

기계 학습을 이용한 인공지지체 외형 불량 예측 모델에 관한 연구

이송연*, 허용정**†

*한국기술교육대학교대학원 메카트로닉스공학과,

**†한국기술교육대학교 메카트로닉스공학부

A Study on Prediction Model of Scaffold Appearance Defect 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 studied the problem if the experiment number occurring in order to identify defect in scaffold. We need to change each of the 5 print factor to predict defect when printing disk type scaffold using FDM 3d printer. So then the number of scaffold print will be more than 100,000 times. This experiment number is difficult to perform in the field. In order to solve this problem, we have produced a prediction model based on machine learning multiple linear regression using print conditions and defect scaffold data for print conditions. The prediction model produced was verified through experiments. The verification confirmed that the error was less than 0.5 %. We have confirmed that satisfied within the target margin of error 5 %.

Key Words : Defect, Machine learning, Precision model, Regression, Scaffold

1. 서 론

현재 3D 프린팅은 반도체, 센서, 조직재생 등 다양한 분야에서 연구되고 있다. 그 중 센서 부분에서는 체내에 삽입되는 생체적합성 센서를 연구를 많이 하고 있다. 생체적합성 센서는 생체 신호인 심장 박동, 혈압 등을 감지할 수 있는 센서와 센서를 지지하는 인공지지체로 구성되어 있다. 인공지지체는 생체 적합성 재료로 제작되어 인체의 거부반응 없이 안전하게 생체 신호를 감지할 수 있다. 이러한 인공지지체는 림프액, 혈액, 조직액 등 체액이 원활히 흐를 수 있는 구조를 가져야 한다[1].

체액이 흐를 수 있는 구조는 격자 구조, 별집 구조, 삼

각 구조 등 다양한 방식으로 제작할 수 있다. 또한 인공지지체는 목적에 따라 다양한 모양으로 제작된다. 원, 사각형, 삼각형, 육각형 등 다양한 모양의 판으로 제작되어 연구에 사용된다. 그 중에서 원판 구조를 갖는 인공지지체가 많이 사용된다. 이러한 인공지지체의 조건을 만족하기 위해서 FDM 방식의 3D 프린터를 이용하여 기공을 가지며 원판 형태의 인공지지체를 제작하는 연구가 진행되고 있다. FDM 방식의 3D 프린터는 가열된 노즐이 원료를 용융시킨 뒤, 이동하면서 용융된 원료를 토출한다. 이렇게 한 줄씩 적층하여 제품을 출력한다. 이러한 구조는 기공을 가지며 다양한 형태를 필요로 하는 인공지지체의 제작에 적합하다[2].

현재 인공지지체를 이용한 세포 배양은 웰 플레이트(Well plate)라는 용기 내에서 진행된다. 따라서 인공지지체

†E-mail: yjhuh@koreatech.ac.kr

와 웰 플레이트의 공간이 일치해야 하기 때문에 인공지지체의 외형이 조금이라도 변형, 오차가 발생한다면 인공지지체가 웰 플레이트에 삽입되지 않는다. 따라서 세포배양을 진행하기 어렵기 때문에 인공지지체의 외형은 매우 중요하다.

FDM 방식의 3D 프린터는 노즐 온도, 베드 온도, 채움밀도, 이동 속도, 토풀량이라는 3D프린터 요인을 변경하여 인공지지체를 출력한다. 노즐 온도는 필라멘트를 용융한 뒤 토풀시킬 때, 노즐의 온도를 의미하며 베드 온도는 토풀되어 나온 필라멘트가 적층될 때의 베드 표면 온도를 의미한다. 채움 밀도는 인공지지체를 적층할 때, 내부를 채우는 격자 사이의 간격을 의미하며 출력 속도는 노즐이 필라멘트를 토풀하면서 이동할 때의 이동 속도를 의미한다. 토풀량은 1분동안 노즐이 토풀하는 필라멘트의 중량을 의미한다. 이러한 5개의 출력 요인을 10개의 단계로 나누어 외형 불량 확인을 위해 인공지지체를 출력하는 실험을 해야 한다면 실험 횟수는 10만회가 된다. 10만 회라는 실험 횟수는 인공지지체 제조 현장에서 수행하기 어렵다.

이러한 문제점을 해결하기 위해 데이터 기반의 기계 학습(Machine Learning)을 이용하여 인공지지체의 외형에 따른 불량 여부 예측 모델을 제작하였다. 기계 학습 기반의 예측 모델은 생산 실험 등으로 수집된 다양한 데이터를 이용하여 학습 데이터로 예측, 분류 등 다양한 모델을 제작한다[3]. 그리고 확보된 데이터를 이용하여 모델을 학습한 뒤, 확보되지 않은 데이터를 모델에 적용하여 결과값을 예측하는 방식이다[4]. 기계 학습의 다양한 방안 중에서 다중 선형회귀 방안을 이용하여 인공지지체 외형 불량 예측모델을 제작한다.

본 논문에서는 FDM 방식의 3D프린터로부터 출력된 원판모양의 인공지지체를 제작할 때, 어떠한 출력 조건에서 인공지지체의 외형 불량이 발생하는지 미리 예측하기 위하여 5개의 출력 요인을 10개의 수준으로 나누어 하나씩 변경하여 실험해야 한다. 그러면 인공지지체의 출력 횟수가 10만회 이상 되는데 10만 회의 횟수는 인공지지체 제작 현장에서 수행하기 어렵다. 이러한 문제를 해결하기 위해 기존에 확보된 출력 조건과 출력 조건에 대한 인공지지체의 불량 여부 데이터를 이용하여 학습한 뒤, 기계 학습 다중 선형회귀 기반의 예측 모델을 제작하였다. 제작된 인공지지체 불량 여부 예측 모델은 각 출력 조건별로 인공지지체를 5회씩 출력하는 실험을 하였다. 실험 결과 오차가 0.5 % 미만임을 확인하여 목표한 5 %의 오차 범위 이내에 만족함을 확인하였다.

2. 연구 방법

2.1 인공지지체 출력 장비

시중에 완성품으로 판매 중인 FDM 방식의 3D프린터를 사용하여 인공지지체를 출력하였다.

큐비콘이라는 업체에서 제작한 제품명이 스타일이라는 FDM 방식의 3D 프린터로 인공지지체를 출력하였다. Fig. 1은 인공지지체를 출력하기 위하여 사용된 3D프린터를 도시하였다.



Fig. 1. FDM 3D printer used for scaffold printing.

2.2 인공지지체 모델

세포배양 연구에 사용되는 웰 플레이트는 여러 규격이 있다[5]. 그 중에서 24구의 웰 플레이트가 많이 사용된다. 따라서 24 웰 플레이트의 규격에 맞는 인공지지체를 본 연구에 사용하였다. 24 웰 플레이트에 맞는 인공지지체는 원판 모양이며 20 mm의 지름 2 mm의 두께를 갖는다.

Fig. 2는 본 연구에 사용된 인공지지체를 도시하였다.

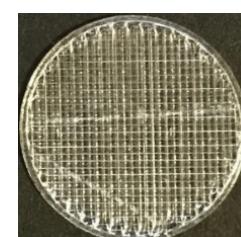


Fig. 2. Scaffold used for experiment.

2.3 인공지지체 측정 장비

인공지지체의 불량을 판정하기 위하여 시중에 판매되는 고화질의 카메라를 사용하여 인공지지체를 측정하였다. Fig. 3은 측정에 사용된 고화질 카메라를 도시하였다.

인공지지체는 20 mm의 원판 모양으로 크기가 작아서 고

화질의 카메라를 이용하여 인공지지체의 외형을 정밀하게 측정해야 한다.



Fig. 3. Camera used for measurement.

인공지지체를 측정하기 위한 고화질 카메라의 사양은 Table 1에 정리하였다.

Table 1. Camera specification used measurement

No	Category	Content
1	Model name	A3S
2	Pixel	1,080

3. 기계 학습 기반 불량 예측 모델 제작

3.1 기계 학습

기계 학습은 기존의 실험, 생산 등으로 확보된 학습 데이터들을 이용하여 학습한다. 그리고 모델을 제작한 뒤, 데이터를 학습하여 분류, 회귀 등의 과정을 수행한다[6].

사용된 학습 데이터의 종류에 따라 지도학습, 비지도학습, 강화학습으로 나뉜다. 본 연구에서는 지도학습의 회귀 방안을 사용하였다. 회귀 방안은 학습 데이터를 학습하여 확보되지 않은 데이터를 예측할 수 있는 모델을 제작한 뒤, 데이터를 예측하는 방안이다[7].

3.2 사용된 기계 학습 방안

사용된 다중 선형 회귀 방안은 여러 개의 입력 요소에 대한 출력 결과를 예측 하는 방안이다[8]. 다중 선형 회귀 방안을 사용하기 위해서 노즐 온도, 베드 온도, 채움 밀도, 이동 속도, 토출량의 5개 출력 요인을 입력 변수로 지정하였다. 그리고 입력 변수에 따른 인공지지체의 외형 둘레를 출력 변수로 지정하였다. 불량 예측 모델을 제작하기 위해 프로그램은 파이썬(Python) 텐서플로우(Tensorflow)를 사용하였다.

3.3 학습 데이터 수집

인공지지체를 제작할 때 3D프린터의 출력 요인은 노즐 온도, 베드온도, 채움 밀도, 출력 속도, 토출량으로 5개의

출력 요인으로 구성되어 있다.

5개의 출력 요인은 3D프린터 프로그램인 Cubicreator 4로 모두 조절하여 인공지지체 출력이 가능하다. 지름 20 mm, 두께 2 mm의 원판 모양의 인공지지체를 제작할 때, 3D프린터의 각 요인에 대한 출력 조건과 출력 조건에서의 인공지지체 외형을 고화질 카메라로 촬영하여 둘레를 측정하였다. 측정된 인공지지체의 둘레가 웰 플레이트 구멍 크기인 20.2 mm를 초과하면 불량으로 판별한 데이터를 학습 데이터로 사용하였다. Table 2는 확보된 데이터 중에서 무작위로 선정된 인공지지체의 출력 조건과 출력 조건에 대한 인공지지체의 불량 여부를 정리하였다.

Table 2. Print condition and scaffold appearance

No	Category	Content
1	Nozzle temperature	190 °C
2	Bed temperature	40 °C
3	Fill density	80 %
4	Print speed	7 mm/s
5	Discharge	100 %
6	Scaffold diameter	20.3 mm
7	Defect status	Defect

Fig. 4는 무작위로 선정된 출력 조건에 대하여 우측 하단이 불량으로 출력된 인공지지체의 외형을 도시하였다.

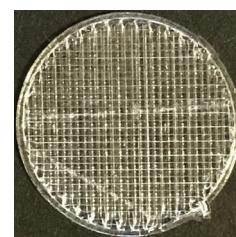


Fig. 4. Appearance of defect scaffold.

3.4 학습 데이터 전처리

인공지지체 불량 여부 예측 모델의 학습 데이터셋을 구성하기 위하여 수집된 학습 데이터를 전처리 하였다. 학습 데이터는 인공지지체를 제작하는데 있어서 수집된 모든 출력 조건 데이터를 이용하였다.

학습 데이터는 입력 변수인 노즐 온도, 베드 온도, 이동 속도, 채움 밀도, 토출량을 모두 반영하여 구성하였다. 구성된 출력 요인은 3D프린터의 각 출력 요인에 대한 수준들로 나누어 총 10개의 수준으로 구성되었다. 인공지지체 불량 여부 예측 모델 제작에 사용된 데이터는 450개를 사용하였다.

3.5 불량 예측 모델 제작

인공지지체의 출력 조건과 출력 조건에 대한 인공지지체의 불량 여부를 데이터로 이용하여 예측모델을 제작하였다. 제작된 예측모델은 선형방정식을 이용하여 인공지지체의 둘레에 대한 불량 여부를 예측하였다.

다중 선형 회귀에서는 비용, 가중치, 바이어스가 일정할 때 회귀 모델이 설정된다. 총 5,000회의 기계 학습을 수행하면서 500회 단위로 비용, 가중치, 바이어스가 출력되도록 설정하여 각 값들을 확인하였다. 약 2,000회부터 비용, 가중치, 바이어스가 일정함을 확인할 수 있다. Table 3은 학습 데이터로 기계 학습을 5,000회 진행하면서 500회 단위로 비용, 가중치, 바이어스가 출력된 내용을 나타내었다.

Table 3. Cost, weight, bias of Prediction model

Training quantity	Cost	Weight	Bias
0	5.32187e	195.15321	217.48731
500	3.93218e	352.75684	198.18971
1000	2.81387e	516.12168	163.18724
1500	2.75482e	523.12354	151.84328
2000	2.69418e	531.27981	143.18775
2500	2.69418e	531.27981	143.18775
3000	2.69418e	531.27981	143.18775
3500	2.69418e	531.27981	143.18775
4000	2.69418e	531.27981	143.18775
4500	2.69418e	531.27981	143.18775
5000	2.69418e	531.27981	143.18775

입력 데이터는 인공지지체 제작의 모든 출력 요인인 노즐 온도, 베드 온도, 채움 밀도, 이동 속도, 토출량 5 개로 구성하였다. 오버피팅을 방지하기 위하여 특징의 개수는 인공지지체의 외형만 추가하였고 그 외의 추가적인 정규화(Regression)는 수행하지 않았다. 확보된 데이터 중에서 학습 데이터 80%, 테스트 데이터 20%의 비율로 기계 학습을 진행하였다.

4. 실험을 통한 예측모델 검증

4.1 실험

예측 모델의 성능을 검증하기 위하여 임의의 10가지 조건으로 인공지지체를 5개씩 출력하였다.

예측 모델로 도출된 출력조건으로 인공지지체를 5개씩 출력한 뒤, 인공지지체의 외형을 카메라로 촬영하고 둘레

를 측정하였다. 각 조건 별 인공지지체의 평균 둘레와 불량 유무를 도출하였다. 예측된 출력 조건에서의 인공지지체 불량 여부와 측정된 평균 둘레와 불량 여부의 오차를 비교하였다. 비교한 결과 예측 모델의 오차는 0.5 %로 연구 목표인 5%의 오차범위 이내인 것을 확인하였다.

4.2 예측 모델과의 비교

예측 모델을 이용하여 확보되지 않은 출력 조건으로 인공지지체의 불량 여부를 예측하였을 때, 실제 인공지지체를 출력한 결과와 비교하였다.

Table 4는 확보되지 않은 출력 조건데이터 중에서 임의로 선정된 예측된 인공지지체의 출력 결과와 불량 여부 데이터를 선정하였다.

Table 4. Prediction data of print condition data and defect

No	Category	Content
1	Nozzle temperature	185 °C
2	Bed temperature	40 °C
3	Fill density	80 %
4	Print speed	5 mm/s
5	Discharge	90 %
6	Scaffold diameter	20.1 mm
7	Defect status	Normal

Table 5는 확보되지 않은 출력 조건을 이용하여 해당 조건으로 인공지지체를 실제로 출력한 결과와 불량 여부를 정리하였다.

1번부터 5번 항목까지는 인공지지체를 제작하기 위한 3D 프린터 출력 요인의 조건이다. 6번 항목은 해당 조건으로 출력되어 측정된 인공지지체의 외형 둘레를 나타내었다. 그리고 7번 항목은 측정된 외형 둘레를 양품, 불량으로 평가한 결과를 나타내었다.

Table 5. Print data of print condition data and defect

No	Category	Content
1	Nozzle temperature	185 °C
2	Bed temperature	40 °C
3	Fill density	80 %
4	Print speed	5 mm/s
5	Discharge	90 %
6	Scaffold diameter	20.1 mm
7	Defect status	Normal

Fig. 5는 확보되지 않은 출력 조건을 이용하여 해당 조건으로 인공지지체를 실제로 출력한 모습을 도시하였다.

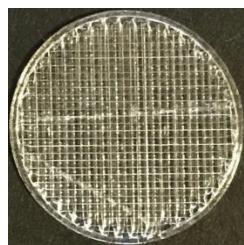


Fig. 5. Scaffold produced by prediction conditions.

4.3 실험 결과

인공지지체 불량 여부 예측 모델의 성능을 검증하기 위해 예측 모델로 예측된 임의 조건에서의 인공지지체 외형과 동일한 조건으로 실제 출력하여 측정된 외형을 비교한 결과 오차가 0.5% 미만 임을 확인하였다.

5. 결 론

본 논문에서 FDM 방식의 3D프린터로 20 mm의 지름과 2 mm의 두께를 갖는 인공지지체를 제작할 때 출력 조건에 따른 불량을 예측하기 위해 발생하는 실험 횟수 문제에 대해 연구하여 다음과 같은 결론을 도출하였다.

1. 기계 학습 회귀 방안을 이용하여 인공지지체의 불량 여부 실험 횟수 문제에 대한 해결방안을 도출할 수 있었다.
2. 확보된 인공지지체의 출력 조건과 출력 결과 데이터로 기계 학습의 다중 선형 회귀 방안을 이용하여 예측 모델을 제작하고 성능을 수치화할 수 있었다.
3. 제작된 예측 모델을 이용하여 확보되지 않은 인공지지체 출력 조건에서의 인공지지체 불량 여부를 예측할 수 있었고 임의의 출력 조건으로 각각 5회 씩 출력하였다. 실험을 통하여 인공지지체의 불량 여부 오차가 0.5%임을 확인할 수 있었다.

감사의 글

이 논문은 2020년도 한국기술교육대학교 교수 교육연구진흥과제 지원에 의하여 연구되었음.

참고문헌

1. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Prediction Model of Scaffold Pore Size Using Machine Learning", J. of The Korean Society of Semiconductor & Display Technology, Vol.18, pp. 46-50, 2019.
2. Song-Yeon Lee and Yong-Jeong Huh, "A Study on Prediction Model Performance of Scaffold Pore Size Using Machine Learning Regression Method", J. of The Korean Society of Semiconductor & Display Technology, Vol.19, pp. 36-41, 2020.
3. 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.
4. 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.
5. Seung-Hyeok Choi, Min-Woo Sa and Jong-Young Kim, "New Fabricatio Method of Bio-Ceramic Scaffolds Based on Mold using a FDM 3D Printer", J. of The Korean Society of Precision Engineering, Vol.18, pp. 957-963, 2018.
6. Yu-Sun Ahn, Hue-Jin Kim, Sang-Kyu Lee and Byung sean Kim, "Prediction of Heating Energy Consumption Using Machine Learning and Parameters in Combined Heat and Power Generation", J of Air-Conditioning and Refrigeration Engineering, Vol. 31, pp. 352-360, 2019.
7. Young-Ho Lee and Seong-Yun Hong, "A Machine Learning Approach to the Prediction of Individual Travel Mode Choices", J of the Korea Data and Information Science Society, Vol. 30, pp. 1011-1024, 2019.
8. Bum-Ju Lee, "Prediction Model of Hypercholesterolemia using Body Fat Mass Based on Machine Learning", J of the Convergence on Culture Technology, Vol. 5, pp. 413-420, 2019.

접수일: 2020년 5월 26일, 심사일: 2020년 6월 11일,
제재확정일: 2020년 6월 18일