

Neural Network을 이용한 연삭가공의 트러블 검지 (Detection of Grinding Troubles Utilizing a Neural Network)

곽 세 섭¹, 송 사 복, 김 건 회, 하 만 경, 김 희 순, 이 세 정
(부산대·원) (부산대) (KIMM) (부산공업대) (영남대) (KIMM)

ABSTRACT

Detection of grinding trouble occurring during the grinding process is classified into two types, i.e. based on the quantitative and qualitative knowledge.

But, since the grinding operation is especially related with a large amount of functional parameters, it is actually difficult to cope with the grinding troubles occurring during the grinding process.

Therefore, grinding trouble-shooting has difficulty in satisfying the requirement from the user. To cope with the grinding troubles occurring during the process, the application of neural network is an effective way.

In this study, we identify the four parameters derived from the AE(Acoustic Emission) signals and present the grinding trouble-shooting system utilizing a back-propagation model of the neural network.

Key Word : Grinding Operations, Neural Network, Back-propagation Model, AE Signal,
In-process Monitoring

1. 서 론

연삭가공은 불규칙적인 절인을 갖는 연삭숫돌을 고속회전시켜 미소절삭을 행하기 때문에 다른 가공과는 달리 고경도 재료등의 난삭재 가공이 가능하고, 배출되는 칩이 미소하기 때문에 정밀하게 다듬질된 면을 얻을 수 있는 특징이 있다. 그러나, 연삭가공은 동일한 가공조건에서도 재현성을 얻기가 힘들고, 또 트러블 발생시 복잡한 파라메타들간의 직접적인 인과관계의 규명뿐만 아니라, 그들 상호간의 정량화 또한 여러 가지 어려움이 있다.

연삭가공에 발생하는 트러블 중, 특히 연삭 Burning과 Chatter Vibration의 문제는 매우 빈번히 발생하기 때문에 이들에 관한 연구^[1~7]가 주목을 받아왔다. 특히, 연삭가공중에 발생하는 Chatter Vibration은 다른 가공공정의 Chatter Vibration과는 재생효과등의 면에서 상당히 다른 것으로 알려져 있다^[2]. 연삭가공에서의 Chatter 안정성을 해석하기 위하여 연삭가공체의

특성방정식의 근으로 부터 Chatter Vibration의 발달 속도를 시간영역에서 검토한 연구가 있다^[1]. 그러나 이들의 대부분이 Trouble 발생의 규명에 국한되어 있기 때문에 실제 연삭가공에서 실용화하기는 곤란하므로 종래의 연구방식을 보완한 보다 지능화된 트러블 인식·처리시스템의 구축이 요구되고 있다.

본 연구에서는 원통 플런지 연삭가공을 대상으로, AE (Acoustic Emission) 신호로부터 얻어진 Data를 이용하여 4개의 파라메타를 동정(Identification)하고, 이것을 Neural Network^[9]에 적용하여 가공중에 발생하는 Burning과 Chatter Vibration을 검지하는 시스템을 구축하였다.

2. 연삭가공의 Trouble 발생과 AE 신호특성

2-1. 연삭 Burning의 발생

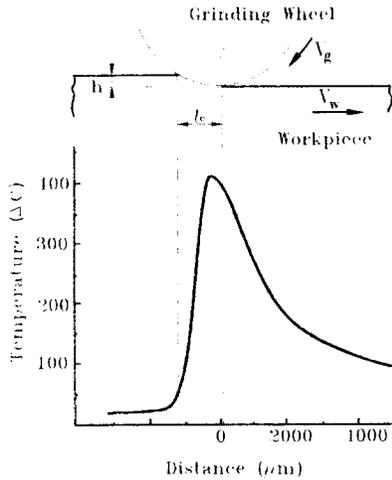


Fig.1 Distribution of Grinding Temperature

연삭가공은 매우 짧은 시간에 순간적으로 연삭숫돌과 공작물의 간섭영역에서 온도가 상승한다. 이때의 온도분포는 Fig.1과 같이 공작물과 연삭숫돌의 간섭영역 내에서 절입방향으로 부터 $l_c/3$ 지점에서 최고온도가 발생한다. 이러한 연삭열에 기인하여, 가공면이 고온에서 순간적으로 산화하여 산화막이 생기고, 막 두께에 따라서 반사광의 간섭상태가 변하기 때문에 여러가지로 착색되어 보이는 현상을 연삭 Burning이라고 한다.

연삭 Burning의 발생은 연삭 다듬질면의 결정조직, 경도, 잔류응력등에 영향을 미치며, 가공물의 내마모성, 내식성, 내피로성등에 악영향을 미친다.

2-2. 연삭가공에서 Chatter Vibration의 발생

Chatter Vibration은 연삭반의 동특성과 연삭공정간의 상호작용에 의해서 일어나는 동적 불안정이며, 이는 공구의 수명을 단축하며, 가공공정의 생산성을 저하시키고, 공작물의 가공표면을 악화시키는 요인이 된다. 특히 원통연삭에서는 공작물과 연삭숫돌이 모두 회전하는 형태이므로 평면연삭에 비해 채터진동의 문제가 중요한 트러블로 되고 있다.

2-3. 연삭 트러블과 연삭동력의 변화

연삭 Burning이 일어날 때는 연삭숫돌의 눈매율

현상이 현저해져서 연삭동력이 정상상태에서 보다 급격히 증가하기 때문에, 연삭동력의 변화를 관찰함으로써 연삭 Burning이 발생하는 시점을 감시할 수가 있다. 또한 Chatter Vibration의 발생시에는 연삭 Burning과는 반대로, 연삭동력이 정상상태보다 급격히 감소하고, 동력변화의 요동이 심하기 때문에 연삭동력의 변화로서 연삭 Chatter Vibration이 일어나는 시점을 알 수가 있다.

이러한 관점에서, 연삭동력을 이용한 연삭 Burning과 Chatter Vibration의 인식·처리에 관한 연구를 행한 바가 있다¹⁾²⁾.

그러나 연삭동력의 변화로서 Chatter Vibration을 감시할 경우에 있어서는, 트러블의 발생에 대한 연삭동력의 감도가 좋지 못한 것으로 확인 되었다. 따라서 본 연구에서는 이러한 단점을 보완하기 위해서 트러블 발생에 따른 민감도가 우수한 AE 신호를 이용하여 시스템의 보안을 시도하였다.

2-4. 연삭 트러블 발생과 AE 신호

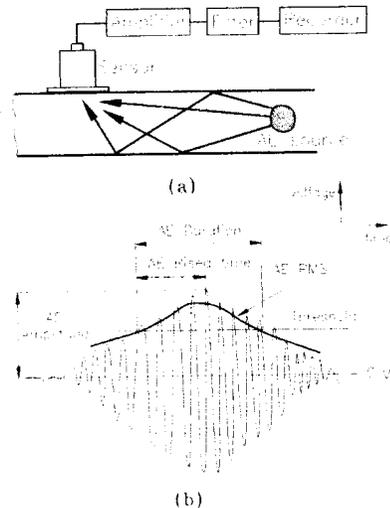


Fig.2 AE Signals and AE Parameters

AE는 Fig.2 (a)와 같이 주파수 대역이 주위의 노이즈 주파수와 비교해서 매우 높을 뿐만아니라, 연삭 트러블에 대한 민감도가 우수 하므로 연삭가공의 감시에 유효하다.

Fig.2 (b)는 AE 신호로부터 가공상태를 감시할 때 사용되는 파라메타들을 나타낸다. 이들 파라

메타 중에서도 한개의 사건(Event)에 대한 설정치(Threshold)이상의 신호의 갯수(Count)와 AE 신호로부터 얻어진 RMS(Root Mean Square)가 효과적임이 확인 되었다.

3. 실험장치의 구성 및 파라메타의 동정

3-1. 실험장치의 구성

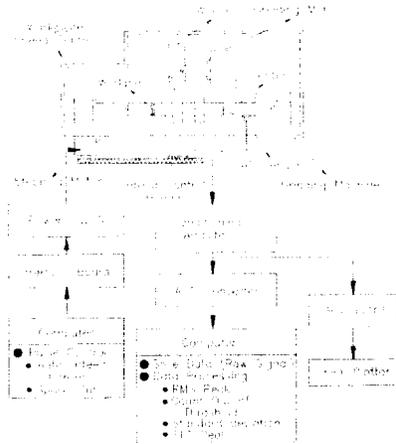


Fig.3 Experimental Set-up

본 연구를 수행하기 위해서 사용된 실험장치의 구성도는 Fig.3과 같다. 먼저 원통 플런지 연삭에서 가공상태를 감시하기 위해서, 공작물을 고정하는 Center에 진공 그리스(Vacuum Grease)를 사용하여 AE 센서를 부착하였고, AE 센서에서 검출된 신호는 Conditioning Amplifier를 거쳐서, 12bit A/D 변환이 가능한 A/D Converter를 통해서 0.01msec의 Sampling Time으로 데이터를 얻었다. 얻어진 데이터는 컴퓨터에 저장하여 신호처리를 하였다.

본 연구에서는 보다 정확한 제어를 위해서 스톱 주축에 자동 Infeed 장치를 부착하고, 신호처리를 하는 컴퓨터와는 별도의 컴퓨터를 사용하여, Pulse 제어를 통한 Stepping 모터의 구동과 Spark-Out 시간을 제어하였다. Stepping 모터와 Infeed 제어 핸들의 연결은 벨트를 이용하였다.

실험에 사용된 장비의 주요사양과 연삭조건은 Table 1과 같다.

Table 1 Experimental Equipment and Grinding Conditions

Grinding Machine	<ul style="list-style-type: none"> Model : GU28-50 Manufacturer : TOYODA Machine Works,LTD. Capacities : <ul style="list-style-type: none"> RPM of Wheel Shaft : 1710 RPM of Workpiece Shaft : Max. 300 Capacity of Wheel Motor : 3.7kW Capacity of Workpiece Motor : 0.4kW
Grinding Wheel	<ul style="list-style-type: none"> Type : GC60LmV Shape : $\varphi 288 \times 24$
Workpiece	<ul style="list-style-type: none"> Material : SKD11 Hardness : HRC 35
Grinding Method	<ul style="list-style-type: none"> Clyndrical Plunge Grinding Spark-out Time : 1 sec
Grinding Conditions	<ul style="list-style-type: none"> Condition 1 <ul style="list-style-type: none"> Infeed rate : 0.5mm/min (75 Times) Condition 2 <ul style="list-style-type: none"> Infeed rate : 1.0mm/min (75 Times) Condition 3 <ul style="list-style-type: none"> Infeed rate : 2.0mm/min (75 Times)
Dressing Conditions	<ul style="list-style-type: none"> Depth of Cut : 0.125mm Lead : 0.15mm/rev

3-2. 파라메타의 동정(Identification)

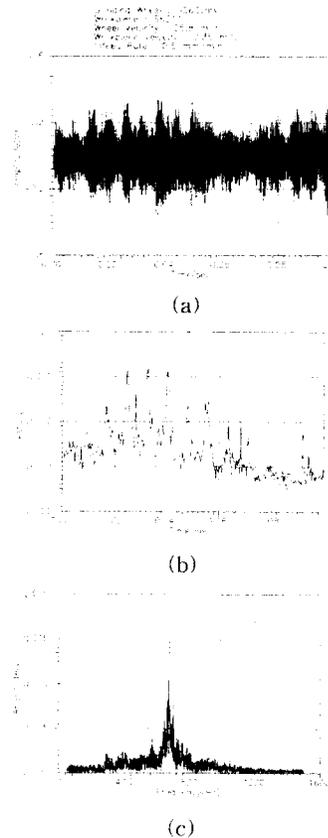


Fig.4 Conceptual Diagram for the Identification Parameters Adapted in Grinding Trouble-shooting

Fig.4에서 (a)는 AE 센서로부터 얻어진 원신호 (Raw Signal)를 나타내며, (b)는 (a)의 신호를 40개의 데이터 간격으로 RMS 취한 것이며, (c)는 (a)를 주파수 변환하여 얻어진 것을 나타낸다. 그림에서와 같이 연삭가공 중에 가공상태에 따라서 주파수 변환된 신호의 최대값(Peak Value)과 RMS의 최대값의 변화가 크므로, 이들을 가공상태의 감시를 위한 파라메타로 선정하는 것이 가능하다. RMS 변환된 신호의 최대값은 가공상태에 따른 돌발형 신호를 나타내므로, 원신호의 진폭의 크기를 평가하기 위해서 설정치(Threshold) 이상의 RMS 데이터의 갯수(Count)를 조사하는 것이 필요하다.

한편 통계학적인 처리방법으로서, 얻어진 데이터의 평균값에 대한 분산정도를 나타내는 표준편차(Standard Deviation)를 이용하여, AE 센서로부터 얻어진 데이터를 평가하여 파라메타로 선정하였다.

이들 4개의 파라메타에 대한 실험으로부터 얻어진 Data를 각각 Fig.5~8에 나타낸다.

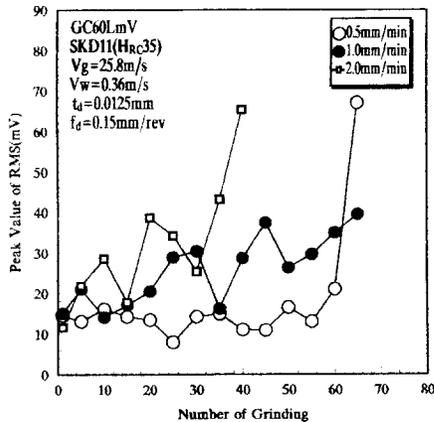


Fig.5 Amplitude Characteristic of RMS Peak Value according to Number of Grinding

Fig.5~8에서와 같이 각각의 파라메타는 연삭횟수의 변화에 따라서 변화가 심하기 때문에, 하나의 파라메타 별로 연삭상태를 감시하는 것보다는 이들을 종합적으로 평가하는 시스템이 필요하며, 이러한 요구에 가장 효과적인 것이 Neural Network을 이용한 시스템이다.

4개의 파라메타를 Neural Network에 이용하기 위한 흐름도는 Fig.9와 같다.

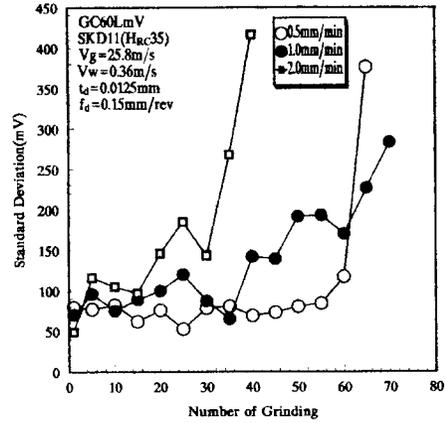


Fig.6 Characteristic of Standard Deviation according to Number of Grinding

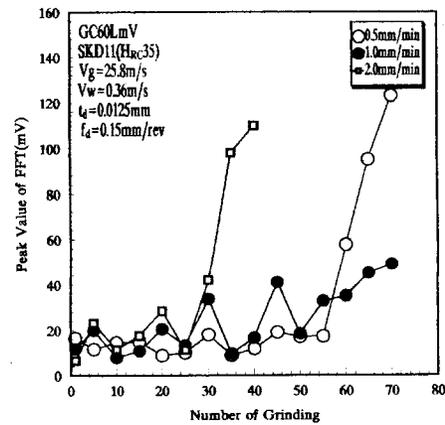


Fig.7 Amplitude Characteristic of FFT Peak Value according to Number of Grinding

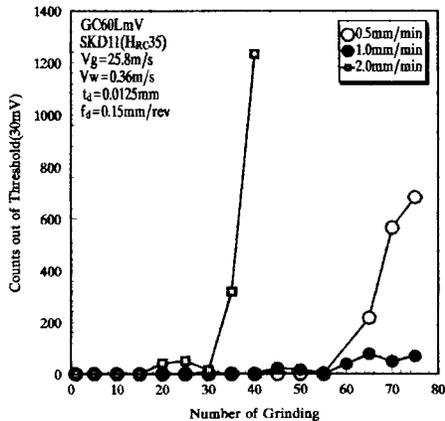


Fig.8 Characteristic of Threshold(30mV) Count according to Number of Grinding

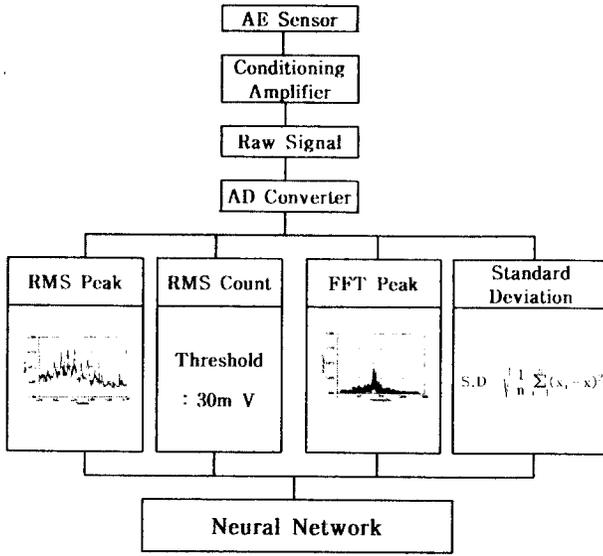


Fig.9 Signal Flow of Input Parameters for the Neural Network

4. Neural Network의 구성 및 Computer Simulation

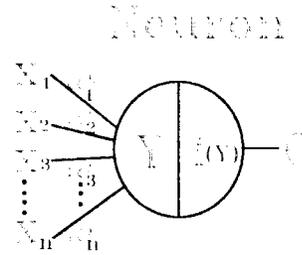
4-1. Neural Network의 구성

연삭가공 중에 발생하는 트러블의 검지에 Neural Network을 응용하는 목적은 각 파라메타들 사이의 직접적인 인과관계가 뚜렷하지 않고, 애매한 성질을 갖는 정보를 효과적으로 처리하기 위한 것으로, 지식이 규칙의 형태로 구성되어 있는 알고리즘과는 차이가 있다.

Neural Network은 사전지식이나 내부 시스템의 동작에 대한 지식이 거의 필요없고, 경향이 뚜렷한 Sample들로 부터의 학습경험에 바탕을 두고, 새로운 유사 입력패턴들이 주어질 경우에 그 출력패턴을 추정할 수 있도록 자기조직화(Self-organization)하는 잇점이 있다.

Neural Network에 있어서 각각의 요소에 해당하는 Neuron과 입력, 출력 그리고 그들을 상호 연결하는 결합하중(Connection Weight)사이의 관계를 도식적으로 나타낸 것이 Fig.10이다.

본 연구에 사용한 Neural Network의 구성도는 Fig.11과 같이 입력층(Input Layer)의 뉴런(Neuron)의 수는 AE 신호로부터 얻어진 Parameter들에 해당하



$$Y = \sum_{i=1}^n (X_i \cdot \omega_i) + \theta$$

Where, X_i : Input Value
 ω_i : Weighted Value
 θ : Offset Value
 O : Output Value
 $f()$: Transfer Function

Fig.10 Conceptual Diagram of Neuron

Input Layer Hidden Layer 1 Hidden Layer 2 Output Layer

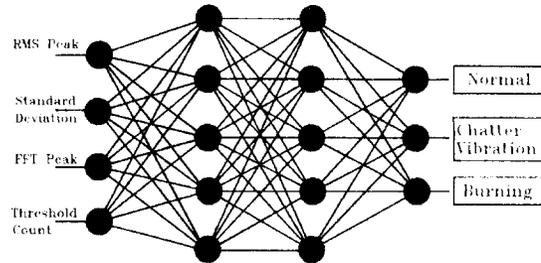


Fig.11 Schematic Diagram of Neural Network

는 4개이고, 비선형 분리의 효과를 높이기 위해서 입력층의 뉴런의 갯수보다 많은 5개의 뉴런을 갖는 2개의 중간층(Hidden Layer)이 있고, 출력층(Output Layer)에서는 세개의 유니트변수 즉, Normal, Chatter Vibration, Burning의 값을 구하여, 이들을 비교하여 최대값을 출력하도록 IV-V-V-III의 형태를 갖는 Neural Network으로 구성하였다. 원하는 출력값을 교사 데이터(Supervised Data)로 하여, 교사 데이터에 근접할 수 있도록 연결강도를 조절하는 과정인 학습(Learning)은 출력층 내의 뉴런에서 하위층 뉴런의 연결강도를 조절하는데 필요한 오차항을 역전파하는 반복적 방법 즉, 역전파 알고리즘(Back-Propagation Algorithm)을 사용하였다.

뉴런으로 입력되는 연결강도를 조절하여, 뉴런의

실제 출력값과 교사 데이터와의 차이인 오차(Error)를 줄이기 위해서 오차의 제곱을 최소화하는 Delta Rule을 사용하였다. 또한 각 층에서의 뉴런을 활성화시키는 전달함수는 시그모이드 함수(Sigmoidal Function)를 선정하여 큰 입력값과 작은 입력값에 대해서도 적절히 반응할 수 있도록 구성하였다.

4-2. Trouble 인식을 위한 교사 데이터와 학습

본 연구를 위한 실험조건들 중에서 절입속도가 1.0mm/min일때 연삭횟수가 증가함에 따라서 초기에는 안정된 상태를 유지하였으나, 연삭횟수가 43회부터 48회까지는 Burning이 발생하였으며, 62회부터는 Chatter Vibration 현상이 나타났다.

이를 토대로 Neural Network의 학습(Learning)을 위한 교사 데이터를 Table 2와 같이 선정하였다. 즉 Normal 상태를 나타내기 위해서는 연삭횟수가 5회 때부터 9회 때까지의 5개를 사용하였고, Burning 상태를 나타내기 위해서는 Burning이 발생하기 시작하는 43회 때부터 45회 때까지의 Data를 사용하였고, Chatter Vibration이 현저하게 나타났던 70회 때부터 74회 때까지의 Data를 Chatter Vibration을 인식할 수 있도록 하였다.

학습조건은 각 결합하중과 오프셋값(Offset Value)을 Random한 값으로 초기화하고, 각 뉴런의 오차값이 0.01이하이고, 전체 시스템의 오차가 0.01이하로 되도록 하면서 반복(Iteration)횟수는 2000번으로 제한하여 Personal Computer를 이용하여 학습을 완료하였다.

Table 2 Supervised Data for the Learning of the Neural Network

	Input Parameters				Desired Output			Results
	RMS Peak	S.D	FFT Peak	Count	Normal	Burning	Chatter	
5	0.021	0.096	0.0200	0	1	0	0	Normal
6	0.018	0.087	0.0081	0	1	0	0	Normal
7	0.021	0.109	0.0138	0	1	0	0	Normal
8	0.024	0.091	0.0093	0	1	0	0	Normal
9	0.019	0.078	0.0069	0	1	0	0	Normal
43	0.034	0.155	0.0245	10	0	1	0	Burning
45	0.037	0.139	0.0409	23	0	1	0	Burning
46	0.032	0.140	0.0223	9	0	1	0	Burning
70	0.033	0.283	0.0490	48	0	0	1	Chatter
71	0.048	0.322	0.1130	626	0	0	1	Chatter
72	0.042	0.342	0.0664	931	0	0	1	Chatter
73	0.039	0.305	0.0569	607	0	0	1	Chatter
74	0.033	0.256	0.0382	68	0	0	1	Chatter

4-3. Computer Simulation

실제 연삭가공에서 일어날 수 있는 입력 파라메타의 값들은 Table 2에서 나타낸 것 보다는 다양하다.

따라서 이들을 포함하면서 새로운 값을 갖는 입력 파라메타들로 구성된 Data를 사용하여, 학습된 Neural Network을 Computer Simulation한 결과를 Table 3과 Table 4에 표시한다.

Table 3은 Table 2에서 학습한 Data를 Neural Network이 인식하는 정도를 알아보기 위한 것이고, Table 4는 동일한 조건에서 얻어진 학습되지 않은 새로운 값들로 구성된 Data이다.

Table 3 Implementation Results Utilizing the Neural Network (I)

	Input Parameters				Outputs of Neural Network			Results
	RMS Peak	S.D	FFT Peak	Count	Normal	Burning	Chatter	
5	0.021	0.096	0.0200	0	0.987990	0.010019	0.010521	Normal
6	0.018	0.087	0.0081	0	0.987986	0.010020	0.010523	Normal
7	0.021	0.109	0.0138	0	0.987993	0.010019	0.010518	Normal
8	0.024	0.091	0.0093	0	0.987988	0.010020	0.010522	Normal
9	0.019	0.078	0.0069	0	0.987984	0.010020	0.010525	Normal
43	0.034	0.155	0.0245	10	0.010223	0.813255	0.185224	Burning
45	0.037	0.139	0.0409	23	0.010218	0.0813217	0.185274	Burning
46	0.032	0.140	0.0223	9	0.010221	0.0813247	0.185241	Burning
70	0.033	0.283	0.0490	48	0.010217	0.013243	0.985249	Chatter
71	0.048	0.322	0.1130	626	0.010221	0.013241	0.985247	Chatter
72	0.042	0.342	0.0664	931	0.010216	0.013242	0.985251	Chatter
73	0.039	0.305	0.0569	607	0.010217	0.013242	0.985250	Chatter
74	0.033	0.256	0.0382	68	0.010224	0.014232	0.985243	Chatter

Table 4 Implementation Results Utilizing the Neural Network (II)

	Input Parameters				Outputs of Neural Network			Results
	RMS Peak	S.D	FFT Peak	Count	Normal	Burning	Chatter	
10	0.014	0.075	0.0078	0	0.987983	0.010020	0.010525	Normal
11	0.023	0.116	0.0165	0	0.987995	0.010018	0.010517	Normal
12	0.023	0.111	0.0116	0	0.987993	0.010019	0.010518	Normal
13	0.019	0.097	0.0144	0	0.987990	0.010019	0.010521	Normal
14	0.019	0.105	0.0084	0	0.987992	0.010019	0.010519	Normal
15	0.017	0.089	0.0108	0	0.987987	0.010020	0.010522	Normal
44	0.034	0.194	0.0409	11	0.010223	0.613252	0.386741	Burning
47	0.034	0.155	0.0372	13	0.010219	0.613253	0.386746	Burning
48	0.033	0.158	0.0403	16	0.010217	0.613256	0.386741	Burning
66	0.040	0.234	0.0450	156	0.010219	0.413252	0.586742	Chatter
67	0.047	0.239	0.0493	258	0.010221	0.413255	0.586744	Chatter
68	0.037	0.266	0.0451	114	0.010221	0.413253	0.586745	Chatter
69	0.037	0.279	0.0387	94	0.010217	0.413255	0.586741	Chatter

Computer Simulation의 결과는, Table 3과 같이 이미 잘 알려진 입력 파라메타의 조합에 대해서는 매우 우수한 인식능력을 나타낼 뿐만아니라, 또 Table 4와 같이 전혀 새로운 입력 패턴들에 대해서도 Neural Network의 장점인 우수한 적응성을 나타냄을 알 수가 있다.

4. 결 론

본 연구는 AE 센서에서 얻어진 신호로부터 연삭가공중에 발생하는 트러블을 검지하기 위하여 Neural Network을 적용하였으며, 다음과 같은 결론을 얻었다.

- (1) 연삭 가공중에 발생하는 AE 신호의 변화를 관찰하여, 연삭트러블인 Burning과 Chatter Vibration을 검지하는 것이 가능함을 제시하였다.
- (2) AE 신호와 관련된 4개의 파라메타를 동정하여, (IV-V-V-III)의 Neural Network로 구성하여 실행한 결과 인식률이 우수하고, 새로운 Pattern에 대해서도 트러블을 효과적으로 인식됨이 확인 되었다.
- (3) Neural Network 감시 시스템을 이용한 연삭공정의 In-process 제어 시스템의 가능성을 제안하였다.

< 참 고 문 헌 >

1. D. Dornfeld, and He Gao Cai, "An Investigation of Grinding and Wheel Loading Using Acoustic Emission," ASME Journal of Engineering for Industry, Vol. 106, Feb. 1984, p. 28
2. K. Srinivasan, "Application of the Regeneration Spectrum Method to Wheel Regenerative Chatter in Grinding," ASME Journal of Engineering for Industry, Vol. 104, Feb. 1982, p.46
3. F. Hasimoto, "Growing Mechanism of Chatter Vibration in Grinding Processes and Chatter Stabilization Index of Grinding Wheel," Annals of the CIRP, Vol. 33, 1984, p. 259
4. Y. S. Liao, and L. C. Shiang, "Computer Simulation of Self-Excited and Forced Vibrations in the External Cylindrical Plunge Grinding Process", ASME Journal of Engineering for Industry, Vol. 113, August, 1991, p. 297
5. T. Ei-Wardani, M. M. Sadek, and M. A. Younis, "Theoretical Analysis of Grinding Chatter", ASME Journal of Engineering for Industry, Vol. 109, November, 1987, p. 314
6. 小野浩二, "研削 ヤケ, フレの發生原因と對策", 日本精密工學會, 1974, 6, p. 39
7. 河村末久, "研削焼けの基礎的研究", 日本精密工學會, 1981, 9, p. 106
8. 松原十三生, 水本洋, "フランチ"研削の被削材再生びびり振動に關する實驗的解析", 日本精密工學會, 1985, 12, p. 134
9. Richard P. Lippmann, "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, April, 1987, p. 4
10. 竹中規雄, "研削加工のトラブル"と對策", 誠文堂新光社, 1972, 10, p. 107
11. 星鐵太郎, "機械加工ひびり現象", 工業調査會, 1977, 5, p. 9
12. 김건희, 송지복, 박재섭, "Neural Network을 응용한 연삭가공의 트러블 인식·처리에 관한 연구", 한국정밀공학회 춘계학술대회 논문집, 1995, p. 113