

신경망 회로를 이용한 연삭가공의 트러블 검지(II)

곽 재섭*, 김 건희**, 하 만경***, 송 지복****, 김희술*****

Monitoring Systems of a Grinding Trouble Utilizing Neural Networks(2nd Report)

J.S. Kwak*, G.H. Kim**, M.K. Ha***, J.B. Song****, H.S. Kim*****

ABSTRACT

Monitoring of grinding trouble occurring during the process is classified into the quantitative data which depends upon a sensor and the qualitative knowledge which relies upon an empirical knowledge. Since grinding operation is highly related with a large amount of functional parameters, it is actually difficult in coping with the grinding troubles through the process.

To cope with grinding trouble, it is an effective monitoring systems when occurring the grinding process. The use of neural networks is an effective method of detection and/or monitoring on the grinding trouble.

In this paper, four parameters which are derived from the AE(Acoustic Emission) signatures are identified, and grinding monitoring system utilized a back propagation learning algorithm of PDP neural networks is presented.

Key Words: Grinding Operations(연삭가공), Neural Networks(신경망회로), PDP Neural Networks Model(PDP 신경망회로 모델), AE Signatures(AE 신호), Inprocess Monitoring(인프로세스 감시)

1. 序 論

研削加工은 불규칙적인 粒子切刃을 갖는 연삭낫들을 고속회전시켜 정밀하게 다듬질된 표면을 얻는 가공법의 일종이다. 그러나, 연삭가공은 다른 가공과는 달리 동일한 가공조건에서도 再現性을 얻기 힘들고, 加工工程에 關聯된 構成要素間의 相互關係가 統一的으로 규명되기 어렵기 때문에 加工中 트러블(Trouble) 發生時에도 직

접적인 因果關係의 규명이나, 파라메터에 대한 定量化에도 많은 어려움이 따른다.

研削加工中에 발생하는 트러블 중, 특히 연삭 베닝과 Chatter Vibration은 비교적 빈번히 발생하기 때문에 이들에 관한 연구⁽¹⁻⁷⁾가 많은 주목을 받아왔다. 특히, 연삭가공중에 발생하는 Chatter Vibration은 다른 가공 공정의 Chatter Vibration과는 再生效果 등의 측면에서 그 性質이 상당히 다른 것으로 알려져 있다⁽⁴⁾. 연삭

* 부산대학교 대학원 박사과정

** 창원대학교 공과대학

*** 부경대학교 기계설계학과

**** 부산대학교 정밀기계학과

***** 영남대학교 기계공학과

가공의 Chatter Vibration의 安定性을 해석하기 위해 研削加工系의 特성방정식의 근으로부터 Chatter Vibration의 발달속도를 시간영역에서 검토한 연구가 있다⁽⁷⁾. 그러나, 이를 대부분이 트러블 발생의 규명에만 국한되어 왔기 때문에 실제 연삭가공의 自動化生產 시스템에서 실용화하기에는 곤란하므로 이들을 보완한 보다 知能化시킨 트러블을 檢知 · 處理 시스템의 구축이 바람직하다.

本研究에서는 圓筒研削을 대상으로 AE (Acoustic Emission) 신호로부터 얻어진 데이터를 分析하여, 이들을 4개의 파라메타로 구성된 모델로 同定(Identification)을 하고, 이것을 神經網回路(Neural Network)^(8,9)에 적용하여 가공 중에 발생하는 연삭버닝과 Chatter Vibration에 대한 Monitoring 시스템을構成하고, 構築한 연삭가공용 트러블 모니터링 시스템의 有效性을 比較 · 檢討하였다.

2. 研削加工中의 트러블 發生特性과 AE 信號의 特性

2.1 연삭버닝과 Chatter Vibration의 發生특성

연삭가공중에 발생하는 加工溫度는 매우 짧은 시간에 순간적으로 연삭수들과 공작물의 干涉領域에서 매우 높은 온도가 발생하며, 특히 高硬度 공작물 가공의 경우에는 1500°C까지 상승한다. 이때의 온도분포는 공작물과 연삭수들의 干涉領域 내에서 切入方向으로부터 대략 1/3 지점에서 最高溫度가 된다⁽¹⁰⁾. 이러한 연삭열에 기인하여 가공면이 고온에서 순간적으로 酸化하여 산화막이 생기고, 막 두께에 따라서 반사광의 干涉狀態가 변하기 때문에 여러 가지로 치색되어 보이는 현상을 연삭버닝이라고 한다. 연삭버닝의 발생은 연삭 다듬질면의 結晶組織, 硬度變化, 殘留應力 등에 영향을 미치며, 나아가서는 가공물의 耐磨耗性, 耐蝕性, 耐疲勞性 등에 악영향을 미친다.

한편, Chatter Vibration은 연삭을 포함한 대부분의 가공에 있어서 공작기계의 動特性과 절삭 공정간의 相互作用에 의해서 일어나는 動的不安定으로 이는 공구의 수명을 단축하며 加工工程의 生產性과 공작물의 加工品位을 低下시키는 요인이 된다. 특히 원통연삭에서는 공작물과 연삭수들이 동시에 회전하므로 평면연삭에 비해 Chatter vibration의 발생은 트러블의 주요 인자가 된다. 또한 Chatter Vibration도 연삭버닝과 더불어 공작물의 加工品位를 低下시키는 주요한 影響因子이다.

2.2 연삭트러블 檢知와 AE 신호

AE(Acoustic Emission)는 Fig.1의 (a)와 같이 周波數 代役이 주위의 노이즈 주파수(Noise Frequency)와 비교해서 매우 높을 뿐만 아니라, 연삭 트러블에 대한 민감도가 우수하므로 연삭가공의 트러블 검지에 유효하다. Fig.1의 (b)는 本研究에서 AE 신호로부터 가공상태를 감시할 때에 사용되는 파라메타들을 나타낸다.

한편, 본연구 대상인 연삭가공용 트러블 檢知 · 處理 시스템을 위해 AE 信號을 분석한 결과, 이들 파라메타 중에서도 한 개의 사건(Event)에 대한 設定值(Threshold Value) 이상인 신호의 개수, AE 신호로부터 얻어진 RMS(Root Mean Square) 值, FFT Peak 值 및 AE 신호로부터 얻은 표준편차(Standard Deviation)가 효과적이며 實驗을 통해 확인 되었다. 따라서, 本研究에서는 이들의 값을 연삭가공중에 발생하는 트러블 모니터링 시스템에 導入하였다.

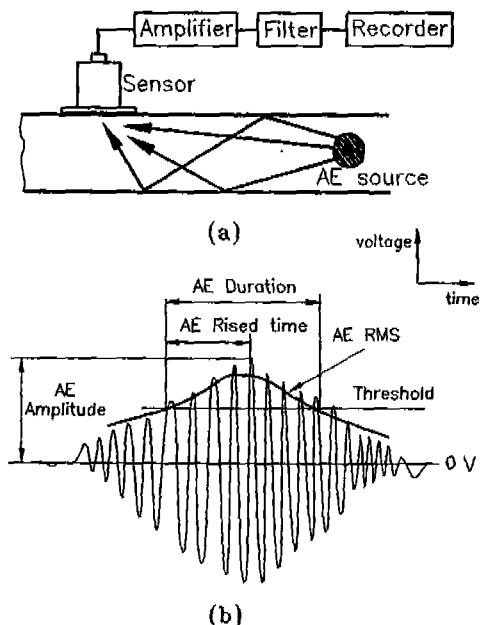


Fig. 1 AE Signatures and AE Parameters

3. 實驗장치의 구성 및 파라메타의 同定

3.1 實驗장치의 구성

Fig.2는 본 연구를 수행하기 위해서 사용된 實驗裝置의概略圖이며, 實驗에 사용된 장비의 主要仕樣과 연삭조건

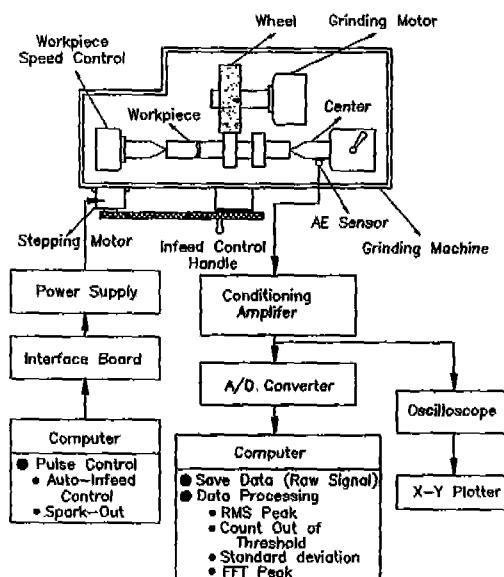


Fig. 2 Experimental Set-up

Table 1 Experimental Equipment and Grinding Conditions

Grinding Machine	<ul style="list-style-type: none"> Model: GU28-50, Toyoda Machine Works 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 : φ288 x 24
Workpiece	<ul style="list-style-type: none"> Material : SKD11 Hardness : HRC 35
Grinding Method	<ul style="list-style-type: none"> Cylindrical 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

은 Table 1과 같다. 즉, 實驗條件 중에서 연삭수들은 GC60LmV, 공작물은 SKD11, 연삭수들의 周速度(V_g)는 28.5 m/s, 공작물의 周速度(V_w)는 0.37m/s, 절입량(h)은 0.5-2.0 mm/min이며, 초기 드레싱 조건은 드레싱 깊이(t_d)가 0.125mm, 드레싱시의 피이드(f_d)는 0.15mm/rev로 하였다.

또한, 먼저 원통연삭의 가공상태를 감시하기 위해서 공작물을 고정하는 Center에 진공 그리스(Vacuum Grease)를 사용하여 AE 센서를 부착하였고, AE 센서에서 검출된 신호는 Conditioning Amplifier를 거쳐 16bit A/D 변환이 가능한 A/D Converter를 통해서 100msec의 Sampling Time으로 하여 데이터를 얻고, 데이터는 컴퓨터에 저장하여 신호처리를 하였다. 그리고 보다 정확한 제어를 위해서 연삭수들 주축에 진동 Infeed 장치를 부착하고, 신호처리를 하는 컴퓨터와는 별도의 컴퓨터를 사용하여 펄스제어(Pulse Control)를 통한 Stepping Motor의 구동과 Spark-out 시간을 제어하였다. Stepping Motor와 Infeed Control을 위한 핸들의 연결은 벨트를 이용하였다.

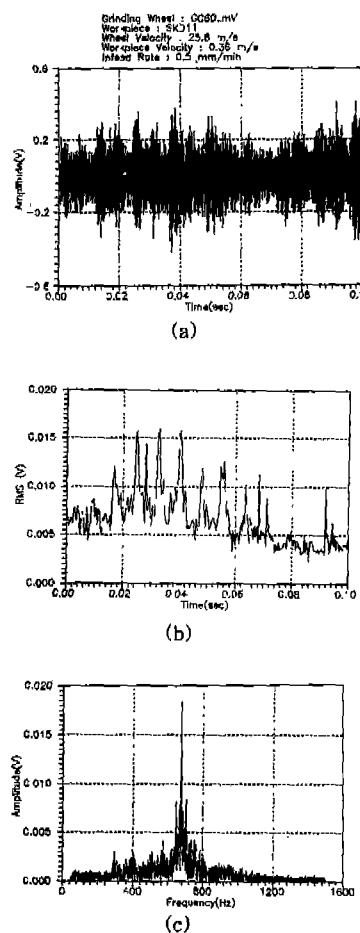


Fig. 3 Identification Parameters Adopted in Monitoring Systems for Grinding

3.2 파라메타의 동정

Fig.3에서 (a)는 AE 센서로부터 얻어진 원신호(Raw Signal)를 나타내며, (b)는 (a)의 신호를 40개의 데이터 간격으로 RMS Value를 취한 것이며, (c)는 (a)를 주파수 변환하여 얻어진 것을 나타낸다. 그림에서와 같이 연삭가공 중에는 가공상태에 따라서 주파수 변환된 신호의 최대값(Peak Value)과 RMS(Root Mean Square)의 최대값의 변화가 현저하므로 이들을 가공상태의 Monitoring를 위한 파라메타로 선정하는 것이 가능하다. RMS 변환된 신호의 최대값은 가공상태에 따른 突發型信號를 나타내므로, 원신호의 진폭의 크기를 평가하기위해서 설정치(Threshold Value)이상의 RMS 데이터의 개수를 조사하는 것이 필요하다.

또한, 통계학적인 처리방법에서 얻어진 데이터의 평균값에 대한 分散程度를 나타내는 標準偏差(Standard Deviation)을 이용하여, AE 센서로부터 얻어진 데이터를 평가하여 파라메타로 선정하였다.

한편, 이들 4개의 파라메타(RMS Peak, 표준편차, FFT 최대치, Threshold Count)에 대한 실험으로부터 얻어진 데이터를 각각 Fig.4~7에 나타낸다. Fig.4~7에서와 같이 각각의 파라메타는 연삭횟수에 따라서 변화가 심하기 때문에, 각각의 파라메타별로 연삭상태를 감시하는 것 보다는 이들을 종합적으로 평가하는 시스템이 필요하며, 이러한 요구에 가장 효과적인 것이 神經網回路(Neural Networks)을 이용한 시스템이다. 4개의 파라메타를 Neural Networks에 이용하기 위한 흐름도는 Fig.8과 같다.

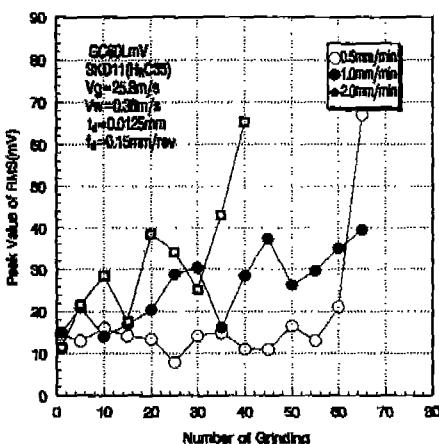


Fig. 4 Characteristic of RMS Peak Value

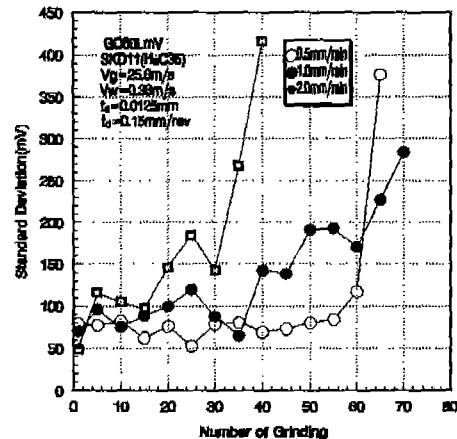


Fig. 5 Characteristic of Standard Deviation

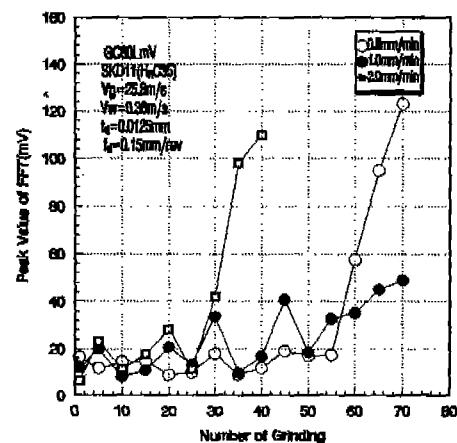


Fig. 6 Characteristic of FFT Peak Value

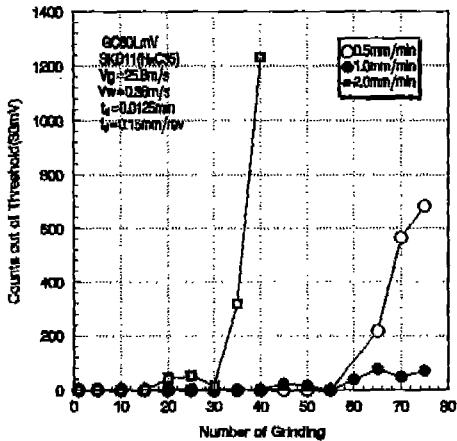


Fig. 7 Characteristic of Threshold Count

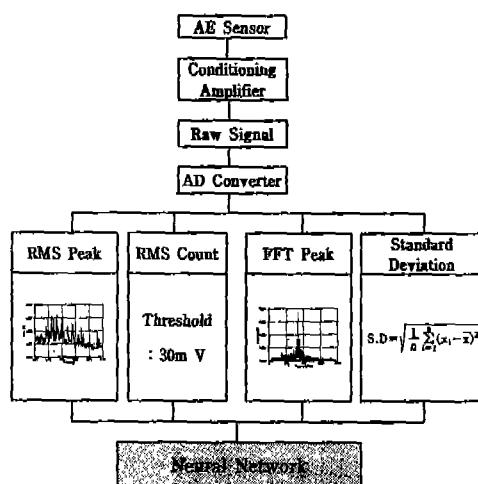


Fig. 8 Conceptual Flow of Input Parameters for Using Neural Networks

4. Neural Works의構成 및 實行結果

4.1 Neural Network의 구성

神經網回路의 적용은 事前知識이나 내부 시스템의 동작에 대한 지식이 거의 필요없고, 경향이 뚜렷한 模本(Sample)으로 부터의 학습경험에 바탕을 두고 새로운 類似 입력 패턴들이 주어질 경우에 그 출력 패턴을 추정할 수 있도록 自己組織化(Self-organization)하는 잇점이 있다. 본 시스템에 적용된 신경망회로 모델은 각각의 요소에 해당하는 뉴런(Neuron)과 입력, 출력 그리고 그들을 相互連結하는 結合荷重(Connection Weight) 사이의 관계를 圖式的으로 나타낸 것이 Fig.9이다. Fig.9에서 X_i 는 入力值, w_i 는 加重值, θ 는 Offset Value, O 는 出力值, $f()$ 는 傳達函數(Transfer Function)을 의미한다.

또한 Fig.10은 Chatter Vibration의 檢知를 위해 사용한 Neural Networks의 구성도를 나타내며, 입력층(Input Layer)의 뉴런(Neuron)의 수는 AE 신호로부터 얻어진 Parameter에 해당하는 4개(RMS Peak, RMS Count, FFT Peak, Standard Deviation)이고, 非線形 分離의 효과를 높이기 위해서 입력층의 뉴런의 개수보다 많은 5개의 뉴런을 갖는 2개의 중간층(Hidden Layer)이 있고, 출력층(Output Layer)에서는 세개의 유니트변수 即, Normal, Chatter Vibration, Burning의 값을 구하여, 이들을 비교하여 최대값을 출력하도록 한 $IV-(V-V)-III$ 의 형태를 갖는 Neural Networks으

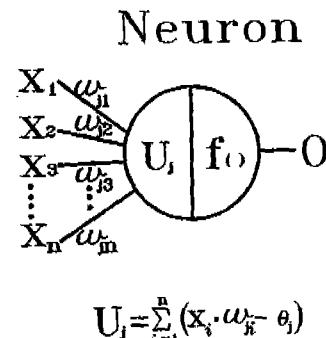


Fig. 9 Conceptual Diagram of a Neuron

Input Layer Hidden Layer 1 Hidden Layer 2 Output Layer

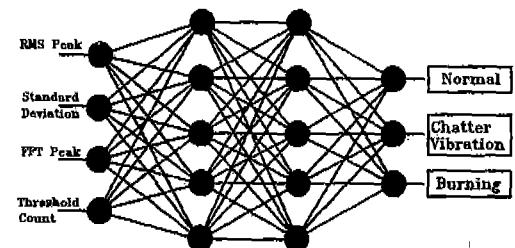


Fig. 10 Architecture of Neural Networks for Grinding Monitoring Systems

로 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 誤差項을 역전파하는 반복적 방법 즉, 역전파 학습 알고리즘(Back-Propagation Learning Algorithm)⁽⁹⁾을 사용하였다.

또한, 뉴런으로 입력되는 連結强度를 조절하여, 뉴런의 실제 출력값과 교사 데이터와의 차이인 오차(Error)를 줄이기 위해 誤差의 제곱을 최소화하는 Delta Rule을 사용하였다. 또한 각 층에서의 뉴런을 활성화시키는 전달 함수는 시그모이드 함수(Sigmoidal Function)를 선정하여 큰 입력값과 작은 입력값에 대해서도 적절히 반응할 수 있도록 구성하였다.

4.2 트러블 검지를 위한 학습

본 연구를 위한 실험조건들 중에서 절입속도가 1.0

mm/min일 때 연삭횟수가 증가함에 따라서 초기에는 안정된 상태를 유지하였으나, 연삭횟수가 43회부터 48회까지는 Burning이 발생하였으며, 62회부터는 Chatter Vibration 현상이 나타났다.

이를 토대로 Neural Networks의 학습을 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 데이터를 사용하였고, Chatter Vibration이 현저하게 나타났던 70회 때부터 74회 때까지의 데이터를 Chatter Vibration을 인식할 수 있도록 하였다.

또한, 학습 조건은 각 결합하증과 읍셋값(Offset Value)을 Random으로 한 값으로 초기화하고, 각 뉴런의 오차값이 0.001이하이고, 전체 시스템의 오차가 0.01이하가 되도록 하면서 반복횟수는 20,000번으로 제한하여 Personal Computer를 이용하여 학습을 완료하였다.

4.3 實行結果 및 考察

실제 연삭가공에서 일어날 수 있는 입력 파라메타의 패턴은 Table 2와 같은 신경망 회로의 학습을 위해서 사용된 것 보다는 多樣하기 때문에 이들을 포함하면서 학습하지 않은 새로운 형태의 입력 파라메타의 패턴(14-25)들로 구성된 데이터를 사용하여 학습된 神經網回路로 컴퓨터 시뮬레이션하여 얻어진 결과를 Table 3과 Table 4에 나타낸다.

Table 2 Supervised Data for the Learning of Neural Networks

No.	Input Parameters			Desired Output			Result	
	RMS Value	S.D. Value	PPV Value	Count	Normal	Burning		
5	0.021	0.096	0.096	0	1	0	0	Normal
6	0.018	0.087	0.087	0	1	0	0	Normal
7	0.021	0.109	0.109	0	1	0	0	Normal
8	0.024	0.091	0.109	0	1	0	0	Normal
9	0.019	0.078	0.078	0	1	0	0	Normal
10	0.034	0.155	0.155	10	0	1	0	Burning
11	0.037	0.139	0.139	23	0	1	0	Burning
12	0.032	0.140	0.140	9	0	1	0	Burning
13	0.033	0.283	0.283	48	0	1	0	Chatter
14	0.048	0.322	0.322	626	0	1	0	Chatter
15	0.042	0.342	0.42	931	0	0	1	Chatter
16	0.039	0.305	0.306	607	0	0	1	Chatter
17	0.033	0.256	0.256	68	0	0	1	Chatter

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

실행 결과는 Table 3과 같이 이미 잘 알려진 입력 파라메터의 조합에 대해서는 매우 우수한 인식 능력을 나타낼 뿐만 아니라, 또한 Table 4와 같이 전혀 새로운 입력 패턴들에 대해서도 Neural Networks의 장점인 우수한 적응성을 나타낼 수 있다.

Table 3 Implementation Results Utilizing the Neural Networks(I)

No.	Input Parameters			Outputs of Neural Networks			Results	
	RMS Peak	S.D. Peak	PPV Peak	Count	Normal	Burning		
5	0.021	0.096	0.096	0	0.987990	0.010019	0.010521	Normal
6	0.018	0.087	0.087	0	0.987986	0.010020	0.010523	Normal
7	0.021	0.109	0.109	0	0.987993	0.010019	0.010518	Normal
8	0.024	0.091	0.109	0	0.987988	0.010020	0.010522	Normal
9	0.019	0.078	0.078	0	0.987984	0.010020	0.010525	Normal
10	0.034	0.155	0.155	10	0.010223	0.813255	0.185224	Burning
11	0.037	0.139	0.139	23	0.010218	0.813217	0.185274	Burning
12	0.032	0.140	0.140	9	0.010221	0.813247	0.185241	Burning
13	0.033	0.283	0.283	48	0.010217	0.013243	0.985249	Chatter
14	0.048	0.322	0.322	626	0.010221	0.013241	0.985247	Chatter
15	0.042	0.342	0.42	931	0.010216	0.013242	0.985251	Chatter
16	0.039	0.305	0.306	607	0.010217	0.013242	0.985250	Chatter
17	0.033	0.256	0.256	68	0.010224	0.014232	0.985243	Chatter

Table 4 Implementation Results Utilizing the Neural Networks(II)

No.	Input Parameters			Outputs of Neural Networks			Results	
	RMS Peak	S.D. Peak	PPV Peak	Count	Normal	Burning		
10	0.014	0.075	0.078	0	0.987983	0.010020	0.010525	Normal
11	0.023	0.116	0.0165	0	0.987985	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	0.081	0.0108	0	0.987987	0.010020	0.010522	Normal
16	0.034	0.194	0.0409	11	0.010223	0.613252	0.386741	Burning
17	0.034	0.155	0.0372	13	0.010219	0.613253	0.386746	Burning
18	0.033	0.158	0.0403	16	0.010217	0.613256	0.586741	Burning
19	0.040	0.234	0.0450	156	0.010219	0.413252	0.586742	Chatter
20	0.047	0.239	0.0493	258	0.010221	0.413255	0.586744	Chatter
21	0.037	0.266	0.0451	114	0.010221	0.413253	0.586745	Chatter
22	0.087	0.279	0.387	94	0.010217	0.413255	0.586741	Chatter

5. 結 論

본연구는 AE 센서에서 얻어진 신호를 분석하여 연삭가공중에 발생하는 트러블을 검지하기 위하여 Neural Networks을 적용한 결과는 다음과 같다.

(1) 연삭가공중에 발생하는 AE 신호의 변화를 분석하여, 연삭 트러블인 Burning과 Chatter Vibration을 검지하는 것이 가능함을 제시하였다.

(2) AE 신호를 분석하여 4개의 파라메타를 同定한 [IV-(V-V)-III] 형태의 Neural Networks로 구성하여 실행한 결과 인식률이 우수하고, 새로운 Pattern에 대해서도 트러블을 효과적으로 인식됨이 확인 되었다.

(3) Neural Networks 검지 시스템을 이용한 연삭공정의 In-process Control의 가능성을 제시하였다.

참 고 문 헌

1. Malkin, S. and Anderson, R.B.: Thermal Aspect of Grinding Part 2 -Surface Temperature and Workpiece Burn, ASME, p. 1184, Nov, 1974.
2. Sato, K.: Grinding Temperature, Bull. Japan Society of Grinding Engineers, Vol.1, p. 31, 1961.
3. Littman, W. E. and Wulff, J.: The Influence of the Grinding Process on the Structure of Hardened Steel, ASME, Vol.47, p. 692, 1955.
4. D. Dornfeld, and He Gao Gai: An Investigation Grinding and Wheel Loading Using Acoustic Emission, ASME Journal of Engineering for Industry, Vol. 106, p. 28, Feb. 1984.
5. K. Srinivasan: Application of the Regeneration Spectrum Method to Wheel Regenerative Chatter in Grinding, ASME Journal of Engineering for Industry, Vol 104, p. 46, Feb. 1982.
6. F. Hasimoto: Growing Mechanism of Chatter Vibration in Grinding Processes and Chatter Stabilization Index of Grinding Wheel, Annals of the CIRP, Vol. 33, p. 259, 1984.
7. 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, p. 297, August. 1991.
8. Richard P. Lippmann: An Introduction to Computing with Neural Nets, IEEE ASSP Magazine, p. 4, April. 1987.
9. H. White, Learning in Artificial Neural Networks: A Statistical Perspective, Neural Computation, p. 425, 1989.
10. 竹中規雄, 研削加工のトラブルと対策, 誠文堂新光社. 10, p. 107, 1972.