

## 심층 학습을 활용한 가상 치아 이미지 생성 연구 – 학습 횟수를 중심으로

배은정, 정준호\*, 손윤식\*\*, 임중연

동국대학교 기계로봇에너지공학과, 공주대학교 컴퓨터공학과\*, 동국대학교 컴퓨터공학과\*\*

### A Study on Virtual Tooth Image Generation Using Deep Learning – Based on the number of learning

EunJeong Bae, Junho Jeong\*, Yunsik Son\*\*, JoonYeon Lim

Dept. of Mechanical Robotics and Energy Engineering, Dongguk University

Dept. of Computer Science & Engineering, Kongju University\*

Dept. of Computer Science & Engineering, Dongguk University\*\*

#### [Abstract]

**Purpose:** Among the virtual teeth generated by Deep Convolutional Generative Adversarial Networks (DCGAN), the optimal data was analyzed for the number of learning.

**Methods:** We extracted 50 mandibular first molar occlusal surfaces and trained 4,000 epoch with DCGAN. The learning screen was saved every 50 times and evaluated on a Likert 5-point scale according to five classification criteria. Results were analyzed by one-way ANOVA and tukey HSD post hoc analysis ( $\alpha = 0.05$ ).

**Results:** It was the highest with  $83.90 \pm 6.32$  in the number of group3 (2,050-3,000) learning and statistically significant in the group1 (50-1,000) and the group2 (1,050-2,000).

**Conclusion:** Since there is a difference in the optimal virtual tooth generation according to the number of learning, it is necessary to analyze the learning frequency section in various ways.

◉ **Key words:** Deep Convolutional Generative Adversarial Networks, Deep learning, Lower first molar, Number of learning, Virtual tooth

\* This research was supported by the Basic Science Research Program through the National Research Foundation (NRF) of Korea, funded by the Ministry of Education (Grant No. 2017R1D1A1B03035688)

\*\* This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2018R1A5A7023490)

Corresponding author	Name	임 중 연	Tel.	02-2260-3316	E-mail	bej1119@naver.com	
	Address	서울시 중구 필동로 1길 30 원흥관 E322호					
Received	2019. 11. 25		Revised	2020. 2. 28		Accepted	2020. 3. 3

## I. 서론

4차 산업혁명 시대로 접어들면서 가상현실, 3D 프린팅, 로봇 그리고 인공지능 등의 광범위한 분야에 진보된 기술과 다양한 산업이 어우러지면서 새로운 패러다임의 융·복합 기술이 소개되고 있다(Lim et al, 2017) 그리고 이러한 4차 산업혁명이 만드는 미래 사회는 컴퓨터와 스마트기체들을 중심으로 데이터 기반의 스스로 학습 능력을 가지는 인공지능이 확산 될 것이라고 전망하고 있다(Yang et al, 2019). 특히 인공지능 분석 기술 중 하나인 딥러닝(deep learning) 분석은 깊은 신경망(deep neural network) 모델을 활용해 영상의 객체를 분류하면서 기존의 기계학습 모델들의 성능을 넘어서는 결과를 보이기 시작했다(Park, 2018; Kim et al, 2019). 나아가 진단·검사 뿐만 아니라 치료처치 및 사후 관리계획까지 인공지능을 활용하면서 단순히 인간의 활동을 보조하는 수준을 넘어 복잡하고 다양한 의료분야에 도움 줄 것으로 기대하고 있다(Hosny et al, 2018).

의료 영상 정보를 활용하기 위해서는 무엇보다 무수히 많은 데이터가 축적되어 있어야 한다(Lee, 2011). 의료 분야 데이터의 활용가치는 매우 긍정적으로 평가되고 있으며, 이를 활용하고자 보건의료 빅데이터의 정책 현황과 과제(Kang, 2016) 및 의료 분야 데이터 활용을 위한 개인정보 비식별화 규정 현황과 과제(Jung, 2015) 등이 보건복지포럼에서 발표되기도 했다.

빅데이터(big data)란 기존 데이터베이스의 저장·관리·분석 능력을 초과하는 다양한 형식을 가진 대량의 데이터를 의미한다. 빅데이터를 보건의료에 활용하면서 의료비 절감, 의료 서비스의 질 향상 등 국가 경쟁력을 향상시키고자 다양한 연구들이 시도되고 있다(Alyass et al, 2015). 그러나 정보오류에 대한 책임과 진단 및 치료 과실에 대한 책임 그리고 개인의 의료정보를 수집하여 사용한다는 점에서 법적 문제가 제기되고 있으며, 이에 대한 분석과 대응이 뒷받침 되어야 한다(Verghese et al, 2018).

치과분야에서도 인공지능을 적절히 활용한다면, 치아의 분류 및 분석이 가능하고 환자들에게 적절한 치

료 안내를 서비스 할 수 있다. 이를 위해 충분히 데이터를 수집해야 하지만 앞에 언급된 문제로 인해 수집되는 양이 매우 적으며, 수집하는데 있어 어려움이 존재한다. 이를 극복하고자 실제 치아 이미지로부터 딥러닝 모델인 Deep Convolutional Generative Adversarial Networks (DCGAN)을 이용해 학습을 시키고, 주어진 조건을 만족하는 가상의 치아 이미지를 분류하는 연구를 제안하고자 하였다.

DCGAN은 실제 이미지의 특징을 바탕으로 유사한 가짜 이미지를 생성하고 이를 평가하는 과정을 반복하여 실제와 매우 유사한 대체재를 생성하는 독립적 학습법이다(Gao et al, 2018). DCGAN을 통해 실제 치아에 대해 학습시키고 이와 유사한 가상 치아를 생성하여 딥러닝을 위한 영상 데이터를 확보하는 것은 매우 중요한 연구이다(Park & Cho, 2019). 이때 생성된 가상의 치아는 대체재이지만 반드시 실제 치아의 특성을 가지고 있어야 한다. 그러나 분석 횟수나 방법 등에 따라서 결과의 질에 차이가 있을 수 있기 때문에 최적화된 학습에 대한 연구가 필요하다. 본 연구에서는 DCGAN을 통해 생성된 가상 치아들 중 최적의 데이터가 가장 많은 학습 횟수 구간을 분석하여 의료 빅데이터를 위한 기초연구 자료로 활용하고자 한다.

## II. 연구 방법

### 1. 실험방법

치과용 스캐너(3shape E1, Copenhagen, Denmark)로 스캔 된 치아 중에서 분석을 위해 하악 좌측 제1대구치 교합면을 jpg 파일 형식으로 추출하였다. 총 50개의 교합면 이미지를 DCGAN 분석에 사용하였다(Fig. 1).

전체 학습 epoch는 4,000번으로 실행했는데, 각각의 학습마다 생성기(generator)가 이미지를 생성하고 식별기(discriminator)가 생성된 이미지를 판별하는 횟수인 배치 사이즈를 다양하게 바꿔보며 모델을 학습하였다. 학습을 진행한 컴퓨터의 GPU RAM 크기가 16GB인 점을 고려해 최종 배치 사이즈는 25개로 설정했다. 실

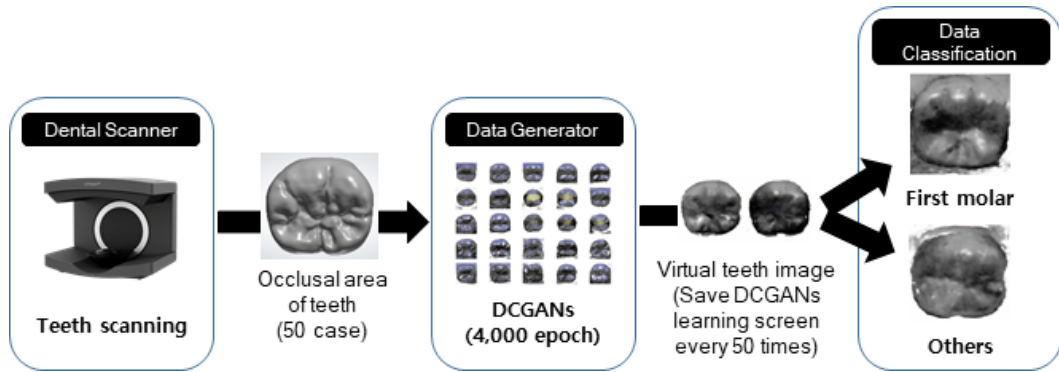


Figure 1. Schematic diagram of tooth image generation and learning model process

험을 위한 컴퓨터의 사용은 다음과 같다. CPU는 Intel I7-9700K를 사용하였고, 그래픽카드는 RTX2080을 사용하였다.

실제 치아 특징과 유사한 가상 치아 데이터가 가장 많은 학습 횟수 구간을 파악하기 위해 50번 단위마다 학습 화면을 저장하였고, 화면 당 25개의 가상 치아가 생성되었다. 생성된 가상 치아가 실제 치아와 어느 정도의 유사성을 가지는지 평가하기 위해 치아형태학(손향옥, 지성출판사)을 참고하여 table 1과 같은 분류 기준을 세웠다.

## 2. 분석방법

분류 기준에 따라 다섯 가지 항목이 모두 일치하는 경우는 5점으로 하여 일치하는 정도를 리커트 5점 척도로 전문지식을 가진 1인의 전문가 1주 간격을 두고 3회에 걸쳐 평가하였다. 전문가는 다섯 가지 기준을 바탕으로 모든 데이터를 비교해가며 다섯 가지 기준 중 얼마나 일치하는지를 평가하였다. 측정자(전문가)의 신뢰도 평가를 위해 한 명의 측정자(전문가)가 3회 동일한 분

석을 반복하였으며, 급내상관분석을 통해 신뢰성 분석을 실시하였다. 측정자 내 신뢰도 분석은 급내상관계수 (Intraclass correlation coefficient, ICC)로 표시하고 0에서 1사이의 값 중 1에 가까울수록 일치도가 높은 것을 의미한다.

학습 횟수에 따른 차이를 확인하고자 1,000번 단위로 나누어 그룹간 평균을 비교하였다. 그룹은 50~1,000번(그룹1), 1,050~2,000번(그룹2), 2,050~3,000번(그룹3), 3,050~4,000번(그룹4)로 총 4개의 그룹이었으며, 그룹간의 차이를 보기위해 one-way ANOVA분석과 tukey HSD 사후분석을 실시하여 유의수준 0.05에서 검정하였다(IBM SPSS statistics 23).

## III. 결과

급내상관분석 결과는 모든 항목에서 0.9이상으로 나타나 매우 높은 일치도를 보였다(table 1). Table 1의 분류기준에 따라 리커트 5점 척도로 평가된 가상의 하악 좌측 제1대구치 기술통계 결과는 table 2와 같다. 50부

Table 1. Match classification standards of the virtual mandibular left first molars and inter-rater reliability analysis results (ICC)Item

Item	Standards	classification	ICC
Number of cusps	① Number of buccal cusps	3 ea	0.912
	② Number of lingual cusps	2 ea	0.956
Ratio of occlusal areas	③ Ratio of buccal to lingual occlusal areas with respect to the main groove	3:2	0.961
	④ Ratio of buccal cusps – mesiobuccal cusp(5) : distobuccal cusp(4) : distal cusp(2)	5:4:2	0.903
	⑤ Ratio of lingual cusps	4.5:4.5	0.948

※ ICC : Intraclass correlation coefficient for intra rater reliability

터 1,000번 학습된 그룹1에서 가상 치아들의 일치도 평균과 표준편차는 34.35±16.36점으로 그룹 중 가장 낮게 나타났다. 1,050~2,000번 학습한 그룹2는 52.90±9.93점, 3,050~4,000번 학습한 그룹4는 81.30±7.83점으로 두 번째로 높았으며, 2,050~3,000번 학습한 그룹3은 83.90±6.32점으로 네 그룹 중 가장 높은 것으로 나타났다. 그룹간 평균을 ANOVA 테스트한 결과 p-value는 0.001보다 작아 유의한 차이가 있는 것으로 나타나(table 3) tukey HSD 사후분석을 실시하였다. 사후분석 결과 그룹1은 그룹2, 그룹3, 그룹4에서 모두 유의한 차이가 있었다(p<0.001). 그룹2도 그룹3, 그룹4

에서 유의한 차이가 있었다(p<0.001). 그러나 그룹3과 그룹4에서는 유의한 차이가 나타나지 않았다(p=0.872)(Table 4). 그룹별로 특징을 확인할 수 있도록 무작위로 이미지를 추출하여 그림으로 나타내었다(Fig. 2).

#### IV. 고찰

의료용 인공지능을 활용한 연구로는 영상분석기술에서 활발하게 진행되고 있다(Choi, 2016). 현재는 엑스레이(x-ray)나 자기공명영상(MRI) 또는 컴퓨터 단층

Table 2. Descriptive statistical results of mandibular left first molar measured on a likert 5-point scale

Group	Mean	Standard deviation	Standard error	95% confidence interval		Minimum value	Maximum value
				Lower	Upper		
Group1	34.35	16.36	3.66	26.69	42.01	0.00	54.00
Group2	52.90	9.93	2.22	48.25	57.55	36.00	67.00
Group3	83.90	6.32	1.41	80.94	86.86	72.00	92.00
Group4	81.30	7.83	1.75	77.64	84.96	68.00	96.00
Total	63.11	23.27	2.60	57.93	68.29	0.00	96.00

※ Likert 5-point scale : 5 points; Match all segments, 0 points; Classifiers all mismatch

※ Group description (number of learning) : group1; 50-1,000 learning, group2; 1,050-2,000, group3; 2,050-3,000, group4; 3,050-4,000.

Table 3. ANOVA test results between groups according to the number of learning

	Sum of squares	Degrees of freedom	Mean square	F	p-value
Between group	33889.638	3	11296.546	96.657	0.000
With-in group	8882.350	76	116.873		
Total	42771.988	79			

Table 4. Tukey HSD multiple comparison results for mandibular left first molar classification

(I) Groups	(J) Groups	Mean difference (I-J)	Standard error	p-value	95% confidence interval	
					Lower	Upper
group1	group2	-18.55*	3.42	0.000	-27.53	-9.57
	group3	-49.55*	3.42	0.000	-58.53	-40.57
	group4	-46.95*	3.42	0.000	-55.93	-37.97
group2	group3	-31.00*	3.42	0.000	-39.98	-22.02
	group4	-28.40*	3.42	0.000	-37.38	-19.42
group3	group4	2.6	3.42	0.872	-6.38	11.58

\*. Mean difference is significant at 0.05 level

※ Group description (number of learning) : group1; 50-1,000 learning, group2; 1,050-2,000, group3; 2,050-3,000, group4; 3,050-4,000.

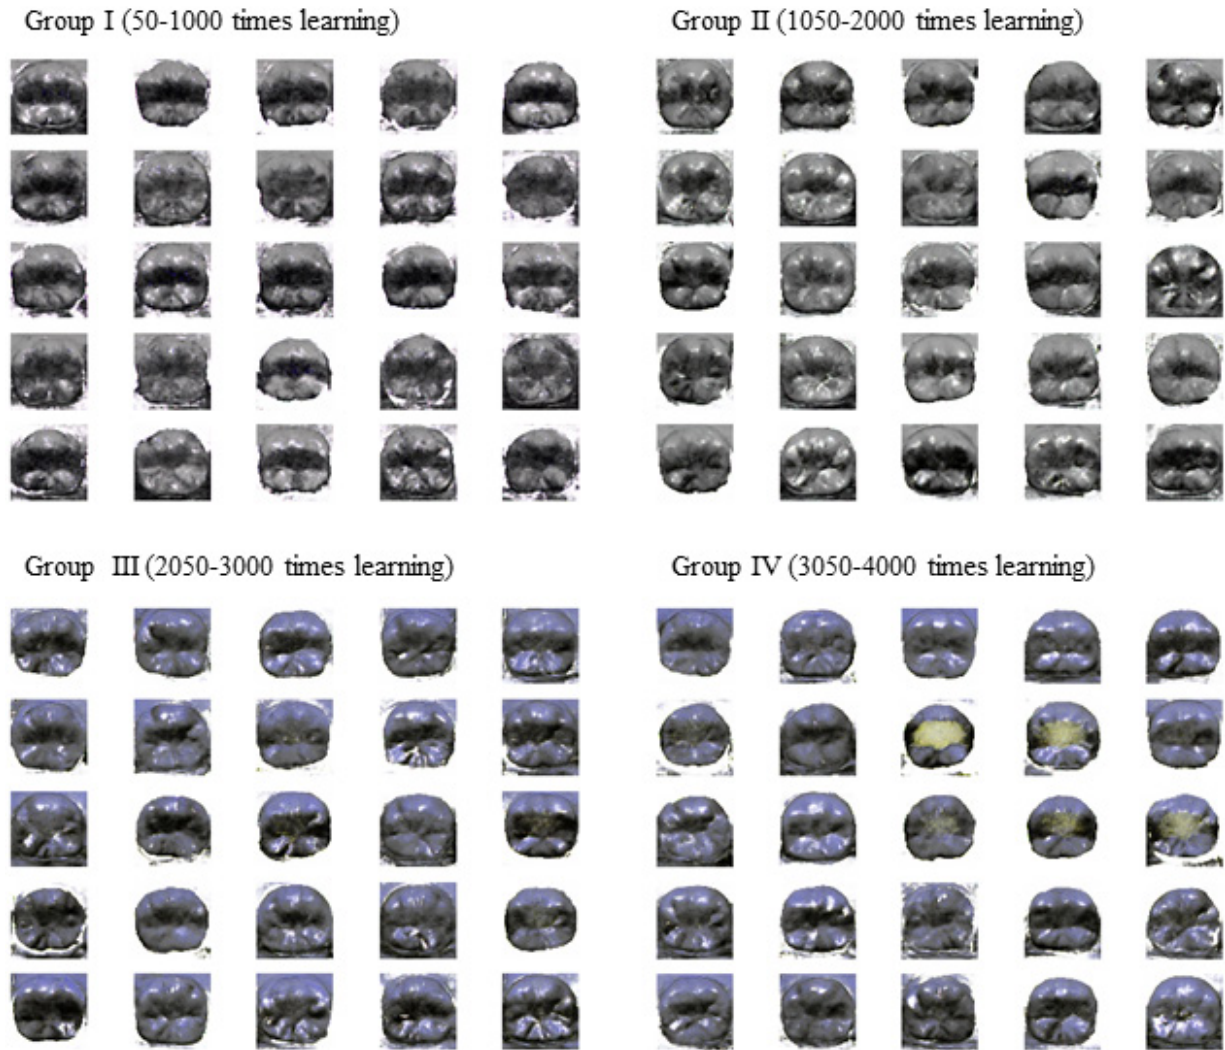


Figure 2. Random image by group

촬영(CT) 등의 의료영상자료를 분석해서 스스로 진단을 내리고 질환 여부를 판단하는 기술에 관심이 집중되어 있으나 최근 구강스캐너의 도입으로 치아 외형에 대한 인공지능과 딥러닝 연구도 점차 증가되고 있다(Kim, 2019, Moon et al, 2016).

실제 치아 이미지로부터 딥러닝 모델인 Deep Convolutional Generative Adversarial Networks (DCGAN)을 이용해 학습을 시키고, 주어진 조건을 만족하는 가상의 치아 이미지를 분류하는 딥러닝 모델을 제안하고자 본 연구에서는 DCGAN을 통해 생성된 가상 치아들 중 최적의 데이터가 가장 많은 학습 횟수 구간을 분석하였다.

본 연구에서는 실제 치아를 학습한 인공지능에서 만들

어낸 가상 치아가 실제 치아와 얼마나 유사한지 알아보 고자 하였으며, 그 중에서도 학습 횟수 구간에 따라 어떤 차이가 있는지 분석하였다. 리커트 5점 척도로 분석한 평균의 점수가 높을수록 일치하는 항목이 많다는 점에서 2,050~3,000번 학습한 그룹3의 학습 횟수에서 가상 치아의 유사도가 높은 것을 알 수 있었다. 그러나 학습 횟수가 많을수록 우수하다고 판단하기는 어렵다. 3,050~4,000번 학습한 그룹4에서는 평균이 81.30으로 그룹3(83.90)보다 낮은 것으로 나타났으나 통계적으로 유의한 차이는 없었기 때문이다. 즉, 2,050~3,000번의 학습 횟수가 가장 우수한 가상 치아들을 생성하였으나, 학습 횟수가 더 늘어났을 때의 결과도 추가적인 연구를 통해 확인해야 할 것이다.

Lee와 Lee(2018)의 연구에서도 학습 횟수가 증가하면서 오차율은 감소하는 경향을 나타냈으나 변곡 구간에 따라 오차율이 증가하기도 하였다면서 본 연구와 유사한 경향을 보였다. 본 연구에서도 학습 구간에 따라 최적의 결과를 보인 곳도 있으나 반드시 학습 횟수 증가에 비례하지는 않았다. Lee와 Lee(2018)는 학습 횟수에 따라 오차율이 달라질 수 있기 때문에 다양한 학습 횟수에서의 분석이 필요하다고 보고하였다.

Kim et al(2015)의 연구에서는 학습 반복 횟수 당 테스트 정확도 증가율이 달라지기는 하지만 학습 횟수가 많아진다고 해서 테스트 정확도에 큰 영향을 주지 않는다고 보고하였으며, 오히려 딥러닝 분석 시 메모리 사용량이 증가하기 때문에 효율이 감소될 수 있음을 언급하였다. Yun et al(2019)의 학습 데이터를 이용하여 객체 인식하는 연구에서는 2,000번과 4,000번 학습 횟수를 비교했는데 2,000번에서는 평균 손실 값이 최소로 나타났으나 4,000번 학습했을 경우 오히려 과적합(over fitting)된 결과를 보고하였다.

본 연구에서는 4,000번을 학습했는데 Jung et al(2018)의 연구에서는 3,000번의 학습 횟수로 연구하였고, Lee et al(2016)도 학습 횟수를 3,000번으로 설정하여 연구하였다. 적용하는 분야마다 차이는 있겠지만 딥러닝을 통한 분석 시 약 3,000번 정도의 학습을 하는 것을 알 수 있었다. 본 연구에서도 4,000번의 학습이 끝난 후 생성된 이미지들을 확인해보니 DCGAN의 향상된 성능 덕분에 2,000~3,000번 사이의 학습만으로도 충분히 좋은 이미지를 생성할 수 있었다.

본 연구에 사용된 데이터 셋은 총 50개로 Choi 등의 DCGAN 기반영상 패틴 제거 연구에서는 1100장의 영상을 사용하였고 Choi et al(2018), 약 2000장의 이미지를 학습데이터로 사용한 Jang 등(Jang et al, 2018)의 연구에 비해 많은 데이터는 아니지만 DCGAN 모델이 적은 양의 데이터만으로도 학습이 가능하다는 점에서 50개의 데이터로 연구를 수행하였다. Jung 등의 연구에서는 40장의 원본 데이터를 사용하여 추가적인 데이터를 생성하는 연구를 진행하면서 본 연구와 유사한 수준의 데이터를 사용하였다(Jung et al, 2019).

본 연구에서는 치아 영상을 jpg로 추출하였는데 이

는 다양한 파일 포맷 중 jpg가 대표적으로 많이 사용되는 포맷이기 때문이다. Yoon 등 (Yoon et al, 2019)과 Anderson 등 (Anderson et al, 2019)의 연구에서도 jpg 파일 형식으로 추출하여 DCGAN연구에 활용하였다.

본 연구에서는 객관적인 분류기준을 만들기 위해서 치아형태가 기록된 전문 서적을 참고하여 다섯 가지의 분류기준을 만들었다. 그리고 이 다섯 가지 분류기준에 일치하는 정도를 리커트 5점 척도로 평가하였다. 다섯 가지 기준으로만 평가했기 때문에 리커트 척도에서 5점으로 판정된 가상 치아들이 완벽하게 하악 좌측 제1대구치라고 보기에 한계가 있다. 비록 연구에 한계점은 있으나 실제 치아와 유사한 형상이라는 의미로 본 연구에서는 딥러닝을 통해 생성된 하악 제1대구치 대체제를 가상 치아라고 명명하였다.

신뢰도 분석을 위해 전문가 1인이 반복으로 측정하였는데 이러한 관찰자 내 신뢰도는 한명의 관찰자가 모든 측정 대상에 대하여 계속적으로 일관성 있게 측정하는지를 나타낸다. Kim 등의 연구에서도 2회의 관찰자내 신뢰도 평가를 통해 0.7 이상이면 관찰자내 신뢰도가 있거나 높다고 평가할 수 있다고 보고하였으며(Kim et al, 2013), Cho 등은 동일 검사자가 3주의 간격을 가지고 평가한 관찰자내 일치도를 사용하여 결과의 신뢰성을 판단하였다(Cho et al, 2009). 본 연구에서도 총 3회의 분석 결과 관찰자내 일치도가 모두 0.9점 이상으로 나왔으므로 결과의 신뢰도가 높다고 판단하였다.

## V. 결론

DCGAN을 통해 생성된 가상 치아들 중 최적의 데이터가 가장 많은 학습 횟수 구간을 분석하고자 50~1,000번 학습한 구간을 그룹1, 1,050~2,000번 학습한 구간을 그룹2, 2,050~3,000번 학습한 구간을 그룹3, 3,050~4,000번 학습한 구간을 그룹4로 구분하여 비교한 결과를 요약하면 다음과 같다.

1. 최적의 가상 치아 데이터가 가장 많은 분석 구간은 그룹3으로  $83.90 \pm 6.32$ 점이었고 가장 낮은 구간은

34.35±16.36점인 그룹1이었다.

2. 사후분석 결과 그룹1은 그룹2, 그룹3, 그룹4에서 모두 유의한 차이가 있었다(p<0.001). 그룹2도 그룹3, 그룹4에서 유의한 차이가 있었다(p<0.001). 그러나 그룹3과 그룹4에서는 유의한 차이가 나타나지 않았다(p=0.872).

3. 학습 횟수 증가와 최적의 가상 치아 생성은 비례하지는 않았다.

최적의 분석 횟수 구간은 그룹3(2,050~3,000) 이었으나, 그룹3보다 분석 횟수가 많은 그룹4가 81.30±7.83점으로 오히려 낮게 나타나면서 분석 횟수가 증가한다고 해서 최적의 가상치아 생성이 비례하지는 않았다. 그러나 학습 횟수에 따라 최적의 결과를 얻어내는 데 차이가 있는 것으로 나타나면서 학습 횟수 구간을 다양하게 나누어 분석할 필요가 있을 것으로 사료된다. 또한 학습 횟수별로 소요되는 시간에 차이가 있기 때문에 가장 최적의 데이터를 많이 확보하면서 효율적으로 분석이 가능한 구간을 파악한다면 가상 치아를 생성하는 딥러닝 알고리즘을 더욱 정밀하게 만들어 낼 수 있을 것이다.

## REFERENCES

- Alyass A, Turcotte M, Meyre D. From big data analysis to personalized medicine for all: challenges and opportunities. *BMC Med genomics*, 8(1), 33, 2015.
- Anderson N, Paavola M, Sognnes J. On the use of Denoising Autoencoders and Deep Convolutional Adversarial Networks for Automated Removal of Date Stamps (Master's thesis, University of Agder). 2019.
- Cho HJ, Chang CB, Jung JW, Seong SC, Kim TK. Prevalence of Radiographic Knee Osteoarthritis in Elderly Koreans. *Knee Surg Relat Res*, 21(4), 223-231, 2009.
- Choi EJ, Jo HY, Kim KS, Kim JT. The Study on Removing Image Pattern based on Deep Convolutional Generative Adversarial Network. *IEIE*, 456-458, 2018.
- Choi KT. Real-time Artificial Neural Network for High-dimensional Medical Image. *J. Korean Soc. Radiol*, 10(8), 637-643, 2016.
- Gao F, Yang Y, Wang J, Sun J, Yang E, Zhou H. A deep convolutional generative adversarial networks (DCGANs)-based semi-supervised method for object recognition in synthetic aperture radar (SAR) images. *Remote Sens*, 10(6), 846, 2018.
- Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJ. Artificial intelligence in radiology. *Nat Rev Cancer*, 18(8), 500-510, 2018.
- Jang YC, Anisetti M, Jeon G. A Study on demosaicking using DCGAN. In *Proceedings of the Korea Information Processing Society Conference, KIPS*, 792-794, 2018.
- Jung SH, Cho HS, Kim JY, Lee GH. Prediction of water level in a tidal river using a deep-learning based LSTM model. *J Korea Water Resour Assoc*, 51(12), 1207-1216, 2018.
- Jung WH, Jung DH, Kim YH, Kim CH, Lee HS, Yu HJ, Ryu JH, Oh HS. Deep Generative Models to Overcome an Insufficient Data Problem in Structural Health Diagnosis. *Trans Korean Soc Mech Eng A*, 43(3), 169-176, 2019.
- Jung YC. De-identification Policy of Personal Information and Tasks on Healthcare Big Data. *Health and welfare policy forum*, 227(0), 50-60, 2015.
- Kang HJ. National-Level Use of Health Care Big Data and Its Policy Implications. *Health and welfare policy forum*. 238(0), 55-71, 2016.

- Kim HY, Jung DC, Choi BW. Exploiting the Vulnerability of Deep Learning-Based Artificial Intelligence Models in Medical Imaging: Adversarial Attacks. *J Korean Soc Radiol*, 80(2), 259–273, 2019.
- Kim KS, Yun YH, Part JS, Kim NK, Kim KJ, Kim HT, Hong SU, Jang BH, Yoon HJ, Choi IH, Ko SG. Inter- and Intra-rater Reliability of Pattern Identification Using Nasal Endoscopy for Allergic Rhinitis. *J Korean Med Ophthalmol Otolaryngol Dermatol*, 26(2), 10–18, 2013.
- Kim SJ. Reliability evaluation of dental caries detection using deep learning. Master's Thesis Seoul National University Graduate School: Dentistry, Graduate School of Dentistry, 2019.
- Kim YG, Park HJ, Lee SG, Cha EY. Correlation Analysis and Optimization between Parameters using with Deep Learning. In *Proceedings of the Korea Information Processing Society Conference*, 22(2), 1285–1288, 2015.
- Lee MJ. Big Data and the Utilization of Public Data. *Internet and Information security*, 2(2), 47–64, 2011.
- Lee SH, Sim KS, Goo YH, Kim MS. Application Traffic Classification using TensorFlow Machine Learning Tool. *J Commun Netw - S Kor*, 224–225, 2016.
- Lee SJ, Lee HS. HA Basic Study on the Effect of Number of Hidden Layers on Performance of Estimation Model of Compressive Strength of Concrete Using Deep Learning Algorithms. *J Korea Inst Build Constr*, 18(1), 130–131, 2018.
- Lim JH, Ryu KH, Kim BC. An exploratory study on the direction of education and teacher competencies in the 4th industrial revolution. *J Korean Educ*, 44, 5–32, 2017.
- Moon SY, Choi BD, Moon YL. Virtual Reality for Dental Implant Surgical Education. *IEIE*, 53(12), 169–174, 2016.
- Park SH, Cho YB. An Effect of Genetic Algorithm for Creating a Dataset. *J. Digit. Contents Soc.*, 20(1), 127–133, 2019.
- Park SH. Artificial Intelligence in Medicine: Beginner's Guide. *J Korean Soc Radiol*, 78(5), 301–308, 2018.
- Vergheze A, Shah NH, Harrington RA. What this computer needs is a physician: humanism and artificial intelligence. *Jama*, 319(1), 19–20, 2018.
- Yang KC, Varol O, Davis CA, Ferrara E, Flammini A, Menczer F. Arming the public with artificial intelligence to counter social bots. *Human Behavior and Emerging Technologies*, 1(1), 48–61, 2019.
- Yoon HJ, Jeong YJ, Kang DY, Kang H, Yeo KK, Jeong JE, Ha SW. Effect of Data Augmentation of F-18-Florbetaben Positron-Emission Tomography Images by Using Deep Learning Convolutional Neural Network Architecture for Amyloid Positive Patients. *J Korean Phys Soc*, 75(8), 597–604, 2019.
- Yun JR, Chun SK, Kim HM, Kim UY. Object Recognition in 360° Streaming Video. In *Proceedings of the Korean Society of Computer Information Conference*. *J Korea Soc Comput Inf*, 27(2), 317–318, 2019.