

# 코어 다중가공에서 공구마모 예측을 위한 기계학습 데이터 분석

최수진\*<sup>#</sup>, 이동주\*\* , 황승국\*\*\*

\*한국폴리텍VII대학 스마트융합금형과, \*\*공주대학교 산업시스템공학과

\*\*\*한국폴리텍VII대학 기계시스템과

## Machine Learning Data Analysis for Tool Wear Prediction in Core Multi Process Machining

Sujin Choi\*<sup>#</sup>, Dongju Lee\*\* , Seungkuk Hwang\*\*\*

\*Department of Smart Convergence Mold, Korea Polytechinc, \*\*Industrial & Systems Engineering,  
Kongju National University, \*\*\*Department of Mechanical system, Korea Polytechinc

(Received 9 August 2021; received in revised form 12 August 2021; accepted 22 August 2021)

### ABSTRACT

As real-time data of factories can be collected using various sensors, the adaptation of intelligent unmanned processing systems is spreading via the establishment of smart factories. In intelligent unmanned processing systems, data are collected in real time using sensors. The equipment is controlled by predicting future situations using the collected data. Particularly, a technology for the prediction of tool wear and for determining the exact timing of tool replacement is needed to prevent defected or unprocessed products due to tool breakage or tool wear. Directly measuring the tool wear in real time is difficult during the cutting process in milling. Therefore, tool wear should be predicted indirectly by analyzing the cutting load of the main spindle, current, vibration, noise, etc. In this study, data from the current and acceleration sensors; displacement data along the X, Y, and Z axes; tool wear value, and shape change data observed using Newroview were collected from the high-speed, two-edge, flat-end mill machining process of SKD11 steel. The support vector machine technique (machine learning technique) was applied to predict the amount of tool wear using the aforementioned data. Additionally, the prediction accuracies of all kernels were compared.

**Key Words** : Tool Wear(공구마모), CNC Machinnig(CNC가공), Support Vector Machine(서포트벡터머신)

### 1. 서 론

스마트팩토리 구축을 통한 지능형 무인가공 시

스템이 저변 확대되고 있다. 생산성 저하와 불량 품에 대한 원인으로는 다양한 요소들이 존재하지만 가공시 공구 파손에 의한 불량률이 큰 비중을 차지한다고 할 수 있다. 공구의 파손 시기를 인지하고 대처하기 위한 공구파손 모니터링이 중요하다고 할 수 있다<sup>[1]</sup>. 특히 고경도 재료의 절삭가공에

# Corresponding Author : sjchoi7335@kopo.ac.kr

Tel: +82-55-279-1831, Fax: +82-55-260-1177

서 야간 무인가공을 위한 공구파손 감지와 공구마모 예측은 장비가동률과 생산성 향상에 직접적인 영향을 준다. 무인가공 시스템에는 최적가공 조건과 가공부하 모니터링을 적용하여 공구교체시점을 예측함으로써 보다 안정적인 절삭가공을 실현하기 위한 방법들이 연구되고 있다<sup>[2]</sup>. 각종 기계 구성 부품의 가공정밀도의 개선, 생산성의 개선은 가공경비를 감소시켜 경쟁력을 강화시키고 있다. 특히 최근 기계 가공에서 요구되는 납기단축과 제조경비절감에 따른 생산성 향상이 이루어지고 있다.<sup>[3]</sup>

공구 교체 시점은 가공데이터를 기반으로 진동, 절삭력, 마모량 등의 변화특성을 모니터링 하는 방법과 기상측정을 통한 제품정밀도를 측정하는 방법 등으로 공구마모상태를 진단한다. 공구마모에 대한 예측에는 Random Forest, Artificial Neural Network 등의 다양한 기계학습기법(Machine Learning)이 적용되었다<sup>[4]</sup>.

밀링가공에서 공구의 마모는 절삭가공 중에 실시간 측정(진단)이 어렵고, 매 가공마다 다른 마모 패턴이 발생한다. 공구마모를 실시간 진단하기 위해서 다양한 방법이 도입되었으며, i) 주축의 절삭부하를 이용하는 방법, ii) 외부에 추가적인 센서(acoustic, vibration, current sensor)를 부착하여 실시간 모니터링 하는 방법, NC데이터의 기하학적 가공부하를 예측하고 공구마모 진단에 사용하는 방법 등 많은 연구가 수행되었다. 그러나 정확한 공구위치 정보가 없거나 공구위치에 따른 가공부하 예측값이 없다면, 가공중의 절삭력을 비교할 수 없어 정확한 공구마모를 진단할 수 없다<sup>[5]</sup>.

본 연구에서는 코어재료 SKD11의 고속도강 2날 평엔드밀 가공에서 가속도 센서 x,y,z축 변위량 데이터와 Newroview를 통해 관찰된 공구 마모값 및 형상변화 데이터를 기반으로 기계학습기법 중 하나인 서포트벡터머신(Support Vector Machine, SVM) 기법<sup>[6]</sup>을 적용하여 공구마모량을 예측하고자 한다.

서포트 벡터 머신(SVM)은 하루 최고 온도 예측<sup>[7]</sup>, 건물의 에너지 소비량 예측<sup>[8]</sup>, 인도에서 COVID19으로 인한 사망자 수, 회복자 수 예측<sup>[9]</sup> 등 다양한 분야의 예측이나 분류에 사용되는 머신러닝 기법 중 하나이다. 특히 예측을 위해 회귀식

을 사용하는 것을 서포트벡터 회귀(SVR, Support Vector Regression)라고 한다. 서포트벡터 회귀에서는 선형추정뿐만 아니라 비선형추정이 가능하게 하는 커널(kernel)이라는 개념이 있다.

본 연구에서는 전류, x축, y축, z축 가속도를 이용하여 서포트벡터 회귀를 이용하여 공구마모를 예측하고 다양한 커널함수별 정확도 차이를 검증하고자 한다.

## 2. 실험방법

### 2.1 실험장치

본 실험은 코어 다중코어 가공에서 많이 사용되는 수직형 머시닝센터(SIRIUS UL+ 20K) 모델로 Fig. 1과 같고 이송거리는 X1050mm, Y600mm, Z550mm, 급속이송속도 X40m/min, Y40m/min, Z40m/min, 테이블 크기 1200x600mm, 주축최대회전수 20,000rpm, 주축모터 22/18.5kw, NC Controller Fanuc31i-B 이다.

공작기계 스핀들 주축관련 부하조건에 따른 진동, 전류 패턴 분석을 위해 3축 진동센서(Hansford, HS173T)를 부착하여 데이터 수집기 4ch dynamic signal analyzer (AT-9837, 24bit, 51.2kHz sampling rate)와 전류센서(DC~AC 50KHz, 100A(1)&200A(2))를 통하여 실시간으로 데이터를 수집하였다.



Fig. 1 Experimental equipment

주축모터에 부착된 가속도 센서를 통해 공구마모 및 파손을 검출하기 위한 실험장치에 대한 구성도를 Fig. 2에 나타내었다. 절삭가공시 발생하는 가속도센서 값은 3축 Vib-x, Vib-y, Vib-z의 시간파형과 스펙트럼 data로 나타내었고 전류측정값은 CT의 시간파형과 스펙트럼 data로 Fig. 3에 나타내었다.

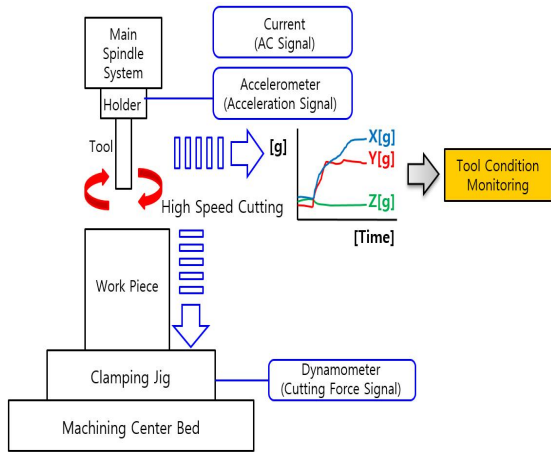


Fig. 2 Schematic diagram of experimental equipment

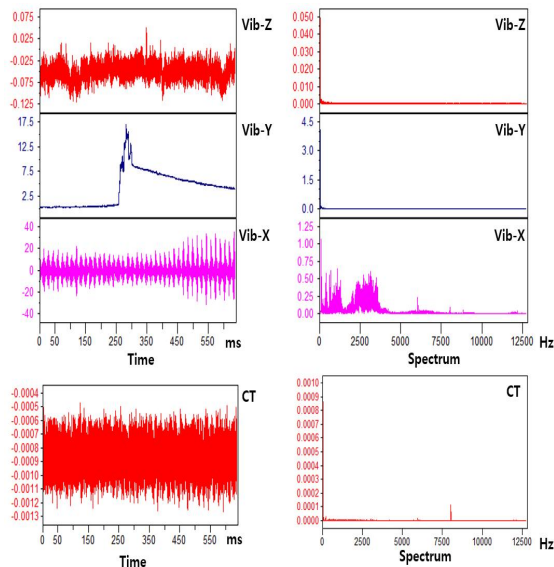


Fig. 3 Experimental settings for vibration and current measurement

## 2.2 실험방법

본 연구에 사용된 피삭재는 일반적으로 코어 재료로 많이 사용하고 있는 SKD11으로 재료의 규격과 표준성분은 Fig. 4의 Table 1과 같다. 실험재료는 50×40×40mm 육면체로 가공 중 발생하는 절삭부하를 고려하여 가공모델에 측벽기울기 3°, 가공깊이 25mm를 적용하였다. 공작물 고정과 공구세팅 및 표준화된 실험에 사용된 절삭조건은 가공방향은 Fig. 5와 같다. 실험재료는 Table 2과 같은 표준화된 절삭조건 하에서  $\varnothing 10$  평엔드밀로 회전속도 2,000rpm, 이송속도 1,000mm/min으로 가공하였다. 50개의 공구를 5분, 10분, 15분...50분까지 5분 간격의 각 분량 가공프로그램으로 각각 5개씩 가공하였다.




Fig. 4 Material specifications

Table 1 Material chemical components (SKD11)

	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





Fig. 5 Cutting direction

**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


**Table 3 Lens specification**

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



**Fig. 6 Newroview measurements**

공구마모상태 촬영은 CNC Type 비접촉 측정기 VIKI331로 Measuring Range 300x300x150mm, Vision System의 사양은 Table 3과 같다. 머시닝센터 가공 중 발생하는 가속도 신호를 실시간 데이터로 수집하고, 각 단위시간 가공 후 공구의 마모상태를 CCD카메라와 LD센서로 Fig. 6과 같이 광학 촬영한 다음 Newroview 3D CAD 기반 측정 S/W를 이용해 공구마모의 진행변화를 거리 측정하였다.



**Fig. 7 Results of tool wear measurement**

### 3. 분석 및 고찰

#### 3.1 공구마모 진행 분석

공구마모 진행상태의 분석은 각 단위시간별로 측정된 공구마모 데이터의 최대, 최소, 평균값 산출을 위해 기준공차를 벗어나는 공구마모의 시작지점을 기준으로 광학 촬영 및 마모량 결과를 측정하였다. Fig. 7은 가속도 센서에서 수집된 데이터로 V1, V2, V3, V4는 x축, y축, z축 가속도와 전류 평균값이고 V5, V6, V7, V8은 순서대로의 표준편차이며 V9, V10, V11, V12는 최대값으로 나타내었다.

#### 3.2 서포트벡터 회귀(SVR)

서포트벡터 회귀에서는 실제값과 예측값의 차이가  $\epsilon$ 이내인 것은 별점이 없고 그 이상의 오차는 별점으로 하는 손실함수라는 것을 사용하는데 이는 다음과 같다.

$$L(u) = \begin{cases} 0, & -\epsilon \leq u \leq \epsilon \\ u - \epsilon, & u > \epsilon \\ -u - \epsilon, & u < -\epsilon \end{cases}$$

여기서  $u$ 는 실제값과 예측값의 차이이다.

서포트벡터 회귀는 다음과 같은 수학적모형  $P$ 로 표현될 수 있다.

$$P: \text{Minimize } \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

subject to  $y_i - \langle \omega, x_i \rangle - b \leq \epsilon + \xi_i$

$$\langle \omega, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0$$

훈련데이터가  $\{(x_1, y_1), \dots, (x_l, y_l)\} \subset X \times R$  로 주어지는데,  $X = R^d$ 인 입력벡터이다. 서포트벡터 회귀는 실제값  $y_i$ 와의 오차가  $\varepsilon$ 이내가 되는 함수  $f(x)$ 를 구하는 것을 목적으로 한다.

특히 수학모형  $P$ 는 소프트마진(Soft Margin)을 나타내는데, 이는 여유변수(Slack Variable),  $\xi_i, \xi_i^*$ 를 도입하여 함수  $f(x)$ 와의 오차가  $\varepsilon + \xi_i$  혹은  $-(\varepsilon + \xi_i^*)$ 이내가 되도록 하며, 오차가  $\varepsilon$  이내의 오차는 무시하고  $\varepsilon$  이상의 오차를 최소화하고자 한다. 여기서  $C$ 는 얼마만큼 여유를 가지고 오류를 인정할지 판단해서 결정된다.

수학모형  $P$ 를 효율적으로 풀기 위해 수학모형  $P$ 의 듀얼 라그랑지안(Dual Lagrangian)  $DL$ 을 구하면 다음과 같다.

$$DL: \text{Minimize } \frac{1}{2} \alpha^T H \alpha - 1^T \alpha + C \sum_{i=1}^l (\xi_i + \xi_i^*)$$

$$\text{subject to } \sum_{i=1}^l \alpha_i y_i = 0$$

$$0 \leq \alpha_i \leq C$$

여기서  $H_{i,j} = y_i y_j x_i^T x_j$ 이고  $\alpha$ 는 수학모형  $P$ 의 제약식들의 라그랑지안 변수이다.

서포트벡터 회귀의 장점 중 하나는 커널(kernel)이라는 개념을 이용하여 선형추정뿐만 아니라 비선형추정도 가능하게 한 것이다. 즉, 선형추정이 불가능한 현재 공간의 분포를 선형추정이 가능하도록 한 차원 높은 공간으로 변환하기 위해  $x \rightarrow \Phi(x)$ 로 두면  $H_{i,j} = y_i y_j k(x_i, x_j) = y_i y_j \Phi(x_j)$ 로 표현할 수 있다. 이때 변환 함수끼리 스칼라 곱인  $\Phi(x_i)^T \Phi(x_j) := k(x_i, x_j)$ 들을 모아놓은 집합을 커널(kernel)이라고 한다.

본 연구에서 고려하는 커널함수(kernel function)는 선형(linear), 비선형인 다항식(polynomial), 가우시안(R.B.F, Radial Basis Function), 시그모이드(sigmoid)로 총 4개이다. 커널 함수와 매개변수는 Table 4와 같다.

**Table 4 Description for used Kernels**

kernel	formula	parameters
linear	$x^T y$	-
polynomial	$(\gamma x^T y + c_0)^d$	$\gamma, c_0, d$
R.B.F	$\exp(-\gamma  x - y ^2)$	$\gamma$
sigmoid	$\tanh(\gamma x^T y + c_0)$	$\gamma, c_0$

**Table 5 Input variables and output variable**

	Input variables (total 12ea)	Output variable
Data	Vib-x	average standard deviation maximum Tool wear value
	Vib-y	
	Vib-z	
	Current	

### 3.3 서포트벡터 회귀를 이용한 추정 및 정확도 검증

서포트벡터 회귀의 구현은 R language 이용하였고 e1071 package를 활용하였다. 총 데이터의 70%는 훈련데이터(training data)로 30%는 검증데이터(validation data)로 사용하였다.

또한, x축, y축, z축 가속도 센서의 데이터들과 전류센서의 데이터들의 각 가공에 대한 평균, 표준편차, 최대값을 입력변수로 하고 공구의 마모값을 반응변수로 고려하였다. 입력변수와 출력변수는 Table 5와 같다. 예측의 정확도(Accuracy)를 측정하기 위해 RMSE(Root Mean Squared Error), MAE(Mean Absolute Error), MAPE(Mean Absolute Percentage Error)의 세가지 척도를 사용하였다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}, \quad MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n},$$

$$MAPE = 100 \times \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{n}$$

여기서  $n$ 은 데이터의 개수,  $y_i$ 는  $i$ 번째 데이터의

실제값,  $\hat{y}_i$ 는  $i$ 번째 데이터의 예측값이다. 또한,  $\epsilon=0.1$ 을 사용하였다.

입력변수 12개를 모두 고려한 경우의 결과는 Table 6과 같다. 각 커널별 매개변수의 최적값은 다음과 같이 구하였다.

먼저 선형 커널을 사용한 경우에는  $C=1, 2, 4, 8, 16, 32$  중에서 MSE (Mean Squared Error)를 최소화하는 것을 사용하였는데  $C=1$ 을 사용하였다.

다항식 커널을 사용하는 경우에는  $d=2$ 로 하고  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $c_0=1, 2, 4, 8, 16, 32$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값 중 MSE값을 최소화하는 매개변수 값은 반응변수가  $\gamma=2^{-5}, c_0=16, C=2$ 이었다.

가우시안 커널을 사용하는 경우에는  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값들 중에서 MSE를 최소화하는 매개변수 값은  $\gamma=2^{-3}, C=1$ 이었다.

마지막으로 시그모이드 커널을 사용하는 경우  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $c_0=1, 2, 4, 8, 16, 32$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값들 중 MSE를 최소화하는 매개변수 값은 모든 경우  $\gamma=2^{-9}, c_0=1, C=16$ 이었다.

**Table 6 RMSE, MAE, MAPE values of response variables by kernel (Current included)**

kernel	RMSE	MAE	MAPE
linear	0.2273449	0.1973003	28.6139
polynomial	0.2463506	0.1602439	23.35558
R.B.F	0.1595998	0.1120997	17.03216
sigmoid	0.2468025	0.1983756	38.74334

**Table 7 RMSE, MAE, MAPE values of response variables by kernel (Current not included)**

kernel	RMSE	MAE	MAPE
linear	0.316	0.231	34.542
polynomial	0.358	0.217	32.156
R.B.F	0.163	0.145	21.031
sigmoid	0.271	0.216	43.219

비선형 커널 중 하나인 가우시안 커널(R.B.F)의 예측의 정확도가 RMSE, MAE, MAPE 모든 척도에서 가장 좋은 결과가 나왔다. 그 다음으로는 다항식 커널과 선형 커널이 좋은 정확도를 보여 주었는데 RMSE로는 선형커널이 MAE와 MAPE로는 다항식 커널이 더 좋은 것으로 나타났다.

시그모이드 커널은 모든 척도에 대해 가장 나쁜 결과를 보여주었다.

전류값을 제외한 x축, y축, z축 가속도와 관련된 입력변수 9개를 이용한 공구마모 추정의 정확도 결과는 Table 7과 같다. 각 커널별 매개변수의 최적값은 다음과 같이 구하였다.

먼저 선형 커널을 사용한 경우에는  $C=1, 2, 4, 8, 16, 32$  중에서 MSE (Mean Squared Error)를 최소화하는 것을 사용하였는데  $C=16$ 을 사용하였다.

다항식 커널을 사용하는 경우  $d=2$ 로 하고  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $c_0=1, 2, 4, 8, 16, 32$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값 중 MSE값을 최소화하는 매개변수 값은 반응변수가  $\gamma=2^{-6}, c_0=1, C=32$ 이었다.

가우시안 커널을 사용하는 경우에는  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값들 중에서 MSE를 최소화하는 매개변수 값은  $\gamma=2^{-3}, C=8$ 이었다.

마지막으로 시그모이드 커널을 사용하는 경우  $\gamma=2^{-9}, 2^{-8}, \dots, 2^{-1}, 2^0$ ,  $c_0=1, 2, 4, 8, 16, 32$ ,  $C=1, 2, 4, 8, 16, 32$ 의 값 중에서 MSE를 최소화하는 매개변수 값은 모든 경우에  $\gamma=2^{-9}, c_0=2, C=32$ 이었다.

가우시안 커널(R.B.F)의 예측의 정확도가 RMSE, MAE, MAPE 모든 척도에서 가장 좋은 결과가 나왔다. 그 다음으로는 시그모이드 커널이 RMSE와 MAE에서 좋은 결과를 보여주었고, 다항식 커널이 MAPE에서는 좋은 결과를 보여주었다.

전류값을 포함하거나 미포함하거나 간에 정확도 척도 모두에서 가우시안 커널을 이용한 추정이 가장 정확도가 높았다. 또한, 가우시안 커널의 경우에 전류값을 포함한 경우와 미포함한 경우의 정확도 결과는 큰 차이가 없는 것으로 나타났다.

## 4. 결 론

본 연구에서는 코어 다중가공에서 공구마모 및 파손을 예측하기 위해 기계학습 데이터인 커널합수를 통한 공구교체시기를 예측할 수 있는 방법을 연구하였고 그 결과 다음과 같은 결론을 얻을 수 있었다.

1. 코어 다중가공 모델과 표준화된 절삭조건을 통해서 광학측정을 해 본 결과 실제 공구의 마모를 검출할 수 있었다.
2. 코어가공에 있어서 공구교체시기 예측은 무인가공 자동화의 필수요소인데 본 실험을 통해서 미가공 및 재가공 발생을 방지할 수 있는 공구마모를 예측함으로써 장비가동률의 신뢰성을 향상시킬 수 있는 데이터를 확보하였다.
3. 데이터베이스 구축 및 예측 방법론을 개발함으로써 향후 개발되는 알고리즘을 통해 더 나은 오픈 시스템을 구축할 수 있다.
4. 추정의 정확도 측면에서 4가지 커널 중 가우시안 커널을 사용한 경우가 가장 좋은 결과를 보여주었다. 특히, 가우시안 커널을 적용한 경우의 정확도는 전류값을 포함하거나 미포함하거나 간에 큰 차이가 없는 것으로 나타났다.

## REFERENCES

1. Jeong, Y. H., "Tool Breakage Detection Using Feed Motor Current", Journal of the Korean Society of Manufacturing Process Engineers, Vol. 14 No. 6, pp. 1-6, 2015.
2. Lee, K. B., Park, S. H., Sung, S. H., Park, D. M., "A Study on the Prediction of CNC Tool Wear Using Machine Learning Technique", Journal of the Korea Convergence Society, Vol. 10. No. 11, pp. 15-21, 2019.
3. Lee, J.-K., Lee, S.-W., "Downtime tracking for small-medium sized manufacturing company using shop floor monitoring", Journal of the Korea Industrial Information Systems Research Vol. 19, No. 4, pp. 65-72, 2014.
4. Wu, D., Jennings, C., Terpenney, J., Gao, R. X., & Kumara, S., "A Comparative Study on Machine Learning Algorithms for Smart Manufacturing : Tool Wear Prediction Using Random Forests", Journal of Manufacturing Science and Engineering, Vol. 139, No. 7, pp. 071018, 2017.
5. Lee, C. S., Heo, E. Y., Lee, D. Y., Kim, J. M., Lee, H. G., "Tool Wear Monitoring System Considering the Tool Path Pattern", Korean Society for Precision Engineering, Vol. 70, pp. 1106-1106, 2015.
6. Smola, A. J. and Schölkopf, B., "A tutorial on support vector regression", Statistics and Computing Vol. 14, No. 3, pp. 199-222, 2004.
7. Paniagua-Tineo, A., Salcedo-Sanz, S., Casanova-Mateo, C., Ortiz-García, E. G., Cony, M. A., & Hernández-Martín, E. "Prediction of daily maximum temperature using a support vector regression algorithm", Renewable Energy, Vol. 36, No. 11, pp. 3054-3060, 2011.
8. Zhong, H., Wang, J., Jia, H., Mu, Y., & Lv, S., "Vector field-based support vector regression for building energy consumption prediction", Applied Energy, Vol. 242, pp. 403-414, 2019.
9. Parbat, D., & Chakraborty, M., "A python based support vector regression model for prediction of COVID19 cases in India", Chaos, Solitons & Fractals, Vol. 138, 2020.