



공학석사 학위논문

신경회로망과 CSM을 이용한 Ni-Ti 합금의 회전연마특성 예측모델 개발



부경대학교 대학원

기계공학과

정여경

공학석사 학위논문

신경회로망과 CSM을 이용한 Ni-Ti 합금의 회전연마특성 예측모델 개발



부경대학교 대학원

기계공학과

정여경

정여경의 공학석사 학위논문을 인준함.

2022년 8월 26일



목	차
---	---

Nomenclature	iii
List of tables	v
List of figures	vi
List of photographs	viii
Abstract	ix
1 HE	1
1. 세근 1.1 연구배경 및 필요성 ······	1
1.2 국내외 연구 동향	4
2. 이론적 배경	7
2.1 자기 수송체 회전연마공정	7
2.1.1 자기 수송체 거동에 따른 연마재의 운동상태	9
2.1.2 자기 수송체에 작용하는 힘	12
2.2 유한요소해석 (Finite element analysis)	15
2.2.1 정적자기해석 (Magnetostatic analysis)	16
2.2.2 과도구조해석 (Transient structural analysis)	27
2.3 표면가공성 예측모델	30
2.3.1 PyTorch framework	30
2.3.2 합성곱 신경회로망 (Convolutional neural network)	32
2.3.3 CSM이 적용된 EfficientNet	35

- 3. 자기 수송체 과도구조해석 시뮬레이션 ………………………………………… 40
 - 3.1 자기 수송체 과도구조해석 시뮬레이션 설계 …………… 40
 - 3.2 시뮬레이션 결과 및 표면 이미지 점수화 …………… 46
 - 3.2.1 표면 이미지 점수화 46
 - 3.2.2 직경에 따른 표면가공성 비교 51
 - 3.2.3 회전속도에 따른 표면가공성 비교 54
- 4. 표면가공성 예측모델 개발
 60

 4.1 CNN을 이용한 표면가공성 예측모델
 61

 4.2 CSM을 이용한 표면가공성 예측모델
 64

 4.3 실험을 통한 시뮬레이션 검증
 68

 5. 결론
 72

 REFERENCES
 74

Nomenclature

: The rotational velocity of the magnetic transporter [m/sec]
: Fluid viscosity [cP]
: Fluid density [kg/m ³]
: The rotational velocity of fluid [m/sec]
: Proportional factor
: Earth gravity [m/s ²]
: Magnetic force [N]
: Magnetic susceptibility
: Volume of the magnetic transporter [m ³]
: The intensity of the magnetic field [A/m]
: Radius of the magnetic transporter [mm]
: Resistance force [N]
: Centrifugal force [N]
: The mass of the magnetic transporter [kg]
: Distance from center [mm]
: Magnetic flux density [T]
: Magnetic filed strength [A/m]
: Total magnetic flux [Wb]
: Space permeability [H/m]
: Area of magnetized material [m ²]
: Magnetic dipole moment [A/m ²]

μ	: The magnetic permeability of the material [H/m]
$\cos(u,v)$: Cosine similarity
i	: Radius of the cylinder [mm]
$I_{\!uv}$: Set of magnetic flux density distributions
r(u,i)	: Magnetic flux density measurements
r(v,i)	: Magnetic flux density simulation results
f(x)	: Function for original image data
g(x)	: Kernel function
ϕ	: Compound coefficient
α	: The depth of a neural network
eta	: Width of channel
γ	: Resolution of image data
X'	: Normalized contact time data [sec]
X_{\min}	: Minimum contact time data for each region
X_{\max}	: Maximum contact time data for each region
X	: Original contact time data
Ι	: Impulse $[\mu N \cdot s]$
$\overrightarrow{F_m}$: Force acting on a magnetic transporter [N]
Δt	: Contact time [sec]
$\overrightarrow{v_i}$: Velocity before contact [m/sec]
$\overrightarrow{v_f}$: Velocity after contact [m/sec]
$R_{\!a_i}$: Initial surface roughness $[\mu m]$
R_{a}	: Surface roughness after experiment $[\mu m]$

List of tables

Table 2.1	Fixed conditions for magnetostatic simulation	22
Table 3.1	Properties of Ni-Ti alloy	43
Table 3.2	Properties of STS304	43
Table 3.3	Fixed conditions for simulation	44
Table 3.4	Nodes and elements of simulated model	45
Table 3.5	Simulated factor and level	45
Table 3.6	Scoring criterion range	49
Table 3.7	Score data based on simulation results	50
Table 4.1	Fixed conditions of the CNN model	62
Table 4.2	Fixed conditions of the CSM model	65
Table 4.3	Experimental verification at optimal and arbitrary condition	71

List of figures

Fig.	1.1 A flowchart for this study	· 3	
Fig.	2.1 Schematic apparatus of MTRF process		
Fig.	2.2 Force diagram on the magnetic transporter in MTRF process 14		
Fig.	2.3 Nd-Fe-B permanent magnet arrangement on rotating disc	20	
Fig.	2.4 The magnetic flux density on the cylinder plate	23	
Fig.	2.5 The distribution of magnetic flux density	23	
Fig.	2.6 Different vector modeling spaces using cosine similarity	24	
Fig.	2.7 Comparison of magnetic flux density distribution within		
	measurement and simulation	25	
Fig.	2.8 Magnetic force on the magnetic transporter at each position	26	
Fig.	2.9 Types of nonlinear systems	29	
Fig.	2.10 Deep learning framework	31	
Fig.	2.11 Basic architecture of convolutional neural network algorithm \cdots	33	
Fig.	2.12 CNN architecture	34	
Fig.	2.13 Scaling method of convolutional neural network	38	
Fig.	2.14 EfficientNet with CSM architecture	39	
Fig.	3.1 Area of interest in the finite element model	42	
Fig.	3.2 Force diagram on the magnetic transporter in simulation	48	
Fig.	3.3 Image score of surface finishing pocess	49	
Fig.	3.4 Surface integrity by the diameter of magnetic transporter	53	
Fig.	3.5 Comparison of surface images by diameter at 650rpm	54	
Fig.	3.6 Surface integrity by the rotational velocity	57	

Fig.	3.7	7 Comparison of surface images by the rotational velocity		
		at 1.0mm	58	
Fig.	3.8	The minimum score and the maximum score conditions	59	
Fig.	4.1	Learning graph of the CNN model	63	
Fig.	4.2	Learning graph of the CSM model	66	
Fig.	4.3	Test result of the CSM prediction model	67	
Fig.	4.4	Measuring points on workpiece	70	



List of photographs

Photo. 2.	1 Flow of fluid at low rotational velocity	11
Photo. 2.	2 Flow of fluid at high rotational velocity	11
Photo. 2.	3 Experimental apparatus for MTRF	19
Photo. 2.	4 Tesla meter of TM-701	21
Photo. 4.	1 Surface roughness tester	70



Development of a Predictive Model for Rotational Finishing Characteristics of Ni-Ti Alloy Using Neural Network and CSM

Yeo-Kyung Jung

Department of Mechanical Engineering, The Graduate School, Pukyong National University

Abstract

UNI

For decades demands for small components requiring high precision have been steadily increasing. Among them, the use of Ni-Ti alloy materials increases, and the need to improve surface roughness that affects the performance and quality of products is emphasized. However, the conventional finishing processing methods were limited in the size and shape of the workpiece. Hence, this study presents a magnetic transporter rotational finishing(MTRF) process using a magnetic field that was not restricted by the shape of the workpiece. This study aims to explore the optimal condition of the process parameter in the MTRF to improve the surface roughness of Ni-Ti alloy.

The MTRF process simultaneously processes a plurality of complex-shaped components using a flexible tool. However, it is not economical in terms of cost and time to find the optimal surface finishing processing conditions by performing numerous experiments with an expensive Ni-Ti alloy material to reduce surface roughness. Hence, finite element analysis was employed to predict and score the surface integrity by considering the movement of the magnetic transporter in proportion to the abrasive motion.

Since the magnetic transporter flow was affected by magnetic force, the magnetic flux density distribution was simulated using the magnetostatic simulation. Surface integrity was scored based on impulse, contact time, and contact distribution from the transient structural simulation results. Also, image classification was conducted by using a convolutional neural network(CNN) and the EfficientNet with compound scaling method(CSM). This study is significant for applying a predictive model that does not undergo trial and error to the simulation result image.

The prediction results of these networks were compared to evaluate the surface integrity of Ni-Ti alloy in the MTRF process. As a result, the CSM model achieved excellent performance for classification accuracy with 98.4% and 93.8% of train datasets and validation datasets compared to the CNN model, respectively.



1. 서론

1.1 연구배경 및 필요성

최근 다양한 산업이 발달함에 따라 반도체 기기, 로봇 센서, 수 마이크 로 크기의 의료기기 등 높은 정밀도를 요구하는 제품의 수요가 급증하는 추세이다. 그중 Ni-Ti 합금 소재는 형상기억특성과 초탄성 효과를 바탕으 로 혈관 스텐트, 치아 보철물, 인공 근육, 마이크로 센서 등의 정밀 부품 제작에 사용되고 있다^[1-2]. Ni-Ti 합금 소재의 활용도가 높아짐에 따라 Ni-Ti 합금의 성능과 품질에 영향을 미치는 표면가공성 개선을 위하여 기존의 기계적 표면연마법이 아닌 새로운 표면연마 기술개발이 요구된다 ^[3]. Ni-Ti 합금의 가공을 위하여 기존 연구에서는 고속 밀링, 방전가공, 레이저 가공 등의 가공방식을 시도하였다^[4-6]. 기존의 가공방식으로 가공 된 공작물은 가공 후 마이크로미터 수준 이상의 우수한 표면거칠기를 얻 기 어렵고 공작물의 크기와 형상에 제약을 받는다.

본 연구에서는 Ni-Ti 합금 공작물의 형상에 제약을 받지 않는 자기장 을 이용한 자기 수송체 회전연마공정(Magnetic transporter rotational finishing, MTRF)을 제시한다. 유연한 공구를 갖는 자기 수송체 회전연마 공정은 다수 개의 부품을 동시에 가공할 수 있으므로 가공시간 측면에서 경제적인 이점이 있다^[7]. 하지만 표면가공성 향상을 위하여 고가의 Ni-Ti 합금 소재로 수많은 실험을 수행하여 최적의 표면연마 가공조건을 찾는 것은 비용과 시간 측면에서 경제적이지 않다.

이러한 문제점을 해결하기 위하여 실험에 앞서 과도구조해석 시뮬레이

- 1 -

선을 수행하였다. 이때 연마에 직접적인 영향을 미치는 것은 연마재의 운동상태지만 수 마이크로미터의 작은 연마재의 크기와 형상 등의 제약 으로 인해 연마재의 시뮬레이션을 수행하기 어렵다^[8]. 따라서 자기 수송 체의 운동상태를 시뮬레이션함으로써 자기 수송체의 운동상태와 비례하 는 연마재의 운동을 예측할 수 있다. 자기 수송체와 공작물의 과도구조 해석 시뮬레이션을 통해 자기 수송체가 공작물 표면에 접촉할 때 발생하 는 충격량, 접촉시간, 접촉분포 데이터를 얻어 이 3가지 데이터를 바탕으 로 표면가공성을 평가하기 위하여 각 공정조건에 대한 표면 이미지를 점 수화하였다.

점수화된 이미지 데이터를 바탕으로 표면연마 성능을 평가하기 위하여 이미지 데이터를 직접 활용하고자 한다. 이미지 데이터의 분류를 위한 예측모델로 주로 합성곱 신경회로망(Convolutional neural network, CNN) 예측모델이 사용되고 있다^[9]. 하지만 CNN을 통한 예측모델의 정확도 등 성능을 개선하기 위하여 제한된 자원 내에서 시행착오 법을 통해 최적의 학습 모델을 찾아야 하는 한계점이 있다^[10].

따라서 본 연구에서는 CSM(Compound scaling method)이 적용된 EfficientNet을 활용하여 시행착오를 거치지 않고 높은 분류정확도를 갖는 표면가공성 예측모델을 제시하고 기존의 CNN 예측모델과 비교하고자 한다. Fig. 1.1은 본 연구의 구성을 도식적으로 나타낸 것이다.



Fig. 1.1 A flowchart for this study

1.2 국내외 연구 동향

산업기술의 발달에 따라 기계 재료에 요구되는 특성이 다양해지고 다 양한 형상을 요구하는 소형화, 정밀화된 부품의 수요가 증가하고 있다. 이와 함께 복잡한 형상을 갖는 소형부품의 기계적 성능에 많은 영향을 미치는 표면거칠기 개선을 위한 연구는 꾸준히 이어져 오고 있다.

Bagehorn^[11]은 Ti 합금의 표면거칠기 개선을 위하여 밀링, 블라스팅, 진 동가공 등의 기계적 연마공정을 수행하였다. 그중 밀링 공정을 통해 표 면거칠기 값을 17.9μm에서 1μm 이하로 개선하였다. 하지만 래핑, 그라 인딩, 호닝 등과 같이 고정된 공구를 사용하는 기존의 접촉식 가공법은 공작물 형상의 제약이 존재하므로 비접촉식 가공법이 요구된다. Grover^[12]은 MRH(Magnetorheological honing) 공정을 사용하여 원통형 공 작물 내부의 표면거칠기를 개선하였고, Kumar^[13]은 BEMRF(Ball end magnetorheological finishing) 공정을 통해 복잡한 형상을 갖는 비자성 재 료 공작물의 표면거칠기를 20μm에서 0.1μm 수준으로 개선하였다. 이와 같은 연구를 통해 자기력을 이용한 비접촉식 표면연마 공정이 복잡한 형 상을 갖는 공작물의 표면연마에 적합함을 알 수 있다.

Ni-Ti 합금의 표면거칠기 개선을 위한 가공법은 전해연마공정이 주로 사용되고 있다^[14]. 하지만 Kozak^[15]은 시뮬레이션을 통해 전해가공에서 복 잡한 구조의 합금에서 표면거칠기는 임곗값 이상으로 향상시킬 수 없음 을 보였다. 반면 Deng^[16]은 MAF(Magnetic abrasive finishing) 공정 실험을 통해 Ni-Ti 합금으로 제작된 혈관 스텐트 튜브 내면을 연마하여 표면거 칠기를 0.75μm에서 0.08μm까지 개선하여 자기장을 이용한 표면연마 공 정의 효과를 Ni-Ti 합금에서도 확인하였다. 부품 제작 시 요구하는 표면거칠기의 수준에 따라 후처리 공정은 가장 고가의 공정비용을 요구한다^[17]. Ni-Ti 합금과 같은 고가의 소재를 가공 하는 경우 후처리 공정비용의 절감은 생산비용을 낮추기 위하여 필수적 이다^[18]. 따라서 본 논문에서는 복잡한 형상을 갖는 소형부품들을 동시에 연마할 수 있는 비접촉식 가공법인 자기 수송체 회전연마공정을 제안한 다.

자기 수송체 회전연마공정에서 Ni-Ti 합금의 표면거칠기 개선을 위한 최적의 가공조건을 판단하기 위한 실험에 앞서 가공조건에 따른 표면가 공성 평가를 위한 시뮬레이션을 수행하였다. 시뮬레이션 결과 Ni-Ti 합금 의 표면 이미지를 바탕으로 표면가공성을 분류하는 예측모델을 인공신경 회로망 알고리즘을 사용하여 개발하고자 한다.

일반적으로 이미지 데이터가 입력값일 때 CNN 알고리즘이 예측모델 로 주로 사용된다^[19]. CNN 알고리즘은 Region feature를 학습시키기 위하 여 LeCun^[20]에 의해 1995년 제안되었으나 학습시간이 오래 걸리며 그 당 시 인공신경회로망 알고리즘의 단점으로 인해 주목받지 못하였다. 이후 2010년대에 들어 알고리즘과 하드웨어의 발전으로 인해 CNN 알고리즘 을 이미지를 처리하는 인공신경회로망으로 널리 사용하게 되었다.

ImageNet은 이미지 분류모델의 성능을 측정하기 위하여 가장 널리 사 용되는 데이터 세트이다. 이 ImageNet 데이터를 분류하는 모델 대회인 ILSVRC(ImageNet large scale visual recognition challenge)에서는 수많은 우 수한 예측모델이 소개되고 있다^[21]. Wu^[22]는 2015년 마이크로소프트에서 제안한 ResNet 예측모델을 사용하였다. Residual block 개념을 도입하여 이전 층의 특징 맵(Feature map)을 잔차(Residual)와 같이 다음 층의 특징 맵에 더해주는 Skip connection을 적용하였다. 신경회로망이 깊어짐에 따 라 초기 층의 정보가 뒤의 층으로 갈수록 희석된다는 단점을 보완할 수 있어 지금까지도 기본 딥러닝 프레임으로 활용되고 있다. 기존의 CNN 예측모델은 효율적인 예측모델을 구성하기 위하여 수많은 시행착오를 거 쳐 최적의 파라미터를 찾았으나 최근 이러한 과정을 딥러닝으로 해결하 려는 연구가 진행되고 있으며 이 분야를 AutoML(Auto machine learning) 이라 지칭한다^[23]. Kong 등^[24-26]은 모바일 기기에서도 동작할 수 있는 가 벼운 MobileNet 구조를 사용하였다. 이 구조를 통해 Depthwise separable convolution 개념이 제시되어 기존의 CNN보다 연산비용을 절감할 수 있 었고 이를 바탕으로 MBConv(Mobile inverted bottleneck convolution) 구조, Squeeze and excitation 기법이 발전하였으며 Swish 비선형 함수가 소개되 었다.

Bansal^[27]은 AutoML 프로그램을 사용하여 시행착오를 거치지 않으며 MobileNet과 같이 가벼운 모델구조를 갖는 분류모델을 사용하여 90%의 예측정확도를 달성하였다. Pereira 등^[28-29]은 기존보다 훨씬 적은 파라미터 수로 높은 예측성능을 달성하기 위하여 신경회로망의 깊이, 채널의 너비, 이미지의 해상도 등 3가지 차원의 균형을 맞추어 Scale-up 하는 CSM을 적용하였다.

실험결과 사진을 바탕으로 이미지를 분류한 연구는 활발하게 진행되고 있는 반면에 시뮬레이션 결과 이미지를 바탕으로 효과적으로 회전연마특 성을 예측한 연구는 미흡한 실정이다. 따라서 본 논문에서는 자기 수송 체 회전연마공정의 최적 공정조건을 판단하기 위하여 시행착오를 겪지 않고 가벼운 모델구조를 가지며 높은 정확도를 나타내는 CSM을 적용한 EfficientNet 예측모델을 개발하고자 한다.

2. 이론적 배경

2.1 자기 수송체 회전연마공정

자기 수송체 회전연마공정은 자기 수송체를 표면가공의 공구로 사용하는 비접촉식 표면연마공정이다. 이는 접촉식 공정과 비교할 때 소재의 열변형이나 공구마모가 없어 효율적이라는 장점이 있으며, 유연한 연마 공구 사용으로 인해 복잡한 형상을 가지는 소형부품의 표면가공에 적합 한 표면연마공정이다.

Fig. 2.1은 실제 자기 수송체 회전연마 장치를 도식화하여 나타낸 것이 다. 가공조건을 조절할 수 있는 컨트롤러와 AC모터, Nd-Fe-B 영구자석이 부착되어 회전하는 디스크, 공작물이 가공되는 수조로 구성되어 있다. 효 과적인 자기장의 분포를 위하여 영구자석은 N극과 S극의 극성이 교차로 배열되어 디스크에 부착되어있다. 수조 내부에는 냉각 효과를 위한 물에 자기 수송체와 연마 입자를 균일하게 분산시키기 위한 분산제가 희석되 어있다.

자기 수송체 회전연마공정에서 AC모터에 의해 영구자석이 부착된 디 스크가 회전하면 수조 내부에 자기장이 형성된다. 이로 인해 자기장 내 부에서 자기 수송체가 자화되므로, 디스크의 회전에 따른 자기장의 영향 을 받아 수조 내에서 거동하게 된다. 자기 수송체의 거동에 따라 수조 내부의 연마 입자가 공작물과 접촉하며 표면연마가 이루어진다.



Fig. 2.1 Schematic apparatus of MTRF process

2.1.1 자기 수송체 거동에 따른 연마재의 운동상태

자기 수송체 회전연마공정에서는 자기 수송체의 거동에 따라 연마재가 공작물과 접촉하며 직접적인 표면연마가 이루어진다. 하지만 수 마이크 로미터 크기의 연마재의 운동상태를 직접 계산하는 것은 어려우므로 자 기 수송체의 거동을 통해 연마재의 거동을 간접적으로 해석하고자 한다. 자기 수송체 회전연마공정에서 영구자석에 의해 형성된 자기장에 의해 자기 수송체는 자기력의 영향을 받는다. 자기력에 의해 자기 수송체가 운동하면서 수조 내부의 연마액에서는 Fig. 2.2와 같이 디스크와 같은 회 전 방향으로 유체유동이 발생한다. 유체의 회전운동으로 인해 연마재가 함께 운동하며 공작물의 표면을 가공한다.

자기 수송체와 연마재는 연마액 내에서 불규칙한 분산상태로 존재한 다. 영구자석에 의한 자기장 영역 내에서 자기장의 세기에 따라 분극화 (Polarization)된 자기 수송체 입자들은 체인구조로 클러스터(Cluster)를 형 성한다. 이때 자기 수송체는 자기력에 의해 영구자석이 부착된 디스크와 함께 운동한다.

수조 내부의 연마액에서는 운동하는 자기 수송체에 의해 유체유동이 발생한다. Photo. 2.1은 디스크의 회전속도가 낮은 경우 수조 내부의 유 체유동 상태를 나타낸다. Photo. 2.2는 디스크의 높은 회전속도에서의 유 체유동 상태이며 회전속도에 따라 유체의 유동도 활발해짐을 확인할 수 있다. 자기 수송체에 의한 유체유동은 3차원 비정상, 점성, 비압축성, 회 전 유동이다. 식 (2.1)과 같이 유체의 속도 v_{fluid} 는 자기 수송체가 회전하 는 운동속도 v_{maq} 에 비례하며 유체의 점도 η와 밀도 ρ에 반비례한다.

$$\overrightarrow{v_{fluid}} = k \frac{\overrightarrow{v_{mag}}}{\eta \rho}$$
(2.1)

여기서 *k*는 속도손실 등을 고려한 비례상수를 나타낸다. 이때 유체의 회 전운동에 의해 연마재가 함께 운동하게 되므로 연마재의 운동상태를 자 기 수송체의 거동으로 가정하여 시뮬레이션을 진행하였다.





Photo. 2.2 Flow of fluid at high rotational velocity

2.1.2 자기 수송체에 작용하는 힘

자기 수송체 회전연마공정에서 연마 입자들의 움직임을 해석하기 위해 자기 수송체에 고려된 힘을 소개한다. Fig. 2.2에서 나타낸 공작물에 중 력 $\overrightarrow{F_G}$ 이외에 작용하는 힘은 자기장 형성에 따른 자기력, 수조 내부에 서 발생하는 물에 의한 저항력과 Nd-Fe-B 영구자석이 부착된 디스크의 회전속도에 따른 원심력이다.

자기 수송체 회전연마공정에서 영구자석이 부착된 디스크가 회전하면 수조 내부에 자기장이 발생한다. 이로 인해 자화된 자기 수송체는 식 (2.2)와 같이 자기력 $\overrightarrow{F_M}$ 을 받게 된다.

$$\overrightarrow{F_M} = \chi V H_m \cdot \nabla H_m \tag{2.2}$$

여기서 χ는 자기 수송체의 자화율, V는 구 형상 자기 수송체의 부피, H_m은 자기 수송체에 작용하는 자기장의 세기이다. 자기력에 의해 운동 에너지를 갖게 된 자기 수송체는 수조 내에서 공작물과 접촉하며 공작물 의 표면을 가공한다.

영구자석이 부착된 디스크가 반시계방향으로 회전한다고 가정할 때, 수조 내부에 발생한 자기장에 의해 자기 수송체는 디스크의 회전 방향을 따라 반시계방향으로 거동한다. 이때 수조 내부에서는 디스크의 회전 반 대 방향인 시계방향으로 물에 의한 저항력이 자기 수송체에 작용한다. 물은 Newton 유체이므로 전단 속도의 크기와 무관하게 일정한 점도 η을 가지며, 반경 r_m의 자기 수송체가 속도 v_{mag} 로 거동하는 경우 물에 의한 저항력 $\overrightarrow{F_R}$ 은 Stokes' Law에 의해 식 (2.3)과 같이 계산할 수 있다^[30].

$$\overrightarrow{F_R} = -6\pi r_m \eta \overrightarrow{v_{mag}}$$
(2.3)

여기서 물은 25℃ 기준 1 cP로 가정하였으며 유체의 속도벡터와 반대 방향으로 작용하므로 음수로 힘의 방향을 표현하였다.

영구자석이 부착된 디스크가 AC모터에 의해 등속원운동을 할 때 자기 수송체들은 식 (2.4)와 같이 회전에 의한 원심력 $\overrightarrow{F_C}$ 이 작용하고 중심방 향의 반대 방향인 디스크 외측으로 자기 수송체의 분포가 집중된다.

$$\overrightarrow{F_C} = \frac{m \overrightarrow{v_{mag}}^2}{r_d}$$
(2.4)

여기서 m은 자기 수송체의 질량, r_d 는 디스크 중심과 자기 수송체 사이의 거리이다.



Fig. 2.2 Force diagram on the magnetic transporter in MTRF process

2.2 유한요소해석 (Finite element analysis)

유한요소해석(Finite element analysis)은 다양한 물리적 조건에서 물체가 어떻게 행동할 수 있는지를 예측하고 이해하기 위하여 사용하는 계산 및 시뮬레이션기술이다. 수치계산 방법으로는 물체의 구조를 여러 요소로 자른 다음 노드라고 불리는 지점에서 요소를 다시 연결하여 각 영역에 대해 계산하는 유한요소법(Finite element method)을 활용한다.

유한요소해석의 수행은 전처리기, 해석기, 후처리기 등 3가지 단계로 나눌 수 있다. 전처리기 단계에서는 해석하고자 하는 모델, 재료, 상황, 환경 등을 설정하고 요소 망 형성이라는 이산화 작업을 수행한다. 해석 기 단계에서는 모든 단일 요소에 대해 힘, 압력 등의 경계조건과 균형 방정식, 변형 관계, 변환 방정식 등의 세 가지 지배방정식을 포함하는 원 칙에 기초하여 대수 방정식 세트를 만들어 계산과 해석을 수행한다. 후 처리기 단계에서는 개별 요소에 대한 계산 결과를 조합하여 가공 및 저 장하여 해석 결과를 사람이 이해하기 쉽게 변경하는 작업을 수행한다. 본 논문에서는 자기 수송체 회전연마공정에서 자기 수송체에 작용하는

자기력을 계산하기 위하여 정적자기해석을 수행하고 Ni-Ti 합금 공작물 의 표면가공성을 평가하기 위하여 과도구조해석을 수행한다.

2.2.1 정적자기해석 (Magnetostatic analysis)

정적자기해석(Magnetostatic analysis)은 영구자석 모델의 정적 자계강도 해석, 선형 또는 비선형 재료 모델의 자계강도 해석에서 자기력, 토크 등 을 계산할 수 있는 유한요소해석 종류이다.

자속밀도 B [T]는 식 (2.5)와 같이 정의되며 자속의 방향과 수직인 단 위 면적당 자속선의 수를 의미한다. 영구자석이 만드는 자기력이 작용하 는 공간을 자기장이라고 하며 자기장의 세기(Magnetic field strength) *H* [A/m]는 단위 면적당 통과하는 자기력선의 밀도로 나타낸다. 식 (2.6)과 같이 균일하게 자화된 재료에서의 단위면적당 자기력선속 Ø [Wb]인 자 속밀도 B는 식 (2.7)과 같이 나타낼 수 있다.

$$B = \mu_0 (H + M)$$

$$\Phi = B \times S$$
(2.5)
(2.6)

여기서 *Ф*는 총 자기력선속, *S*는 자화된 재료의 면적을 나타낸다.

$$B = \mu_0 (1 + \chi) H = \mu H$$
 (2.7)

여기서 μ_0 [H/m]는 진공에서의 투자율로 $4\pi \times 10^{-7}$ [H/m]의 값을 가지며, χ 는 자화율(Magnetic susceptibility), μ 는 재료의 투자율을 나타낸다.

재료에는 식 (2.8)과 같이 자기장의 세기 H와 자화율 χ 에 따라 재료 내의 단위 부피당 유도된 쌍극자 모멘트인 자기 벡터 M가 발생한다. 자 화율의 크기가 $|\chi| << 1인 경우 외부 자기장에 재료가 약하게 자화되$ $며, 자화율의 크기가 <math>|\chi| >> 1인 경우 재료 내부는 외부 자기장에 의해$ 재료가 강하게 자화된다.

$M = \chi H$

(2.8)

자기 수송체 회전연마공정에서는 디스크가 회전할 때 수조 내부에 발 생하는 자기장이 자화된 자기 수송체와 연마 입자의 거동에 영향을 미친 다. Photo 2.3은 자기 수송체 회전연마 실험장치를 나타내며 Fig. 2.3은 실험장치에 부착된 영구자석의 배열을 나타낸 것이다. 실험장치에서 위 치에 따른 자속밀도의 세기는 Photo 2.4의 테슬라 미터(TM-701, KANETEC) 로 실측할 수 있으나 자속밀도의 방향을 측정할 수 없다. 따라서 본 논 문에서는 자기장의 필드 분포를 계산하기 위하여 정적자기해석을 수행한 다. 정적자기해석에서 얻어진 필드 분포를 활용하면 직접 계산하기 어려 운 각각의 위치에서의 자화된 자기 수송체에 작용하는 자기력 $\overrightarrow{F_M}$ 의 방 향과 크기를 계산할 수 있다.

TIONAT

과도구조해석을 수행하기에 앞서 Table 2.1의 해석조건에서 정적자기 해석을 수행한 결과 수조 바닥면에서의 자속밀도의 분포는 Fig. 2.4와 Fig. 2.5와 같이 나타난다. 정적자기해석 결괏값과 실제 실험장치의 자속 밀도 측정값을 정량적으로 비교하기 위하여 Fig. 2.6과 식 (2.9)의 코사인 유사도를 계산하여 비교한 결과, 코사인 유사도 0.9937로 Fig. 2.7과 같이 유사한 분포를 나타내어 시뮬레이션 결과의 신뢰성을 확인할 수 있다.

$$\cos(u, v) = \frac{\sum_{i \in I_w} r(u, i) r(v, i)}{\sqrt{\sum_{i \in I_w} r(u, i)^2} \sqrt{\sum_{i \in I_w} r(v, i)^2}}$$
(2.9)

여기서 I_{uv} 는 수조의 반경 i에 대응하는 자속밀도 벡터의 집합, r(u,i)는 실제 자속밀도 측정값, r(v,i)는 시뮬레이션 결괏값을 나타낸다.

실험장치로부터 위치에 따른 자속밀도의 방향과 자기력의 세기를 직접 계산할 수 없었으나 Fig. 2.8에 나타난 바와 같이 각 위치에서 자기 수송 체에 작용하는 자기력 $\overrightarrow{F_M}$ 을 정적자기해석을 통해 계산할 수 있다.





Photo. 2.3 Experimental apparatus for MTRF

Fig. 2.3 Nd-Fe-B permanent magnet arrangement on rotating disc

Photo. 2.4 Tesla meter of TM-701

Item		Condition
	Elements	21,931
	Nodes	43,857
Acrylic	Mesh size	10
1	Isotropic resistivity (ohm·m)	101.5
	Isotropic relative permeability	1
No.	Elements	20
Nd Eo D	Nodes	168
Nu-re-D	Mesh size	10
magnet	Coercive force (A/m)	8.6739E+5
1	Residual induction (T)	1.19
	Elements	70,124
Air	Nodes	110,821
All	Mesh size	40
	Isotropic relative permeability	1

Table 2.1 Fixed conditions for magnetostatic simulation




Fig. 2.5 The distribution of magnetic flux density



Fig. 2.6 Different vector modeling spaces using cosine similarity



Fig. 2.7 Comparison of magnetic flux density distribution within measurement and simulation



Fig. 2.8 Magnetic force on the magnetic transporter at each position

2.2.2 과도구조해석 (Transient structural analysis)

과도구조해석을 진행하는 경우는 Fig. 2.9와 같이 하중, 재료, 접촉상태 가 비선형적인 경우이다. Fig. 2.9 (a)는 물체의 형상이 과도한 변형을 일 으키거나 하중의 방향이 변하는 기하 비선형 상태를 나타낸다. Fig. 2.9 (b)는 물체의 응력과 변형률 관계가 탄성 범위는 벗어나거나 비선형적 탄성을 나타내는 재료 비선형 상태를 나타내며 Fig. 2.9 (c)는 물체의 거 동에 따라 물체의 접촉 경계조건이 변하는 경계 비선형 상태이다. 자기 수송체 회전연마공정에서 구형의 자기 수송체와 평면인 공작물의 접촉상 태는 점 접촉에서 면 접촉으로 시간에 따라 변화하는 경계 비선형 상태 이다.

또한, 과도구조해석에서는 회전속도에 따른 원심력을 고려할 수 있으 므로 회전하는 물체의 거동을 해석하기에 적합하다. 따라서 본 연구에서 는 과도구조해석 시뮬레이션을 통해 자기 수송체에 작용하는 원심력을 고려하여 Ni-Ti 합금 공작물의 표면가공성을 평가할 수 있다.

5

11 10



(b) Material nonlinear



Fig. 2.9 Types of nonlinear systems

2.3 표면가공성 예측모델

2.3.1 PyTorch framework

딥러닝 모델은 C, C++, Julia, Lua, R, Java 등과 같은 다양한 프로그래 밍 언어를 활용하여 설계할 수 있다. 그중 코드가 직관적인 Python 프로 그래밍 언어가 주로 사용되고 있다. Python 프로그래밍 언어에서 딥러닝 모델을 설계하기 위하여 TensorFlow와 PyTorch 프레임워크를 이용한다.

PyTorch는 Python 기반의 딥러닝 라이브러리이므로 직관적인 코드로 인해 디버깅이 상대적으로 쉬우며 코드를 데이터에 따라 조절하기 편리 하다. 또한, 미리 학습된 모델을 인터넷에서 불러와 사용 가능하므로 활 발한 커뮤니티를 바탕으로 여러 가지 딥러닝 모델을 적용해볼 수 있다는 장점이 있다.

이러한 장점들을 바탕으로 TensorFlow가 PyTorch보다 먼저 출시됐기 때문에 기본적으로 TensorFlow가 많이 이용되고 있으나 Fig. 2.10 (a)와 같이 PyTorch의 이용률이 점점 높아지고 있다. Fig. 2.10 (b)와 같이 2019 년 1월부터 6월까지 약 1,800개의 논문에서 TensorFlow를 활용하였고 비 슷한 수의 논문에서 PyTorch를 활용했으며 연구자들 사이에서 동기간 2018년 대비 2019년 PyTorch 활용이 194% 증가하였다^[31].

본 논문에서는 이러한 추세를 바탕으로 PyTorch 프레임워크를 이용하 여 표면가공성 예측모델을 개발하고자 한다.



(a) Percentage of deep learning frameworks used in the paper



(b) Number of papers that mention a given framework

Fig. 2.10 Deep learning framework

2.3.2 합성곱 신경회로망 (Convolutional neural network)

합성곱 신경회로망(Convolutional neural network)은 이미지 데이터를 입 력 데이터로 받는 경우 각 픽셀이 갖는 공간적 데이터를 활용하여 이미 지 데이터의 특징을 효율적으로 추출할 수 있는 딥러닝 기법이다.

Fig. 2.11과 Fig. 2.12는 합성곱 신경회로망 알고리즘의 개략도와 구조 를 나타낸 것이다. 입력된 이미지 데이터들은 합성곱 계층에서 식 (2.10) 의 합성곱 연산을 통해 필터 역할을 하는 커널을 통과하며 이미지의 특 성이 추출된다.

$$(f * g)(t) = \int_{-\infty}^{\infty} f(x)g(x-t)dx$$
(2.)

(2.10)

여기서 f(x)는 원본 이미지 데이터 함수, g(x)는 커널 함수를 나타낸다. 합성곱 계층에서 이미지의 특성이 추출된 데이터는 Pooling 과정을 거치 며 이미지 데이터의 크기를 줄여 과적합 현상을 방지한다. Pooling 기법 중에서 Max pooling 기법은 이미지의 특성을 더욱 강조할 수 있어 일반 적으로 사용되고 있다. 또한, 과적합 방지를 위하여 제로 패딩과 드롭아 웃 기법을 적용하기도 한다. 모델에 따라 합성곱 계층과 Pooling 계층 사 이클을 여러 번 반복한 후 이미지를 분류하기 위하여 데이터를 평탄화하 는 과정을 거친다. 평탄화 과정은 입력된 특징 맵의 픽셀을 하나의 벡터 로 모두 나열하는 벡터화 과정이다. 마지막으로 합성곱 신경회로망 알고 리즘에서는 벡터 형태의 데이터를 완전결합 계층에 연결하여 원하는 조 건에 따라 이미지 데이터를 분류한다.



Fig. 2.11 Basic architecture of convolutional neural network algorithm



Fig. 2.12 CNN architecture

2.3.3 CSM이 적용된 EfficientNet

합성곱 신경회로망의 성능을 개선하기 위하여 일반적으로 신경회로망 의 깊이, 채널의 너비, 이미지의 해상도 등의 크기를 조정한다. Fig. 2.13 (a)의 기본 구조에서 Fig. 2.13 (b), (c), (d)와 같이 깊이, 너비, 해상도 중 한 가지의 크기를 키우는 것도 좋지만 세 가지의 크기를 모두 키워 신경 회로망의 최적 성능을 기대해볼 수 있다. 하지만 이 방법은 하드웨어 메 모리 문제를 발생시키며 정확도에 비해 지나치게 많은 자원을 낭비한다. 또한, 신경회로망의 깊이, 채널의 너비, 이미지의 해상도를 계속해서 높 일수록 정확도는 특정 부분에서 수렴하게 된다. 따라서 지금까지의 학습 모델은 하드웨어의 메모리, 연산 수행시간 등 제한된 자원 내에서 시행 착오 법을 통해 최적의 성능을 찾아야만 하였다^[32].

합성곱 신경회로망의 크기를 키우는 것은 정확도 향상을 위해 중요하 지만 어떻게 크기를 키워야 하는지에 대한 이해가 부족하므로 한정된 자 원 내에서 기준이 없는 시행착오 법은 비효율적이며 최적 성능 평가가 어렵다는 문제가 존재한다. 이 문제를 해결하기 위하여 본 연구에서는 CSM을 적용한 EfficientNet을 제안한다.

CSM을 적용한 EfficientNet에서는 Fig. 2.13 (e)와 같이 신경회로망의 깊 이와 채널의 너비, 이미지의 해상도를 Compound coefficient를 통해 조절 하여 효율적인 네트워크 구조를 찾아낸다^[33]. 예측모델의 정확도를 높이 기 위하여 합성곱 모델의 크기를 조정할 때 식 (2.11)과 같이 신경회로망 의 깊이, 채널의 너비, 이미지의 해상도 차원 사이의 비율을 조정한다.

depth :
$$d = \alpha^{\phi}$$
,
width : $w = \beta^{\phi}$,
resolution : $r = \gamma^{\phi}$
s.t. $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \ (\alpha \ge 1, \beta \ge 1, \gamma \ge 1)$

$$(2.11)$$

여기서 φ는 Compound coefficient를 나타내며 사용 가능한 자원의 크기에 따라 적절히 선택할 수 있다. 사용할 수 있는 자원을 신경회로망의 깊이, 채널의 너비, 이미지의 해상도에 따라 α, β, γ에 할당한다. 일반 합성곱 모델에서의 FLOPS(Floating-point operations per second)는 깊이에 비례해 서 배로 증가할 때 너비와 해상도는 가로와 세로가 각각 곱해져 제곱 배 로 증가하므로 α·β²·γ²에 비례한다.

본 논문에서는 Fig. 2.14의 구조를 갖는 EfficientNet-B0 모델을 선택하 여 표면가공성 예측모델에 적용하였다. EfficientNet-B0 모델은 AutoML(Auto machine learning) 프로그램을 통해 최적화된 모델로서 가벼우면서도 높은 정확도를 나타내며 일반화가 용이하다. 여기서 AutoML은 신경회로망의 구조를 직접 설계하는 대신 학습을 통해 최적의 구조를 탐색하여 학습하 는 방법을 의미한다. 또한, CSM을 적용한 EfficientNet은 강화학습으로 최적의 모델을 찾는 MnasNet 구조를 사용하였다. MnasNet에서 사용하는 MBConv 구조를 기본 블록으로 사용하여 이미지의 특징을 추출하고 Softmax 활성화함수를 활용하여 이미지를 분류한다.





Operator	stride	kernel size	Resolution	#Channels
Input image			224×224	
Conv 3×3	2		224×224	32
Batch normalization			()	
Swich				
			112, 112	16
MBConvI		3×3	112×112	16
MBConv6 MBConv6	2	3×3	112×112	24
MBConv6		ON		
MBConv6	2	5×5	56×56	40
MBConv6			- V	
MBConv6 MBConv6	2	3×3	28×28	80
MBConv6				
MBConv6	1	5×5	14×14	112
MBConv6				5
MBConv6 MBConv6				
MBConv6	2	5×5	14×14	192
MBConvo	2	Tan	T W	
MBConv6		3×3	7×7	320
Conv 1×1	1		7×7	1280
Batch normalization				
Swish				
Average pooling			7×7	1280
Dropout				
Linear			7×7	1280
• Output categorization				

Fig. 2.14 EfficientNet with CSM architecture

3. 자기 수송체 과도구조해석 시뮬레이션

3.1 자기 수송체 과도구조해석 시뮬레이션 설계

본 연구에서는 Ansys workbench 소프트웨어의 과도구조해석을 통해 자 기 수송체 회전연마공정에서의 Ni-Ti 합금 표면가공성 평가를 위한 시뮬 레이션을 수행하였다. 자기 수송체 회전연마공정에서 자기 수송체인 구 형상의 STS304가 연마재의 수송체 역할을 하며 공작물과 연마재가 접촉 할 때 표면연마가 진행되므로 자기 수송체에 작용하는 원심력을 고려할 수 있는 과도구조해석을 활용하고자 한다.

불필요한 해석 시간을 단축하고 자원을 절약하기 위하여 Fig. 3.1과 같 이 Ni-Ti 합금 공작물의 국소평면을 관심 영역으로 설정하였다. Table 3.1^[34]과 Table 3.2는 각각 Ni-Ti 합금 공작물과 자기 수송체의 물성치를 나타낸 것이며 Table 3.3은 시뮬레이션에 적용된 Ni-Ti 합금 판재와 총 15개의 STS304 재질의 구형 자기 수송체의 조건을 나타낸 것이다. 공작 물의 관심 영역인 접촉평면에서 해석 결괏값의 정확도를 향상시키기 위 하여 격자 크기를 0.25mm로 가정하였고, 초기 자기 수송체와 공작물 사 이의 거리는 모두 1mm로 가정하였다. 자기 수송체와 회전 중심 사이의 거리는 정적자기해석을 통해 자속밀도 값이 가장 크게 나타난 구간인 60~70mm 사이에 2.5mm 간격으로 배치하였다. 또한, 자기 수송체는 표면 연마가 이루어지는 수조 바닥면으로부터 각각 1, 2, 3mm 위치에 배치하 여 초기 위치 분포를 고르게 하였다. Table 3.4에서 나타나듯 각 모델의 노드와 요소의 개수는 표면가공성 평가의 정확도 향상을 위하여 공작물 의 접촉 표면을 가장 촘촘하게 구성하였으며 시뮬레이션은 각각의 공정 조건에서 자기 수송체들이 공작물과 충분히 접촉할 수 있도록 0.01초 동 안의 해석을 수행하였다. 또한, 본 시뮬레이션은 공작물이 고정된 상태에 서 자기 수송체의 운동상태를 해석하므로 접촉 표면을 제외한 공작물 표 면의 경계조건을 Frictionless support로 설계하였다. 아크릴 수조 내부에서 자기 수송체는 수조 바닥면과도 접촉하며 연마가 진행되므로 수조 바닥 면을 모델링하여 공작물 표면과 수직 방향으로 고정하였다.

Table 3.5는 과도구조해석 시뮬레이션에 적용한 공정 인자와 수준을 나타낸 것이다. 선행연구를 통해 자기 수송체 회전연마공정에서 표면가 공성에 가장 큰 영향을 미치는 자기 수송체의 직경과 디스크의 회전속도 를 공정 인자로 선정하였다. 자기 수송체의 직경은 선행연구를 바탕으로 0.5, 0.8, 1.0mm의 3수준으로 설계하였다. 회전속도는 실험 기기의 사양 을 고려하여 50rpm부터 900rpm까지는 50rpm 간격, 900rpm에서 1,800rpm 까지는 100rpm 간격의 27수준으로 설계하였다. 따라서 자기 수송체의 직 경과 회전속도의 수준에 따라 총 81번의 시뮬레이션을 수행하였다.

A H DI M



Fig. 3.1 Area of interest in the finite element model

Properties	Value		
Density (g/cm ³)	6.45		
Young's modulus (GPa)	30		
Poisson's ratio	0.33		
Yield strength (MPa)	195		
Ultimate tensile strength (MPa)	895		
Elongation of failure (%)	25		

Table 3.1 Properties of Ni-Ti alloy

Table 3.2 Properties of STS304

Properties	Value		
Density (g/cm ³)	8.00		
Shear modulus (MPa)	77,000		
Poisson's ratio	0.29		
Yield strength (MPa)	215		
Ultimate tensile strength (MPa)	505		

FISI

Parameter		Condition	
Workpiece	Material	Ni-Ti shape memory alloy	
	Interest area(mm ²)	6×4	
	Mesh size(mm)	0.25	
Magnetic transporter	Material	STS304	
	Shape	Sphere-shaped	
Step end time(sec)		0.01	
Initial distance from workpiece(mm)			
Distance from center(mm)		60~70	
Distance from base plate(mm)		1~3	

Table 3.3 Fixed conditions for simulation

Items		Nodes	Elements
Workpiece		7,230	1,350
Base plate		5,299	900
Magnetic transporter	0.5mm	409	201
	0.8mm	366	178
	1.0mm	382	184

Table 3.4 Nodes and elements of simulated model

Table 3.5 Simulated t	factor and leve	el		RSIT	
Factor		Level			
		CH O	T	2	3
Diameter of the magnetic transporter(mm), A		0.5	0	.8	1.0
Rotational velocity(rpm), B	Range	50~900 90		00~1,800	
	Increment	50			100

3.2 시뮬레이션 결과 및 표면 이미지 점수화

3.2.1 표면 이미지 점수화

Fig. 3.2와 같이 시뮬레이션에서 고려한 자기력, 저항력, 원심력 등이 자기 수송체에 작용하면 공작물 표면에는 압력이 발생한다. 구형 자기 수송체와 평면 Ni-Ti 합금 공작물은 점 접촉을 하며, 시뮬레이션 결과 응 답의 정확성은 격자 밀도에 따라 큰 차이를 보이므로 공작물 표면 전체 의 격자 밀도를 높여 정확한 압력 값을 해석하는 것은 정확도가 낮으며 비효율적이다. 따라서 표면에 발생한 압력 값이 아닌 자기 수송체와 연 마재가 공작물 표면에 접촉하는 시간, 접촉분포와 접촉 시 공작물에 가 해지는 충격량의 크기 등 3가지 요인을 동일한 가중치로 고려하여 Ni-Ti 합금 공작물의 표면가공성을 평가하였다.

과도구조해석 결과를 바탕으로 표면가공성을 평가하기 위하여 공작물 의 접촉 영역을 4영역으로 나누어 표면 이미지를 점수화하였다. 먼저 각 영역에서 자기 수송체가 공작물의 표면가공을 위해 접촉한 시간을 기준 으로 접촉분포를 고려하였다. 접촉시간과 접촉분포는 각각 2개의 구간으 로 구성하여 점수화하였다. 접촉분포는 각 영역 데이터 간의 표준편차로 평가하였으나 각 영역 데이터 간의 표준편차는 접촉시간의 크기에 따라 일정하지 않다. Min-Max scaling method를 사용하면 모든 접촉시간 데이 터의 중요도를 일정하게 반영할 수 있으므로 각 영역의 접촉시간을 식 (3.1)의 Min-Max scaling method를 사용하여 0부터 1 사이의 값으로 정규 화하였다.

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \tag{3.1}$$

여기서 X_{\min} 은 각 영역의 최소접촉시간 데이터, X_{\max} 는 최대접촉시간 데 이터를 나타내며 모든 X'값은 [0, 1] 범위 내에 존재한다. 정규화된 접촉 시간 데이터를 바탕으로 정규화된 표준편차를 계산하여 각 이미지의 접 촉분포에 대한 점수를 부여하였다.

또한, 식 (3.2)와 같이 자기 수송체가 공작물과 접촉할 때 자기 수송체 의 속도 변화를 계산하여 공작물에 가해진 충격량 *I*의 크기를 분석하여 3개의 구간으로 나누어 점수화할 수 있다.

$$I = \overrightarrow{F_m} \Delta t = m \overrightarrow{v_f} - m \overrightarrow{v_i}$$
(3.2)

여기서 $\overrightarrow{F_m}$ 은 자기 수송체에 작용하는 힘, Δt 는 접촉시간, $\overrightarrow{v_i}$ 와 $\overrightarrow{v_f}$ 는 각 각 접촉 전 속도와 접촉 후 속도를 나타낸다.

Table 3.6은 표면가공성을 점수화한 기준범위를 나타낸다. 접촉시간이 길수록 표면연마가 활발히 진행되며 접촉분포의 표준편차가 작을수록 고 른 분포를 보이므로 이때 높은 점수를 부여하였다. 충격량의 크기가 지 나치게 큰 경우 자기 수송체가 공작물 표면과 접촉하며 압입자국이 남아 표면가공성에 부정적인 영향을 미치므로 감점하는 반면 충격량의 크기가 작은 경우 자기 수송체와 연마재 모두 표면연마를 위한 충분한 운동이 발생하지 않으므로 점수를 부여하지 않았다. 자기 수송체의 직경과 회전 속도에 따른 표면가공성 점수는 Table 3.7과 Fig. 3.3과 같이 산출된다.



Fig. 3.2 Force diagram on the magnetic transporter in simulation

	Score			
Factor	-1	0	1	
Contact time(msec), C	-	$0 \le C \le 1$	$1 \le C$	
Distribution, D	-	$0.5 \le D \le 1$	$0 \le D \le 0.5$	
Impulse($\mu N \cdot s$), F	0.10≤F	$0 \le F \le 0.02$	$0.02 \le F \le 0.10$	

Table 3.6 Scoring criterion range



Fig. 3.3 Image score of surface finishing process

Factor		A(mm)				
		0.5	0.8	1.0		
	50	1	2	2		
	100	1	2	3		
	150	1	2	3		
	200	0	1	3		
	250	1	3	3		
	300	1	3	3		
	350	1	3	3		
	400	0	3	2		
	450	0	3	2		
	500	<u>)</u> 1	3	0		
	550	1	3	0		
	600	1	3	2		
	650	1	3	0		
B(rpm)	700	0	3	1		
	750	0	3	0		
	800		3	0		
	850	0	3	0		
	900	1	2	0		
	1,000	P	3	0		
	1,100	1	2	1		
	1,200	1	-1	1		
	1,300	0	-1	1		
	1,400	1	-1	0		
	1,500	2	-1	0		
	1,600	2	-1	0		
	1,700	1	0	0		
	1,800	1	0	0		

Table 3.7 Score data based on simulation results

3.2.2 직경에 따른 표면가공성 비교

점수화된 표면 이미지 데이터를 바탕으로 자기 수송체의 직경에 따른 표면가공성을 비교하였다. Fig. 3.4는 디스크의 회전속도와 관계없이 자 기 수송체의 직경 A 인자에 따른 공작물 표면과의 접촉시간, 분포, 충격 량의 크기를 비교한 것이다. 공작물 표면과 자기 수송체의 접촉시간은 자기 수송체의 직경이 1.0mm인 경우 평균 1.53msec로 나타나 직경이 커 질수록 접촉시간도 길어져 표면연마에 효과적임을 알 수 있었다.

또한 자기 수송체의 직경에 따른 접촉분포에 따른 표면가공성을 비교 한 결과, 접촉분포를 나타내는 표준편차의 값은 자기 수송체의 직경이 0.8mm인 경우 평균 0.423으로 가장 고른 분포로 접촉함을 알 수 있었다. 자기 수송체의 직경이 0.5mm로 지나치게 작은 경우 자기 수송체의 부피 가 작아 자기력의 영향을 적게 받으므로 상대적으로 중력의 영향을 크게 받아 수조 바닥면을 향해 분포가 치우치는 것을 확인할 수 있었다. 반면 자기 수송체의 직경이 1.0mm인 경우 평균 0.471로 직경을 기준으로 비 교하였을 때 가장 불균일한 분포로 접촉하는 것을 알 수 있었다. 이는 자기 수송체의 질량과 비례하여 원심력이 크게 작용하므로 디스크 외측 으로 자기 수송체의 분포가 집중되었기 때문이다. 또한, 자기 수송체의 직경이 증가할수록 자기 수송체의 질량이 커지기 때문에 충격량의 크기 는 자기 수송체의 직경이 1.0mm일 때 가장 높게 나타났다.

Fig. 3.5와 같이 자기 수송체의 직경에 따른 표면연마효과를 표면 이미 지를 비교함으로써 판단 수 있다. 동일한 회전속도에서 비교하기 위하여 디스크의 회전속도를 650rpm으로 고정하였을 때, 직경이 0.5mm인 경우 Fig. 3.5 (a)와 같이 접촉시간이 짧고 불균일한 접촉분포 경향을 나타내었 고 직경이 0.8mm인 경우 Fig. 3.5 (b)와 같이 접촉시간이 길고 균일한 접 촉분포 경향을 나타내었다. Fig. 3.5 (c)의 직경이 1.0mm인 경우 접촉시간 은 길었으나 불균일한 접촉분포 경향을 보였다.





(a) Surface image data at 0.5mm



(c) Surface image data at 1.0mm

Fig. 3.5 Comparison of surface images by diameter at 650rpm

3.2.3 회전속도에 따른 표면가공성 비교

디스크의 회전속도에 따른 표면가공성을 비교하기 위하여 Fig. 3.6과 같이 자기 수송체의 직경에 관계없이 디스크의 회전속도 B 인자에 따른 접촉시간, 접촉분포의 표준편차, 충격량의 크기를 나타내었다. 공작물 표 면과 자기 수송체의 접촉시간은 회전속도가 커질수록 접촉시간이 짧아지 는 경향을 보인다. 회전속도가 250rpm인 경우 접촉시간은 평균 1.74msec 로 가장 길게 나타나 회전속도와 접촉시간은 대체로 반비례하는 것을 알 수 있었다. 충격량의 크기는 회전속도와 비례하여 증가하여 회전속도가 1,800rpm인 경우 가장 높게 나타났다. 하지만 접촉분포를 나타내는 표준 편차의 값은 회전속도가 높거나 낮은 경우 증가하거나 감소하는 경향을 보이지 않으므로 접촉분포는 회전속도와의 관련성이 미미하다고 판단할 수 있었다.

Fig. 3.7과 같이 디스크의 회전속도에 따른 표면 이미지 경향을 대표하 여 나타낼 수 있다. 동일한 자기 수송체의 직경에서 비교하기 위하여 자 기 수송체의 직경을 1.0mm로 고정하였을 때, 회전속도가 200rpm으로 낮 은 경우 Fig. 3.7 (a)와 같이 접촉시간이 길었으나 회전속도가 1,800rpm으 로 높은 경우 Fig. 3.7 (b)와 같이 접촉시간이 짧은 경향성을 보였다.

총 81가지 시뮬레이션 표면 이미지 데이터에서 접촉시간, 접촉분포, 충 격량의 크기에 따른 표면가공성을 비교해보았다. 표면가공성 점수는 Fig. 3.8 (a)에 도시된 바와 같이 직경이 1.0mm, 회전속도가 250rpm 조건일 때 접촉시간이 길고 균일한 분포로 공작물에 0.06μN·s의 충격량이 가해 져 높은 점수가 산출된 가공조건을 대표한다. 이는 직경이 1.0mm인 경 우 대체로 불균일한 접촉분포를 보였으나, 회전속도가 낮은 경우 균일한 접촉분포를 나타내었고 자기 수송체의 직경이 크지만, 회전속도는 낮아 적절한 충격량이 가해진 것으로 해석할 수 있다. 이와 반대로 Fig. 3.8 (b)와 같이 직경이 0.8mm, 회전속도가 1,500rpm 조건일 때 접촉시간이 짧고 접촉분포가 불균일하며 공작물에 가해진 충격량의 크기가 0.14µN·s 로 높아 표면에 부정적인 영향을 미칠 것이라 해석된 가공조건을 대표한 다. 직경이 0.8mm인 경우 평균적으로 접촉분포가 균일하게 나타나긴 하 였으나 회전속도가 지나치게 높은 경우 불균일한 접촉분포와 높은 충격 량이 나타난 것으로 판단된다.





Fig. 3.6 Surface integrity by the rotational velocity



(b) Surface image data at 1,800rpm

Fig. 3.7 Comparison of surface images by the rotational velocity at 1.0mm


(b) Contact time distribution at 1.0mm, 250rpmFig. 3.8 The minimum score and the maximum score conditions

4. 표면가공성 예측모델 개발

Ni-Ti 합금의 표면가공성 예측모델을 개발하기 위하여 데이터를 입력 하면 답이 출력되는 일반 프로그래밍 알고리즘이 아닌 데이터와 답을 입 력하면 규칙이 출력되는 딥러닝 알고리즘을 채택하였다. 앞서 수행한 총 81가지 시뮬레이션 결과 데이터를 입력 데이터로 이용하여 접촉시간, 접 촉분포와 충격량 기준에 따라 표면가공성을 점수화하여 다섯 그룹으로 분류한 결과를 출력하는 예측모델을 개발하였다.

일반적으로 학습 세트로 모델을 학습하고 테스트 세트로 모델을 검증 하는데 고정된 테스트 세트를 통해 모델의 성능을 검증하고 수정하는 과 정을 반복하게 되면 테스트 세트에 과적합 된다는 문제가 발생한다. 이 문제를 해결하기 위하여 입력 데이터를 학습 세트, 검증 세트와 테스트 세트로 나누어 교차 검증을 수행하였다. 교차 검증을 통해 모든 입력 데 이터 세트를 학습과 평가에 활용할 수 있으므로 데이터의 개수 부족으로 인한 과소 적합 문제를 방지할 수 있고 검증에 사용되는 데이터의 편향 을 방지할 수 있다.

본 연구에서는 자기 수송체 회전연마공정의 최적 가공조건을 판단하기 위하여 일반적으로 사용되는 CNN과 CSM이 적용된 EfficientNet을 활용 하여 시뮬레이션 조건에 따른 공작물의 표면가공성을 점수화하여 분류하 였다. 또한, 학습된 분류모델의 비교를 통하여 제안한 연마공정에 가장 적합한 예측모델을 제시하고자 한다.

4.1 CNN을 이용한 표면가공성 예측모델

시뮬레이션 이미지를 바탕으로 Table 4.1의 조건으로 CNN 예측모델을 구성하였다. 시뮬레이션 결과를 바탕으로 얻어진 데이터를 학습, 겸증데 이터로 8:2의 비율로 무작위로 분리하였다. 학습데이터는 예측모델 함수 를 적합시킬 데이터를 의미하며, 학습데이터를 적합시킨 함수를 검증시 킬 데이터를 검증데이터라고 한다. 예측성능을 평가하기 위한 성능 지표 로는 전체 데이터 중 실제로 잘 예측한 데이터의 비율을 의미하는 예측 정확도를 사용하였다. 학습데이터로부터 일부의 특정 정보만으로 결론을 도출하지 못하도록 규제하기 위하여 Dropout 기법을 사용하였다. 지정한 비율만큼의 유닛을 누락시켜 데이터의 값을 0으로 변경함으로써 과적합 을 방지할 수 있다. 전체 학습 세트를 여러 개의 소그룹으로 나누었을 때 하나의 소그룹에 속하는 데이터의 수를 Batch size라고 한다. 전체 학 습 세트를 그대로 신경회로망에 적용하면 자원을 비효율적으로 사용하게 되어 학습시간이 오래 걸리는 문제가 발생한다. 따라서 본 연구에서는 학습데이터를 3개의 Batch size로 나누어 자원을 효율적으로 사용함으로 써 빠르게 학습을 진행하였다.

학습시간과 자원을 효율적으로 사용하기 위하여 입력 이미지 데이터의 크기를 75×75로 변환하여 CNN 예측모델을 적용한 결과, Fig. 4.1과 같 이 총 71번의 Epoch에서 67번째 Epoch일 때 학습 세트의 예측정확도가 91.7%, 검증 세트의 예측정확도가 83.3%로 나타났다. CNN을 이용한 표 면가공성 예측모델은 학습 과정에서 예측정확도의 편차가 크고 검증 세 트의 예측정확도가 일정한 수준 이상으로 높아지지 않기 때문에 효과적 인 표면가공성 예측모델이라고 판단하기 어렵다.

Parameter		Condition	
Input image	Shape	(75, 75)	
	Color	NAL 3	
Validation split		0.20	
Dropout ratio		0.25	
Batch size		3 5	
Epoch		71	
Kernel size		(3, 3)	
Pool size		(2, 2)	
Activation function		ReLU, Softmax	
Padding		Same	

Table 4.1 Fixed conditions of the CNN model



Fig. 4.1 Learning graph of the CNN model

4.2 CSM을 이용한 표면가공성 예측모델

CSM을 이용한 예측모델을 Table 4.2의 조건으로 구성하였다. 학습할 수 있는 이미지 데이터가 많을수록 복잡한 예측모델에 적용하기 용이하 므로 Data augmentation 기법 중 Rotation을 적용하여 한정적인 데이터를 임의로 변형해 데이터의 수를 증가시켰다. 데이터 분할을 통해 예측모델 의 과적합 정도를 판단할 수 있으므로 얻어진 데이터를 학습, 검증, 테스 트데이터로 8:1:1의 비율로 나누었다. 이론적으로 제안한 방법론이 어떤 성능을 보유하고 있는지 측정만 하는 것이 아니라 예측모델을 실제 데이 터에 적용하여 성능을 측정하기 위하여 학습 과정에 참여하지 않았던 테 스트데이터를 활용하였다.

점수화한 이미지 데이터를 바탕으로 CSM을 적용한 EfficientNet 예측 모델 결과, Fig. 4.2와 같이 총 71번의 Epoch에서 58번째 Epoch일 때 학 습 세트의 예측정확도가 98.4%, 검증 세트의 예측정확도가 93.8%로 가장 높은 분류정확도를 나타내었다. 학습된 예측모델을 통해 학습에 사용되 지 않은 새로운 공정조건에서의 표면가공성을 평가하기 위하여 테스트 세트에 예측모델을 적용하였다. 예측결과 Fig. 4.3과 같이 예측정확도 94.1%로 사전에 학습되지 않은 공정조건에 대한 시뮬레이션에도 높은 정확도로 표면가공성 예측이 가능함을 확인할 수 있었다.

따라서 CNN 예측모델을 사용하였을 때보다 CSM을 적용하였을 때 AutoML 프로그램을 활용하기 때문에 시행착오를 거치지 않고 더 높은 예측정확도를 얻을 수 있어 점수화된 이미지 분류를 통한 표면가공성 예 측모델로 적합함을 알 수 있었다.

Parameter		Condition	
Input image	Shape	(75, 75)	
	Color	3	
Data split ratio (Training : Validation : Test)		8:1:1	
Dropout ratio		0.2	
Batch size		3 6	
Epoch		71	
$lpha,\ eta,\ \gamma$		1.0, 1.0, 1.4	
Data augmentation		Rotation 180°	
Activation function		Swish	
Padding		Same	

Table 4.2 Fixed conditions of the CSM model



Fig. 4.2 Learning graph of the CSM model



Fig. 4.3 Test result of the CSM prediction model

4.3 실험을 통한 시뮬레이션 검증

파도구조해석 시뮬레이션을 수행하여 얻은 데이터를 바탕으로 Ni-Ti 합금의 표면가공성을 점수화하였다. 시뮬레이션 결과를 바탕으로 점수화 된 이미지가 실제 실험에서 적합한지 검증하기 위하여 검증 실험을 수행 한다. Photo. 2.3에서 나타낸 실험장치는 AC모터와 영구자석이 부착된 회 전 디스크, 표면연마가 진행되는 수조, 컨트롤러로 구성된다. 회전 디스 크는 2장에 나타낸 바와 같이 12개의 영구자석을 배열하였다. 영구자석 간 거리는 65mm, 아크릴 수조 내부 직경은 360mm, 수조의 높이는 200mm이다. 실험 시 공작물의 크기가 50mm × 35mm × 3mm인 경우 2 *l*의 연마액 내에서 자기 수송체의 양을 0.5kg으로 고정하였으며 실험은 5분 동안 수행되었다. 공작물 시편의 초기 표면거칠기 *R_a*는 0.10µm로 디스크 샌더 등을 이용하여 전처리하였다. 검증 실험 전후 공작물의 표 면가공성을 평가하기 위하여 Photo. 4.1의 표면 조도계(SJ-301, Mitutoyo) 를 사용한다. 표면거칠기 측정 시 Fig. 4.4와 같이 공작물 표면의 중앙과 좌우에서 각각 10번씩 측정함으로써 측정값의 신뢰도를 높일 수 있다.

CSM을 적용한 합성곱 신경회로망 예측모델에 의해 선정된 자기 수송 체 회전연마공정조건에 대하여 검증 실험을 Table 4.3과 같이 2가지로 수행한다. 1번 실험은 예측모델에서 표면가공성 점수가 3점으로 예측된 공정조건이고 2번 실험은 예측모델에서 접촉 시 충격량의 크기가 지나치 게 커 표면가공성에 부정적인 영향이 예측된 공정조건이다.

실험 전후 Ni-Ti 합금 공작물의 표면거칠기를 통해 예측모델의 신뢰성 을 평가하였다. 1번 실험결과, 표면거칠기 R_a 가 평균 0.08 μ m로 개선되었 으나 2번 실험에서는 표면거칠기 R_a 가 평균 0.14 μ m로 증가하였다. 이는 공작물 표면에 과도한 충격량이 가해져 표면에 자기 수송체에 의한 압흔 이 발생한 것으로, 표면상태에 부정적인 영향을 미쳤음을 확인할 수 있 었다. 이러한 결과로부터 자기 수송체의 직경과 회전속도에 따라 표면가 공성에 영향을 미침을 알 수 있었고, 본 연구의 시뮬레이션 결과에 따른 예측모델의 신뢰성을 확인할 수 있었다.





Fig. 4.4 Measuring points on workpiece



Table 4.3 Experimental verification at optimal and arbitrary condition

Experiment No.	Experiment	Surface roughness			
	A(mm)	B(rpm)	Ra(μ m)		
1	1.0	250	0.08		
2	0.8	1,500	0.14		
W 3 CH OL IN					

5. 결론

본 연구에서는 Ni-Ti 합금의 표면가공성 개선을 위하여 자기 수송체 회전연마공정을 제안하였다. 이 공정에서 최적의 가공조건 선정을 위하 여 고가의 Ni-Ti 합금 시편으로 수많은 실험을 수행하는 것은 경제적이 지 않으므로 실험에 앞서 과도구조해석 시뮬레이션을 수행하였다. 시뮬 레이션 결과 이미지를 바탕으로 접촉시간과 접촉분포, 충격량의 크기를 기준으로 표면가공성을 점수화하였다. 또한, 기존의 시행착오 법을 통한 CNN 예측모델과 CSM을 적용한 EfficientNet 예측모델을 비교하여 분류 정확도가 우수한 예측모델을 개발하였다. 본 연구에서 얻어진 결론은 다 음과 같다.

(1) 자기 수송체 회전연마공정의 과도구조해석 시뮬레이션 결과, 자기 수송체의 직경이 증가할수록 접촉시간이 증가하여 직경이 1.0mm일 때의 평균 접촉시간은 1.53msec로 표면연마에 효과적임을 알 수 있었다. 또한, 접촉분포를 나타내는 표준편차의 값은 직경이 0.8mm인 경우 평균 0.423 으로 가장 고른 분포로 접촉하는 반면 직경이 1.0mm인 경우 표준편차의 값은 평균 0.471로 비교적 불균일한 분포로 접촉하는 것을 알 수 있었다.

(2) 자기 수송체의 회전속도와 공작물과의 접촉시간은 반비례함을 알
수 있었다. 회전속도가 250rpm인 경우 평균 접촉시간이 1.74msec로 가장
길게 나타났으며 회전속도가 1,800rpm인 경우 평균 접촉시간이 0.74msec
로 가장 짧게 나타났다. 하지만 접촉분포를 나타내는 표준편차의 값은

회전속도가 높거나 낮은 경우 증가하거나 감소하는 경향을 보이지 않으 므로 접촉분포는 회전속도와의 관련성이 미미하다고 판단된다.

(3) 공작물 표면에 작용하는 충격량의 크기는 자기 수송체의 직경이
1.0mm, 회전속도가 1,800rpm인 경우 0.40μN·s로 가장 큰 값을 보여 직경
과 회전속도에 비례하여 증가하는 것을 알 수 있었다.

(4) 기존의 시행착오 법을 거친 CNN 예측모델과 CSM을 사용해 시행 착오 없이 적용한 EfficientNet 예측모델을 비교한 결과, CNN 예측모델의 학습 및 검증 정확도는 각각 91.7%와 83.3%, EfficientNet 예측모델의 학 습 및 검증 정확도는 각각 98.4%와 93.8%로 나타났다. 따라서 CSM을 적용한 EfficientNet 예측모델이 자기 수송체 회전연마공정의 최적 가공조 건 선정을 위한 예측모델로 가장 적합함을 알 수 있었다. 또한, 학습에 참여하지 않은 테스트 세트에서의 정확도가 94.1%로 나타나 새로운 공 정조건에서도 CSM을 적용한 EfficientNet 예측모델이 표면가공성을 우수 한 정확도로 예측할 수 있을 것이라 판단할 수 있었다.

REFERENCES

- R. Ran, L. Zhao, V. V. Silberschmidt, H. Willcock and F. Vogt, "Pioneering personalised design of femoropopliteal nitinol stents", Materials Science and Engineering: C, Vol. 130, No. 1, pp. 112462, 2021.
- T. Nath and S. Kumar, "Nitinol shape memory alloy spring", Indian Journal of Engineering and Materials Sciences, Vol. 28, No. 5, pp. 446-453, 2021.
- R. Chakraborty, S. Datta, M. S. Raza and P. Saha, "A Comparative study of surface characterization and corrosion performance properties of laser surface modified biomedical grade nitinol", Applied Surface Science, Vol. 469, No. 1, pp. 753-763, 2019.
- H. Huang, "A study of high-speed milling characteristics of nitinol", Materials and Manufacturing Processes, Vol. 19, No. 2, pp. 159-175, 2004.
- J. V. Mwangi, V. D. Bui, K. Thuesing, S. Hahn, M. F. X. Wagner and A. Schubert, "Characterization of the arcing phenomenon in micro-EDM and its effect on key mechanical properties of medical-grade Nitinol", Journal of Materials Processing Technology, Vol. 275, No. 1, pp. 116334, 2020.
- C. H. Fu, J. F. Liu, Y. B. Guo and Q. Z. Zhao, "A comparative study on white layer properties by laser cutting vs. electrical discharhe machining of Nitinol shape memory alloy", Procedia CIRP, Vol. 42, No.

1, pp. 246-251, 2016.

- J. Guo, K. L. Au, C. N. Sun, M. H. Goh, C. W. Kum, K. Liu, H. Sunzuki and R. Kang, "Novel rotating-vibrating magnetic abrasive polishing method for double-layered internal surface finishing", Journal of Materials Processing Technology, Vol. 264, No. 1, pp. 422-437, 2019.
- D. V. De Pellegrin and G. W. Stachowiak, "Simulation of three-dimentional abrasive particles", Wear, Vol. 258, No. 1, pp. 208-216, 2005.
- T. P. Nguyen, S. Choi, S. J. Park, S. H. Pack and J. Yoon, "Inspecting method for defective casting products with convolutional neural network (CNN)", International Journal of Precision Engineering and Manufacturing-Green Technology, Vol. 8, No. 2, pp. 583-594, 2021.
- R. Zatarain Cabada, H. Rodriguez Rangel, M. L. Barron Estrada and H. M. Cardenas Lopez, "Hyperparameter optimization in CNN for learning-centered emotion recognition for intelligent tutoring systems", Soft Computing, Vol. 24, No. 10, pp. 7593-7602, 2020.
- S. Bagehorn, J. Wehr and H. J. Maier, "Application of mechanical surface finishing processes for roughness reduction and fatigue improvement of additively manufactured Ti-6Al-4V parts", International Journal of Fatigue, Vol. 102, No. 1, pp. 135-142, 2017.
- V. Grover and A. K. Singh, "Modelling of surface roughness in a new magnetorheological honing process for internal finishing of cylindrical workpieces", International Journal of Mechanical Sciences, Vol. 144, No. 1, pp. 679-695, 2018.
- 13. A. Kumar, Z. Alam, D. A. Khan and S. Jha, "Nanofinishing of

FDM-fabricated components using ball end magnetorheological finishing process", Materials and Manufacturing Processes, Vol. 34, No. 2, pp. 232-242, 2019.

- 14. E. S. Lee, T. H. Shin. B. K. Kim and S. Y. Beak, "Investigation of short pulse electrochemical machining for groove process in Ni-Ti shape memory alloy", International Journal of Precision Engineering and Manufacturing, Vol. 11, No. 1, pp. 113-118, 2010.
- J. Kozak and M. Zybura-Skrabalak, "Some problems of surface roughness in electrochemical machining (ECM)", Procedia Cirp, Vol. 42, No. 1, pp. 101-106, 2016.
- 16. Y. Deng, T. Zhao, G. Zhao, Y. Gao, G. Liu and G. Wang, "Study on magnetic abrasive finishing of the inner surface of Ni-Ti alloy cardiovascular stents tube", The International Journal of Advanced Manufacturing Technology, Vol. 118, No. 7, pp. 2299-2309, 2022.
- N. Rodriguez, L. Vázquez, I. Huarte, E. Arruti, I. Tabernero and P. Alvarez, "Wire and arc additive manufacturing: a comparison between CMT and TopTIG processes applied to stainless steel", Welding in the World, Vol. 62, No. 5, pp. 1083-1096, 2018.
- P. Hariharan, "Evaluation of 3D surface roughness in electrochemical micromachining of Nitinol", Surface Topography: Metrology and Properties, Vol. 9, No. 4, pp. 045012, 2021.
- 19. L. Cai, J. Gao and D. Zhao, "A review of the application of deep learning in medical image classification and segmentation", Annals of translational medicine, Vol. 8, No. 11, 2021.
- 20. Y. LeCun and Y. Bengio, "Convolutional networks for images, speech,

and time series", The handbook of brain theory and neural networks, Vol. 3361, No. 10, pp. 255-258, 1995.

- 21. L. Yao and J. Miller, "Tiny ImageNet classification with convolutional neural networks", CS 231N, Vol. 2, No. 5, pp. 8, 2015.
- S. Wu, S. Zhong and Y. Liu, "Deep residual learning for image steganalysis", Multimedia Tools and Applications, Vol. 77, No. 9, pp. 10437-10453, 2018.
- B. Syamsuri and G. P. Kusuma, "Plant disease classification using lite pretrained deep convolutional neural network in android mobile device", International Journal of Innovative Technology and Exploring Engineering, Vol. 9, No. 2, pp. 2796-2804, 2019.
- 24. Y. H. Kong, C. C. Zhu and L. L. Che, "Flower recognition in comples background and model pruning based on MobileNets", Science Technology and Engineering, Vol. 452, No. 19, pp. 89-93, 2018.
- 25. C. H. Karadal, M. C. Kaya, T. Tuncer, S. Dogan and U. R. Acharya, "Automated classification of remote sensing images using multileveled MobileNetV2 and DWT techniques", Expert Systems with Applications, Vol. 185, No. 1, pp. 115659, 2021.
- M. Abd Elaziz, A. Dahou, N. A. Alsaleh, A. H. Elsheikh, A. I. Saba and M. Ahmadein, "Boosting COVID-19 image classification using MobileNetV3 and Aquila optimizer algorithm", Entropy, Vol. 23, No. 11, pp. 1383, 2021.
- P. Bansal, R. Kumar and S. Kumal, "Disease detection in apple leaves using deep convolutional neural network", Agriculture, Vol. 11, No. 7, pp. 617, 2021.

- J. Pereira, J. Monteiro, J. Silva, J. Estima and B. Martins, "Assessing flood severity from crowdsourced social media photos with deep neural networks", Multimedia Tools and Applications, Vol. 79, No. 35, pp. 26197-26223, 2020.
- S. Zheng, L. J. Cornelissen, X. Cui, X. Jing, R. N. Veldhuis, M. Oudkerk and P. M. van Ooijen, "Deep convolutional neural networks for multiplanar lung nodule detection: Improvement in small nodule identification", Medical Physics, Vol. 48, No. 2, pp. 733-744, 2021.
- J. H. Cartwright, "Stokes' law, viscometry, and the Stokes falling sphere clock", Philosophical Transactions of the Royal Society A, Vol. 378, No. 1, pp. 20200214, 2020.
- J. Han, E. Shihab, Z. Wan, S. Deng and X. Xia, "What do programmers discuss about deep learning frameworks", Empirical Software Engineering, Vol. 25, No. 4, pp. 2694-2747, 2020.
- V. Passricha and R. K. Aggarwal, "PSO-based optimized CNN for Hindi ASR", International Journal of Speech Technology, Vol. 22, No. 4, pp. 1123-1133, 2019.
- M. Afif, R. Ayachi, Y. Said and M. Atri, "Deep learning based application for indoor scene recognition", Neural Processing Letters, Vol. 51, No. 3, pp. 2827-2837, 2020.
- R. DesRoches, J. McCormick and M. Delemont, "Cyclic properties of superelastic shape memory alloy wires and bars", Journal of Structural Engineering, Vol. 130, No. 1, pp. 38-46, 2004.