

뉴럴 네트워크를 이용한 밸브 부품 생산용 플런지 연삭의 거칠기 예측모델 개발

최정주¹, 박준홍^{2*}

¹동아대학교 고기능성밸브기술지원센터, ²동아대학교 신소형재가공청정공정개발연구센터

Development of Roughness Estimation Model for Plunge Grinding of Valve Parts Using Neural Network

Jeongju Choi¹ and Joon-Hong Park^{2*}

¹Technical Center for High-Performance Valves, Dong-a University

²Center for Advanced Net Shape Manufacturing and Clean Processes, Dong-a University

요 약 본 연삭공정은 제품의 품질 만족도를 충족시키기 위해 기계가공의 마지막단계에서 이루어지는 공정이다. 일반적으로 연삭된 공작물의 가공 표면은 연삭 조건 및 드레싱 조건에 의해 그 정도가 결정된다. 이리케 연삭된 공작물의 표면 거칠기를 예측하기 위해서 몇 가지 거칠기 모델들이 연구되었다. 기존의 모델들은 몇 가지 주요 파라미터를 선정하고 이들 파라미터를 곱의 형태로 모델을 만들어 그 파라미터의 영향도를 고려하였다. 그러나 이러한 파라미터간 곱의 형태는 복잡한 연삭 메커니즘을 나타내기에는 충분하지가 않다. 따라서 본 연구에서는 뉴럴네트워크 알고리즘을 이용하여 플런지 연삭의 연삭 모델을 제안하였다. 제안된 구조는 초기 거칠기 모델과 최종 거칠기 모델로 구성되어 있다. 제안된 뉴럴네트워크의 입력 파라미터는 기존의 거칠기 모델들의 것을 이용하였다. 제안된 모델의 거칠기 예측 성능은 실험을 통해 검증하였다.

Abstract Grinding process is executed in the final machining stage to meet the quality requirements. In generally the ground surface of workpiece is affected by dressing condition as well as grinding condition. In order to estimate the roughness of workpiece, the several roughness models have been researched. These models defined the specific parameters and considered the several parameters which affect to roughness as multiply relationship among them. However, the multiply relationship among parameters is not enough to show the complicated grinding mechanism. Therefore, the neural network algorithm is used in this paper to predict the ground roughness for the plunge grinding. The proposed structure is composed of the initial roughness as well as final roughness model. The input parameters of proposed neural network are referred with the existing roughness model's. The performance of the proposed model is verified through experiments.

Key Words : Neural Network, Grinding, Rognhness

기호

		d_{eq}	등가 지름 ($= \frac{d_w d_s}{d_w + d_s}$)
a	연삭깊이	s_d	드레싱 절입속도
d_w	연삭숫돌 지름	t_s	스파크아웃 시간
d_s	공작물 지름	v_w	연삭숫돌 회전속도

본 연구는 지식경제부 지정 지역혁신센터사업(RIC) 고기능성밸브기술지원센터 지원으로 수행되었음.

*교신저자 : 박준홍(acttom@dau.ac.kr)

접수일 10년 11월 15일

수정일 10년 12월 17일

게재확정일 11년 01월 13일

- v_s 공작물의 회전속도
- N_s 스파크아웃동안의 공작물의 회전수
- h_{eq} 등가 칩두께
- V'_w 누적 절삭량
- w 가공행렬

1. 서론

공작물의 기계 가공에 있어 연삭은 최종 단계에서 이루어지는 공정으로 이를 통해 가공물의 가공 정밀도 및 품질 요구 사항을 만족시킬 수 있다. 연삭 공정을 통해 얻을 수 있는 공작물의 표면 거칠기는 연삭 공정 전에 수행하는 드레싱(dressing) 및 연삭 조건에 의해 그 결과값이 결정된다. 연삭 조건 및 드레싱 조건에 의해 추정 가능한 공작물의 표면 거칠기는 많은 연구자들에 의해서 수학적 모델로써 개발되었다[1]. 수학적 모델을 개발하기에 앞서 공작물의 거칠기와 관련되는 연삭 조건들 중 연삭 후 공작물의 거칠기에 지배적 영향을 주는 인자들을 선정하고 이를 거칠기 모델의 파라미터로써 사용하였다. 또한 이러한 파라미터를 이용하여 연삭 공정 중에 소요된 가공 파워, 표면 거칠기 및 버닝(burning) 조건 등을 수학적 모델로써 개발하였다[1-3]. 이러한 모델들은 연삭 공정에 의한 공작물의 상태를 예측하거나, 연삭공정의 자동화를 위한 알고리즘 개발에 이용되었다[7,8,12]. 이 중 표면 거칠기는 연삭 가공 후 공작물의 품질과 직결되는 요소로써 이에 대한 연구가 활발히 이루어지고 있다. 지금까지 개발된 거칠기 모델식은 드레싱 직후 수행한 연삭에 의해 얻을 수 있는 초기 거칠기 모델 식과 가공이 진행됨에 따라 거칠기의 변화를 나타내는 모델식으로 구분되었다[3,4,9]. 일반적으로 초기 거칠기는 연삭에 앞서 연삭 스톨에 가해지는 드레싱 조건에 지배적인 영향을 받으며 이후 공작물의 거칠기는 연삭 조건에 영향을 받으며 변화하는 것을 알 수 있다[5,6]. 이러한 거칠기 특성을 묘사하기 위해 드레싱 깊이 및 드레서(dresser)의 이동 속도, 스톨 및 공작물의 회전속도, 연삭 깊이 등이 변수로 선정되어 표면 거칠기를 예측하였다. 그러나 이러한 기존의 거칠기 모델들은 연삭 환경의 변화에 적극적으로 대응하기는 어렵다[10,11]. 예를 들어 거칠기 모델의 변수간 영향 정도는 연삭 스톨이나 공작물의 열처리 정도에 따라 상이하여 그 계수를 선정하기 위해 매번 실험을 통해 결정하여야 하며 이러한 실험을 위한 준비 단계는 지루하며 긴 시간을 요구한다[1]. 따라서 본 논문에서는 인공지능 알고리즘 중 대표적인 뉴럴네트워크 알고리즘을


이용하여 변수 선정을 위한 실험 결과 및 실제 가공 시의 결과치를 계속하여 활용할 수 있는 모델을 제안하였다. 제안된 모델은 입력 변수로 드레싱 및 연삭 조건을 이용하여 초기 거칠기 값을 예측할 수 있도록 구성하였고, 연삭이 진행됨에 따라 변화하는 거칠기는 누적된 공작물의 가공량 및 연삭 조건을 변수로 이용하였다.

이후 논문의 구성은 2장에서 기존에 개발된 대표적인 거칠기 모델을 제시하고 본 논문에서 제안한 뉴럴네트워크 모델의 구조를 나타내었다. 제안된 모델의 성능은 실험을 통해 기존의 모델과 비교하였다. 끝으로 3장에서는 결론을 기술하였다.

2. 뉴럴 네트워크를 이용한 거칠기 모델

2.1 실험조건

거칠기 모델 개발을 위해 수행한 실험은 그림 1의 Supertec OD 사의 원통형 연삭기이다. 연삭을 위해 사용된 스톨은 32A60K-VBE이며 크기는 14''×5''×1.5'' 이다. 공작물은 AISI4140합금에 RC40의 열처리를 수행한 시편을 이용하였다. 공작물의 거칠기를 측정하기 위해서는 Mitutoyo사의 SJ-201 표면거칠기 측정기를 이용하였다. 기존에 제안된 초기 거칠기 모델과 본 논문에서 제안한 뉴럴네트워크 모델과의 결과 비교를 위해서 드레싱 및 연삭 조건은 표 1과 같이 선정하였다.



[그림 1] 실험을 위한 레이아웃

[표 1] 드레싱과 연삭 조건

	d_{eq} [mm]	a_d [mm]	S_d [mm/rev]	t_s [s]	v_w [m/min]	v_s [m/s]	a [mm]
1	34.42	0.015	0.04	1	20	28	0.0013
2	34.42	0.023	0.1	3	25	30.5	0.0038
3	34.42	0.03	0.16	5	30	33	0.0064

4	49.24	0.015	0.04	3	25	33	0.0064
5	49.24	0.023	0.1	5	30	28	0.0013
6	49.24	0.03	0.16	1	20	30.5	0.0038
7	62.75	0.015	0.1	1	30	30.5	0.0064
8	62.75	0.023	0.16	3	20	33	0.0013
9	62.75	0.03	0.04	5	25	28	0.0038
10	34.42	0.015	0.16	5	25	30.5	0.0013
11	34.42	0.023	0.04	1	30	33	0.0038
12	34.42	0.03	0.1	3	20	28	0.0064
13	49.24	0.015	0.1	5	20	33	0.0038
14	49.24	0.023	0.16	1	25	28	0.0064
15	49.24	0.03	0.04	3	30	30.5	0.0013
16	62.75	0.015	0.16	3	30	28	0.0038
17	62.75	0.023	0.04	5	20	30.5	0.0064
18	62.75	0.03	0.1	1	25	33	0.0013

표 1의 실험 조건을 이용하여 얻은 공작물의 거칠기 값은 비선형 커브피팅(curve fitting) 알고리즘을 통해 기존 모델의 계수를 선정하였다. 선정된 거칠기 모델의 계수에 대한 검증용을 위해 표 2의 실험 조건을 수립하여 실험을 수행한 후 선정된 모델의 변수를 검증하였다.

[표 2] 기존 거칠기 모델을 위한 실험 조건

	d_{eq} [mm]	a_d [mm]	s_d [mm/rev]	t_s [s]	v_w [m/min]	v_s [m/s]	a [mm]
1	34.42	0.017	0.15	4	23	30.5	0.0038
2	34.42	0.025	0.1	2.5	28	30.5	0.0038

연삭 슷들의 마모에 따른 거칠기 변화를 예측하기 위한 모델 실험을 위해서는 표 3과 같은 드레싱과 연삭 조건을 선정하였다. 표 4의 실험 조건은 표 3을 이용한 거칠기 모델 피팅을 검증하기 위한 실험 조건이다. 표 4의 Level은 연삭이 슷을 고려하여 정삭에서 황삭에 이르는 절입속도의 정도이다.

[표 3] 연삭가공이 진행됨에 따른 거칠기 변화 실험 조건

Run	u [mm/s]	v_s [mm/s]	d_w [mm]	a_d [mm]	s_d [mm/rev]
1	0.027	30.48	71.74	0.0508	0.114
2	0.017	30.48	70.31	0.0508	0.114
3	0.007	30.48	71.31	0.0508	0.114


[표 4] 모델 규명을 위한 연삭 조건

status	Level 1	Level 2	Level 3
u [mm/s]	0.00847	0.01693	0.0254
$t_s = 5 \text{ sec}$			

2.2 뉴럴 네트워크 알고리즘을 이용한 초기 거칠기 모델식의 제안

연삭에서 초기 거칠기는 드레싱 후 수행한 연삭 공정을 통해 얻게 되는 거칠기 값으로 그 값은 드레싱 조건에 지배적인 영향을 받는다.

따라서 본 논문에서 제안하는 뉴럴 네트워크를 이용한 초기 거칠기 모델의 입력 변수는 드레싱 조건과 연삭 조건을 다음과 같이 고려하였다.



[그림 2] 제안된 초기 거칠기 구조

$$P_1 = [a_d \ s_d \ v_w \ v_s \ a]^T \quad (1)$$

여기서 a_d 는 드레싱 깊이, s_d 는 드레싱 속도, v_w 와 v_s 는 공작물 및 연삭스틀의 회전속도이고 a 는 절삭 깊이이다.

식 (1)과 같은 입력변수를 이용하여 피드포워드(feed forward) 네트워크는 1개의 히든 레이어(hidden layer)에 15개의 뉴런을 가지는 구조로 설계하였다. 그림 2는 본 논문에서 제안하는 초기 거칠기 예측을 위한 뉴럴 네트워크의 구조이다. 네트워크 가중 행렬의 갱신을 위해서는 Levenberg- Marquardt 알고리즘을 이용하였다. Levenberg - Marquardt 알고리즘의 간략한 구조는 아래와 같다.

$$w = w_{old} + J\delta \quad (2)$$

$$\delta = (J^T J + \lambda I)^{-1} J^T e \quad (3)$$

여기서 w 는 가중행렬이고, $J = \frac{\partial f(P_1, w)}{\partial w}$ 이다.

본 논문에서 제안하는 뉴럴네트워크 알고리즘을 이용한 거칠기 모델과 기존의 거칠기 모델의 비교를 위해서 아래의 두 모델을 이용하였다[2][4].

$$R_{xa,0} = r_{x1} s_d^{r_{x2}} h_{eq}^{r_{x3}} \left(\frac{Q_w'}{v_s} \right)^{r_{x4}} \quad (4)$$

$$R_{sa,0} = r_{s1} a_d^{r_{s2}} s_d^{r_{s3}} h_{eq}^{r_{s4}} \{1 + \exp(-r_{s5}(N_s))\} \quad (5)$$

여기서 h_{eq} 는 등가 칩 두께이고, $r_{xi}(i=1, \dots, 4)$ 와 $r_{si}(i=1, \dots, 5)$ 는 모델 계수이다.

표 1의 실험 조건을 이용하여 수행한 드레싱 및 연삭의 결과와 식(4), (5) 및 제안한 뉴럴네트워크를 이용한 모델식의 커브피팅 결과는 그림 3에 나타내었다. 제안된 모델의 학습 회수는 12회이며, λ 는 10^{-5} 이다.

그림 3에서 모델 1과 2는 식(4)와 (5)를 의미하며 피팅 결과는 식 (6)과 (7)에 나타내었다. 추정치에 대한 결정계수 R^2 는 model 1, model 2 그리고 제안된 모델에 대해서 각각 90.5, 91.2, 95.3이다.


$$R_{xa,0} = 0.3607 s_d^{0.3953} h_{eq}^{-0.0615} \left(\frac{Q_w'}{v_s} \right)^{0.2509} \quad (6)$$

$$R_{sa,0} = 2.8991 a_d^{-0.0162} s_d^{0.3721} h_{eq}^{0.2456} \times \{1 + \exp(-0.2145(N_s))\} \quad (7)$$

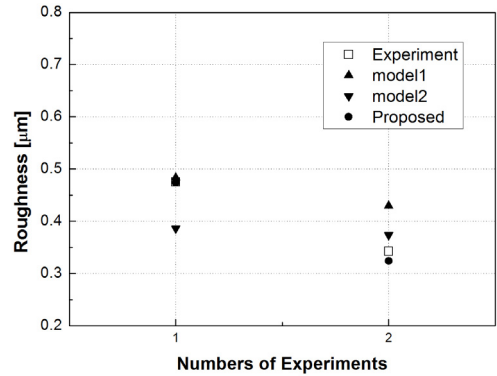
피팅 결과에 대한 검증을 위하여 표 2의 실험 조건으로 드레싱 및 연삭을 수행하여 그 결과를 비교하였다. 비교 결과는 그림 4에 나타내었다.

그림 4의 결과와 같이 제안된 뉴럴네트워크 알고리즘을 이용한 초기 거칠기의 추정치가 기존의 초기 거칠기 모델들에 비해 더욱 좋은 추정치를 제시하는 것을 알 수 있다.

이는 기존의 모델식은 거칠기에 영향을 주는 인자를 선정하고 이들의 상관 관계를 식 (4), (5)와 같이 곱의 관계로 나타냄으로써 연삭 변수들 사이의 비선형 관계를 명확히 결정하기 어려우나 제안된 뉴럴네트워크 알고리즘은 이를 좀더 유연하게 대처할 수 있기 때문에 사료된다.



[그림 3] 초기 거칠기에 대한 피팅 결과



[그림 4] 피팅 결과에 대한 검증 실험 결과

2.3 뉴럴 네트워크 알고리즘을 이용한 거칠기 모델의 제안

연삭공정이 진행됨에 따라 연삭 슷들의 마모, 윤활조건 변화 등과 같은 외부 요인으로 인해 공작물의 거칠기는 드레싱 직후 수행되는 거칠기에 비해 더욱 더 거칠어지게 된다. 이러한 거칠기를 예측하기 위한 모델 중 대표적인 것이 아래의 식 (8), (9)와 같다[2,4].

$$R_{a,x} = R_{xa,\infty} + (R_{xa,0} - R_{xa,\infty}) \exp\left(-\frac{V_w'}{V_0}\right) \quad (8)$$

$$R_{a,s} = R_{sa,0} + (R_{sa,\infty} - R_{sa,0}) \times \{1 - \exp(-\beta V_w')\} \quad (9)$$

여기서 $R_{xa,0}$, $R_{sa,0}$ 는 앞 절의 model 1과 2에서 사용한 초기 거칠기이고, $R_{xa,\infty}$, $R_{sa,\infty}$ 는 최종 거칠기를 나타낸다. V_w' 는 누적된 절삭량이다. 그리고 β 와 V_0' 는 모델의 계수이다. 두 모델에서 최종 거칠기를 나타내는


$R_{xa,\infty}$ 와 $R_{sa,\infty}$ 는 다시 식 (10), (11)과 같다.

$$R_{xa,\infty} = r_{x,1} \left(\frac{v_w}{v_s} a \right)^{r_{x,2}} \quad (10)$$

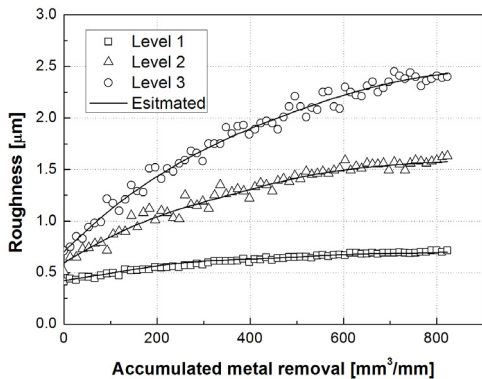
$$R_{sa,\infty} = r_{s,1} h_{eq}^{r_{s,2}} \{1 + \exp(-r_{s,3} N_s)\} \quad (11)$$

여기서 v_w 와 v_s 는 공작물 및 연삭 슷들의 회전속도, a 는 절삭 깊이, h_{eq} 는 등가 칩두께, N_s 는 스파크 아웃(spark-out) 동안의 공작물의 회전수이다. 그리고 $r_{x,i}$ ($i=1, 2$), $r_{s,i}$ ($i=1, \dots, 3$)는 모델 계수이다.


식 (10), (11)의 거칠기 모델식을 대체하기 위해서 그림 5와 같은 구조의 뉴럴네트워크 모델을 본 논문에서는 제안하였다.



[그림 5] 제안된 거칠기 모델 구조



[그림 6] 피팅 결과



[그림 7] 학습된 가중 행렬을 적용하여 추정된 거칠기와 실험 결과치

그림 5와 같이 제안한 네트워크 모델은 기존의 모델에서 사용한 변수를 입력변수로 사용하였다. 또한 네트워크의 가중행렬은 앞 절에서 사용한 Levenberg - Marquardt 알고리즘을 이용하였다. 제안한 모델의 성능을 검증하기 위하여 표 3의 조건으로 연삭을 수행하고 그 결과치를 이용하여 뉴럴네트워크의 가중행렬을 갱신하였다. 학습이 완료된 가중행렬의 성능을 표 4의 실험 조건을 이용하여 수행한 연삭의 결과를 학습된 가중행렬을 이용한 결과와 비교하였다.

그림 6은 표 3의 연삭 및 드레싱 조건을 이용한 거칠기 변화를 나타내며 이에 대한 뉴럴네트워크 학습 결과를 실선으로 나타내었다. 결과에서와 같이 학습된 가중행렬은 실험결과를 잘 묘사하는 것을 알 수 있다. 그림 7은 학습된 가중행렬의 성능을 확인하기 위해서 드레싱 후 연삭 조건을 변화시켜 얻은 거칠기 변화이다. 결과의 실선은 학습된 가중행렬을 적용하여 추정한 공작물의 거칠기로서 연삭조건 변화에 대해 제안된 모델이 가공조건 변화에 대한 거칠기 변화를 충분히 추정할 수 있음을 보여준다.

3. 결론

본 논문에서는 기계 가공의 마지막 단계에서 이루어지는 연삭 공정에 대해서 가공된 공작물의 거칠기를 추정하는 뉴럴 네트워크 알고리즘을 제안하였다. 제안된 거칠기 모델의 입력 변수는 기존에 제안된 거칠기 모델식의 변수를 활용하였다. 제안된 거칠기 모델은 기존의 거칠기 모델식이 변수 상호간의 관계를 명확히 규명할 수 없는 한계점을 극복하기 위해 뉴럴네트워크 알고리즘을 사용하

여 입력변수에 대한 출력 거칠기를 Levenberg- Marquardt 학습알고리즘을 적용하여 학습하도록 하였다. 학습된 가중행렬은 초기 거칠기에서 부터 최종 거칠기에 이르기까지 연삭 조건의 변화에 대해서도 충분히 그 거칠기 변화를 추정할 수 있음을 실험적으로 검증하였다. 제안된 알고리즘의 사용을 통하여 연삭 작업을 수행하는 현장에서 가공 중 예상되는 공작물의 거칠기를 사전에 예측하여 그 작업 공정률의 향상을 가져올 것으로 사료된다.

참고문헌

[1] Choi, T. J., Subrahmanya, N. and Shin, Y. C., "Generalized Practical Models of Cylindrical Plunge grinding processes," Machine Tools and Manufacture, Vol. 48, pp. 61 - 72, 2008.

[2] Xiao, S. and Markin, S., "On-line Optimization for Internal Plunge Grinding," CIRP- Manufacturing Technology, Vol. 45, No. 1, pp. 287 - 292, 1996.

[3] Markin, S., Grinding Technology: Theory and Application of Machining with Abrasives, John Wiley & Sons, New York, 2008.

[4] Subrahmanya, N., Choi, T. and Shin, Y. C., "Model-Based Optimization of the OD Plunge Grinding Process via Generalized Intelligent Grinding Advisory System(GIGAS)," Transactions of NAMRI/SME, Vol.35, pp. 489 - 496, 2007.

[5] Xiao, G., Markin, S. and Danai, K., "Autonomous System for Multistage Cylindrical Grinding," Journal of Dynamic Systems, Measurement and Control, Vol. 115, pp. 667 - 672, 1993.

[6] Ivester, R. W. and Heigel, J. C., "Smart Machining Systems: Robust Optimization and Adaptive Control Optimization for Turning Operations," Transaction of NAMRI/SME, Vol. 35, pp. 505 - 512, 2007.

[7] Ivester, R., Danai, K. and Markin, S., "Cycle-Time Reduction in Machining by Recursive Constraint Bounding," Journal of Manufacturing Science and Engineering, Vol. 119, pp. 201 - 207, 1997.

[8] Perters, J., Snoeyes, R. and Decneut, A., "The proper selection of grinding conditions in cylindrical plunge grinding," Annals of the CIRP, Vol. 26, No. 1, pp.387 - 394, 1976.

[9] Li, L. and Fu, J., "A study of grinding force mathematical model," Annals of the CIRP, Vol. 29, No. 1, pp.245 - 249, 1980.

[10] Werner, G., "Influence of work material on grinding

forces," Annals of the CIRP Vol. 27, No. 1, pp.243 - 248, 1978.

[11] Lindsay, R. P. and Hahn, S., "On the surface finish-metal removal relationship in precision grinding," Annals of the CIRP, Vol. 22, No.1 pp. 105 - 106, 1973.

[12] Wen, X. M. A., Tay, A. O. A. and Nee, Y. C., "Micro-computer-based optimization of the surface grinding process," Journal of Material Processing Technology, Vol. 29, pp. 75 - 90, 1992.

최 정 주 (Jeongju Choi)

[정회원]



- 2001년 8월 : 부산대학교 공과대학원 지능기계공학과 (공학석사)
- 2006년 8월 : 부산대학교 공과대학원 지능기계공학과 (공학박사)
- 2008년 3월 ~ 2009년 2월 : University of Michigan-Dearborn 포스터닥터

- 2009년 3월 ~ 현재 : 동아대학교 고기능성 밸브 기술 지원 센터 연구교수

<관심분야>

지능형 가공시스템, 적응제어, 인공지능

박 준 흥 (Joon-Hong Park)

[정회원]



- 1999년 2월 : 부산대학교 공과대학원 정밀기계공학과 (공학석사)
- 2003년 2월 : 부산대학교 공과대학원 정밀기계공학과 (공학박사)
- 2003년 3월 ~ 현재 : 동아대학교 신소형재 가공청정공정개발 연구센터 연구교수

<관심분야>

소성가공, 단조가공