방법에 대하여 설명 및 수집된 개인 정보 데이터의 활용 방안에 대하여 설명을 한 뒤, 동의를 얻은 실험 참가자에 한해서만 본 실험에 참가하도록 하였다.

3. 실험 결과

3.1 수집된 데이터 셋

Fig. 4는 실험 참가자를 통하여 구축된 데이터 셋의 일부를 보여주고 있다. 본 실험에서 측정 장비로 사용한 마이크로스코프 측정 이미지를 보면 피부표면 색깔과 모세혈관의 분포 및 개

EfficientNetB0	<pre>In [4]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 9s 2s/step Out[4]: [0.609375]</pre>
EfficientNetB1	<pre>In [8]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 18s 4s/step Out[8]: [0.71875]</pre>
EfficientNetB2	<pre>In [12]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 15s 4s/step Out[12]: [0.53125]</pre>
EfficientNetB3	<pre>In [16]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 24s 6s/step Out[16]: [0.4375]</pre>

(a) Results of training from EfficientNet-B0 to EfficientNet-B3.

(200,200), 20, 0.2	<pre>In [8]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 18s 4s/step Out[8]: [0.71875]</pre>
(300,300), 20, 0.2	<pre>In [20]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 36s 9s/step Out[20]: [0.734375]</pre>
(250,250), 20, 0.4	<pre>In [24]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 4/4 [-----] - 37s 9s/step Out[24]: [0.578125]</pre>
(250,250), 12, 0	<pre>In [28]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 6/6 [-----] - 38s 6s/step Out[28]: [0.546875]</pre>
(300,300), 25, 0	<pre>In [32]: eval = model.evaluate_generator(test_generator, workers = 4, verbose=1) eval 3/3 [-----] - 66s 22s/step Out[32]: [0.796875]</pre>

(b) Results of EfficientNet-B1 to tune with target size, batch size, Dropout.

Figure 5. Results of performance from EfficientNet-B0 to EfficientNet-B3 and the regulated EfficientNet-B1 through target size, batch size, and dropout.

수 등을 쉽게 파악할 수 있는 것을 알 수 있다.

혓바닥 표면의 이미지 데이터 (410배 확대 이미지 데이터)가 흡연자 160장, 비흡연자 160장으로 총 320장이 수집되었다. Keras의 내장 함수인 ImageGenerator를 사용하여 이미지 데이터를 각각 1,000장까지 증가시켜서 학습과 예측에 사용하였다. 본 데이터 셋은 사람의 눈으로 어느 정도 가능한 것도 있고 도저히 육안으로 불가능한 이미지 데이터도 혼재하고 있다.

3.2 EfficientNet 학습 성능

EfficientNet 모델은 모델의 크기에 따라 EfficientNet-B0부터 EfficientNet-B7 까지로 구성되어 있다. 수집한 이미지 데이터를 학습시키기 위해 가장 적합한 모델을 찾기 위해 같은 조건에

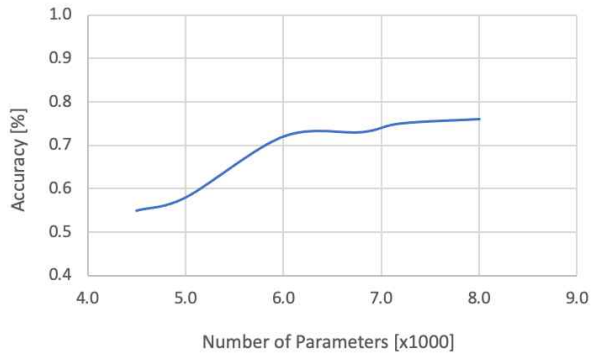


Figure 6. Relationship between the number of parameters and the accuracy to decide the hyperparameter for good tuning.

서 각 모델을 학습시킨 후 성능을 비교해 보았다. 학습에 사용한 이미지 데이터는 Fig. 4에서 보여준 흡연자와 비흡연자의 혀바닥 표면을 측정된 데이터 셋을 (훈련, 검증, 예측 = 60, 20, 20)으로 나누어서 학습을 시켰다.

Fig. 5는 EfficientNet으로 학습시킨 결과를 보여주고 있다. Fig. 5(a)에 target size = (200, 200), batch size = 20, dropout = 0.2의 동일한 조건을 설정하여 학습시켰다. EfficientNet-B0보다 EfficientNet-B1을 사용하였을 때 정확도가 0.61에서 0.72로 증가하는 것을 확인할 수 있었다. 하지만 EfficientNet-B2를 사용하였을 경우 정확도가 0.53으로 하락하였고, EfficientNet-B3을 사용하였을 경우 정확도가 0.44로 하락하는 것을 확인할 수 있었다.

수식 (1)을 통하여 알 수 있듯이 모델이 달라짐에 따라서 학습 파라미터의 개수도 증가하는 것을 알 수 있는데, EfficientNet-B1의 경우 이외에는 증가된 파라미터가 오히려 과학습 (overfitting)으로 인하여 정확도의 증가보다는 하락을 시키는 요인이 작용한 것으로 이해할 수 있다. 즉, 학습 데이터의 양보다 모델의 크기가 너무 커서 모델이 학습 데이터에 과적합되는 것으로 생각할 수 있다. 따라서, 현재 구축된 데이터 셋을 사용하여 혀바닥 표면의 이미지 데이터를 학습시키기에는 EfficientNet-B1이 가장 성능이 뛰어난 것을 확인할 수 있었다.

```
In [5]: print('EfficientNetB1: '+str(evaluate1[1]))
        print('VGG16: '+str(evaluate2[1]))
        print('ResNet50: '+str(evaluate3[1]))
        print('DenseNet121: '+str(evaluate4[1]))

EfficientNetB1: 0.796875
VGG16: 0.5
ResNet50: 0.5
DenseNet121: 0.578125
```

Figure 7. Results of comparison with VGG16, ResNet50, DenseNet121, and EfficientNet-B1.

Fig. 5(b)는 선정한 EfficientNet-B1에 target size, batch size, dropout을 조절하여 가장 높은 정확도를 가진 조건을 구해 보았다. target size와 batch size를 크게 하면 모델의 정확도가 상승하게 되고 dropout을 크게 하면 모델의 정확도가 떨어지는 경향을 확인할 수 있었다. 따라서 target size와 batch size를 키우고 dropout을 줄이는 방향으로 학습을 진행하였다. target size = (300, 300)이고 batch size = 25, dropout = 0인 모델로 학습시켰을 경우 정확도가 0.8로 가장 높은 것을 확인할 수 있었다.

Fig. 6은 학습 파라미터의 수와 정확도의 관계를 나타내고 있는 결과로 Fig. 5(b)의 결과를 정리하여 나타낸 것이다. 하이퍼파라미터의 세팅에 따라서 학습 파라미터의 수가 달라지기 때문에 높은 정확도를 얻기 위하여 하이퍼파라미터 조절이 중요하다는 것을 알 수 있다.

3.3 다른 딥러닝 모델과 성능 비교

본 연구에서 사용한 EfficientNet-B1과 다른 딥러닝 모델의 성능과 비교하여 보았다. Fig. 7에 다른 모델과 비교한 결과를 보여주고 있다. 다른 모델에서는 VGG-16, ResNet-50, DenseNet-121을 사용하여 실험 참가자를 통하여 구축한 데이터 셋으로 학습시켜 보았다.

depth scaling 혹은 width scaling만 증가시켜 학습시키는 모델과 비교하여, 세 가지 scaling factor (depth scaling, width scaling, resolution scaling)를 동시에 고려하는 compound scaling 기법을 적용하여 학습 파라미터를 증가시키는




Figure 8. Results of tongue buds between smokers and non-smokers.

EfficientNet의 좋은 성능을 확인할 수 있다.

4. 고찰

대부분의 맛을 구분하기 위해서 뇌는 냄새 및 맛 양쪽 모두에 대한 정보가 필요하다. 이러한 감각들은 코와 입을 통해서 뇌로 소통된다. 뇌의 여러 부분들이 정보를 통합하고 사람들이 맛을 인식하고 인정할 수 있도록 돕는 것이다. 그 중 혀 표면의 대부분을 덮고 있는 수천 개의 아주 작은 미뢰에 대하여 살펴본 후, 흡연이 미뢰에 미치는 영향과 관련하여 본 연구에서 제안한 방법의 유용성에 대하여서도 고찰해 보도록 하겠다.

미뢰는 섬모가 있는 여러 유형의 미각 수용체들을 포함하고 있다. 각각의 유형은 달고, 짜고, 시고, 고소한 맛의 다섯 가지 기본 맛들 중 하나를 감지한다 (Kale et al, 2019). 이러한 맛들은 혀 전체에서 감지될 수 있으나, 특정한 부분들은 각각의 맛에 대해 좀 더 민감하다. 단맛은 혀 끝에서 더 쉽게 식별되는 반면에 짠맛은 혀의 앞쪽 양면에서 가장 잘 느껴진다. 신맛은 혀의 옆쪽을 따라 가장 잘 인지되고 쓴 감각은 혀 뒤쪽의 1/3 지점에서 쉽게 감지된다.

입안에 놓은 음식은 섬모를 자극하여 맛의 뇌 신경 (얼굴 및 설인두 신경)과 연결되어 있는 주변 신경 섬유들의 신경 충격을 촉발한다. 충격은 이들 뇌신경들을 따라 뇌로 이동하고 뇌는 다양한 유형의 맛 수용체로부터 충격들의 조합을 뚜렷한 맛으로서 이해하게 된다. 음식의 냄새,

맛, 식감 및 온도에 대한 감각 정보는 뇌에 의해 처리되어 음식이 입에 들어와서 씹었을 때 뚜렷한 맛을 생산할 수 있도록 한다.

최근 흡연이 미각 기능을 둔화시킨다는 연구 결과가 발표되었다. Pavlidis Pavlos 박사팀은 흡연자 28명과 비흡연자 34명을 대상으로 미각의 민감성을 측정하는 실험을 한 결과 흡연자가 비흡연자보다 미각의 민감성이 크게 떨어진다는 결과를 얻어서 흡연이 미각 세포인 미뢰의 수를 감소시키고 민감성을 저하시킨다는 사실을 밝혀내었다 (Pavlos et al 2009). 실험은 혀에 전류를 통하게 하는 방법으로 실시되는데 혀에 전류가 가해지면 특이한 금속 맛이 나는데 이런 맛을 느끼는데 전류가 얼마나 필요한지를 측정하면 미각의 민감성을 측정할 수 있게 되는 것이다 (Tomassini et al, 2007).

본 연구에서 제안한 방법은 이미지 데이터를 통한 흡연자와 비흡연자의 차이를 검출하는 방법으로 Fig. 8에 흡연자와 비흡연자의 미뢰 상태의 비교 예시를 통하여서도 알 수 있지만, 미뢰의 크기 및 모세혈관의 분포 상태에 차이가 있는 것을 알 수 있다. 흡연자의 경우, 미뢰의 크기가 대부분 작아져서 비정상 상태에 있고 정상 상태에 있는 미뢰라도 모세혈관의 혈관이 두꺼워지면서 비대해져 있는 것을 알 수 있는데 이는 모세혈관이 소멸되는 과정 중에 나타나는 현상이다. 반면, 비흡연자의 경우, 미뢰의 크기가 대부분 정상 상태에 있고 모세혈관도 균일하게 분포되어 있는 상태인 것을 확인할 수 있다.

따라서 본 연구에서 제안하는 방법이 전류의 자극을 통하여 민감도를 측정하는 방법보다 이미지 데이터이기 때문에 직관적으로 알기 쉽다는 장점이 있다. 본 연구의 동기인 흡연자에게 흡연이 신체에 미치는 악영향이 본인 자신의 문제라는 인식을 높여 금연에 대한 의지를 강화하기 위해서 이미지 처리에 관한 전문 지식이 없더라도 측정된 이미지 데이터만으로 그 자리에서 바로 직관적으로 알 수 있다는 점에서 더 효과적이지 않을까 생각된다.

5. 결 론

본 논문에서는 흡연자와 비흡연자의 혀바닥 표면에 분포하고 있는 미뢰를 마이크로스코프를 사용하여 410배 확대된 이미지로 데이터 셋을 구축하여 딥러닝 모델로 학습 후, 흡연자의 혀바닥 표면에 이상징후 여부를 검출할 수 있다는 것을 알았다. 수집할 수 있는 데이터가 한정적 일 경우, 딥러닝 모델을 스케일링하는 방법 (width scaling, depth scaling, resolution scaling) 중 한 가지 방법만 사용하는 VGG-16, ResNet-50, DenseNet-121과 비교하여 세 가지 방법을 동시에 모두 적용할 수 있는 EfficientNet의 성능의 우수성을 확인할 수 있었다.

감사의 글

본 연구는 전남대학교 국립대학교 육성사업비 교내 신진 학술연구비 (과제번호: 2020-2020)와 한국산업기술평가관리원 연구비 (과제번호: 2020-3414)의 지원에 의하여 진행되었다. 또한 전남대학교 4단계 BK21사업 인공지능 융합 인재 양성 사업단의 지속적인 관심과 지원에 깊은 감사를 표현한다.

References

Ayanian, JZ. (1999). Perceived risks of heart disease and cancer among cigarette smokers, *JAMA*, 281(11), (pp. 1019-1-21).

Carosella, AM, Ossip-Klein, DJ, Watt, CA, and Podgorski, C. (2002). Smoking history, knowledge, and attitudes among older residents of a long-term care facility, *Nicotine & Tobacco Research*, 4, (pp. 161-169).

Chen, WW, and Lindsey, R. (2001). Evaluation of a tobacco prevention program on

knowledge, attitudes, intention and behavior of tobacco use among fourth grade students - a preliminary study, *J Drug Educ*, 31(4), (pp. 399-410).

Frank, E, Denniston, M, and Pederson, L. (2002). Declines in smokers' understanding of tobacco's hazards between 1986 and 1998: a report from north Georgia, *South Med J*, 95(7), (pp. 675-680).

Geckova, A, Van Dijk, JP, van Ittersum-Gritter, T, and Groothoff, JW. (2002). Determinants of adolescents' smoking behaviour: A literature review, *Cent Eur J publ Health*, 10(3), (pp. 79-87).

Hakeem, R, Thomas, J, and Badruddin, SH. (2001). Urbanisation and health related knowledge and attitudes of South Asian children, *J Pak Med Assoc*, 51(12), (pp. 437-443).

He, K, Zhang, X, Ren, S, and Sun, J. (2016). Deep residual learning for image recognition, *CVPR*, (pp. 770-778).

He, Y, Lin, J, Liu, Z, Wang, H, Li, LJ, and Han, S. (2018). Amc: Automl for model compression and acceleration on mobile devices, *ECCV*.

Howard, AG, Zhu, M, Chen, B, Kalenichenko, D, Wang, W, Weyand, T, Andreetto, M, and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications, *arXiv preprint arXiv: 1704.04861*.

Hu, J, Shen, L, and Sun, G. (2018). Squeeze-and-excitation networks, *CVPR*.

Huang, Y, Cheng, Y, Chen, D, Lee, H, Ngiam, J, Le, QV, and Chen, Z. (2018). Gpipe: Efficient training of giant neural networks using pipeline parallelism, *arXiv preprint arXiv: 1808.07233*.

Jeong, YS, Lee, HR, Baek, JH, Kim, KH, Chung YS, and Lee, CW. (2020). Deep Learning-based Rice Seed Segmentation for

- Phynotyping, *Journal of the Korea Industrial Information Systems Research*, 25(5), (pp. 23-29).
- Kale, YS, Vibhute, N, Belgaumi, U, Kadashetti, V, Bommanavar, S, and Kamate, W. (2019). Effect of using tobacco on taste perception, *J Family Med Prim Care*, 8(8), (pp. 2699-2702).
- Kim, SW, Cha, KA, and Park, SH. (2020). Lip-reading System based on Bayesian Classifier, *Journal of the Korea Industrial Information Systems Research*, 25(4), (pp. 9-16).
- Kim, DH, Hwang, BW, Lee, SW, and Kwak, SY. (2020). 3D Human Shape Deformation using Deep Learning, *Journal of the Korea Industrial Information Systems Research*, 25(2), (pp. 19-27).
- Kornblith, S, Shlens, J, and Le, QV. (2019). Do better imagenet models transfer better?, *CVPR*.
- Krizhevsky, A, Sutskever, I, and Hinton, GE. (2012). Imagenet classification with deep convolutional neural networks, *NIPS*, (pp. 1097-1105).
- Lu, Z, Pu, H, Wang, F, Hu, Z, and Wang, L. (2018). The expressive power of neural networks: A view from the width, *NeurIPS*.
- Pavlos, P, Vasilios, N, Antonia, A, Dimitrios, K, Georgios, K, and Georgios, A. (2009). Evaluation of young smokers and non-smokers with Electrogustometry and Contact Endoscopy, *BMC Ear Nose Throat Disord*, 9(9), doi: 10.1186/1472-6815-9-9.
- Sargent, JD, Beach, ML, Dalton, MA, Mott, LA, and Tickle, JJ, (2001). Ahrens, MB, Heatherton, TF. Effect of seeing tobacco use in films on trying smoking among adolescents: cross sectional study, *BMJ*, 323(7326), (1394-1397).
- Sharir, O, and Shashua, A. (2018). On the expressive power of overlapping architectures of deep learning, *ICLR*.
- Suga, S, Otomo, A, Jeong, H, and Ohno, Y. (2019). Image Similarity Check of Nailfold Capillary by Template Matching, *IEEE 8th Global Conference on Consumer Electronics (GCCE)*, Osaka, Japan.
- Szegedy, C, Liu, W, Jia, Y, Sermanet, P, Reed, S, Anguelov, D, Erhan, D, Vanhoucke, V, and Rabinovich, A. (2015). Going deeper with convolutions, *CVPR*, (pp. 1-9).
- Tan, M, and V. Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, *Proceedings of the 36th International Conference on Machine Learning (ICML)*, Long Beach, California, PMLR 97.
- Tomassini, S, Cuoghi, V, Catalani, E, Casini, G, and Bigiani, A. (2007). Long-term effects of nicotine on rat fungiform taste buds, *Neuroscience*, 147(3), (pp. 803-810).
- Torabi, MR, Yang, J, and Li, J. (2002). Comparison of tobacco use knowledge, attitude and practice among college students in China and the United states, *Health promot int*, 17(3), (pp. 247-254).
- World Health Organization (WHO). (1983). Guidelines for the conduct of tobacco-smoking surveys among health professionals, *Report of a WHO meeting held in Winnipeg, Canada*.
- Woo, E. (2003). Study on the Knowledge Level of Smoking and Smoking Behavior, Master Thesis, *The Graduate School of Yonsei Univeristy*, Seoul, Korea.
- Zagoruyko, S, and Komodakis, N. (2016). Wide residual networks, *BMVC*.



정 희 용 (Hieyong Jeong)

- 정회원
- 부경대학교 제어계측공학과 학사
- Hiroshima University 로봇공학과 석사
- Osaka University 기계공학과 박사
- 삼성중공업 산업기술연구소 책임연구원
- Osaka University 의학대학원 교수
- (현재) 전남대학교 AI융합대학 인공지능융합학과 교수
- 관심분야: 헬스케어, 지능로봇, 생체신호, 인간-로봇 상호작용, 컴퓨터비전



고 정 원 (Jeongwon Go)

- 전남대학교 AI융합대학 IoT인공지능융합전공 학사
- (현재) ROTC 장교 군복무 중
- 관심분야: 이미지처리, 기계학습, 딥러닝



신 춘 성 (Choonsung Shin)

- 숭실대학교 컴퓨터학부 학사
- 광주과학기술원 정보통신공학과 석사
- 광주과학기술원 정보통신공학과 박사
- 카네기멜론대학(CMU) HCI연구소 박사후연구원
- 전자부품연구원 VR/AR연구센터 책임연구원
- 문화체육관광부 문화기술PD
- (현재) 전남대학교 문화전문대학원 미디어예술공학전공 교수
- 관심분야: 디지털 문화콘텐츠, 문화기술, 인간-컴퓨터 상호작용