

신경회로망을 이용한 극저온 절삭특성의 예측

김 칠 수*, 오 석 영**, 오 선 세***

The Prediction of the Cutting Characteristics in Cryogenic Cutting Using Neural Network

Chill-Su Kim*, Sueg-Young Oh**, Sun-Sae Oh***

ABSTRACT

We experimented on cutting characteristics - cutting force, behavior of cutting temperature, surface roughness, chip thickness under low temperature, which generated by liquid nitrogen(77K). The work-pieces were freezed to -195°C and liquid nitrogen was also sprinkled on cutting area in order to decrease an experimental error of machining in low temperature. The workpiece became to -195°C in 5 minutes. In cooled condition surface roughness of workpiece was better than normal condition. In addition, we investigated the possibility that surface roughness of workpiece and cutting force can be predicted analyzing cutting conditions by the trained neural network.

Key Words : Cryogenic Cutting(극저온절삭), Neural Network(신경회로망), Cooled Condition(저온절삭조건), Normal Condition(상온절삭조건)

1. 서 론

난삭재는 절삭성이 좋지 않을뿐 아니라 절삭가공중에 발생되는 절삭열에 의해 구성인선의 발생과 가공경화 현상이 발생되어 공구의 마멸이나 수명단축의 요인이 되고 있다. 그러므로 이와같은 난삭재의 절삭특성을 파악하고, 능률적이며 합리적인 절삭을 시도할 수 있는 연구는 당면 한 과제라 할 수 있다. 현재까지 난삭재의 절삭가공에 대한 연구가⁽¹⁻³⁾ 많이 발표된 바 있으나, 이와같은 연구들은 거의 대부분 난삭재의 절삭성을 향상시키기 위하여, 세라

믹 공구 등을 이용한 방법으로서 절삭공구의 마멸특성이 나 칩의형상, 그리고 공구의 형상변화등에 관한 보고이며, 이와같은 연구에서도 역시 절삭온도에 대한 문제가 제기되고 있는 실정이다.

또한, 일부 연구결과^(2,3)에서 난삭재를 절삭할 경우 공구 손상의 주 원인은 절삭시 발생되는 열에 의한 용착, 확산, 화학반응등에 의한 마모에 기인한 것으로 제시되고 있는데 이와같은 문제점을 해결하기 위한 저온절삭 방법으로, 가공물을 저온으로 냉각시키는 방법⁽⁴⁾과 절삭공구를 저온으로 냉각시키는 방법^(5,6)등이 있다.

* 중경공업전문대학 기계설계학과

**: 한국수자원공사 수자원연구소

*** 대전기술대학 생산기계기술학과

따라서 본 연구에서는 액체질소를 이용하여 가공물을 -195°C 로 냉각시킨 후 절삭 부분에 액체질소를 뿌려주는 방법을 시도하였으며, 가공물은 상온절삭에서 난삭재로 알려진 SCM440재, STS304 재를 선정하였다. 이때 절삭 공구는 초경합금 공구(KTP10)를 사용하였으며, 가공물의 극저온 냉각 효과에 따른 절삭 저항과 동특성, 표면 거칠기, 절삭온도의 거동, 침두께의 변화관계를 상온 절삭조건과 극저온 절삭조건에서 실험적으로 고찰하고, 신경회로망을 적용함으로써 절삭가공중에 가공물의 표면거칠기와 절삭저항을 예측할 수 있는 가능성에 대하여 연구하였다.^[7,8]

2. 실험 및 데이터 처리방법

2-1. 가공물 극저온냉각 절삭 장치의 구성

본 연구에서는 가공물의 극저온 냉각을 위해서 액체질소 (77K)를 사용하였으며, 이를위한 실험장치의 개략도를 Fig.1에 나타내었다.

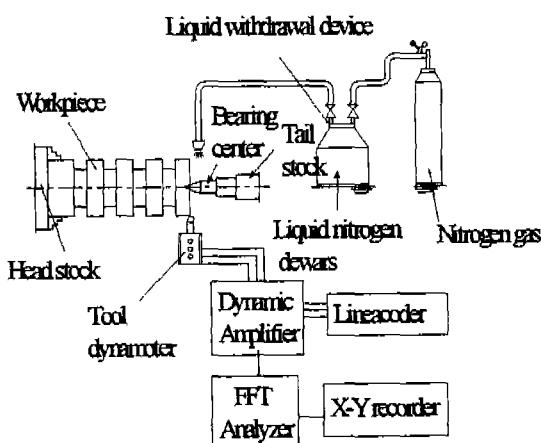


Fig.1 Schematic view of experimental set up

가공물을 단열된 액체질소 용기 속에 넣으면 약 5분 후에 온도 평형을 이루어 -195°C 로 냉각이 되므로 이것을 신속하게 선반의 연동체에 고정시킨다. 그리고 절삭실험 중에 온도 상승을 최대한 억제 시키기 위해 절삭부분에 액체질소를 연속적으로 공급시켰다. 액체질소의 원활한 공급을 위하여, 액체질소 용기에 액체질소 배출장치를 설계, 제작해서 설치 하였고, 0.25 Kg/cm^2 로 감압된 질소 가스를 공급장치를 통하여 액체질소 용기에 유도시키면

용기내의 압력이 상승되어, 용기내의 액체질소는 배출 파이프를 통하여 액체 상태로 절삭 위치에 공급된다.

2-2. 절삭온도의 측정

Fig.2는 가공물의 냉각온도를 측정하기 위한 장치의 개략도이다. 액체질소 용기내에서 온도평형이 이루어진 가공물을, 액체질소 용기내에서 꺼내는 즉시 열전대(Thermocouple)를 센터 드릴 가공 부위에 접촉시키면, 기준온도 설정부(Reference junction thermo couple box)를 통하여 그 출력이 DMM(Digital multimeter)에 연결되고 이때 표시된 mV값이 증폭기에 의해 증폭된 후 A/D변환기에서 디지털신호를 아나로그신호로 변환하여 컴퓨터에 입력된다.

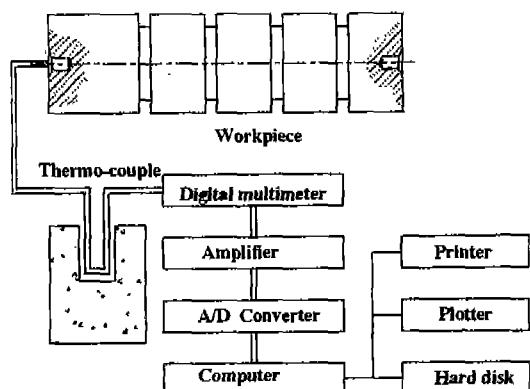


Fig. 2 Schematic diagram of the acquisition system for frozen workpiece

그리고, 온도 측정용 프로그램에 의하여 섭씨온도로 환산된 값을 프린터에 1초 간격으로 20초까지 기록토록 하였다. Fig.3은 절삭 실험중의 인서트의 날끝 부분의 절삭온도를 측정하기 위하여 제작한 공구과 공구홀더를 나타내고 있다. 인서트의 날끝 부분에서 1.25mm 떨어진 위치에 Super drill E.D.M(electric discharge machining)으로 직경 0.55 mm의 구멍을 뚫고 열전대를 삽입하여 온도측정장치를 설치 하였다. 이때 사용한 열전대는 $-270^{\circ}\text{C} \sim 1370^{\circ}\text{C}$ 의 범위까지 측정할 수 있는 K-type을 사용하였으며 열전대의 직경은 0.5mm의 크롬엘(chromel)과 알로멜(alume1)로 되어있고 바깥부분은 단열재로 피복되어 있으므로 주변의 온도 영향으로 인한 측정 오차를 최소한으로 방지할 수 있었다.

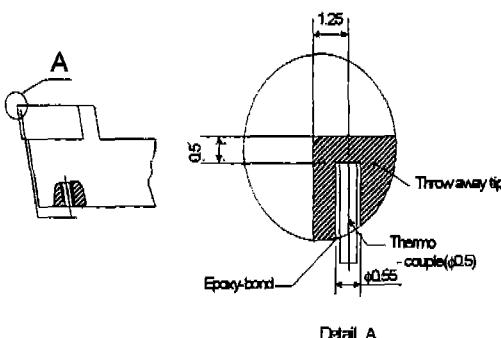


Fig.3 Throw away tip for cutting temperature measurement

열전대는 인서트의 절삭온도 측정점으로 부터 연결되어 있고, 또한 기준 온도 설정부를 통해서 그 출력이 디지털 멀티메타에 연결되어 mV로 표시되며 이것을 다시 증폭기로 증폭시킨 후 A/D 변환기에서 아나로그신호로 변환된 후에 컴퓨터에 입력된다. 또한, 측정된 절삭온도는 H.D.D(Hard disk driver)에 데이터로 자동 저장되어, 프린터 또는 플로터에서 온도 측정 결과를 자동으로 기록 토록 하였다.

2-3. 실험방법

절삭실험은 각각 상온과 저온으로 나누어서 실시 하였으며, 실험조건은 표1과 같다.

이때 절삭실험을 실시할 때마다 가공물의 편심을 제거

하기 위하여 절삭깊이 0.2mm로 다듬질가공을 실시 하였으며, 공구의 돌출길이는 30mm로 일정하게 하고 공구마찰에 따른 실험값의 오차를 줄이기 위하여 매 절삭 실험마다 인서트를 교환하였다.

절삭 저항 측정은 AST식 공구 동력계로 검출한 신호를 증폭기를 통하여 리니어 코더(lineacorder)에서 그래프로 나타나도록 하였으며, 파워 스펙트럼(power spectrum)은 주분력 성분만을 주파수 분석기로 분석하여 X-Y 레코더에서 그래프로 나타내었다. 절삭 실험이 끝난 가공물은 성애현상이 제거된 후에 표면거칠기 측정기에서 표면거칠기값 (R_{max} , R_a)을 측정하였다.

그리고 냉각된 가공물의 온도거동과 절삭실험 중의 절삭온도의 거동을 확인하기 위하여 각각의 온도측정을 병행하였다.

2-4. 역전달 방식의 신경회로망

신경회로망은 Fig.4와 같이 입력층, 중간층, 출력층으로 구성되어 있는 다층신경회로망이 패턴분류를 위하여 사용된다. 입력층에는 절삭속도, 이송량, 침두께, 절삭력의 파워 스펙트럼을 입력패턴요소로 사용하였고, 중간층과 출력층은 처리소자와 연결강도를 지니고 있으며, 노드(node)마다의 처리소자는 강도를 곱한 각각의 입력값에 바이어스(bias) 값을 더하여 시그모이드함수를 통하여 출력을 만들어 낸다. 입력층을 제외한 각 노드에 대한 총 입력은 그 전층의 모든 노드의 출력값에 강도를 곱한 값이다. 즉, k 층의 j 노드에 대한 총입력은 식(1)과 같다.

Table1. Experimental conditions

Engine	380 WL(100×380, 2.2Kw)
Cutting tool	Tool holder : PSBNR 2020 K12 insert : ① SNMA 120408(P10) Overhang length : 30mm
Workpiece	SCM440, STS304 $D \times L = \phi 50 \times 180$ Chucking length : 30mm
Cutting conditions	Cutting speed: 52,97,141,198m/min Feed rate: 0.075,0.105,0.135,0. 165mm/rev Depth of cut : 0.5mm Cutting temperature : Normal con. Cooled con.

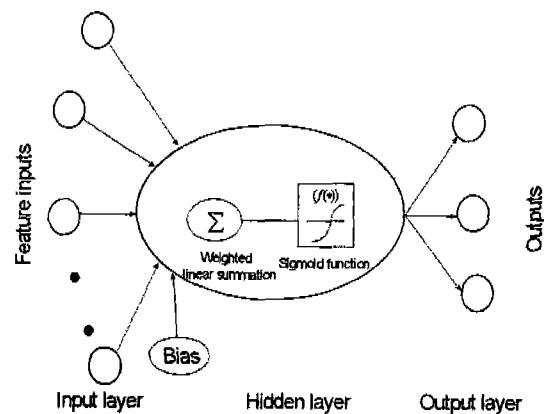


Fig.4 Back-propagation neural network with one hidden layer.

$$net_j^k = \sum_{i=1}^N W_{ji}^k o_i^{k-1} \quad (1)$$

여기서, N : (k-1)번째 층의 노드의 수

W_{ji}^k : (k-1)번째 층의 j번째 노드에서

k번째 층의 i번 노드 사이의 연결강도

o_i^{k-1} : (k-1)번째 층의 i번째 노드의 출력값

따라서, k층에서의 j노드에서의 출력은 식(2)와 같다.

$$o_j^k = \frac{1}{1 + e^{-(net_j^k + \theta_j^k)}} \quad (2)$$

식(2)는 Bias θ_j^k 를 지닌 시그모이드(sigmoid)함수를 나타낸다.

3. 실험 결과 및 고찰

3-1. 가공물의 극저온냉각에 따른 절삭온도의 거동

Fig.5는 극저온 상태로 냉각시킨 가공물의 시간의 경과에 따른 온도변화를 측정하여 그 결과를 나타낸 도면이다. 단열된 액체질소 용기 속에 가공물을 넣으면 처음에는 액체질소가 기화하여 공기중으로 날아간다. 시간이 경과 할수록 기화현상은 점점 사라지고 약 5분이 경과하면 액체질소의 표면이 잔잔하게 되면서 기화현상이 멈추게 된다. 이때의 온도가 -195°C이며, 가공물을 액체질소 밖으로 꺼내서 온도를 측정한 결과 -190°C정도의 온도를 유지하고 있었으며 이와같은 온도는 약 2분이 경과할 때 까지 지속됨을 확인할 수 있었다.

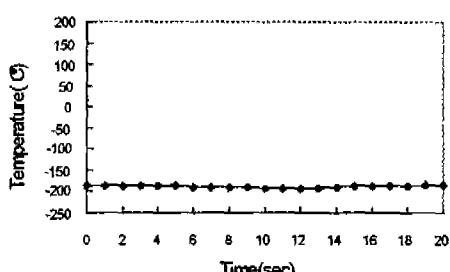


Fig.5 Variation of temperature for the frozen workpiece
(material : SCM440)

Fig.6은 초경합금 공구 KTP10으로 SCM440재를 절삭속도 51.8m/min, 이송량 0.105mm/rev, 절삭깊이 0.5mm의 절삭조건으로 절삭할 때, 상온절삭과 극저온 절삭의 절삭온도를 측정하여 그 결과를 비교한 도면이다.

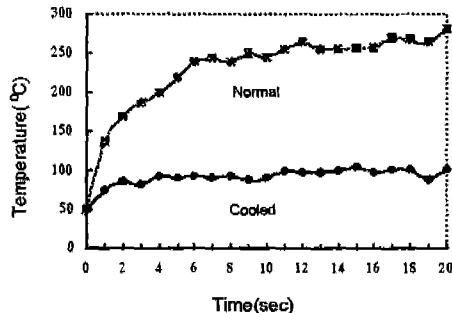


Fig.6 Variation of cutting temparature under normal and cooled cutting condition

절삭온도의 거동을 분석해 보면, 상온절삭에서는 절삭 직후에는 절삭온도가 약 50°C 이었으나, 약 2초까지는 급속하게 상승하고, 약 6초까지는 원만하게 상승하다가, 그 이후에는 약 270°C 평형상태를 유지하고 있다. 반면에 가공물 냉각에 의한 극저온절삭에서는 절삭 직후에는 절삭온도가 약 50°C 이었으나, 약 2초까지는 급속하게 상승하고 그 이후에는, 약 100°C정도의 평형상태를 유지하고 있음을 알 수 있다. 따라서 절삭온도는 가공물 냉각에 의한 극저온절삭이 상온절삭에 비하여 약 170°C 정도 낮은 온도를 유지하고 있음을 알 수 있다.

3-2. 가공물의 극저온 냉각영향에 따른 절삭특성

Fig.7, Fig.8은 절삭속도와 이송량의 변화에 따른 절삭 저항의 주분력의 변화관계를 나타낸 것으로서 이송량이 증가함에 따라서 절삭저항은 증가되는 경향이지만, 절삭 속도의 증가에 따라서는 오히려 감소되는 경향을 나타내고 있다. 또한 극저온절삭의 경우가 상온절삭에 비하여 다소 크게 나타나고 있다. 이와같은 현상은, 일반적으로

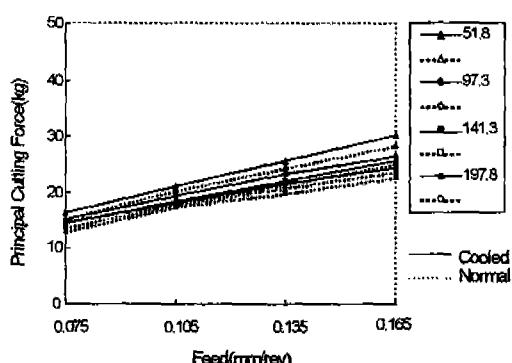


Fig.7 Principal cutting force vs feed for various cutting speeds (STS304, KPT10)

금속은 저온 상태가 될수록 강도와 취성이 증가하게 되므로, 이로 인한 소성변형 응력 또는 항복응력이 증가되는 데 기인되는 현상으로 생각할 수 있다.

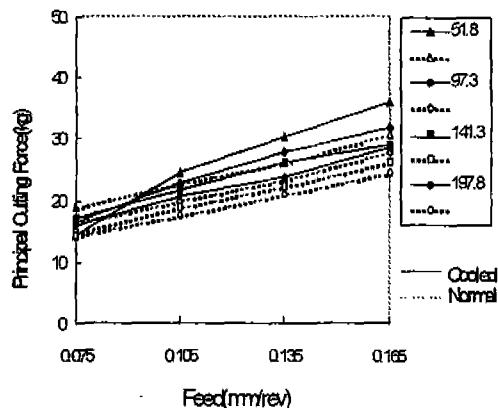


Fig. 8 Principal cutting force vs feed for various cutting speeds(SCM440, KTP10)

Fig.9은 극저온절삭과 상온절삭에서의 칩의 두께를 비교 검토한 도면이다. 칩의 두께는 절삭속도의 증가에 따라 감소되고 있으며, 저온절삭의 경우가 상온절삭에 비하여 약 30% 감소되는 경향을 보이고 있다.

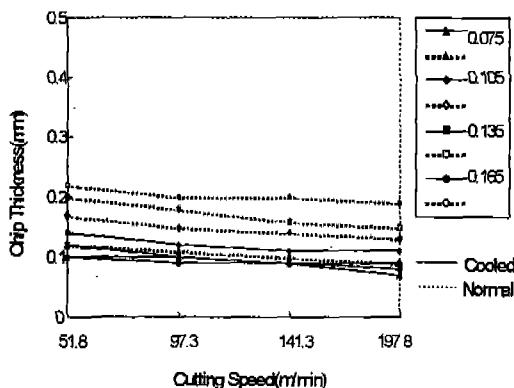


Fig. 9 Chip thickness vs cutting speed for various feeds (STS 304, KTP 10)

이 영향은 전단각의 변화를 일으키는 요인이 된다. 일 반적으로는 절삭 방향과 전단면이 이루는 전단각이 커지면 칩은 얇고 길게되며, 전단각이 작아지면 칩은 두껍고 짧게 된다.

3-3. 표면거칠기에 미치는 가공물의 극저온 냉각영향

Fig.10은 STS304재에 대한 절삭속도 및 이송량의 변화에 따른 표면거칠기의 변화관계를 도시한 그림이다. 가공면의 표면거칠기 값은 이송량의 증가에 따라서 증가하며, 극저온절삭의 경우가 상온절삭에 비하여 다소 양호한 거칠기를 형성하고 있는데, 이와같은 현상은 이송량이 0.165mm/rev에서 뚜렷하게 나타나고 있다. 이와같은 현상은 상온절삭에서는 구성인선이 발생되기 쉬운데 반하여 극저온 상태에서는 구성인선의 발생이 작고 또, 마찰 저항의 감소에서 오는 영향으로 생각할 수 있다.

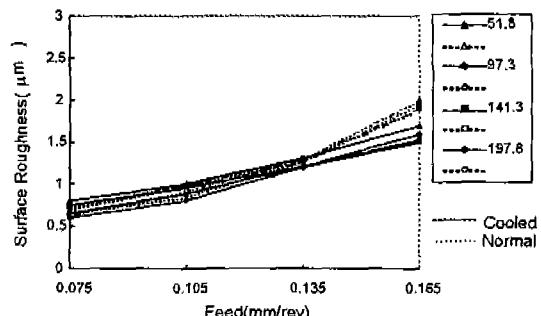


Fig.10 Surface roughness vs feed various cutting speeds (STS304, KTP10)

3-4. 신경회로망을 이용한 예측결과

사용된 신경회로망의 구조와 입력조건을 Table2에 나타내었다. 신경회로망은 실험시의 절삭조건인 절삭속도 및 이송과 절삭 후에 얻을 수 있는 절삭력의 파워스펙트럼과 칩두께를 표본 데이터로 하여 학습을 시켰다.

Table2 Structure of neural networks for training

classification	cooled condition	normal condition
number of input units	4	4
number of hidden units	9	9
number of output units	2	2
number of hidden layers	1	1
No. of learning patterns	16	16
learning rate(α)	0.7	0.7
momentum rate(η)	0.9	0.9

학습은 총오차(Total error)를 0.0001 수준으로 학습시켰으며, Fig.11과 Fig.12에는 학습이 진행되는 과정에서의 구성된 신경회로망의 총 오차값의 변화과정을 나타낸 것으로써 SCM440재 절삭시 Fig.11은 가공물 극저온 절삭시를, Fig.12는 상온절삭시 신경회로망의 총 오차값을 최소화 시키기 위한 수렴과정으로 매개변수가 최적화 되어가는 과정을 볼 수 있다. 학습의 반복횟수가 증가함에 따라 총 오차값은 감소되어 감으로 학습횟수를 늘린다면 오차는 인식자 수렴정리에 의해서 거의 영에 가까워 질 것이다.

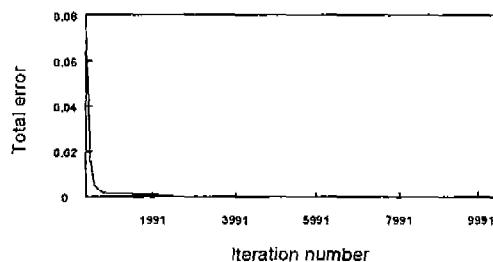


Fig.11 Variation of normalized total error according to iteration number in various cooled cutting conditions for SCM440.

다층인식자는 자료에 대한 적합능력은 뛰어나지만 방대한 자료에 대한 학습이 수렴할 때까지는 많은 횟수의 반복학습이 필요하므로, 본 연구에서는 반복횟수를 10,000회로 하여 학습시켰다. 그림에서 알 수 있듯이 학습에 의한 결과 총오차의 값은 정확히 영에 수렴됨을 알 수 있다.



Fig.12 Variation of normalized total error according to iteration number in various normal cutting conditions for SCM440.

3-4-1. 가공물 극저온 절삭시 절삭특성 예측

가공물의 극저온 절삭의 경우 가공면의 표면거칠기와 절삭저항의 주분력의 실험결과치와 학습된 신경회로망의 예측치를 Table 3 과 Table 4에 나타내었다.

Table3 Test result of neural network and experimental result in cooled condition (material : SCM440)

cutting condition and result				experimental result		test result of neural network	
cutting speed (mm/min)	feed (mm/rev)	chip thickness (mm)	power spectrum (dB Volt)	surface roughness (μm)	principal cutting force (kg)	surface roughness (μm)	principal cutting force (kg)
51.8	0.075	0.25	19.6	1.70	14.3	1.73	14.7
51.8	0.105	0.29	16.2	2.65	24.5	2.63	23.5
51.8	0.135	0.36	13.8	3.20	30.2	3.22	31.9
51.8	0.165	0.35	12.0	3.30	35.9	3.26	34.3
97.3	0.075	0.23	13.5	1.20	16.5	1.08	16.6
97.3	0.105	0.25	10.2	1.15	22.8	1.21	22.5
97.3	0.135	0.26	8.0	1.38	27.9	1.35	28.0
97.3	0.165	0.27	7.0	1.50	31.9	1.49	31.4
141.3	0.075	0.17	11.9	0.70	17.1	0.73	16.3
141.3	0.105	0.17	9.4	0.90	21.7	0.96	21.3
141.3	0.135	0.18	7.5	1.30	26.2	1.23	25.9
141.3	0.165	0.19	6.6	1.42	29.1	1.43	29.3
197.8	0.075	0.11	10.7	0.55	16.0	0.56	15.7
197.8	0.105	0.12	9.0	0.85	20.5	0.82	20.1
197.8	0.135	0.14	7.6	1.15	23.9	1.12	24.2
197.8	0.165	0.15	7.0	1.30	28.5	1.33	27.5

Table4 Test result of neural network and experimental result in cooled condition (material : STS304)

cutting condition and result				experimental result		test result of neural network	
cutting speed (mm/min)	feed (mm/rev)	chip thickness (mm)	power spectrum (dB Volt)	surface roughness (μm)	principal cutting force (kg)	surface roughness (μm)	principal cutting force (kg)
51.8	0.075	0.10	21.0	0.80	16.5	0.78	16.2
51.8	0.105	0.10	16.9	1.00	21.1	0.99	21.0
51.8	0.135	0.12	14.3	1.30	25.7	1.32	25.9
51.8	0.165	0.14	12.3	1.70	30.2	1.69	29.9
97.3	0.075	0.10	14.3	0.75	15.1	0.72	16.0
97.3	0.105	0.09	12.2	0.95	19.4	0.93	19.6
97.3	0.135	0.10	10.9	1.21	23.4	1.22	23.3
97.3	0.165	0.12	10.0	1.60	26.5	1.54	26.6
141.3	0.075	0.09	13.7	0.65	14.5	0.62	14.3
141.3	0.105	0.09	11.7	0.88	18.5	0.86	17.9
141.3	0.135	0.09	9.1	1.21	22.2	1.22	22.5
141.3	0.165	0.11	8.3	1.53	25.7	1.53	25.4
197.8	0.075	0.07	13.7	0.60	14.6	0.58	14.4
197.8	0.105	0.08	11.5	0.80	18.2	0.84	18.1
197.8	0.135	0.09	9.2	1.20	21.7	1.16	21.8
197.8	0.165	0.11	8.0	1.50	24.5	1.46	24.5

Table5 Test result of neural network and experimental result in normal condition (material : SCM440)

cutting condition and result				experimental result		test result of neural network	
cutting speed (mm/min)	feed (mm/rev)	chip thickness (mm)	power spectrum (dB Volt)	surface roughness (μm)	principal cutting force (kg)	surface roughness (μm)	principal cutting force (kg)
51.8	0.075	0.30	15.5	2.00	18.8	2.01	19.4
51.8	0.105	0.38	14.8	2.50	22.8	2.49	21.8
51.8	0.135	0.48	11.6	3.10	26.2	3.12	27.2
51.8	0.165	0.48	10.0	3.25	30.8	3.23	30.2
97.3	0.075	0.22	14.7	0.50	16.5	0.51	16.2
97.3	0.105	0.28	12.6	0.35	20.0	0.35	19.9
97.3	0.135	0.35	11.0	0.45	23.4	0.42	24.5
97.3	0.165	0.38	9.8	0.75	28.0	0.76	27.2
141.3	0.075	0.19	14.6	0.65	14.8	0.66	14.9
141.3	0.105	0.25	12.4	0.30	18.8	0.35	18.7
141.3	0.135	0.27	10.8	0.40	22.2	0.43	22.2
141.3	0.165	0.32	9.4	0.70	26.2	0.67	25.3
197.8	0.075	0.17	14.5	0.50	14.2	0.52	14.3
197.8	0.105	0.22	12.4	0.30	17.6	0.28	17.5
197.8	0.135	0.24	10.9	0.35	21.0	0.29	20.8
197.8	0.165	0.31	9.5	0.65	24.5	0.36	24.3

Table 6 Test result of neural network and experimental result in normal condition (material : STS304)

cutting condition and result				experimental result		test result of neural network	
cutting speed (mm/min)	feed (mm/rev)	chip thickness (mm)	power spectrum (dB Volt)	surface roughness (μ m)	principal cutting force (kg)	surface roughness (μ m)	principal cutting force (kg)
51.8	0.075	0.12	22.5	0.75	15.4	0.78	16.5
51.8	0.105	0.17	18.1	1.00	20.5	0.95	20.3
51.8	0.135	0.20	14.7	1.30	24.5	1.30	24.6
51.8	0.165	0.22	11.4	2.00	28.5	2.01	28.4
97.3	0.075	0.11	17.4	0.72	15.0	0.69	14.6
97.3	0.105	0.15	14.4	0.95	18.2	0.97	18.3
97.3	0.135	0.18	13.1	1.27	21.7	1.27	21.8
97.3	0.165	0.20	10.9	1.95	25.1	1.98	25.1
141.3	0.075	0.10	16.4	0.65	13.7	0.64	13.7
141.3	0.105	0.14	13.9	0.92	18.0	0.93	17.8
141.3	0.135	0.16	12.5	1.30	21.0	1.26	20.6
141.3	0.165	0.20	10.5	1.90	23.9	1.98	24.1
197.8	0.075	0.09	15.4	0.67	13.1	0.61	13.5
197.8	0.105	0.13	13.5	0.85	17.6	0.91	17.3
197.8	0.135	0.15	12.4	1.27	20.0	1.23	19.8
197.8	0.165	0.19	10.5	1.90	22.8	1.88	22.9

표에서 알 수 있듯이 표면거칠기 및 절삭저항의 주분력을 예측한 결과, SCM440의 경우 16개의 실험패턴(test pattern) 중에서 15개의 표면거칠기가 $0.1\mu\text{m}$ 이내의 오차 범위내에 있었으며, 절삭저항의 주분력은 16개 중 14개가 1kg 이내의 오차범위 아래에 있음을 알 수 있다. 또한, STS304의 경우에는 16개의 실험패턴 중에서 16개 모두가 $0.1\mu\text{m}$ 오차 이내의 표면거칠기를 예측하였으며, 절삭저항의 주분력은 16개 모두를 1kg 이내의 오차범위로 예측하였다. 이와같은 방법을 적용하면 극저온절삭후에 가공물의 표면거칠기와 절삭저항의 주분력을 정확히 예측할 수 있으리라 생각된다.

3-4-2. 상온절삭시 절삭특성 예측

상온절삭의 경우 가공면의 표면거칠기와 절삭저항의 주분력의 실제 측정치와 학습된 신경회로망을 이용하여 예측한 결과치를 Table 5와 Table 6에 나타내었다. 표에서 알 수 있듯이 가공물의 표면거칠기 및 절삭저항의 주분력을 예측한 신경회로망은 SCM440의 경우에 16개의 실험패턴 중에서 15개의 표면거칠기가 $0.1\mu\text{m}$ 이내의 오차범위에 있었으며, 절삭저항의 주분력은 16개 모두가 1kg의 오차 범위내에 있음을 알 수 있다. 또한, STS304의 경우

에는 16개의 실험패턴 중에서 16개 모두의 표면거칠기를 $0.1\mu\text{m}$ 이내 까지 정확히 예측하였으며, 절삭저항의 주분력의 경우에도 마찬가지로 16개 중 16개 모두를 1kg 이내 까지 예측하였다. 이와같이 구축된 신경회로망은 상온절삭시에도 가공물의 표면거칠기와 절삭저항의 주분력을 정확히 예측하고 있어서, 절삭조건을 이용하여 가공물의 표면상태를 예측하는데 유용하게 쓰일 것으로 생각된다.

4. 결 론

SCM440재, STS304재를 상온절삭과 극저온절삭을 실시할 때 극저온절삭이 가공재의 절삭성에 미치는 영향을 분석하고, 신경회로망을 적용하여 가공면의 표면거칠기와 절삭저항의 주분력을 예측한 결과 다음과 같은 결론을 얻었다.

(1) 본 연구와 같은 조건에서, 가공물은 액체질소내에서 -195°C 의 저온상태로 냉각시켰을 때는 상온에 노출시켜도 약 2분 정도 극저온 상태가 유지됨을 확인할 수 있었으며, 극저온절삭이 상온절삭에 비하여 약 170°C 정도 낮은 온도를 유지한다.

(2) 칩의 두께는 극저온절삭이 상온절삭에 비하여 약 30% 감소되며, 그 결과 절삭저항의 주분력을 다소 증대시키는 결과를 가져오게 된다.

(3) STS304재의 경우는 극저온절삭을 시도하였을 때 상온절삭에 비하여 구성인선의 감소 효과가 있으며, Ra 값이 약 5% 감소된 양호한 표면거칠기를 얻을 수 있는 효과가 있다.

(4) 극저온 절삭시 역전달방식의 신경회로망은 가공물의 표면거칠기를 $0.1\mu\text{m}$ 이내의 정확도로 97%, 그리고 절삭저항의 주분력을 1kg 이내의 정확도로 94%까지 정확히 예측하였다.

(5) 상온절삭시 제안된 역전달방식의 신경회로망은 가공물의 표면거칠기를 $0.1\mu\text{m}$ 이내의 정확도로 97%, 절삭 저항의 주분력을 1kg 이내의 정확도로 100%를 예측하였다.

참 고 문 헌

1. Bigneau, "Influence of the Microstructure of the Composite Ceramic Tools on Their Composite Ceramic Tools on Their Performance when Machining Nickel Alloys", CIRP, Vol. 36-1, PP.13-16, 1987.
2. Toshiaki Ohtani and Hiroshi Yokogawa, "The

Effects of Workpiece Hardness on Tool Wear Characteristics of Machining of Cold Work Tool Steel with CBN, Ceramic and Carbide Tools", JSPE, Vol. 22-3, PP. 229-231, 1988.

3. J.Vigeneau, J.J.Boulanger / F.Le Maitre(3), "Behaviour of Ceramic Tools during the Machining of Nickel Base Alloys", CIRP, Vol. 31-1, PP.35-40, 1982.
4. G.Pahitzsch, "Low Temperature Cooling, a Means of Increasing Cutting Tool Life", Microtechnic, Vol.9-2, PP.65-69, 1955.
5. A.Iwabuchi, T.Honda and J.Tami, "Tribological Properties Temperature of 293.77 and 4k in Fretting", Cryogenics, Vol. 29-2, PP.124-131, 1989.
6. K.Okushima, Y.Kawashima, "Study on Machining with Internally Cooled Tool", JSPE, Vol. 34-2, PP.97-104, 1968.
7. 오석영, 정의식, 강형보, 임영호, "신경회로망을 이용한 공작기계 주축용 배어링의 고장 검지", 한국정밀공학회, 제12권 5호, pp.33-39, 1995.
8. 김칠수, 오석영, 임영호, "극저온절삭에서 절삭특성 예측을 위한 신경회로망의 적용", 한국정밀공학회 '95년도 추계학술대회논문집 pp.32-37, 1995.