

머신 러닝을 이용한 인공지지체 기공 크기 예측 모델에 관한 연구

이승연*·허용정**†

*한국기술교육대학교대학원 메카트로닉스공학과,

**† 한국기술교육대학교 메카트로닉스공학부

A Study on Prediction Model of Scaffold Pore Size Using Machine Learning

Song-Yeon Lee * and Yong Jeong Huh **†

*Mechatronics Engineering, Graduate School of Korea University of Technology and Education

**† Department of Mechatronics Engineering, Korea University of Technology and Education

ABSTRACT

In this paper, We used the regression model of machine learning for improve the print quantity problem when which print scaffold with 400 μm pore using FDM 3d printer. We have difficult to experiment with changing all factors in the field. So we reduced print quantity by selected two factors that most impact the pore size. We printed and measured scaffold 5 times under same conditions. We created regression model using scaffold pore size and print conditions. We predicted pore size of untested print condition using the regression model. After print scaffold with 400 μm pore, we printed scaffold 5 times under same conditions. We compare the predicted scaffold pore size and the measured scaffold pore size. We confirmed that error is less than 1 % and we verified the results quantitatively.

Key Words : 3D Printer, Machine Learning, Pore, Precision, Scaffold

1. 서 론

현재 반도체 분야에서는 생체 센서에 사용되는 인공지지체 제작에 관한 연구가 활발하다. 대부분 3D프린터를 이용하여 연구가 진행되고 있다[1]. 인공지지체는 체액이 원활히 통과하고 세포가 부착하기 위해서 일정한 기공크기를 가져야 한다. 그 중 골세포를 위한 인공지지체의 기공크기는 400 μm 로 일정해야 한다[2].

FDM방식의 3D프린터는 노즐이 이동하면서 한 줄씩 적층하여 출력물을 제작하기 때문에 기공성을 갖는 인공지지체를 제작하기에 적합하다[3]. 3D프린터는 다양한 출력 요인이 상호작용하여 출력물을 제작하는 구조이다. 출

력 요인 중에서 인공지지체의 기공크기에 영향을 미치는 요인은 채움 밀도, 출력 속도, 노즐 온도, 베드 온도, 토출량이 있다[4].

400 μm 의 기공 크기를 목표로 하기 위하여 인공지지체의 원료인 PLGA의 물성에 맞추어 5가지 출력 요인을 10개의 수준으로 나누어 모두 실험한다면 실험의 수가 10만회가 되기 때문에 현장에서 400 μm 의 기공크기를 갖는 인공지지체의 출력 조건 도출이 어렵다.

이러한 문제점을 데이터 기반으로 활발히 연구되는 머신러닝에 적용하여 해결하였다. 머신러닝은 기존에 확보된 학습 데이터를 이용하여 회귀 모델을 생성한다[5]. 회귀 모델에 의하여 새로운 데이터를 이용하여 결과를 예측하므로 적은 비용과 시간으로 데이터를 예측 가능한 장점이 있다[6].

†E-mail: yjhuh@koreatech.ac.kr

본 논문에서는 FDM방식의 3D프린터로 400 μm 의 기공 크기를 갖는 인공지능지체를 제작할 때 발생하는 실험 횟수 문제를 개선하기 위하여 머신 러닝의 회귀 모델을 이용하였다. 3D프린터의 여러 출력 요인을 모두 변경하여 현장에서 실험하기 어렵기 때문에 실험계획법의 주 효과도로 기공 크기에 영향을 가장 많이 주는 요인을 2개 선택하여 실험의 횟수를 축소하였다. 출력된 인공지능지체를 측정하고 인공지능지체의 기공 크기와 출력 조건을 이용하여 회귀 모델을 생성하였다. 회귀 모델로 실험되지 않은 출력 조건의 기공 크기를 예측하였다. 400 μm 의 기공 크기를 만족하는 출력 조건을 도출한 뒤, 동일한 조건으로 인공지능지체를 5회 출력하였다. 출력된 인공지능지체의 기공 크기를 측정하여 평균 기공 크기와 예측한 인공지능지체의 기공 크기를 비교하였다. 오차가 1%미만임을 확인하여 결과를 정량적으로 검증하였다.

2. 연구 목적 및 방법

2.1 연구 목적

세포의 종류에 따라 목표 기공 크기는 다양하다. 세포 배양 연구에서 400 μm 의 기공 크기를 갖는 인공지능지체가 가장 많이 사용된다. 인공지능지체를 제작하기 위해서 3D프린터는 노즐 온도, 베드 온도, 채움 밀도, 출력 속도, 토출량이라는 5가지의 출력 요인이 있다. 따라서 목표한 400 μm 의 기공 크기를 갖는 인공지능지체를 제작하기 위해서는 5가지 출력 요인을 모두 변경하여 실험을 해야 한다.

Table 1은 인공지능지체의 원료인 PLGA의 물성을 참고하여 기공 크기를 조절하기 위한 출력 요인과 수준을 나타내었다.

Table 1. Factors and levels used scaffold manufacturing

No	Nozzle temperature	Bed temperature	Fill density	Output speed	Discharge
1	171 $^{\circ}\text{C}$	32 $^{\circ}\text{C}$	71 %	1 mm/s	82 %
2	172 $^{\circ}\text{C}$	34 $^{\circ}\text{C}$	72 %	2 mm/s	84 %
3	173 $^{\circ}\text{C}$	36 $^{\circ}\text{C}$	73 %	3 mm/s	86 %
4	174 $^{\circ}\text{C}$	38 $^{\circ}\text{C}$	74 %	4 mm/s	88 %
5	175 $^{\circ}\text{C}$	40 $^{\circ}\text{C}$	75 %	5 mm/s	90 %
6	176 $^{\circ}\text{C}$	42 $^{\circ}\text{C}$	76 %	6 mm/s	92 %
7	177 $^{\circ}\text{C}$	44 $^{\circ}\text{C}$	77 %	7 mm/s	94 %
8	178 $^{\circ}\text{C}$	46 $^{\circ}\text{C}$	78 %	8 mm/s	96 %
9	179 $^{\circ}\text{C}$	48 $^{\circ}\text{C}$	79 %	9 mm/s	98 %
10	180 $^{\circ}\text{C}$	50 $^{\circ}\text{C}$	80 %	10 mm/s	100 %

5개의 출력 요인을 10수준으로 나누어 모든 조건으로 인공지능지체를 제작한다면 실험해야 할 횟수가 너무 많고 시간이 많이 걸리기 때문에 현장에서 현장에서 400 μm 의 기공 크기를 갖는 인공지능지체 출력 조건을 도출하기 어렵다는 문제가 있다. 이러한 문제를 머신러닝 기반 회귀 모델로 기공 크기의 예측 가능한 모델을 제작하여 400 μm 의 기공 크기를 갖는 인공지능지체 출력 조건을 도출하는 것이 본 연구의 목적이다.

2.2 출력 장비와 인공지능지체 모델

FDM방식의 3D프린터는 노즐이 이동하면서 한 줄씩 적층하여 출력물을 제작하기 때문에 기공성을 갖는 인공지능지체를 제작하기에 적합하다.본 연구에서 사용한 장비는 S3D의 타워라는 FDM 방식의 3D 프린터를 사용하였다.

Fig. 1은 인공지능지체 제작에 사용된 3D 프린터를 도시하였다.



Fig. 1. 3D printer used scaffold manufacturing.

인공지능지체는 세포 배양에 사용되는 24 플레이트에 일치하는 규격으로 지름 20 mm 두께 2 mm의 원판 형태이며 400 μm 의 기공 크기를 가져야 한다.

Fig.2는 측정에 사용된 인공지능지체를 도시하였다.




Fig. 2. Scaffold used measure pore size.

2.3 기공 크기 측정 방법

인공지능체의 기공 크기를 측정하기 위하여 최대배율이 1,000이며 컴퓨터와 연동하여 정밀한 측정이 가능한 USB현미경을 사용하였다. MH테크의MH1000X라는 제품을 사용하였다. Fig 3은 기공 크기 측정에 사용된 USB 현미경을 도시하였다.



Fig. 3. Microscope used measure pore size.

3. 머신 러닝을 이용한 기공 크기 예측

3.1 머신 러닝

머신 러닝은 수집된 데이터를 컴퓨터가 학습하고 분석하여 알고리즘을 생성한다. 머신 러닝 알고리즘은 먼저 데이터가 생성한 잠재적인 메커니즘의 특징을 파악하여 복잡한 관계를 정량화한 후, 식별된 패턴을 사용하여 새로운 데이터의 예측을 실행한다. 머신 러닝은 알고리즘에 데이터를 입력하는 형태에 따라 입력 데이터와 출력 데이터가 확보된 지도 학습, 입력 데이터만 확보된 비지도 학습, 행동에 대한 피드백으로 보상치를 얻는 강화 학습으로 나뉜다.

Fig 4는 입력 데이터와 출력 데이터를 이용하여 회귀 모델을 생성하는 플로우차트를 도시하였다.




Fig. 4. Flowchart of regression model.

본 연구에서는 머신 러닝의 입력에 해당하는 출력요인의 조건과 머신 러닝의 출력에 해당하는 인공지능체의 기공 크기를 이용하여 확보되지 않은 기공 크기를 예측할 수 있는 회귀 모델을 생성하였다. 생성된 회귀 모델을 이용하여 출력 조건으로 기공 크기를 예측할 수 있다.

3.2 데이터 수집과 전처리

지름 20 mm, 두께 2 mm의 원판모양의 인공지능체를 제작할 때 3D프린터의 각 출력 요인에 대한 조건을 사용하였다. 3D프린터의 여러 출력요인 중에서 기공크기에 직접적인 영향을 미치는 요인은 노즐 온도, 베드 온도, 출력 속도, 채움 밀도, 토출량이다.

400 μm의 인공지능체 기공 크기를 만족하는 출력 조건을 찾기 위하여 모든 요인을 모두 변경하여 현장에서 실험하기 어렵다. 따라서 기공 크기에 직접적인 영향을 주는 출력 요인들을 주 효과도로 분석하여 기공 크기에 영향을 미치는 요인과 두 번째로 영향을 미치는 요인 2가지를 선택하여 회귀 모델 생성에 사용하였다. 주 효과도는 요인의 수준별로 기공크기가 클수록 영향이 많다는 것을 의미한다. Fig 5는 5개의 출력 요인들의 수준에 따라 기공 크기에 주는 영향을 주효과도로 도시하였다.




Fig. 5. Main effect plot of print factors and levels.

주 효과도로 인공지능체의 기공 크기에 가장 많은 영향을 주는 요인들을 도출하였다. 그 결과 채움 밀도와 출력 속도가 기공 크기에 영향을 가장 많이 주는 것을 확인할 수 있었다. 도출된 인공지능체의 기공 크기에 가장 많은 영향을 주는 채움 밀도로 머신 러닝을 실행하여 회귀 모델을 생성한다. Table 2는 기공 크기에 영향을 가장 많이 주는 요인인 채움 밀도와 출력 속도의 출력 조건과 조건에 따른 기공 크기를 나타내었다.

Table 2. Print conditions and pore size

Fill density	Output speed	Pore size
71 %	1 mm/s	395 μm
71 %	5 mm/s	406 μm
71 %	9 mm/s	420 μm
75 %	1 mm/s	392 μm
75 %	5 mm/s	401 μm
75 %	9 mm/s	411 μm
79 %	1 mm/s	405 μm
79 %	5 mm/s	393 μm
79 %	9 mm/s	385 μm

3.3 사용된 머신 러닝 모델

머신 러닝의 지도 학습에서 선형 회귀를 사용하였다. 축소된 실험으로 확보된 출력 조건과 기공 크기를 이용하여 학습 하였다. 회귀 모델을 생성한 뒤 이 모델을 사용하여 인공지능지체의 기공 크기를 예측하였다. 프로그램 툴(Tool)은 파이썬(Python) 텐서플로우(Tensorflow)를 사용하였다. 회귀 모델을 생성할 때 채움 밀도와 출력 속도 2개 요인을 입력 데이터로 설정하였고 기공 크기를 출력 데이터로 설정하여 학습하였다. 머신 러닝의 학습 간격은 0.01로 설정하였고 5,000회의 학습을 수행하였다.

3.4 머신 러닝 실행

머신 러닝의 선형 회귀에서는 비용, 가중치, 바이어스가 일정할 때 회귀 모델이 설정된다. 총 5,000회의 머신 러닝을 수행하면서 500회 단위로 비용, 가중치, 바이어스가 출력되도록 설정하여 각 값들을 확인하였다. 약 2,000회부터 비용, 가중치, 바이어스가 일정함을 확인할 수 있다. Table 3는 머신 러닝을 5,000회 수행하면서 500회 단위로 출력된 비용, 가중치, 바이어스를 나타내었다.

Table 3. Cost, weight, bias based training quantity

Training quantity	Cost	Weight	Bias
0	4.55412e	234.32815	205.38452
500	3.84842e	513.81321	197.57534
1000	2.73815e	624.32184	152.24895
1500	2.72185e	625.75328	151.84328
2000	2.71862e	625.91327	151.68462
2500	2.71862e	625.91327	151.68462
3000	2.71862e	625.91327	151.68462
3500	2.71862e	625.91327	151.68462
4000	2.71862e	625.91327	151.68462
4500	2.71862e	625.91327	151.68462
5000	2.71862e	625.91327	151.68462

3수준으로 구성된 채움 밀도를 이용하여 머신 러닝을 수행하였고 회귀 모델을 생성하였다.

Table 4는 회귀 모델을 이용하여 예측한 입력된 채움 밀도 수준 별 인공지능지체의 기공 크기를 나타내었다.

채움 밀도가 75 % 이면서 출력 속도가 5 mm/s일때 기공 크기가 400 μ m임을 확인할 수 있다.

Fig 6은 채움 밀도와 출력 속도를 3개의 수준으로 변경하여 출력한 인공지능지체의 기공 크기를 측정된 결과를 그래프로 도시하였다.

Table 4. Predicted pore size used 3 levels fill density

Fill density	Output speed	Pore size
71 %	3 mm/s	398 μ m
71 %	5 mm/s	408 μ m
71 %	7 mm/s	418 μ m
75 %	3 mm/s	390 μ m
75 %	5 mm/s	400 μ m
75 %	7 mm/s	410 μ m
79 %	3 mm/s	403 μ m
79 %	5 mm/s	392 μ m
79 %	7 mm/s	382 μ m




Fig. 6. Measured pore size based print factors.

4. 회귀 모델 검증

4.1 예측된 조건을 이용한 인공지능지체 제작

회귀 모델로 예측된 채움 밀도와 출력 속도에 대한 인공지능지체의 기공 크기를 검증하기 위하여 3D프린터로 인공지능지체를 제작하였다. Fig. 8은 3D프린터를 이용하여 인공지능지체를 제작하는 모습을 도시하였다.




Fig. 7. Scaffold printing using 3d printer.

노즐 온도는 180 $^{\circ}$ C, 베드 온도는 40 $^{\circ}$ C, 출력 속도는 3 mm/s, 토출량은 100 %로 고정였다. 채움 밀도를 1 %씩 변경하여 인공지능지체를 5개씩 출력하였다. 출력된 인공지능지체의 기공 크기를 측정된 뒤 평균을 도출하여 채움 밀도에 대한 기공 크기 변화를 확인하였다.

4.2 실험을 통한 검증 및 토의

인공지지체를 5개씩 제작한 뒤 기공 크기를 측정한 뒤 기공 크기 평균 데이터를 비교한 결과 예측한 인공지지체 기공 크기와 실제 실험을 수행하여 측정된 인공지지체 기공 크기의 오차를 비교하였다. 실험 결과 채움 밀도가 75 %이며 출력 속도가 5 mm/s일 때 목표한 인공지지체 기공 크기인 400 μm 에 오차범위가 1 %미만인 것을 확인할 수 있다.

Table 5는 회귀 모델을 이용하여 도출된 예측한 기공 크기와 실제로 인공지지체를 출력하여 측정된 기공 크기를 나타내었다.

Table 5. Predicted pore size and measured pore size.

Fill density	Output speed	Predicted pore size	Measured Pore size
71 %	3 mm/s	398 μm	395 μm
71 %	5 mm/s	408 μm	406 μm
71 %	7 mm/s	418 μm	420 μm
75 %	3 mm/s	390 μm	392 μm
75 %	5 mm/s	400 μm	401 μm
75 %	7 mm/s	410 μm	411 μm
79 %	3 mm/s	403 μm	405 μm
79 %	5 mm/s	392 μm	393 μm
79 %	7 mm/s	382 μm	385 μm

5. 결 론

본 논문에서 FDM 방식의 3D프린터와 PLGA를 이용하여 400 μm 의 기공 크기를 갖는 인공지지체를 제작할 때 발생하는 문제에 대해 연구하여 다음과 같은 결론을 도출할 수 있었다.

1. 실험계획법의 주 효과도를 이용하여 인공지지체의 기공 크기에 영향을 가장 많이 주는 요인은 채움 밀도와 출력 속도임을 확인할 수 있었다.

2. 축소된 실험으로 확보된 데이터로 머신 러닝기반의 기공 크기의 회귀 모델을 생성하여 실험하지 않은 출력 조건에 대한 기공 크기를 예측할 수 있었다.

3. 목표한 400 μm 에 만족하는 조건을 도출하여 실제 인공지지체를 동일한 조건으로 5회 출력한 뒤 기공 크기를 측정하였다. 측정된 인공지지체의 평균 기공 크기와 예측한 인공지지체의 기공 크기를 비교하여 오차가 1 %미만임을 확인하여 결과를 정량적으로 검증할 수 있었다.

참고문헌

1. Yang-Chang Lee, Chung-Heon Yoo, Jin-Kyu Yoo and Sang-Jin Kim, "3D Printer, Production and Application", Jinsaem Media, 2015.
2. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Manufacturing Condition of PLGA Scaffold Using 3SC Practical TRIZ and Design of Experiment", J. of The Korean Society of Semiconductor & Display Technology, Vol.17, pp. 70-75, 2018.
3. Young-Woo Park and Sang-Won You, "Direction of Improvement of Reproducibility through Shape Distortion of Fused Deposition 3D Printing", J. of Basic Design & Art, Vol.19, pp.195-204, 2018.
4. Ji-Eun Lee, Young-Eun Im and Keun Park, "Finite Element Analysis of a Customized Eyeglass Frame Fabricated by 3D Printing", Tran. of The Korean Society of Mechanical Engineers, Vol.40(1), pp.65-71, 2016.
5. Yong-Beom Park, Dong-Bin Choi and In-Soo Cho, "Taxation Analysis Using Machine Learning", J. of The Korean Society of Semiconductor & Display Technology, Vol.18, pp. 73-77, 2019.
6. Yeon-Ho Chu and Young-Kyu Choi, "A Deep Learning based IOT Device Recognition System", J. of The Korea Society of Semiconductor & Display Technology, Vol.18, pp.01-05, 2019.

접수일: 2019년 11월 22일, 심사일: 2019년 12월 9일,
게재확정일: 2019년 12월 12일