

금형의 절삭가공에서 이론 모형 기반 표면거칠기 예측 결과의 실험적 모형 전환을 위한 인공신경망 구축에 대한 연구

김지우^{1,3} · 이동원^{2,3} · 김종선³ · 김종수^{3,†}

국립한국교통대학교 기계공학과¹

인하대학교 기계공학과²

한국생산기술연구원 금형성형연구부^{3,†}

A Study on the Construction of an Artificial Neural Network for the Experimental Model Transition of Surface Roughness Prediction Results based on Theoretical Models in Mold Machining

Ji-Woo Kim^{1,3} · Dong-Won Lee^{2,3} · Jong-Sun Kim³ · Jong-Su Kim^{3,†}

Dept. of Mechanical Eng., Korea Nat'l Univ. of Transportation¹

Dept. of Mechanical Eng., Inha Univ.², Korea Inst. of Industrial Technology^{3,†}

(Received December 14, 2023 / Revised December 19, 2023 / Accepted December 31, 2023)

Abstract: In the fabrication of curved multi-display glass for automotive use, the surface roughness of the mold is a critical quality factor. However, the difficulty in detecting micro-cutting signals in a micro-machining environment and the absence of a standardized model for predicting micro-cutting forces make it challenging to intuitively infer the correlation between cutting variables and actual surface roughness under machining conditions. Consequently, current practices heavily rely on machining condition optimization through the utilization of cutting models and experimental research for force prediction. To overcome these limitations, this study employs a surface roughness prediction formula instead of a cutting force prediction model and converts the surface roughness prediction formula into experimental data. Additionally, to account for changes in surface roughness during machining runtime, the theory of position variables has been introduced. By leveraging artificial neural network technology, the accuracy of the surface roughness prediction formula model has improved by 98%. Through the application of artificial neural network technology, the surface roughness prediction formula model, with enhanced accuracy, is anticipated to reliably perform the derivation of optimal machining conditions and the prediction of surface roughness in various machining environments at the analytical stage.

Key Words: Artificial neural network, Mathematical model, Milling, Mold, Surface roughness

1. 서론

자동차의 자율주행 기술의 발전과 전자기기화에 발 맞추어 차량용 내부 인포테인먼트 최적화에 많은 투자가 이루어지고 있으며 운전자의 조작 편의성을 고려한 인체공학적 설계와 미래 지향성을 나타낼 수 있는 곡면 멀티 디스플레이가 차량용 인포

테인먼트 디스플레이로 각광 받고 있다. 곡면 멀티 디스플레이의 품질은 탑승자의 시각, 촉각 등 오감을 통해 판단할 수 있는 중요한 요소로 가공에 큰 신경을 기울여야 하는 부분이다.

곡면 멀티 디스플레이 글라스 성형은 금형 가공을 통해 이루어지며, 금형의 품질 요소 중 하나인 표면거칠기는 최종 제품의 품질 및 성능에 큰 영향을 미치게 되므로 금형 가공 시 중요하게 고려되어야 하는 요인이다.

금형 절삭가공에서 목표된 표면거칠기를 얻기 위해서는 일반적으로 절삭 모델 활용 절삭력 예측

† 교신저자: jskimgloria@kitech.re.kr

* 본 논문에 대한 저작권은 저자들에게 있으며 CC BY-NC-SA를 만족하는 조건으로 이용할 수 있습니다.

과 실험적 연구를 통한 가공 조건의 최적화에 의존하고 있다. 이러한 방법은 절삭 변수와 실제 표면거칠기의 상관관계를 직관적으로 유추하기 어렵기 때문에 변화하는 가공 환경에 대응한 다양한 가공 조건에서 실험이 필요하다. 더욱이 본 연구에서와 같은 마이크로 가공 환경에서는 미세 절삭 신호 검출의 어려움, 미세 절삭력 예측 표준모델의 미정립 및 가공소요경비의 증가 등 여러 요인이 해석모델과 실험을 통한 표면거칠기의 확보를 어렵게 하고 있다. 또한 최근 인공지능을 활용하는 산업분야가 증가하는 추세이지만 인공지능경망 구축을 위해 양질의 데이터 수집하는데 수많은 시간과 인력 및 비용이 소모되고 있어 기술 적용의 한계점이 존재한다.

본 연구에서는 이러한 한계를 극복하기 위해 절삭력 예측 모델이 아닌 표면거칠기 예측 수식을 활용한 절삭 조건별 표면거칠기 예측 결과의 실험 데이터 전환을 제안하였다. 또한 인공지능망 기술을 활용하여 표면거칠기 예측 수식 모델의 정확도를 향상하고자 하였다. 제안 방법의 검증 및 예측 모델의 정확도 향상을 위해, 선행 연구에서 확보된 가공 조건 별 실제 표면거칠기 데이터와 제안된 방법을 통한 표면거칠기 예측 데이터를 비교하였다. 이 후 오차 범위를 도출 하고 인공지능망 학습을 통하여 표면거칠기 예측 수식 모델의 오차를 감소하였으며, 결과적으로 예측 모델의 정확도를 98% 이상 향상 수준을 확보하였다. 인공지능망 기술을 통해 정확도가 확보된 표면거칠기 예측 수식 모델은 다양한 가공 환경에서의 최적 가공 조건의 도출 및 표면거칠기 예측을 해석적 단계에서 신뢰성 있게 수행될 것으로 사료된다.

2. 금형 절삭가공 데이터 수집

2.1. 금형 절삭가공 실험 데이터 수집

금형 절삭 가공 데이터를 수집하기 위해 Fig. 1과 같은 Roders 사의 3축 고속 정밀 가공기인 RXP 801 Z2를 사용하였으며, 공구는 Table 1과 같이 0.2mm의 직경을 가진 2날 CBN Ball End Mill을 사용하였다.

Mist typed의 절삭유와 함께 Fig. 2과 같은 형상의 STAVAX 강으로 구성된 시편을 패턴과 평행한 방향인 x방향으로 Case 당 1개 공구, 총 9개 공구를 사

용하여 가공을 진행하였으며, Feed rate, Radial Depth of Cut의 조건을 Table 2과 같이 STAVAX 강을 가공할 때의 가이드라인에 따른 권장조건의 각각 40%, 70%, 100% 수준으로 가공을 진행하였다(1,2).

실험계획법에 의하여 각 가공조건에 표준 순서를 할당하며, 선택된 인자 외 기타 원인들의 영향이 실험결과에 편향되게 미치는 것을 방지하기 위하여 런(run) 순서는 랜덤화 하여 진행하였다.



Fig. 1 High-Speed Precision Machining 3-Axis CNC Machining Center (RXP 801 Z2, roders)

Table 1 Information of cBN ball endmill³⁾

| Geometry | | | |
|-----------------|---------|-----------------------|------|
| | | | |
| Model | SSPB220 | Radius [mm] | 0.1 |
| Tolerance | ball | Length of cut [mm] | 0.15 |
| Helix Angle [°] | 20 | Effective length [mm] | 0.6 |
| Shank Dia. [mm] | 4 | Total length [mm] | 50 |
| No. of flutes | 2 | Type of tool material | cBN |




Fig. 2 STAVAX specimen morphology

Table 2 Machining conditions

| cBN tool (recommended conditions) | Spindle speed, RPM | Feed rate, mm/min | Radial Depth of Cut, ap, mm |
|-----------------------------------|--------------------|-------------------|-----------------------------|
| Minimum (40%) | 42,000 | 320 | 0.002 |
| Medium (70%) | | 560 | 0.0035 |
| Maximum (100%) | | 800 | 0.005 |




Fig. 3 Olympus OLS5100 3D measuring laser microscope

절삭가공을 진행한 STAVAX 강 시편은 Fig. 3와 같은 Olympus사의 3차원 공초점 레이저 현미경을 사용하여 Table 2과 같은 권장조건 별 가공 변수를 조합하여 9개의 조건을 만들고, 1개의 조건당 총 9개 Point에 대해 표면 거칠기를 분석하여 총 81개 데이터를 확보하였다. 각 Point는 패턴 평면구간에 대하여 약 250 μ m 범위 3개 Line의 선 거칠기를 측정하였다.

2.2. 금형 절삭가공 이론 모형 데이터 수집

절삭가공을 진행한 STAVAX 강 시편을 절삭력 예측 모형이 아닌 표면거칠기를 예측하기 위한 이론 모형으로 Shahriar Jahan Hossain, Nafis Ahmad

(2012)에 의해 반응표면분석법(response surfaced method, RSM)에 따라 유도된 response surface equation 식(1)(4)으로 금형의 표면거칠기를 계산 및 산출하여 절삭가공 데이터 셋에 추가하였다.

$$R_a = 1.35355 + 0.0874799\phi + 0.000887986S \quad (1)^4$$

$$- 0.101501f_y + 7.92503f_x - 6.14303t$$

$$- 0.00320667\phi^2 - 1.20701 \times 10^{-7}S^2$$

$$+ 0.00122325f_y^2 + 9.91836f_x^2 + 10.5552t^2$$

$$+ 8.53234 \times 10^{-6}\phi S - 9.68995 \times 10^{-4}\phi f_y$$

$$+ 0.1357\phi f_x + 0.00848098\phi t + 3.41726$$

$$\times 10^{-5}Sf_y - 0.00576076Sf_x - 2.94529 \times 10^{-4}St$$

$$- 0.101860f_y f_x + 0.0719970f_y t - 12.5766f_x t$$

Table 3 Inclination Angle, Spindle Speed, Axial Depth of Cut

| | Inclination Angle | Spindle Speed | Axial Depth of Cut |
|-------|-------------------|---------------|--------------------|
| Value | 0° | 42,000 RPM | 0.006 mm |

식(1)에서 ϕ 는 Inclination Angle, S 는 Spindle speed 그리고 t 는 Axial Depth of Cut을 의미하며 본 연구에서는 Table 3와 같이 고정된 값을 가지는 변수로 지정하였다. f_y 는 Feed rate, f_x 는 Radial Depth of Cut을 의미하며, 본 연구의 절삭가공 과정에서 주된 영향을 미치는 변수로 Table 2에 의해 조합된 9가지의 값에 의해 계산되어 인공지능망 구축을 위한 데이터 셋으로 사용된다.

추가적으로 식(1)에서는 고려하지 않았던 가공 위치 변수를 데이터 셋에 지정하기 위해 가공지시서를 기반으로 유도한 식(2)을 사용하였다.

$$Run\ Time = \left(\frac{15}{f_y} \times 60 \times r\right) + \left(\left(\frac{15}{f_x} - 1\right) \times \frac{15}{f_y} \times 60 \times c\right) \quad (2)$$

식(2)에서 본 연구에 사용된 r 과 c 의 값은 Table 4에 따라 각 Point마다 지정되어 계산되어 인공지능망 구축을 위한 데이터 셋으로 사용된다.

Table 4 Point table for Run time equation

| $r \backslash c$ | 0 | 0.5 | 1 |
|------------------|------|------|------|
| 0 | Pt.1 | Pt.2 | Pt.3 |
| 0.5 | Pt.4 | Pt.5 | Pt.6 |
| 1 | Pt.7 | Pt.8 | Pt.9 |

3. 실험 데이터 전환 및 예측 모델 구축

3.1. 데이터 전환 및 예측 모델 학습

이론 모형을 통해 도출한 금형의 표면거칠기 결과를 실제 금형 절삭가공 실험 결과에 맞추어 유사 실험 데이터로 전환하기 위해 인공신경망 모델을 구축하였다. 인공신경망 모델의 학습에는 Fig. 4와 같이 입력 변수로 Feed rate, Radial Depth of Cut과 같은 공정조건 그리고 이론 모형에서의 금형의 표면거칠기, Run time을 사용하였으며 출력 변수로는 실제 금형 절삭가공 실험에서 수집한 금형의 표면거칠기를 사용하였다.

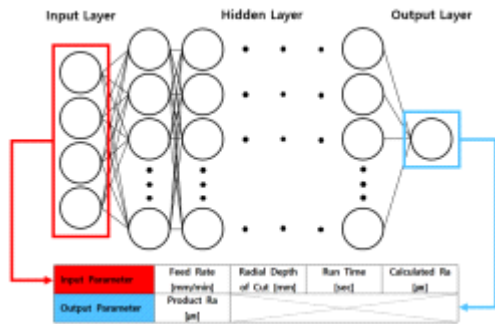


Fig. 4 Input and output parameters for convert model (Theoretical model to Experiment)

인공신경망을 구축하는데 사용한 데이터는 8:1:1 비율에 맞추어 각각 학습 데이터 셋(training data set), 검증 데이터 셋(validation data set), 테스트 데이터 셋(test data set)으로 구성하였다. 학습 데이터 9개 가공조건과 가공조건 당 9 point의 위치로 구성된 총 81개의 전체 실험 데이터 중에서 64개 조건을 사용하였다. 검증 데이터로는 학습 데이터로 사용되지 않은 데이터 셋 중에서 8개 조건을 임의로 선정해 데이터 셋을 사용하였다. 마지막으로 최종 모델의 성능 평가에 사용하기 위한 테스트 데이터는 학습 데이터와 검증 데이터로 사용되지 않은 나머지 9개 조건을 데이터 셋으로 사용하였다.

하이퍼밴드(Hyper-band)5 방법을 사용하여 인공신경망의 구조를 탐색하였다. Table 5와 같이 하이퍼 파라미터의 (hyper parameter) 탐색 범위를 지정하여 Table 6와 같은 최적의 하이퍼 파라미터를 추출하였다. 탐색한 하이퍼 파라미터를 사용하여 인공신경망의 성능(Performance)를 검증하고 학습시켜 전환 모델을 구축하였다^{6,7)}.

Table 5 Search range of hyper parameters

| Factor | Value |
|------------------------------|---|
| Optimizer | Adams ⁸⁾ |
| Learning rate | 0.0001-0.01 [step size 0.001] |
| Number of hidden layers | 1~5 [step size 1] |
| Max neuron | 1~10 [step size 1] |
| Activation | Elu (hidden layers) Linear (output layer) |
| Weight initializer | He normal (hidden layers) Glorot normal (output layer) |
| Drop number per hidden layer | 0.0-0.4 [step size 0.1] |
| Epochs | ~3000 |
| ETC | L2 normalization Batch normalization |

Table 6 Search result of hyper parameters

| Factor | Value |
|------------------------------------|---|
| Optimizer | Adams ⁸⁾ |
| Learning rate | 0.0074 |
| Number of hidden layers | 3 |
| Number of neurons per hidden layer | [6, 4, 4] |
| Activation | Elu (hidden layers) Linear (output layer) |
| Weight initializer | He normal (hidden layers) Glorot normal (output layer) |
| Drop number per hidden layer | [0.0, 0.0, 0.1] (hidden layers) |
| Epochs | 506 |
| ETC | L2 normalization Batch normalization |

3.2. 모델의 성능 평가

테스트 데이터를 사용하여 구축된 모델의 성능을 평가하였다. 테스트 데이터의 공정조건과 기존 이론 모형을 통해 계산된 표면거칠기와 Run time 결과를 입력 값으로 사용하여 금형의 표면거칠기를 도출하였다.

실험 데이터 전환 모델을 통해 도출된 표면거칠기를 테스트 데이터의 실제 금형 표면거칠기와 비교하였다. Table 7의 데이터 셋 조건을 기반으로 Fig. 5와 같이 이론 데이터를 실험 데이터로 전환하는 인공신경망의 성능을 평가하였다. 테스트 데이터를 활용한 전환 인공신경망의 성능을 평가하기 위해 금형의 표면거칠기 예측 값에 대한 RMSE(root mean square error)를 산출하였으며 0.01311mm를 확인하

였다. 이론 모형의 경우, RMSE 값이 1.0537 mm로 마이크로 가공에서 무시할 수 없는 값을 보였지만, 본 연구에서 구축한 인공신경망을 활용하여 이론 데이터를 실험 데이터로 전환하는 모형에서는 98.75% 정확도가 향상되어 결과를 확인하였다. 또한 전체 81개의 조건에 대한 이론 모형과 인공 신경

망 모형의 예측 결과를 비교한 Fig. 5에서도 이론 모형만 사용한 경우보다 이론 데이터를 실험 데이터로 전환하는 인공신경망을 같이 적용한 모형이 우수한 예측 결과를 나타내는 것을 확인하였다.

Table 7 Information of data set number

| No. | Feed rate | Radial Depth of Cut | Run time | No. | Feed rate | Radial Depth of Cut | Run time |
|-----|-----------|---------------------|----------|-----|-----------|---------------------|----------|
| 1 | 320 | 0.002 | 1 | 42 | 560 | 0.0035 | 6 |
| 2 | 320 | 0.002 | 2 | 43 | 560 | 0.0035 | 7 |
| 3 | 320 | 0.002 | 3 | 44 | 560 | 0.0035 | 8 |
| 4 | 320 | 0.002 | 4 | 45 | 560 | 0.0035 | 9 |
| 5 | 320 | 0.002 | 5 | 46 | 560 | 0.005 | 1 |
| 6 | 320 | 0.002 | 6 | 47 | 560 | 0.005 | 2 |
| 7 | 320 | 0.002 | 7 | 48 | 560 | 0.005 | 3 |
| 8 | 320 | 0.002 | 8 | 49 | 560 | 0.005 | 4 |
| 9 | 320 | 0.002 | 9 | 50 | 560 | 0.005 | 5 |
| 10 | 320 | 0.0035 | 1 | 51 | 560 | 0.005 | 6 |
| 11 | 320 | 0.0035 | 2 | 52 | 560 | 0.005 | 7 |
| 12 | 320 | 0.0035 | 3 | 53 | 560 | 0.005 | 8 |
| 13 | 320 | 0.0035 | 4 | 54 | 560 | 0.005 | 9 |
| 14 | 320 | 0.0035 | 5 | 55 | 800 | 0.002 | 1 |
| 15 | 320 | 0.0035 | 6 | 56 | 800 | 0.002 | 2 |
| 16 | 320 | 0.0035 | 7 | 57 | 800 | 0.002 | 3 |
| 17 | 320 | 0.0035 | 8 | 58 | 800 | 0.002 | 4 |
| 18 | 320 | 0.0035 | 9 | 59 | 800 | 0.002 | 5 |
| 19 | 320 | 0.005 | 1 | 60 | 800 | 0.002 | 6 |
| 20 | 320 | 0.005 | 2 | 61 | 800 | 0.002 | 7 |
| 21 | 320 | 0.005 | 3 | 62 | 800 | 0.002 | 8 |
| 22 | 320 | 0.005 | 4 | 63 | 800 | 0.002 | 9 |
| 23 | 320 | 0.005 | 5 | 64 | 800 | 0.0035 | 1 |
| 24 | 320 | 0.005 | 6 | 65 | 800 | 0.0035 | 2 |
| 25 | 320 | 0.005 | 7 | 66 | 800 | 0.0035 | 3 |
| 26 | 320 | 0.005 | 8 | 67 | 800 | 0.0035 | 4 |
| 27 | 320 | 0.005 | 9 | 68 | 800 | 0.0035 | 5 |
| 28 | 560 | 0.002 | 1 | 69 | 800 | 0.0035 | 6 |
| 29 | 560 | 0.002 | 2 | 70 | 800 | 0.0035 | 7 |
| 30 | 560 | 0.002 | 3 | 71 | 800 | 0.0035 | 8 |
| 31 | 560 | 0.002 | 4 | 72 | 800 | 0.0035 | 9 |
| 32 | 560 | 0.002 | 5 | 73 | 800 | 0.005 | 1 |
| 33 | 560 | 0.002 | 6 | 74 | 800 | 0.005 | 2 |
| 34 | 560 | 0.002 | 7 | 75 | 800 | 0.005 | 3 |
| 35 | 560 | 0.002 | 8 | 76 | 800 | 0.005 | 4 |
| 36 | 560 | 0.002 | 9 | 77 | 800 | 0.005 | 5 |
| 37 | 560 | 0.0035 | 1 | 78 | 800 | 0.005 | 6 |
| 38 | 560 | 0.0035 | 2 | 79 | 800 | 0.005 | 7 |
| 39 | 560 | 0.0035 | 3 | 80 | 800 | 0.005 | 8 |
| 40 | 560 | 0.0035 | 4 | 81 | 800 | 0.005 | 9 |
| 41 | 560 | 0.0035 | 5 | | | | |




Fig. 5 Prediction results of surface roughness by artificial neuron network

4. 결론

본 연구에서 금형의 표면거칠기 도출하는 금형 절삭가공 실험과 이론 모형을 통해 절삭 데이터를 수집하였다. 이론 모형 결과에서 도출된 금형의 표면거칠기와 절삭가공 중 Run time에 따른 위치 변수 계산 결과를 절삭가공 데이터로 전환하여 인공신경망 학습에 사용하여 표면 거칠기 예측 모델을 구축하고 성능을 평가하였고 다음과 같은 결과를 확인할 수 있었다.

1) 이론 모형을 통해 예측한 표면거칠기의 평균 오차는 0.91406mm 수준으로 마이크로 가공에서 무시할 수 없는 오차율을 보였지만 인공신경망을 통해 실험 데이터로 전환 후 학습된 데이터를 통해 0.00957mm 수준의 오차율로 98.56% 정확도 향상을 확인할 수 있었다.

2) 이론 모형을 통해 도출한 공정조건에 따른 금형의 표면거칠기를 금형 절삭가공 실험 데이터로 전환 및 예측 인공신경망을 구축한 결과 금형의 표면거칠기의 RMSE는 0.01311mm로 RMSE 1.05371mm를 보이는 이론 모형에 비하여 실제 금형 표면거칠기와 매우 비슷한 예측 결과 값을 보인다는 것을 확인하였다. 해당 결과에 따라, 본 연구에서 구축한 인공신경망을 통한 이론 모형과 금형 절

삭가공 실험 데이터간 전환으로 새로운 이론 모형을 개발하지 않고 다양한 가공조건을 기반으로 기존에 존재하던 여러 이론 모형의 예측 정확도 향상에 기여가 가능한 것을 확인할 수 있었다.

또한 추가 데이터 수집 없이 기존 이론 모형을 통한 정확도 향상이 가능함에 따라 많은 비용과 시간 그리고 인력이 소요되던 가공 데이터 수집 과정을 축소할 수 있어 산업의 부흥에 기여할 수 있을 것이라 판단된다.

후기

본 연구는 2023년도 산업통상자원부의 ‘기계산업 핵심기술개발 (No. 20023669, KM230303)’ 사업의 지원을 받아 연구되었습니다.

참고문헌

- 1) Lee, D. W., Lee, H. H., Kim, J. S., Kim, J. S., A Study on the Surface Roughness Analysis by Cutting Condition in Machining of STAVAX mold for Vehicle Light Guide, Korean Society of Mechanical Technology, Vol. 24:6, 1106-1112, 2022.
- 2) Lee, D. W., Lee, H. H., Kim, J. S., Kim, J. S., A

study on surface roughness depending on cutting direction and cutting fluid type during micro-milling on STAVAX steel, Design & Manufacturing, Vol. 17:2, 22-26, 2023.

- 3) Kim, J. S., A study on the surface roughness of STD11 material according to the helix angle of ball endmill, Design & Manufacturing, vol. 17:1, 33-39, 2023.
- 4) Hossain, M. S. J., Ahmad, N. Artificial intelligence based surface roughness prediction modeling for three dimensional end milling. Int. J. Adv. Sci. Technol., Vol. 45:8, 1-18. 2012.
- 5) Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., Talwalkar, A., Hyperband: A novel bandit-based approach to hyper-parameter optimization. J. Mach. Learn. Res. Vol. 18, 6765 - 6816. 2017.
- 6) Lee, J. H., Kim, J. S., A study on the construction of the quality prediction model by artificial neural intelligence through integrated learning of CAE-based data and experimental data in the injection molding process, Design & Manufacturing, Vol. 15:4, 24-31, 2021.
- 7) Lee, J. H., Kim, J. S., A study on the accuracy of multi-task learning structure artificial neural network applicable to multi-quality prediction in injection molding process, Design & Manufacturing, Vol. 16:3, 1-8, 2022.
- 8) Kingma, D. P., Ba, J., Adam: A method for stochastic optimization., arXiv, 2014.

저자 소개

김 지 우 (Ji-Woo Kim)



- 2018년 3월~현재: 한국교통대학교 기계공학과
- 2023년 7월~현재: 한국생산기술연구원 금형성형연구부분 현장실습생

< 관심분야 >

정밀가공, 최적설계, 진산역학

이 동 원 (Dong-Won Lee)



- 2017년 8월: 인하대학교 기계공학과 (공학석사)
- 2017년 9월~현재: 인하대학교 기계공학과 박사과정
- 2015년 3월~현재: 한국생산기술연구원 뿌리기술연구소 금형성형연구부분, 학연협동과정생

< 관심분야 >

정밀가공, 금형, CAE

김 종 선 (Jong-Sun Kim)



- 2005년 8월: 단국대학교 기계공학과 (공학박사)
- 2006년 3월~현재: 한국생산기술연구원 뿌리기술연구소 금형성형연구부분, 수석연구원

< 관심분야 >

사출성형 및 금형, 유동해석

김 종 수 (Jong-Su Kim)



- 2012년 2월: KAIST 기계공학과 (공학박사)
- 2012년 3월~2019년 1월: 삼성전자 MASK 개발팀, 책임연구원
- 2019년 1월~현재: 한국생산기술연구원 뿌리기술연구소 금형성형연구부분, 수석연구원

< 관심분야 >

정밀가공, 금형, 자동화