

〈論 文〉

적응제어 수치제어 시스템의 개발 (I)

신경회로망 기법에 의한 절삭계수의 지적인 선정

정 성 중*

(1991년 11월 1일 접수)

Development of Adaptive Numerical Control System (I)

Intelligent Selection of Machining Parameters

by Neural-Network Methodology

Sung-Chong Chung

Key Words : Adaptive Control(적응제어), Learning(학습), Machinability(절삭성), Neural-Network(신경회로망), Process Planning(공정계획)

Abstract

Chemical and mechanical properties of workpieces and tools are important factors for selecting machining parameters in machining process planning. As there is no universal rule representing the machinability defined by metal removal rate, the selection of machining parameters still requires experience-oriented methods. In this paper, a new approach is presented to develop mathematical models for generating optimum machinability in turning processes based on chemical and mechanical properties of workpieces. Neural-Network methodology is introduced to identify mathematical models for machinability. It is confirmed by simulations that the proposed methodology can be used for developing numerical controllers with adaptive control performance.

1. 서 론

공정계획이란 제품 및 부품에 관한 가용자원에 대한 정보를 기초로 하여 설계품을 경제적으로 생산하기 위한 가공순서, 사용 공작기계의 종류, 수, 가공조건 및 사용공구의 종류, 수 등을 결정하는 일련의 작업을 일컫는다.^(1,2) 절삭공정에서 절삭계수(절삭속도, 이송속도, 절삭깊이)의 선정에 관한 대부분의 방법론은 경험에 기초한 방법들이며, 그 방법들은 안내서를 통한 수작업이나 데이터베이스로부터 얻어진 결과를 그대로 이용하는 전산화된

방법들이 쓰이고 있다.^(3,4) 이 경우 대부분의 결과들은 이산화된 자료만을 제공하여 절삭깊이나 이송속도 등과 같이 가공중 황삭 및 정삭조건 등의 절삭조건에 따라서 데이터베이스에는 없는 특정한 값이 주어져야 할 경우에는 그 값에 따라서 결정되어야 할 다른 절삭계수인 절삭속도의 선정시 최적의 해를 제공하지 못하고 있다. 그러므로 공정계획에서 절삭계수의 수학적 모형화를 이룩할 수 있다면, 이들에 따른 제반 문제점들을 해결할 수 있게 된다. 공정계획중 적절한 절삭계수를 선택하는데 있어서는 공작물의 화학적 성분, 기계적 성질, 공구형상 및 재질들이 중요한 관건이 된다. 절삭공정에서 이들 사이의 관계를 대표할 수 있는 것이 공작물의 절삭성이며 절삭성은 절삭가공의 편이성의 정

*정회원, 한양대학교 기계설계학과

도를 나타내는 지표로써 사용되고 있다.⁽⁵⁾ 본 논문에서는 단위시간당 절삭량(metal removal rate; MRR)을 절삭성으로 정의하고, 가공조건에 맞는 최적의 절삭계수를 선정하기 위하여 안내서⁽⁶⁾로부터 얻어진 기본 데이터를 이용하여 공작물의 최적 절삭성을 결정하기 위한 방법론을 제시하였으며, 절삭계수를 모형화하기 위하여 신경회로망 기법을 활용하였다. 신경회로망 기법은 많은 양의 데이터를 병렬로 처리할 수 있고, 수학적인 모형화의 수행시 비선형성이 크고 알고리즘의 적용이 곤란한 문제를 연속적인 다변수함수의 모형화에 응용함으로써 그방법이 가지고 있는 학습기능(learning performance)에 의하여 모형화할 수 있는 장점을 가지고 있다. 이러한 신경회로망 기법은 스피indle동력과 표면조도,⁽⁷⁾ 절삭력, 절삭온도 및 공구마모^(8,9) 등의 예측에 관한 생산공정에도 응용이 되어져 왔다.

본 논문에서는 일반화된 델타규칙을 이용한 신경회로망 기법⁽⁷⁻¹²⁾을 사용하여 절삭계수의 수학적인 모형화를 수행하였고, 탄소강 공작물 및 고속도강 공구에 대하여 절삭속도의 추정을 통하여 절삭성을 예측할 수 있는 방법론을 선삭작업에서 개발하였다. 그 결과 방대한 양의 절삭계수를 저장할 필요가 없을 뿐만 아니라, 작업자의 경험에 따른 절삭계수의 선정으로 인하여 발생할 수 있는 단점을 극복하고 유연한 절삭계수의 선정을 할 수 있게 하므로써 적응제어 기능을 갖는 수치제어장치의 개발에 응용할 수 있음을 밝혔다.

2. 절삭계수의 수학적 모형화

절삭계수와 이에 영향을 미치는 제인자 사이의 관계를 규명하기 위하여 다음과 같은 방법을 사용하였다. 절삭작업은 선삭작업에서 탄소강 공작물(AISI; 1xxx)과 고속도강 공구(ISO; S4, S5)를 사용하는 것을 대상으로 하였다. 본 논문에서 사용할 모형화 알고리즘에 적용되는 학습을 위한 기초 절삭정보는 Table 1과 같이 절삭깊이에 따라서 Fine, Medium, Coarse, Rough Cutting 등의 4가지 군의 경우로 구분하였다. 구분된 절삭깊이에 따라서 Machining Data Handbook 등^(5,6,13)을 이용하여 학습(learning) 및 판별(checking)에 필요한 데이터를 채취하였고, 수치실험시 사용한 입출력 변수는 다음과 같다.

2.1 입력 및 출력변수

입력변수는 절삭계수에 영향을 미치는 제인자로서 탄소강 공작물의 화학적 성분을 대표할 수 있는 탄소, 망간의 함유량과 기계적 성질 가운데서 가장 중요한 변수인 경도 그리고 절삭계수들의 상호관계로 규정을 하였다. 탄소와 망간은 공작물의 지배적인 화학적 성분이고, 항복응력, 인장응력, 연신율은 기계적 성질중 경도와 연관성이 크기 때문에 본 연구에서는 제외하였으며 기계적 성질중 경도만을 고려하였다. 경도는 각각의 공작물에 대하여 정확한 수치가 없기 때문에 Table 2와 같이 여섯개의 그룹을 선정하였으며, 이 그룹의 평균치를 선택하였다. 절삭계수는 그들의 상호적 연관성 때문에 절삭속도에 영향을 미치는 인자인 절삭깊이와 이송속도를 입력변수로 고려하였다. 공구의 형상, 화학적 성분 및 기계적 성질 등은 공구를 고속도강인 S4, S5로 한정하였기 때문에 입력변수에서 제외하였다. 출력변수로는 절삭계수 중 절삭속도를 취하였다.

2.2 수학적 모형화를 위한 신경회로망 기법

(1) 학습 및 판별 데이터

Table 3은 2.1 절에서 얻어진 기초 절삭정보를 이용하여 입출력 관계에 따른 수학적 관계식을 얻어내기 위한 학습데이터(learning data)를 보여준

Table 1 Classification of machining level by depth of cut

Cutting Group	Range of Depth of Cut(mm)
Fine	0.01~ 2.5
Medium	2.5 ~ 6.0
Coarse	6.0 ~12.0
Rough	12.0 ~20.0

Table 2 Classification of hardness

Range of Real Hardness (Bhn)	Classified Hardness (Bhn)
85~125	105
125~175	150
175~225	200
225~275	250
275~325	300
325~375	350

Table 3 Learning data for neural-network

Workpiece (AISI)	Chemical Properties		Mechanical Property	Machining Parameters												Material Removal Rate			
	C (%)	Mn (%)		Hardness (Bhn)	Depth of Cut (mm)			Cutting Speed (m/min)			Feedrate (mm/rev)			Fine	Medium	Coarse	Rough		
			Fine		Medium	Coarse	Rough	Fine	Medium	Coarse	Rough	Fine	Medium					Coarse	Rough
1005	0.05	0.30	105	1.0	4.0	8.0	16.0	56	44	35	27	0.18	0.40	0.50	0.75	10.08	70.4	140	324
1008	0.08	0.40	105	1.0	4.0	8.0	16.0	56	44	35	27	0.18	0.40	0.50	0.75	10.08	70.4	140	324
1015	0.15	0.45	150	1.0	4.0	8.0	16.0	46	38	30	24	0.18	0.40	0.50	0.75	8.28	60.8	120	288
1020	0.20	0.45	200	1.0	4.0	8.0	16.0	44	35	29	23	0.18	0.40	0.50	0.75	7.92	56	116	276
1025	0.25	0.85	250	1.0	4.0	8.0	16.0	38	29	23	18	0.18	0.40	0.50	0.75	6.84	46.4	92	216
1011	0.11	0.75	105	1.0	4.0	8.0	16.0	55	43	34	26	0.18	0.40	0.50	0.75	9.9	68.8	136	312
1016	0.16	0.75	150	1.0	4.0	8.0	16.0	44	37	29	23	0.18	0.40	0.50	0.75	7.92	59.2	116	276
1021	0.21	0.75	200	1.0	4.0	8.0	16.0	43	34	27	21	0.18	0.40	0.50	0.75	7.74	54.4	108	252
1026	0.26	0.75	250	1.0	4.0	8.0	16.0	38	29	23	18	0.18	0.40	0.50	0.75	6.84	46.4	92	216
1030	0.30	0.75	150	1.0	4.0	8.0	16.0	43	35	27	11	0.18	0.40	0.50	0.75	7.74	56	108	132
1038	0.38	0.75	200	1.0	4.0	8.0	16.0	40	30	26	20	0.18	0.40	0.50	0.75	7.2	48	104	240
1040	0.40	0.75	200	1.0	4.0	8.0	16.0	40	30	26	20	0.18	0.40	0.50	0.75	7.2	48	104	240
1042	0.42	0.75	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.3	43.2	84	204
1045	0.45	0.75	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.3	43.2	84	204
1053	0.53	0.85	300	1.0	4.0	8.0	16.0	30	23	18	10	0.18	0.40	0.50	0.75	5.4	36.8	72	120
1050	0.50	0.75	300	1.0	4.0	8.0	16.0	30	23	18	10	0.18	0.40	0.50	0.75	5.4	36.8	72	120
1060	0.60	0.95	200	1.0	4.0	8.0	16.0	37	27	21	15	0.18	0.40	0.50	0.75	6.66	43.2	84	180
1070	0.70	0.75	250	1.0	4.0	8.0	16.0	30	24	18	14	0.18	0.40	0.50	0.75	5.4	38.4	72	168
1075	0.75	0.55	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1080	0.80	0.75	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1095	0.95	0.40	350	1.0	4.0	8.0	16.0	18	14	11	7	0.18	0.40	0.50	0.75	3.24	22.4	44	84
1116	0.16	1.25	105	1.0	4.0	8.0	16.0	60	45	37	27	0.18	0.40	0.50	0.75	10.8	72	148	324
1119	0.19	1.15	150	1.0	4.0	8.0	16.0	64	49	38	30	0.18	0.40	0.50	0.75	11.52	78.4	152	360
1109	0.09	0.65	105	1.0	4.0	8.0	16.0	55	41	34	26	0.20	0.40	0.50	0.75	11	65.6	136	312
1115	0.15	0.75	150	1.0	4.0	8.0	16.0	58	44	34	27	0.20	0.40	0.50	0.75	11.6	70.4	136	324
1137	0.37	1.50	200	1.0	4.0	8.0	16.0	52	40	30	24	0.20	0.40	0.50	0.75	10.4	64	120	288
1144	0.44	1.50	200	1.0	4.0	8.0	16.0	52	40	30	24	0.20	0.40	0.50	0.75	10.4	64	120	288
1335	0.35	1.75	250	1.0	4.0	8.0	16.0	35	27	21	27	0.18	0.40	0.50	0.75	6.3	43.2	84	204
1340	0.40	1.75	200	1.0	4.0	8.0	16.0	41	32	24	20	0.18	0.40	0.50	0.75	7.38	51.2	96	240

Table 4 Checking data for neural-network

Workpiece (AISI)	Chemical Properties		Mechanical Property Hardness (Bhn)	Machining Parameters												Material Removal Rate (mm ³ /min × 10 ³)			
	C (%)	Mn (%)		Depth of Cut (mm)			Cutting Speed (m/min)			Feedrate (mm/rev)			Fine	Medium	Coarse	Rough			
			Fine	Medium	Coarse	Rough	Fine	Medium	Coarse	Rough	Fine	Medium					Coarse	Rough	
1006	0.06	0.33	105	1.0	4.0	8.0	16.0	56	44	35	27	0.18	0.40	0.50	0.75	10.08	70.4	140	324
1010	0.10	0.45	105	1.0	4.0	8.0	16.0	56	44	35	27	0.18	0.40	0.50	0.75	10.08	70.4	140	324
1012	0.12	0.45	150	1.0	4.0	8.0	16.0	46	38	30	24	0.18	0.40	0.50	0.75	8.28	60.8	120	288
1017	0.17	0.45	150	1.0	4.0	8.0	16.0	46	38	30	24	0.18	0.40	0.50	0.75	8.28	60.8	120	288
1023	0.23	0.75	200	1.0	4.0	8.0	16.0	44	35	29	23	0.18	0.40	0.50	0.75	7.92	56.0	116	276
1013	0.13	0.65	150	1.0	4.0	8.0	16.0	44	37	29	23	0.18	0.40	0.50	0.75	7.92	59.2	116	276
1018	0.18	0.75	200	1.0	4.0	8.0	16.0	43	34	27	21	0.18	0.40	0.50	0.75	7.74	54.4	108	252
1019	0.19	0.85	200	1.0	4.0	8.0	16.0	43	34	27	21	0.18	0.40	0.50	0.75	7.74	54.4	108	252
1022	0.22	0.85	200	1.0	4.0	8.0	16.0	43	34	27	21	0.18	0.40	0.50	0.75	7.74	54.4	108	252
1029	0.29	0.75	250	1.0	4.0	8.0	16.0	38	29	23	18	0.18	0.40	0.50	0.75	6.84	46.4	92	216
1035	0.35	0.75	150	1.0	4.0	8.0	16.0	43	35	27	11	0.18	0.40	0.50	0.75	7.74	56.0	108	132
1037	0.37	0.85	200	1.0	4.0	8.0	16.0	40	30	26	20	0.18	0.40	0.50	0.75	7.20	48.0	104	240
1039	0.39	0.85	200	1.0	4.0	8.0	16.0	40	30	26	20	0.18	0.40	0.50	0.75	7.20	48.0	104	240
1043	0.43	0.85	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.30	43.2	84	204
1044	0.44	0.45	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.30	43.2	84	204
1046	0.46	0.85	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.30	43.2	84	204
1055	0.55	0.75	300	1.0	4.0	8.0	16.0	30	23	18	10	0.18	0.40	0.50	0.75	5.40	36.8	72	120
1064	0.64	0.65	250	1.0	4.0	8.0	16.0	30	24	18	14	0.18	0.40	0.50	0.75	5.40	38.4	72	168
1065	0.65	0.75	250	1.0	4.0	8.0	16.0	30	24	18	14	0.18	0.40	0.50	0.75	5.40	38.4	72	168
1074	0.74	0.65	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1078	0.78	0.45	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1085	0.85	0.85	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1090	0.90	0.75	300	1.0	4.0	8.0	16.0	24	18	15	10	0.18	0.40	0.50	0.75	4.32	28.8	60	120
1118	0.18	1.45	105	1.0	4.0	8.0	16.0	60	45	37	27	0.18	0.40	0.50	0.75	10.80	72.0	148	324
1215	0.15	0.90	150	1.0	4.0	8.0	16.0	64	49	38	30	0.18	0.40	0.50	0.75	11.52	78.4	152	360
1108	0.08	0.65	105	1.0	4.0	8.0	16.0	55	41	34	26	0.20	0.40	0.50	0.75	11.00	65.6	136	312
1110	0.10	0.45	150	1.0	4.0	8.0	16.0	58	44	34	27	0.20	0.40	0.50	0.75	11.60	70.4	136	324
1132	0.32	1.50	200	1.0	4.0	8.0	16.0	52	40	30	24	0.20	0.40	0.50	0.75	10.40	64.0	120	288
1140	0.40	0.85	200	1.0	4.0	8.0	16.0	52	40	30	24	0.20	0.40	0.50	0.75	10.40	64.0	120	288
1330	0.30	1.75	200	1.0	4.0	8.0	16.0	41	32	24	20	0.18	0.40	0.50	0.75	7.38	51.2	96	240
1345	0.45	1.75	250	1.0	4.0	8.0	16.0	35	27	21	17	0.18	0.40	0.50	0.75	6.30	43.2	84	204

다. 그리고, 얻어진 모형의 정확성을 판별하기 위하여 판별데이터(checking data)를 위의 학습데이터에서 선택되지 않은 공작물에 대하여 Table 4와 같이 취하였다. 이들 데이터는 다음과 같은 방법으로 정리되었다.

(가) 공작물에 해당하는 탄소강의 종류를 결정한다.

(나) 탄소, 망간 함유량을 정리한다.

(다) 절삭깊이에 따라서 Table 1을 이용하여 데이터를 분류한다.

(라) 절삭정도에 따라 선택된 공작물에 대하여 Table 2를 이용하여 여러개의 경도를 선정하고, 이 경도에 따른 절삭계수를 선택한다.

(마) 각각에 대하여 절삭계수들 사이의 곱으로 이상적인 절삭성을 구한다.

(바) 좋은 모형화가 될 수 있도록 절삭정보의 Richness를 부여하기 위하여 탄소, 망간, 경도 등의 정보를 중복되지 않도록 선정한다.

학습데이터는 신경회로망 기법을 이용하여 입력 변수와 출력변수 사이의 수학적 모형화에 필요한 연결강도(weight)와 역치(threshold)를 .2.2절 (2)항의 방법을 이용하여 구하는데 사용되어지며, 판별데이터는 학습과정을 통하여 모형화된 결과식에 입력값을 입력하고 이때 원하는 출력값과 학습모형을 통하여 얻어진 실제값을 비교 검토함으로써 수학적 모형화 결과의 정확성을 판별할 수 있도록 한다.

(2) 신경회로망 기법

Fig. 1은 J개의 숨은단(hidden layer)을 갖는 신경회로망의 구조이다. 입력단(input layer)을 제외한 J번째 단중 K번째 노드(node)의 입력은 식(1)과 같이 된다.

$$X_k = \sum_{i=1}^M W_{ki}^{j-1} O_i^{j-1} \quad (1)$$

여기서, M : (J-1)번째 단의 노드수

W_{ki}^{j-1} : (J-1)번째 단의 I번째 노드로부터

J번째 단의 K번째 노드로의 연결강도

O_i^{j-1} : (J-1)번째 단의 I번째 노드의 출력

이다. 식 (1)을 도식적으로 표현하면 Fig. 2와 같다. 식 (1)에서 계산된 X_k 를 이용하여 J번째 단의 K번째 노드에서 출력 O_k 을 구하면 식 (2)와 같이 된다.

$$O_k = f(X_k - \theta_k) \quad (2)$$

여기서, f는 활성화함수(activating function)이고, θ_k 는 J번째 단의 K번째 노드에서의 역치값이다. 학습과정중 미분가능한 함수로 비선형성을 잘 묘사할 수 있도록 하기 위하여 활성화함수로써 Fig. 3과 같은 Sigmoid 함수를 사용하였다.

$$O_k = \frac{1}{1 + \text{EXP}[-(X_k + \theta_k) / \theta_0]} \quad (3)$$

여기서 θ_0 는 Sigmoid곡선의 형태를 결정하는 형태상수(shape factor)이며 본 연구에서는 연속함수의




Fig. 1 Structure of neural-network




Fig. 2 Inputs and weightings for Kth node in Jth layer




Fig. 3 Sigmoid function with bias(θ_k) and shape factor(θ_0)

모형화에 적합하도록 $\theta_0=1$ 로 하였다.

일반화된 델타규칙^(7~12)은 수학적 모형화 작업시 알고리즘의 적용이 곤란한 문제를 학습을 통하여 해결할 수 있는 장점을 가지고 있다. 본 연구에서는 각각의 숨은단에서의 노드들의 출력을 식(3)으로 계산하고, 출력단에서의 출력 O_f 를 계산한 후 식(4)와 같이 주어지는 출력단에서의 각 입력패턴 I 에 따라서 발생하는 추정치의 자승오차항을 평균으로 하는 오차 E 를 최소화하는 방향으로 입력과 출력단 사이의 연결강도와 역치를 수정하는 과정을 반복한다.

$$E = \frac{1}{2M} \sum_{f=1}^M (t_f - O_f)^2 \quad (4)$$

여기서, M ; 입력으로 선정된 데이터 패턴의 수

t_f ; 각 입력패턴에 대한 목표치

O_f ; 각 입력패턴에 따라서 계산된 추정치이다. 식 (4)에 주어진 E 를 줄이는 학습과정은 Steepest-Descent 법에 기초한 Backpropagation 알고리즘^(7,10,12)을 이용하여 다음과 같이 수행하였다.

(가) 연결강도와 역치를 랜덤하게 초기화 한다.

(나) 탄소량, 망간량 및 경도치 또는 절삭계수 중 일부로 입력패턴을 작성하고, 출력으로 절삭속도를 취한다.

(다) 선정된 절삭계수는 Fig. 3에 주어진 Sigmoid 함수에 맞게 Table 5에 주어진 절삭계수의 선정구간 중 최대값으로 정형화(normalization) 시킨다.

(라) I 번째 입력패턴을 Fig. 1과 같은 신경회로망에 가하여 출력단 L 에서의 출력값 O_f 를 만든다.

(마) 식 (5)를 이용하여 연결강도를 변화시킨다.

$$\Delta W_{ki}(N) = \eta \delta_k^i O_f^{-1} + \alpha \Delta W_{ki}(N-1) \quad (5)$$

여기서, $\Delta W_{ki}(N)$; N 번째 학습단계에서 ($J-1$)번째 단의 I 번째 노드가 J 번째 단의 K 번째 노드에 미치는 연결강도의 증분변화량

η ; 학습율 (learning Rate)

α ; 학습 가중계수 (momentum Rate)

$\Delta W_{ki}(N-1)$; ($N-1$)번째 학습단계에서 계산된 ΔW_{ki}

$$\delta_k^i = -\partial E / \partial X_k^i$$

$$O_f^{-1} = f'(X_f^{-1} - \theta_f^{-1})$$

η 와 α 는 0과 1사이의 상수이며, η 가 크면 빠른 학습활동을 하지만 E 가 X_k 에 대하여 복잡한 함수인 경우 계수추정시 진동현상이 유발되어 Local Minimum에 빠질 위험이 있으므로 그것을 방지하기 위하여 α 를 추가한다.^(7,10~12) α 의 역할은 학습활동시 이전 단계에서 추정된 W_{ki} 를 현단계에서 이용하는 비율을 나타낸 것으로 W_{ki} 의 갑작스런 변화를 방지하고 학습활동이 일정한 방향으로 진행되도록 한다.

(바) E 가 주어진 공차범위 내에 이를 때까지 (나)에서 (마)의 과정을 반복한다. θ_k 의 추정도 위에서 제시한 (가)~(바)의 과정과 유사한 방법으로 진행한다.^(7,10,12)

3. 신경회로망 모형화 결과

3.1 절삭계수

절삭계수의 수학적 모형화는 Table 5에 제시한 범위내에서 수행하였다. 일반적인 경우 선삭작업에서는 절삭계수의 선정시 우선 절삭깊이를 선정하고, 표면조도에 맞추어 이송속도를 선정한다. 그리고, 공구수명식이나 마멸방지 또는 채터방지 조건하에서 절삭속도를 결정하고 있다. 본 논문에서 사용하고 있는 Machining Data Handbook에 제시되어 있는 절삭계수도 절삭깊이와 이송속도를 이산화시켜 지정한 후 공구수명식 등의 제반조건에 맞추어 최적의 절삭속도를 수십년에 걸친 수많은 반복실험을 통하여 추정된 것으로 널리 이용되어져 오고 있다.⁽⁶⁾ 그러므로, 본 논문에서도 탄소강 공작물의 화학적인 성분을 대표하는 탄소와 망간의 함유량, 공작물의 기계적 성질을 대표하는 경도 그리고 절삭계수 중 절삭깊이와 이송속도를 입력으로 취하고 절삭속도를 출력으로 하는 수학적인 모형화를 수행하였다. 즉, 수학적인 모형화 작업후 원하는 절삭깊이와 이송속도를 입력하면, 각각의 공작물의 특성에 따라 Machining Data Handbook에서 제시한 최적 절삭조건에 부합되는 절삭속도를 연속

Table 5 Selection range of machining parameters

Machining Parameters	Range
Depth of Cut (mm)	0.01~20.0
Cutting Speed (m/min)	0.01~100.0
Feedrate (mm/rev)	0.01~2.0

적으로 산출할 수 있도록 하였다.

신경회로망 기법은 Fig. 4와 같이 1개의 숨은단이 20개의 노드를 갖는 신경회로망(5×20×1)을 이용하였다. 2.2절 (2)항에서 제시한 Backpropagation 법에 기초한 지도학습(supervised learning)을 수행하기 위하여 Table 3에 주어진 학습데이터로부터 Table 6과 같은 학습데이터 군을 취하였다. Table 6의 학습조건을 이용하여 각각의 절삭속도의 모형화를 수행하고, 모형화된 결과에 Table 4에 주어진 판별데이터 중 Table 6의 입력데이터에 해당하는 값만 취하여 추정치를 계산한 후 판별데이터의 목표치와 비교하면 Table 7과 같이 된다. Table 7의 결과는 신경회로망을 통하여 추정된 절삭계수의 입력 조건에 따른 수학적 모형화 결과이며, Table 4에 주어진 목표치와의 사이의 오차범위가 5% 이내가 될 수 있도록 학습후 얻어진 결과이다. Table 7에서 볼 수 있듯이 실제 얻어진 목표치와의 퍼센트오차량은 약 6.5% 정도로 판별데이터를 이용한 절삭속도 추정 모형의 학습정도 평

가는 만족하게 이루어지고 있음을 알 수 있다. Table 6에 주어진 오차범위 또는 학습활동을 위한 계산횟수를 더욱 좋게하면 보다 나은 학습결과를 얻을 수 있지만, 학습횟수 100,000회를 5×20×1 모형에 대하여 IBM-PC/386을 이용하여 수행하는데 약 24시간이 소요되는 점을 감안하여 Fig. 4와 같은 신경회로망 구조를 선택하였다.

Fig. 5는 여러가지 신경회로망 모형에 대한 학습활동을 보여주고 있다. 전체적인 학습활동은 초기에는 빠르게 진행되지만 학습횟수가 증대됨에 따라서 오차의 감소율이 둔화되는 경향을 보여주고 있다. 절삭속도 모형화의 경우 숨은단을 넣지 않은 경우에는 학습이 잘 이루어지지 않으며, 신경회로망의 구조가 복잡하여 질수록 모형화가 잘 이루어지고 있음을 볼 수 있다. 즉, 절삭속도는 입력변수와의 사이에 선형적인 관계는 없고 비선형성이 농후하며, 숨은단의 노드수가 적은 것은 복잡한 거동을 하는 모형화에는 적합하지 않음을 알 수 있다.




Fig. 4 5×20×1 neural-network for cutting speed estimation




Fig. 5 Comparison of rates of learning

Table 6 Learning data set for cutting speed

Object Model	Input Nodes	Output Node	Learning Conditions
Cutting Speed	Carbon Content	Cutting Speed	Input Nodes =5
	Manganese Content		Output Node =1
	Hardness(Bhn)		Sample Pattern =116
	Depth of Cut		Learning Rate $\eta=0.9$
	Feedrate		Momentum Rate $\alpha=0.7$
			Error Bound $E=0.000089$
			Hidden Layer =1
	Nodes in Hidden Layer =20		
	Shape Factor =1.0		
	Iteration for Learning =100,000		

Table 7 Neural-network results for cutting speed

Workpiece (AISI)	Cutting Speed (m/min)							
	Estimated Values				Percent Error			
	Fine	Medium	Coarse	Rough	Fine	Medium	Coarse	Rough
1006	56.47	44.92	34.18	26.92	0.84	2.09	2.35	0.31
1010	50.73	39.84	31.96	25.44	9.40	9.45	8.69	5.78
1012	51.76	42.44	35.50	25.63	12.52	11.68	18.35	6.78
1017	44.99	34.28	26.52	22.02	2.20	9.80	11.61	8.27
1023	44.08	34.45	27.48	22.13	0.17	1.56	5.24	3.78
1013	50.47	40.85	33.18	27.69	14.71	10.40	14.43	20.40
1018	44.72	35.11	28.15	24.97	3.99	3.25	4.27	18.90
1019	46.64	35.54	28.22	24.69	8.47	4.53	4.53	17.59
1022	46.24	35.17	27.93	23.64	7.53	3.44	3.45	12.55
1029	38.01	28.82	22.05	17.49	0.03	0.62	4.12	2.85
1035	43.29	33.38	25.11	12.14	0.66	4.63	7.02	10.32
1037	43.86	32.84	26.10	20.98	9.65	9.48	0.37	4.91
1039	43.41	32.40	25.72	20.63	8.53	8.00	1.08	3.17
1043	37.78	27.30	20.88	16.61	7.94	1.11	0.57	2.29
1044	37.08	28.70	22.26	14.79	5.93	6.29	5.99	12.97
1046	37.37	26.87	20.57	16.25	6.76	0.47	2.05	4.38
1055	30.68	22.42	17.05	10.85	2.27	2.50	5.26	8.53
1064	32.95	24.34	18.73	13.52	9.84	1.41	4.05	3.43
1065	32.84	23.85	18.32	13.63	9.48	0.64	1.76	2.68
1074	26.10	19.31	15.15	9.73	8.74	7.28	0.98	2.67
1078	25.63	19.36	15.52	9.72	6.80	7.55	3.50	2.79
1085	25.86	18.72	14.40	9.51	7.74	3.98	4.01	4.92
1090	25.42	18.92	14.79	9.51	5.93	5.12	1.42	4.91
1118	60.86	47.01	28.73	30.63	1.43	4.46	22.34	13.46
1215	57.25	44.42	34.40	26.39	10.54	9.36	9.48	12.02
1108	59.59	45.72	36.95	27.77	8.35	11.52	8.68	6.80
1110	57.47	46.69	39.20	26.60	0.91	6.11	15.29	1.49
1132	53.05	40.51	30.34	26.65	2.03	1.28	1.12	11.06
1140	44.86	32.16	25.52	20.45	13.73	19.60	14.94	14.78
1330	44.91	35.19	24.86	20.62	9.53	9.35	3.58	3.10
1345	34.20	26.42	21.98	16.48	2.29	2.13	4.66	3.07

그러나, 노드의 수가 많아지거나 숨은단의 수가 많아지면 학습에 요구되는 계산시간이 늘어나게 되어 상대적으로 볼 때 불리하게 된다.

학습데이터를 이용하여 모형화한 후 판별데이터로 모형의 타당성을 검토한 결과로부터 본 논문에서 제시한 절삭계수의 수학적 모형화 방법론의 타당성을 입증할 수 있으며, 다른 공작물과 다른 공구에 대하여도 마찬가지로 방법론을 적용할 수 있겠

다. 그리고, 이와같은 절삭계수 모형을 이용하면 이산화된 수많은 절삭정보를 이용하는 대신 공작물과 공구의 주요한 몇가지 성질과 수학적인 모형만으로도 원하는 절삭계수를 연속적으로 얻어 낼 수 있을 것이다.

3.2 절삭성

기존의 Machining Data Handbook⁽⁶⁾을 이용하

면 공구경로 계획시 절삭계수를 선정할 때 절삭깊이를 1, 4, 8, 16 mm 등의 이산화된 값으로 줄 수 밖에 없기 때문에 공작물 가공시 특정한 절삭깊이를 주고자 하는 경우 최적의 절삭조건을 선정할 수 없게 된다. 2.2 절에서 제시한 신경회로망 기법을 적용하여 임의의 절삭깊이와 이송속도를 Table 8과 같이 각각의 공작물에 대하여 선정하고 3.1 절에서 얻어진 절삭속도 모형에 대입하여 절삭계수의 추정치를 구하면 Table 8의 추정절삭속도를 각각의 절삭조건에 따라서 구할 수 있게 된다.

MRR로 정의되는 절삭성은 실제 이상적인 경우 식 (6)과 같이 주어진다.

$$MRR = (DOC) \times (SPEED) \times (FEED) \quad (6)$$

여기서 DOC=절삭깊이(mm)

SPEED=절삭속도(m/min)

FEED=이송속도(mm/rev)

이다. 그리고 임의로 선정된 절삭깊이와 이송속도 및 추정된 절삭속도를 식 (6)에 대입하면 추정된 MRR을 Table 8과 같이 구할 수 있게 된다. 사용자가 선정된 절삭조건에 따라서 추정되어진 Table 8의 MRR과 Table 4에 주어진 가공조건에 따른 MRR을 비교하면 각각의 절삭조건에서 수학적인 모형화를 통하여 얻어진 결과의 타당성을 입증할 수 있게 된다. 즉, 1006 탄소강의 경우 1의 조건에 해당하는 절삭깊이, 이송속도 및 추정된 절삭속도를 이용하면 13,240 mm³/min의 MRR을 얻을 수 있게 되는데, Table 4에서 절삭깊이 1.0 mm, 이송속도 0.18 mm/rev인 경우와 Table 8의 1의 조건인 절삭깊이 0.4 mm, 이송속도 0.38 mm/rev를 비교하면 Table 8의 1의 조건이 절삭속도를 크게할 수 있기 때문에 정상조건시 Table 4의 10,080 mm³/min보다 많은 MRR을 얻을 수 있다는 것을 알 수 있다. 또한 1345 탄소망간강의 경우 Table 4에 주어진 이산화된 값보다 Table 8의 4의 조건에서는 절삭깊이는 2.5 mm, 이송속도는 0.22 mm/rev만큼 많이 주었다. 그결과 측정된 절삭속도는 2.55 m/min만큼 감소되었으나, 상대적으로 심화된 절삭조건 때문에 MRR이 증대되는 결과를 볼 수 있다.

그러므로, 신경회로망을 이용하여 얻어진 절삭계수의 수학적인 모형을 이용하면 절삭계수의 선정시 이산화된 절삭정보 이외에도 Machining Data

Handbook⁽⁶⁾에 제시된 최적의 절삭조건에 맞는 절삭계수를 취할 수 있으며, 실제 절삭가공 공정에서 임의의 절삭깊이와 이송속도를 상황에 따라서 최적으로 제어할 수 있게 되어 적응제어 기능을 갖는 수치제어 장치의 설계에 활용이 가능하게 될 것이다.⁽³⁾

4. 결 론

(1) 신경회로망 기법을 이용하여 선삭공정에서 공구로 고속도강(S4, S5)을 사용하는 경우 탄소강 공작물의 탄소와 망간의 함유량 그리고 경도의 크기, 절삭깊이, 이송속도를 입력으로 취하면 절삭속도를 출력으로써 구할 수 있도록 하는 수학적 모형화 방법론을 개발하였다.

(2) 판별데이터를 이용하여 신경회로망 모형의 정확성을 검토한 결과 개발된 모형화 방법론의 타당성을 입증하였다. 그리고, 다른 공구와 공작물 등에 응용될 수 있도록 확장하면 보다 일반화된 절삭계수의 수학적 모형화 시스템을 개발할 수 있을 것이다.

(3) 절삭계수의 수학적 모형화를 이름으로써 절삭공정에서 필요한 모든 절삭 정보를 데이터베이스화 하는데 있어 메모리 부족현상을 해결할 수 있으며, 수학적 모형으로부터 임의의 절삭계수를 연속적으로 선정할 수 있기 때문에 데이터베이스에 따른 이산화된 절삭계수가 아닌 가공조건에 맞는 최적의 절삭계수를 얻을 수 있다.

(4) 개발된 절삭속도 모형화 방법론은 연속적인 절삭계수의 추정을 가능하게 하고, 가공상황 하에서 절삭조건에 유연하게 대처할 수 있는 기능을 부여하기 때문에 절삭계수의 자동 추정 기능을 갖는 적응제어 수치장치의 개발에 활용되어질 수 있다.

참고문헌

- (1) Chang, T.C. and Wysk, R.A., 1985, "An Introduction to Automated Process Planning System," prentice Hall Inc., N. J.
- (2) Chrystolouris, G. and Chan, S., 1985, "An Integrated Approach to Process Planning and Scheduling," Annals of the CIRP, Vol.34, pp. 413~417.
- (3) 정성중, 1988, "공작기계 자동화를 위한 적응

- 제어 기술의 개발동향”, 대한기계학회지, 제28권 제3호, pp. 344~357.
- (4) Cook, N.H., 1977, “Adaptive Machining Parameter Selection,” Proceedings of the 5th NAMRC, pp. 344~356.
- (5) Degarmo, E.P., Black, J.T. and Kohser, R.A., 1984. “Materials and Processes in Manufacturing,” Macmillan Publishing Co., N.Y.
- (6) Metcut Research Associates, 1980, “Machining Data Handbook (Vol 1 & 2),” Machinability Data Center, Cincinnati, Ohio.
- (7) Chrystolouris, G. and Guillot, M., 1990, “A Comparison of Statistical and AI Approaches to the Selection of Process Parameters in Intelligent Machining,” Transactions of the ASME, Engineering for Industry, Vol.112, pp. 122~131.
- (8) Rangwala, S.S. and Dornfeld, D.A., 1989, “Learning and Optimization of Machining Operations Using Computing Abilities of Neural Networks,” IEEE Transactions on Systems, Man, and Cybernetics, Vol.19, No.2, pp. 299~314.
- (9) Rangwala, S.S. and Dornfeld, D.A., 1990, “Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring,” Transactions of the ASME, Journal of Engineering for Industry, Vol.112, pp. 219~228.
- (10) Pao, Y.H., 1989, “Adaptive Pattern Recognition and Neural Networks,” Addison-Wesley, N. Y.
- (11) Pao, Y.H., 1988, “A Connectionist Net approach to Autonomous Machine Learning of Effective Process Control Strategies,” Robotics & Computer-Integrated Manufacturing, Vol.4, No.3/4, pp. 633~642.
- (12) Lippman, R.P., 1987, “An Introduction to Computing with Neural Nets,” IEEE ASSP Magazine, Vol. 4, pp. 4~22.
- (13) Oberg, E., Jones, F.D. and Horton, H.L., 1975, “Machinery’s Handbook,” Industrial Press Inc., N.Y.