

Real-Time Prediction for Product Surface Roughness by Support Vector Regression

Sujin Choi* · Dongju Lee**†

*Department of Smart Convergence Mold, Korea Polytechnics

**Industrial & Systems Engineering, Kongju National University

서포트벡터 회귀를 이용한 실시간 제품표면거칠기 예측

최수진* · 이동주**†

*한국폴리텍VII대학 스마트융합금형과

**공주대학교 산업시스템공학과

The development of IOT technology and artificial intelligence technology is promoting the smartization of manufacturing system. In this study, data extracted from acceleration sensor and current sensor were obtained through experiments in the cutting process of SKD11, which is widely used as a material for special mold steel, and the amount of tool wear and product surface roughness were measured. SVR (Support Vector Regression) is applied to predict the roughness of the product surface in real time using the obtained data. SVR, a machine learning technique, is widely used for linear and non-linear prediction using the concept of kernel. In particular, by applying GSVQR (Generalized Support Vector Quantile Regression), overestimation, underestimation, and neutral estimation of product surface roughness are performed and compared. Furthermore, surface roughness is predicted using the linear kernel and the RBF kernel. In terms of accuracy, the results of the RBF kernel are better than those of the linear kernel. Since it is difficult to predict the amount of tool wear in real time, the product surface roughness is predicted with acceleration and current data excluding the amount of tool wear. In terms of accuracy, the results of excluding the amount of tool wear were not significantly different from those including the amount of tool wear.

Keywords : Support Vector Regression, Machine Learning, Surface Roughness

1. 서론

IOT기술과 인공지능기술의 발전이 제조현장의 스마트화를 촉진하고 있는데 금형가공분야에서도 스마트팩토리 구축이 활발하다. 고품질, 원가절감, 단납기에 대응하기 위해서 작업공정상 문제해결에 생산설비 데이터를 적극 활용하고 있고, 공작기계에 적용되는 시스템은 최적

의 가공환경을 찾아내기 위한 설비모니터링과 데이터분석이 필수적이다.

기존의 공구마모, 표면거칠기에 대한 연구와 기계학습 기법을 이용한 예측에 대한 연구들을 살펴보면 다음과 같다.

신경회로망을 이용한 원격모니터링을 위한 가공공정의 공구마모와 표면조도에 관한 연구[4]는 생산 가공 시스템에서 공구의 마모로 인한 소재의 파손이나 가공 정밀도, 표면조도 정도가 생산품의 품질과 생산성에 직접적인 영향을 미치므로 실시간 공구 상태 감시는 중요하게 인식되고 자동화의 관점에서 적절한 공구교체시점을

예측하기 위해 실시간 모니터링에 의한 공구상태 감시에서 공작물의 표면조도를 측정하여 모니터링 결과를 검증하였다.

기계학습 기법을 이용한 CNC 공구 마모도 예측에 관한 연구[6]는 CNC머신에서 발생하는 데이터를 중심으로 머신러닝 기법을 활용하여 설비가동조건이 공구 마모에 미치는 영향 분석에서 X축, Y축, Z축의 회전력, 축력, 이송속도, 전력, 전압 등의 48가지 특성을 사용하여 분석을 시도하고 공구 마모도를 예측하였다.

표면거칠기는 가공의 품질을 판단하는 기준으로 표면 거칠기 예측 모델 도출은 다양한 방법으로 시도되었으며 회귀분석, 실험계획법, 그리고 밀링가공 표면거칠기 예측을 위해 인공신경망을 적용한 연구[2] 등과 같이 여러 종류의 공작물, 공작기계, 공구, 가공조건을 적용하여 진행되고 있다.

또한 이미지기술에 사용되는 렌즈 Mold와 같은 초정밀 가공공정은 가공조건에 따른 표면조도 예측을 위한 알고리즘 개발연구를 진행하였다[3].

금형재료는 제품 성형시 반복되는 고온, 고압작용으로 충분한 강도와 인성, 내마모성, 내식성, 내열성이 중요하다. 이러한 이유로 금형재료는 대체적으로 경도가 높지만 기계가공성은 우수해야 하며 표면가공성도 제품자체의 품질에 영향을 주기 때문에 주로 머시닝센터로 가공을 진행하고 후공정으로 방전가공이나 연마가공이 이루어진다.

고속가공기를 사용하면 절삭조건과 절입량을 최적화하여 가공부하에 따른 절삭흔적을 감소시킬 수 있어 표면조도를 향상시키므로, 고품위 무연마 가공제품 완성으로 절삭가공 이후 공정의 작업공수를 줄일 수 있다[11].

Vapnik[1]이 제안한 SVM(Support Vector Machine)은 분류에 많이 사용되는 머신러닝기법인데, 회귀를 적용한 SVR(Support Vector Regression)은 커널(Kernel)이라는 개념을 이용하여 선형 및 비선형 예측에도 널리 사용되고 있다.

SVR은 중국주식시장에서의 수익최대화를 위한 포트폴리오 구성[8], 리튬이온 배터리의 잔여수명 예측[7] 등 다양한 분야에 사용되어 왔다. Lee & Choi[5]는 실제값과 예측값의 오차에 대한 별점이 비대칭적인 경우에 사용할 수 있는 GSVQR(Generalized Support Vector Quantile Regression Model)을 제안하였다.

기존의 연구들은 실시간으로 공구마모량을 예측하기 위해 데이터마이닝기법을 적용하거나, 실시간이 아니라 절삭조건으로 가공 후의 제품 표면거칠기를 예측하거나, 진동값으로 공구마모상태를 예측하고 공구마모로 인해 표면거칠기가 악화되기 전에 적절한 공구교체시기를 결정하는 것에 대한 연구들이었다.

본 연구에서는 금형특수강 재료로 많이 사용되는 SKD11의 절삭가공에서 실험을 통해 가속도, 전류값 데이터를 확보하고 이때의 공구마모량과 제품표면거칠기를 측정하였다. 확보한 데이터를 이용하여 실시간으로 제품표면거칠기를 예측할 수 있도록 SVR 기법을 적용하고자 한다. 또한, 공구마모량과 제품표면거칠기의 관계를 살펴본다. 마지막으로, GSVQR을 적용하여 제품표면거칠기를 과대예측(overestimate), 과소예측(underestimate), 중립적인(neutral) 예측을 하고 이들을 비교해보고자 한다.

이어지는 제2장에서는 실험장비와 실험조건에 대해 설명하고 제3장에서는 공구마모량과 제품표면거칠기의 관계를 살펴본다. 제4장에서는 GSVQR을 설명하고 GSVQR을 이용하여 제품표면거칠기를 예측하였다. 마지막으로 5장에서는 본 연구의 결론과 시사점에 대해 논하였다.

2. 실험장치

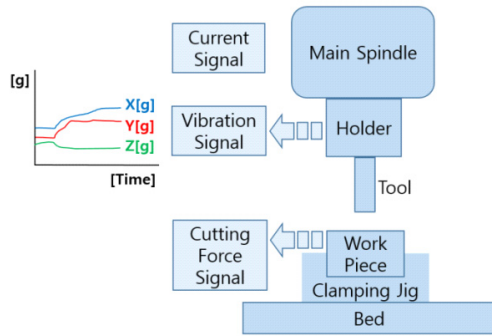
2.1 실험장비

본 실험에 사용한 공작기계는 금형가공 분야에서 많이 사용되는 <Figure 1>의 머시닝센터(SIRIUS UL+ 20K)로 고속 금형가공 수직 머시닝센터이다.

주축최대회전수 20,000rpm, 주축모터 22/18.5kw, 급속이송속도 X40m/min, Y40m/min, Z40m/min, 이송거리 X1050mm, Y600mm, Z550mm, 테이블크기는 1200×600mm, NC Controller Fanuc31i-B이다.



<Figure 1> Machining Center for Experiment



<Figure 2> Experimental Equipment Configuration

고속가공기를 이용한 가공실험에서는 가공부하 상태 실시간 모니터링을 위하여 진동, 전류 데이터를 수집하고 패턴을 분석할 3축 진동센서(Hansford, HS173T)를 부착하였고, 데이터 수집기 4ch dynamic signal analyzer(AT-9837, 24bit, 51.2kHz sampling rate)와 전류센서(DC~AC 50KHz, 100A(1)&200A(2))를 설치하였다. 절삭가공시 발생하는 진동센서에 의한 신호와 전류측정 신호를 시간파형과 스펙트럼 데이터로 출력하기 위한 실험장치 구성도를 <Figure 2>와 같이 나타내었다.


2.2 실험방법

본 실험에 사용한 가공재료는 금형부품 재료로 많이 사용되는 SKD11으로 재료의 성분은 <Table 1>과 같다.

<Table 1> Chemical Components of Material

	C	Si	Mn	P	S	Cu	Ni	Cr	Mo	V
%	1.49	0.33	0.25	0.024	0.001	0.11	0.49	11.24	0.83	0.24

실험재료는 <Figure 3>과 같이 육면체로 크기는 50×40×40mm이며, 가공모델에는 공구의 코너 부분이 접촉되며 절삭을 이루도록 형상의 벽면에는 기울기 3°를 부여하였다. 또한 심한 절삭부하를 받지 않도록 실험공구가 무리 없이 가공이 가능한 가공깊이 25mm를 적용하였다.



<Figure 3> Experimental Material

본 실험의 절삭조건은 샘플가공을 미리 진행하여 실험에 최적화된 표준가공조건을 <Table 2>와 같이 선정하여 Ø10 Flat Endmill, Spindle 2,000rpm, Feed rate 1,000mm/min으로 5분, 10분, 15분, 20분, 25분, 30분, 35분, 40분, 45분, 50분까지 5분 간격의 각 분량 가공프로그램으로 50개의 공구를 사용하여 실험재료를 단위시간별로 각각 5개씩 가공하였다.


<Table 2> Experimental Conditions for Machining

Cutting condition	Value
Spindle revolution(rpm)	2000
Feed rate(mm/min)	1000
Depth of cut(mm)	0.5
Too diameter(mm)	10(flat-endmill)
Flute of Endmill	2
Cutting direction	upward
Measurement Interval(min)	5

공구마모상태 촬영은 CNC Type 비접촉 측정기 VIKI331로 Measuring Range 300x300x150mm, Vision System의 사양은 <Table 3>과 같다. 머시닝센터 가공 중 발생하는 가속도 신호를 실시간 데이터로 수집하고, 각 단위시간 가공 후 공구의 마모상태를 CCD카메라와 LD센서로 <Figure 4>과 같이 광학 촬영한 다음 Newview 3D CAD 기반 측정 S/W를 이용해 공구마모의 진행변화를 거리 측정하였다.

<Table 3> Lens Specification

Specification	Value
Optical magnification	0.7×~4.5×
Screen magnification	35×~225×
Working Distance	92mm




<Figure 4> Newview Measurements

본 실험에 사용한 표면조도측정기는 금형가공 분야에서 많이 사용되는 <Figure 5>의 복합측정기(CS-3200S4)로 윤곽형상·표면조도측정기이다.




<Figure 5> Experimental Equipment for Surface Roughness

측정범위 X축 100mm, Z1축 5mm, 분해능 X축 0.05 μ m Z1축 80nm(5mm 범위), 8nm(0.5mm 범위), 0.8nm(0.05mm 범위), Z2축 1 μ m, 측정력 0.75mN, 구동속도 X축0~80mm/s, Z2축 0~20mm/s, 경사범위 $\pm 65^\circ$, 측정속도 0.02, 0.05, 0.1, 0.2mm/s이다. <Figure 6>은 표면거칠기 측정위치를 나타내었다.



<Figure 6> Measurement Location for Surface Roughness




<Figure 7> Roughness Measurement by Ra, Rz, RzJS

표면거칠기는 <Figure 7>과 같이 Ra, Rz, RzJS로 구하였으며, 측정샘플링의 위치 선정에 따른 편차가 발생할 수 있으므로 동일면 3개소 이상을 접촉측정하였으며 1개 제품당 총12개소를 측정한 평균값을 도출하였다.

표면거칠기를 나타내는 세 척도 중 Ra를 본 연구에서는 사용하였다.

3. 공구마모와 제품표면거칠기

공구마모량과 표면거칠기의 산점도는 <Figure 8>과 같다.



<Figure 8> Scatter Plot for Tool Wear and Product Roughness (Ra)

피어슨 상관계수(Pearson Correlation Coefficient)와 상관관계에 대한 검정(Correlation Test)[9] 결과는 <Figure 9>에 주어져 있다.

```

Pearson's product-moment correlation

data: tool$wear and tool$Ra
t = 7.4802, df = 48, p-value = 1.355e-09
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.5721512 0.8403887
sample estimates:
cor
0.7336587
    
```

<Figure 9> Correlation and Pearson's Correlation Test Result

상관계수 $\rho_{XY}=0.734$ 이고, 유의수준 $\alpha=0.05$ 에서 귀무가설을 기각하기에, 공구마모량과 제품거칠기(Ra)는 상관관계를 가진다고 판단된다.

공구마모량을 독립변수로 하고 제품거칠기(Ra)를 반응변수로 하는 경우에 대한 단순선형회귀분석 결과는 <Figure 10>에 주어져 있다.


```

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.67767    0.04164   16.27 < 2e-16 ***
wear         0.37975    0.05077    7.48 1.36e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.09786 on 48 degrees of freedom
Multiple R-squared:  0.5383,    Adjusted R-squared:  0.5286
F-statistic: 55.95 on 1 and 48 DF,  p-value: 1.355e-09
    
```

<Figure 10> Linear Regression Analysis Result for Tool Wear and Product Roughness(Ra)

회귀식은 $Y=0.678+0.380X$ 이며, y절편값과 기울기는 유의수준 $\alpha=0.05$ 에서 $p<0.05$ 이므로 모두 통계적으로 유의한 것으로 나타났다. 회귀식의 모형적합도 $R^2=0.538$ 이다. 회귀식과 공구마모값과 제품표면거칠기(Ra)는 <Figure 11>에 주어져 있다.



<Figure 11> Linear Regression for Tool Wear and Ra

4. 제품표면거칠기 예측 및 고찰

본 절에서는 실험을 통해 구한 데이터를 이용하여 제품표면거칠기를 예측하고자 한다. 먼저 예측을 위해 사용된 GSVQR은 다음과 같다.

4.1 GSVQR

Lee and Choi[5]은 GSQVR(General Support Vector Quantile Regression Model)을 제안하였는데, ϵ -둔감함수($L_\epsilon(u)$)는 식 (1)과 같다.

$$L_\epsilon(u) = \begin{cases} 0, & -(1-p_1)\epsilon \leq u \leq p_1\epsilon \\ p_2(u-p_1\epsilon), & u > p_1\epsilon \\ -(1-p_2)(u+(1-p_1)\epsilon), & u < -(1-p_1)\epsilon \end{cases} \quad (1)$$

GSVQR의 손실함수($L_\epsilon(u)$)는 ϵ 의 폭은 동일하지만, p_1 을

이용하여 폭의 좌우 비대칭 정도를 조절할 수 있으며, 허용한 계인 $\pm 0.5\epsilon$ 을 벗어나는 ξ_i, ξ_i^* 의 값에 따른 벌점(penalty)의 기울기는 p_2 에 의해 비대칭 정도를 조절할 수 있다.

- $0 \leq p_1 < 0.5$ 이면 무벌점구간(ϵ -tube)의 좌측의 폭이 크고 우측의 폭이 작다.
- $0.5 < p_1 \leq 1$ 이면 무벌점구간(ϵ -tube)의 좌측의 폭이 작고 우측의 폭이 크다.
- $p_1 = 0.5$ 이면 무벌점구간(ϵ -tube)은 좌우대칭이다.
- $0 \leq p_2 < 0.5$ 이면 예측값이 실제값보다 작은 경우(과소예측)의 벌점은 크고 큰 경우(과대예측)의 벌점은 작다.
- $0.5 < p_2 \leq 1$ 이면 예측값이 실제값보다 작은 경우의 벌점은 작고 큰 경우의 벌점은 크다.
- $p_2 = 0.5$ 이면 벌점은 좌우대칭이다.

그러므로 예측값이 실제값보다 작은 과소예측을 위해서는 무벌점구간의 우측이 넓고, 예측값이 실제값보다 큰 경우의 벌점이 커야 하므로 $0.5 < p_1 \leq 1$ 이고 $0 \leq p_2 < 0.5$ 이어야 한다. 반면에 과대예측을 위해서는 $0 \leq p_1 < 0.5$ 이고 $0.5 < p_2 \leq 1$ 이어야 한다. 중립적인 예측을 위해서는 $p_1 = p_2 = 0.5$ 이어야 한다.

원문제(Primal Problem)의 수학적모형은 다음과 같다.

$$\begin{aligned}
 P3: \text{Minimize } & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \\
 \text{subject to } & y_i - \omega^T \phi(x_i) - b \leq p_1 \epsilon + \frac{1}{p_2} \xi_i \\
 & \omega^T \phi(x_i) + b - y_i \leq (1-p_1) \epsilon \\
 & \xi_i, \xi_i^* \geq 0
 \end{aligned}$$

목적식을 Max에서 Min문제로 변환하여 라그랑주 쌍대 문제(DL)로 나타내면 다음과 같다.

$$\begin{aligned}
 DL: \min_{\alpha_i, \alpha_i^*} & \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) \kappa(x_i, x_j) (\alpha_i - \alpha_i^*) \\
 & + \sum_{i=1}^n (\alpha_i p_1 \epsilon + \alpha_i^* (1-p_1) \epsilon) - \sum_{i=1}^n (\alpha_i - \alpha_i^*) y_i \\
 \text{s.t. } & \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\
 & 0 \leq \alpha_i \leq p_2 C, \quad \forall i = 1, \dots, n \\
 & 0 \leq \alpha_i^* \leq (1-p_2) C, \quad \forall i = 1, \dots, n
 \end{aligned}$$

4.2 GSVQR을 이용한 제품표면거칠기 예측

데이터는 다음과 같은 방법으로 표준화(standardization)하였다[1].

$$X' = \frac{X - \mu_X}{\sigma_X}$$

여기서, μ_X, σ_X 는 각각 X의 평균(average), X의 표준편차(standard deviation)이다. 한편, GSVQR은 R code로 코딩되었다.

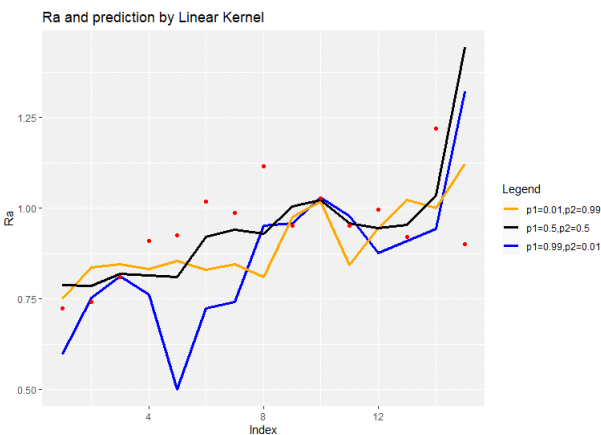
중립적인 예측으로 $p_1 = 0.5, p_2 = 0.5$, 과소예측으로 $p_1 = 0.99, p_2 = 0.01$, 과대예측으로 $p_1 = 0.01, p_2 = 0.99$ 를 사용하였다. 데이터를 훈련용으로는 70%를 검증용으로는 30%로 나누었다. 커널로는 선형커널과 RBF(Radial Basis Function) 커널을 사용하였다. 공구마모량을 실시간으로 측정하는 것은 어려우므로 제품표면거칠기 예측을 위해 공구마모량을 포함하지 않은 경우와 포함한 경우 각각 고려하였다.

선형커널이고 공구마모량을 미포함한 경우에서, $C=2^0, \dots, 2^5, \gamma=2^{-3}, \dots, 2^3$ 중에서 RMSE값을 최소로 하는 매개변수값을 적용하였다. 공구마모 데이터를 제외한 경우의 검증 데이터를 이용한 정확도의 결과는 <Table 4>에 주어졌다.

<Table 4> RMSE, MAE, MAPE values for RBF kernel by p_1, p_2 excluding tool wear

p_1, p_2	Optimal parameter	RMSE	MAE	MAPE
0.5, 0.5	$C=2^0$	0.165	0.103	10.756
0.99, 0.01	$C=2^2$	0.210	0.152	15.756
0.01, 0.99	$C=2^0$	0.140	0.112	11.416

이때의 각 데이터별 실제값과 예측값은 <Figure 12>에 주어졌다. 빨간 점은 실제값을 나타내며 3개의 직선들은 p_1, p_2 에 따른 예측값을 나타낸다.




<Figure 12> Real values of validation data and predicted values for linear kernel by p_1, p_2 (excluding tool wear)

선형커널이고 공구마모 데이터를 포함한 경우의 검증 데이터를 이용한 정확도의 결과는 <Table 5>에 주어졌다.

<Table 5> RMSE, MAE, MAPE values for RBF kernel by p_1, p_2 (including tool wear)

p_1, p_2	Optimal parameter	RMSE	MAE	MAPE
0.5, 0.5	$C=2^0$	0.178	0.115	11.882
0.99, 0.01	$C=2^2$	0.170	0.132	13.834
0.01, 0.99	$C=2^0$	0.158	0.136	14.774

이때의 각 데이터별 실제값과 예측값은 <Figure 13>에 주어졌다. 빨간 점은 실제값을 나타내며 3개의 직선들은 p_1, p_2 에 따른 예측값을 나타낸다.



<Figure 13> Real values of validation data and predicted values for linear kernel by p_1, p_2 (including tool wear)


선형 커널의 경우 공구마모 데이터 포함여부는 예측의 정확도에 큰 영향을 미치지 않는 것으로 보인다.

RBF커널이고 공구마모 데이터를 포함하지 않는 경우의 정확도의 결과는 <Table 6>에 주어졌다.

<Table 6> RMSE, MAE, MAPE values for RBF kernel by p_1, p_2 (excluding tool wear)

p_1, p_2	Optimal parameter	RMSE	MAE	MAPE
0.5, 0.5	$C=2^5, \gamma=2^{-1}$	0.085	0.073	7.653
0.99, 0.01	$C=2^5, \gamma=2^{-1}$	0.095	0.072	7.335
0.01, 0.99	$C=2^4, \gamma=2^{-1}$	0.090	0.077	8.215

이때의 각 데이터별 실제값과 예측값은 <Figure 14>에 주어져 있다. 빨간 점은 실제값을 나타내며 3개의 직선들은 p_1, p_2 에 따른 예측값을 나타낸다.



<Figure 14> Real values of validation data and predicted values for RBF kernel by p_1, p_2 (excluding tool wear)

RBF 커널이고 공구마모량을 포함한 경우 $C=2^0, \dots, 2^5, \gamma=2^{-3}, \dots, 2^3$ 중에서 RMSE값을 최소로 하는 매개변수값을 적용하였다. 검증데이터를 이용한 정확도의 결과는 <Table 7>에 주어져 있다.

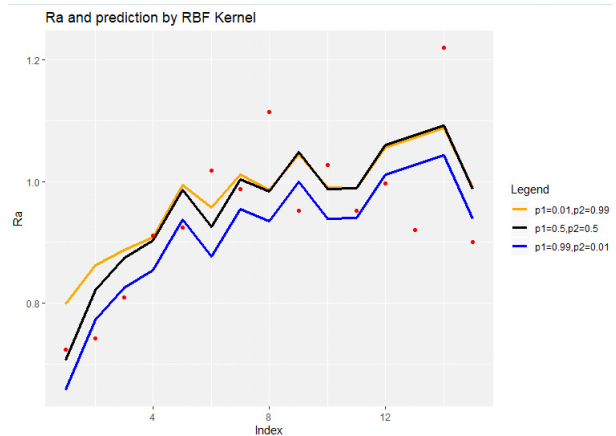
<Table 7> RMSE, MAE, MAPE values for RBF kernel by p_1, p_2 (including tool wear)

p_1, p_2	Optimal parameter	RMSE	MAE	MAPE
0.5,0.5	$C=2^5$ $\gamma=2^{-2}$	0.084	0.072	7.497
0.99,0.01	$C=2^5$ $\gamma=2^{-2}$	0.088	0.068	6.860
0.01,0.99	$C=2^4$ $\gamma=2^{-2}$	0.088	0.078	8.329

이때의 각 데이터별 실제값과 예측값은 <Figure 15>에 주어져 있다. 빨간 점은 실제값을 나타내며 3개의 직선들은 p_1, p_2 에 따른 예측값을 나타낸다.

RBF 커널을 사용하는 경우에 공구마모데이터의 포함 여부는 예측의 정확도에 큰 영향을 미치지 않는 것으로 보인다. 즉, 선형커널과 RBF 커널에서 공구마모데이터의 포함여부는 제품표면거칠기의 예측의 정확도에는 큰 영향을 미치지 않는 것으로 보인다.

공구마모 데이터의 포함 여부는 예측의 정확도에 큰 영향을 미치지 않는 것으로 보인다.



<Figure 15> Real values of validation data and predicted values for RBF kernel by p_1, p_2 (including tool wear)

5. 결론

IOT기술과 인공지능기술의 발전으로 제조현장의 스마트화가 가능해졌다. 본 연구에서는 가속도, 진류값, 공구마모량을 이용하여 실시간으로 제품표면거칠기를 예측하고 정확도를 검증하였다. 머신러닝 기법인 SVR을 이용하였는데, 과대예측, 과소예측, 중립예측이 가능한 GSVQR 기법을 적용하였다. 즉, 보수적인 결정을 위해서는 표면거칠기를 과대예측하는 것이 유리하며, 공격적인 결정을 위해서는 과소예측이 가능하다. 일반적인 예측을 위해서는 중립예측도 가능하다. 정확도 측면에서는 세 예측은 큰 차이가 없는 것으로 보인다. 커널로는 선형커널과 RBF 커널을 사용하였는데 RBF 커널을 사용한 경우가 예측의 정확도가 높은 것으로 나타났다.

공구마모량과 표면거칠기는 통계적으로 상관관계가 있는 것으로 나타났다. 즉, 공구마모가 많이 될수록 표면거칠기에 나쁜 영향을 미치는 것으로 보인다.

공구마모량은 실시간으로 측정하는 것이 매우 어렵다. 제품표면거칠기 예측을 위해 독립변수에 공구마모량을 포함하는 경우와 포함하지 않는 경우를 비교해보았는데, 정확도 측면에서는 큰 차이가 없는 것으로 나타났다. 즉, 가속도와 진류값으로 제품표면거칠기를 예측할 수 있을 것으로 보이며 이는 실시간으로 제품표면거칠기를 예측할 수 있을 것으로 기대된다.

미래의 연구과제로는 좀 더 다양한 센서를 이용하여 데이터를 확보하고 이를 통해 표면거칠기예측의 정확도를 더욱 높이는 것이 필요하다. 또한, 표면거칠기의 측정횟수가 많지 않아 SVR을 적용하였는데, 더욱 많은 데이터를 확보하여 다양한 머신러닝 기법을 적용하고 이들을

비교하는 것이 필요하다.

References

- [1] Cichosz, P., *Data Mining Algorithm: explained using R*, John Wiley & Sons, 2015.
- [2] Chun, S.H., A Study on the Application of ANN for Surface Roughness Prediction in Side Milling AL6061-T4 by Endmill, *Journal of the Korean Society of Manufacturing Process Engineers*, 2021, Vol. 20, No. 5, pp. 55-60.
- [3] Kim, D.M., Nam, E.S., and Lee, D.Y., The prediction model of the surface roughness profiles in the precision machining, *Proceedings of 2020 The Korean Society of Manufacturing Technology Engineers Fall Conference*, 2020.12, Cheju, Korea, pp. 223-223.
- [4] Kwon, J.H., Jang, U.I., Jeong, S.H., Kim, D., and Hong, D.S., A Study on the Tool Wear and Surface Roughness in Cutting Processes for a Neural-Network-Based Remote Monitoring system, *Journal of the Korean Society of Manufacturing Technology Engineers*, 2012, Vol. 21, No. 1, pp. 33-39.
- [5] Lee, D.J. and Choi, S.J., Generalized Support Vector Quantile Regression, *Journal of the Society of Korea Industrial and Systems Engineering*, 2020, Vol. 43, No. 4, pp. 107-115.
- [6] Lee, K.B., Park, S.H., Sung, S.H., and Park, D.Y., A Study on the Prediction of CNC Tool Wear Using Machine Learning Technique, *Journal of the Korea Convergence Society*, 2019, Vol. 10, No. 11, pp. 15-21.
- [7] Li, S., Fang, H., and Shi, B., Remaining useful life estimation of Lithium-ion battery based on interacting multiple model particle filter and support vector regression, *Reliability Engineering and System Safety*, 2021, Vol. 210, online.
- [8] Liu M., Luo, K., Zhang, J., and Chen, S., A stock selection algorithm hybridizing grey wolf optimizer and support vector regression, *Expert Systems With Applications*, 2021, Vol. 179, online.
- [9] Seo, M.G., *Practical Data Processing and Analysis Using R*, Gilbut Publishing, 2019.
- [10] Vapnik, V., *Statistical Learning Theory*, New York, NY: Wiley, 1998.
- [11] Won, J.Y., Nam, S.H., Yoo, S.M., Lee, S.W., and Choi, H.Z., Prediction of Surface Roughness using double ANN and the Efficient Machining Database Building Scheme in High Speed Machining, *2004 The Korean Society of Manufacturing Technology Engineers Conference*, 2004.10, Kwangju, Korea, pp. 411-415

ORCID

Dongju Lee | <http://orcid.org/0000-0001-6650-9270>

Sujin Choi | <http://orcid.org/0000-0002-9155-4353>