

# 피삭재와 공구재종의 상관관계에 근거한 적정 절삭조건 결정

한 동 원\*, 고 성 립\*\*, 이 건 우\*\*\*

## Determination of Optimal Cutting Conditions Based on the Relationship between Tool Grade and Workpiece Material

Dong-Won Hahn\*, Sung-Lim Ko\*\*, Keon-Woo Lee\*\*\*

### ABSTRACT

In determining optimal cutting condition for face milling operation, tool wear is an important factor. For the purpose of establishing the relationship between various machining factors and tool wear, cutting tests have been performed. As a result, hardness and chemical composition of workpiece material, chemical composition and grain size of cutting tool and cutting speed have been selected as machining factors. In addition, relationship between feed rate and workpiece hardness has been observed. Prior to utilizing cutting conditions recommended by 'Machining Data Handbook(MDH)' as a knowledge base, an analysis for the validity of the MDH has been provided. Based on this analysis, tool life criteria applied by MDH has been modified. Finally, using MDH recommended data for neural network training, the results from the trained neural network for optimal cutting condition for some given workpiece and cutting tool can be used as reference cutting conditions.

**Key Words** : Optimal Cutting Condition(최적 절삭조건), Machining Factor(가공인자), Cutting Variable(절삭변수), Machining Data Handbook(절삭조건표), Chemical Composition(화학성분), Neural Network(신경회로망)

### 1. 서 론

절삭공정을 설계함에 있어 작업자에게 주어지는 정보는 완성된 공작물의 형상에 대한 정보와 피삭재에 대한 정보, 공작기계에 대한 정보, 그리고 공구에 대한 정보인데 현재 생산현장에서는 작업자가 이러한 조건들을 염두에 두고 주로 경험에 의존하여 가공에 적절한 절삭조건을 선정하고 있다.

그러나 근래에 들어서 생산의 형태가 소품종 대량생산

의 형태에서 다품종 소량생산으로 이행하고 있고 이러한 추세는 절삭가공에서의 컴퓨터의 도입을 가속시켰다. 컴퓨터로 공정설계를 자동화하기 위한 노력의 결과중 하나로서, 부품 최종형상의 모델링에 의해 NC공작기계에 지령을 내릴 수 있는 NC코드를 자동으로 생성해주는 소프트웨어들이 개발되고 있다. 그러나 생산성을 극대화할 수 있는 공구경로와 공정계획 못지 않게 생산성에 중요한 영향을 미치는 실제 가공에 있어서의 절삭조건을 자동적으로(또는 지능적으로) 선정하는 방법은 아직도 실용화 단

\* 건국대학교 대학원 기계설계학과  
\*\* 건국대학교 기계설계학과  
\*\*\* 대한중석(주)

제에 이르지 못하고 있다. 따라서 피삭재와 공구에 대한 정보를 포괄적으로 포함하고 있는 데이터 베이스와 이들의 조합에 대하여 다양한 절삭작업에 따른 적절한 절삭조건을 합리적인 근거하에 자동적으로 선정해주는 시스템의 개발이 필요하게 된다.

또한 주어진 피삭재와 공구에 대하여 절삭조건을 최적화하기 위해서는 많은 비용과 시간이 요구되는 절삭성 실험을 거쳐야 하는데, 수많은 피삭재와 공구의 조합에 대해 일일이 절삭성 실험을 행하는 것은 매우 비효율적이다. 따라서 기존의 절삭성 실험 데이터를 최대한 분석, 활용하고 절삭성에 영향을 미치는 가공인자들을 추출해서 절삭조건 최적화에 필요한 실험을 최소화하면서 동시에 합리적인 적정절삭조건 예측을 할 수 있는 방법의 개발이 요구된다.

이를 위해 본 연구에서는 우선 절삭성에 영향을 미치는 가공인자의 추출과 피삭재와 공구재종에 대한 포괄적인 분류를 행하고, 이를 바탕으로 기존의 적정절삭조건 데이터를 재구성하여, 이를 지능적인 적정절삭조건 선정 알고리즘의 지식베이스(knowledge base)로서 사용하였다. 그리고 이 알고리즘을 이용하여 피삭재와 공구에 대한 정면밀링(face milling) 작업에서의 절삭조건 최적화를 시도하였다.

이를 위해 우선 절삭조건 최적화에 대한 기존의 연구를 검토하였는데, 이들은 크게 가공비용을 최적화의 기준(criteria)으로 설정하여 수익률(profit ratio)을 최대화하기 위한 최적화와, 기존의 피삭성 데이터와 전문가의 지식을 포함하는 데이터베이스를 구축하고 이를 지식기반(knowledge base)으로하는 인공지능 알고리즘을 통한 최적화라고 하는 두 가지로 나눌 수 있다.

El-Dardiry<sup>(1)</sup>, Wysk<sup>(2)</sup>, Bidhendi<sup>(3)</sup> 등에 의해 연구된 첫 번째 방법에서는, 최적화를 위해 가공에 관여하는 요소들간의 관계를 생산비를 중심으로 한 수식으로 표현하여, 이의 최대, 최소값을 구하는 방법으로 최적화를 시도하였다. 이 방법은 최적화에 사용되는 수식에 사용되는 계수를 얻기 위하여, 여러 종류의 피삭재와 공구에 대해 매우 방대한 양의 실험을 해야 하므로 실용적인 면에서 그 한계를 가지고 있다.

이러한 이유로 인공지능 기법을 도입한 두 번째 방법의 최적화가 최근 많이 행해지고 있다. 그 중 대표적인 것으로는 Sata<sup>(4)</sup>, Usui<sup>(5)(6)</sup> 등에 의해 연구된, 매우 애매하고 불명확한 형태로 존재하는 작업자의 경험에 의한 의사결정방법을 수식화하는 방법과, 정성종<sup>(7)</sup>, Deguchi<sup>(8)</sup> 등에

의한 기존의 최적 절삭조건 데이터베이스나 데이터 핸드북 등에서 주어져 있는 최적 조건을 학습시켜 이 학습 범위에서 벗어나는 조건까지 예측하기 위해 신경회로망(neural network)을 이용하는 방법, 그리고 김희술<sup>(9)</sup>에 의해 연구된 절삭의 효율성을 평가할 수 있는 평가함수와 그에 따른 구속조건을 이용하여 최적 절삭조건을 찾기 위해 유전 알고리즘(genetic algorithm)을 도입하는 방법등이 있다. 이 중 첫 번째 방법인 작업자의 경험을 수식화하는 방법은 탐색공간(search space)에서 전역 최소점(global minimum)을 찾아나가는 방법이 아닌 국부적인 탐색공간에서 지역 최소점(local minimum)을 찾는 방법이 되므로, 현재의 해가 최적의 해가 된다는 것을 보장할 수 없다. 또한 유전 알고리즘<sup>(10)(11)</sup>을 적용하는 방법은 가장 핵심적인 부분인 개체(population)의 적합도(fitness)를 평가하기 위한 평가함수(evaluation function)를 구원하는 것이 문제로 대두된다. 마지막으로 신경회로망<sup>(12)(13)</sup>을 도입하는 방법은 일정한 제한된 가설공간(restricted hypothesis space)내에서 최적해를 탐색함으로써 미지의 절삭조건에서도 해를 찾을 수 있는 방법이다.

그러나 신경회로망을 도입하는 경우에는 학습의 근거가 되는 입력패턴이 목표출력과의 명확한 상관관계하에서 선정되어야 한다. 이러한 상관관계가 명확하지 않은 데이터를 입력패턴으로 사용할 경우에는 신경망의 학습후 신뢰성 있는 해답을 기대하기 어렵게 된다. 따라서 데이터의 양을 최소화하고, 이 데이터를 기초로 한 학습의 효율을 극대화하기 위하여 절삭작업에서 관련된 인자를 추출하고, 이들을 특별별로 분류하여 신경망의 입력패턴으로 사용될 것들을 분류해 낼 필요가 있다. 또한 위의 연구들에서는 특정한 피삭재와 공구에 대한 적정조건 선정만을 행하였으므로 다양한 피삭재와 공구에 대한 적용에는 한계가 있다. Deguchi<sup>(8)</sup>의 경우는 이러한 범용성을 위하여 피삭성에 영향을 미치는 피삭재의 화학성분을 고려하였으나, 공구 재종에 대한 고려는 없다. 사실상 피삭재와 그에 적용되는 공구재종에 대한 최적화가 행해지지 않으면 실제적인 적용에 있어서 그 한계가 있다.

따라서 본 연구에서는 기존의 적정 절삭조건 데이터를 이용하는 신경회로망을 적용하고, 이의 학습을 위한 데이터를 피삭성에 미치는 상관관계가 명확한 피삭재와 공구 재종의 정보를 사용하여, 최적화의 기본 데이터가 되는 적정 절삭조건 데이터를 얻기 위한 실험을 최소화 하면서, 적정절삭조건을 결정할 수 있는 방안을 제시하고자 한다.

## 2. 절삭조건 최적화의 기준

정면 밀링작업에 있어서의 최적 절삭조건의 정의는 절삭작업의 종류에 따라 달라질 수 있다. 절삭작업을 크게 두 가지로 나눈다면 우선 황삭과 정삭으로 나눌 수 있는데 황삭의 경우에는 소재제거율(Material Removal Rate, MRR)로 표현되는 가공 능률을 극대화 시키는 절삭조건의 선정과 공구비용과 공구 교환시간으로 표현되는 가공 비용을 최소화하는 것이 중요하다고 할 수 있다. 즉 황삭의 경우에 절삭조건의 최적화는 한번의 공구 장착으로 가공할 수 있는 부품수를 극대화하는 조건과 일정한 시간 동안 소재를 가급적 많이 제거하는 조건 사이를 절충해야 한다.

정삭의 경우는 최종 가공면의 치수오차가 허용공차안으로 들어가야 하며 표면 거칠기가 최소로 되어야 한다. 치수오차에 대해서는 엔드밀 작업과 같이 정면 밀링에 비해 강성이 상대적으로 떨어지는 공구를 사용하는 절삭작업의 경우에 공구자체의 처짐에 의해 치수오차가 발생하나, 정면 밀링의 경우 상대적으로 절삭계의 강성이 매우 크므로 공구의 처짐에 의한 치수오차는 무시할 수 있다. 오히려 절삭작업이 진행됨에 따라 공구마모가 증가하고 이로 인해 가공면의 치수 오차가 발생하게 된다. 또한 표면 거칠기의 불량은 절삭날끝의 형상에 의한 기하학적 표면 거칠기와 절삭계의 떨림, 공구마모 등에 의해 나타나는 표면 거칠기가 있는데, 전자의 경우 적절한 절삭날의 선정과 적절한 이송량의 선정으로 억제할 수 있다. 그러나 공구마모나 절손에 의한 표면 거칠기의 불량은 절삭 속도와 밀접한 연관이 있으므로 여기에서도 일정 절삭조건 하에서의 공구마모 추이가 중요한 요소가 된다. 두 작업의 경우 모두 공구마모와 그에 의해 결정되는 공구수명이 공통적으로 중요한 요소가 된다. 따라서 본 연구에서는 정면 밀링 작업에서 황삭가공에 대한 적정 절삭조건을 결정하는 기준으로서 공구수명을 택한다.

## 3. 공구수명에 영향을 미치는 공정 변수와 그 상관관계

절삭작업에 있어서 공구수명에 영향을 미치는 공정 변수들은 매우 다양하다. 이들중 피삭재, 공구의 형상, 공구의 재질, 공작기계의 종류, 절삭유제의 종류와 이의 사용여부 등은 작업자가 최종 가공을 시작하기 전에 결정되어 있는 내용으로서 가공인자중 하드웨어적인 부분이라고 할 수 있다. 한편 절삭속도, 이송량, 절삭깊이, 공구수명

을 결정하는 한계 마모량 등의 가공인자는 작업자가 절삭가공시 최종적으로 직접 결정해야하는 내용인데 이들은 가공인자중 소프트웨어적인 부분이라고 할 수 있다. 본 연구에서는 분류의 편의를 위하여 전자를 가공인자(machining factor), 후자를 절삭변수(cutting variable)이라고 칭한다. 결국 절삭조건의 최적화라함은 주어진 서로 다른 가공인자에 대한 적절한 절삭변수의 결정이라고 할 수 있다.

우선 절삭조건의 최적화를 행하기 전에 양자가 공구마모에 미치는 영향을 검토하여, 최적화를 행할 때 고려해야 할 인자를 결정할 필요가 있다.

### 3.1 실험방법

최적화에서 고려할 인자를 결정하기 위한 마모실험은 다음과 같은 방법으로 수행되었다. 우선 규격이 SEKN1203EDTR인 인서트를 직경 125mm의 커터에 1개의 날만 장착하여 절삭깊이를 2.0mm로 고정하고, 절삭변수(절삭속도와 이송량), 가공인자(피삭재와 공구재질)를 변화시켜가면서 절삭하였다. 모든 절삭은 절삭유제를 사용하지 않은 건식절삭을 하였다.

이렇게 절삭을 진행하면서 절삭거리(L)가 400mm가 될 때마다 공구의 플랭크 마모폭(Vb)을 Nikon사의 공구현미경을 이용하여 측정한다. 그리고 Vb가 설정한 한계 마모량을 초과하거나, L이 4000mm에 도달하면 절삭을 중단하였다.

Fig. 1은 대한중석의 초경 P재질의 공구로 크롬-몰리




Fig. 1 Examples of Flank Wear in Carbide P Grade Insert according to Cutting Length  
(V=120m/min, f=0.15mm/rev, SCM4)

브덴 강인 SCM4를 절삭속도(V) 120m/min, 이송량(f) 0.15mm/rev으로 절삭하는 경우의 플랭크 마모사진이다. 사진에서 볼 수 있는 마모구간중 일정한 폭의 마모가 나타나는 구간의 마모폭을 Vb로 사용하기로 한다.

### 3.2 절삭변수와 공구수명과의 상관관계

#### (1) 이송량과 공구수명

이송량이 공구수명에 미치는 영향을 보기 위하여 커터 1회전당 이송량을 0.03mm/rev, 0.05mm/rev, 0.10mm/rev, 0.15mm/rev, 0.25mm/rev으로 변화시키면서 절삭실험을 행하였다. 피삭재는 크롬-몰리브덴강인 SCM4(HBN 175), 공구재종은 대한중석의 초경 P재종, 절삭속도는 120m/min로 하였다.

그 결과 동일한 절삭거리 L에서 이송량이 작을수록 공구마모가 심한 것이 관찰되었는데, 이는 이송량이 작을수록 단위거리를 가공할 때 실제 절삭날의 절삭길이는 그만큼 늘어나기 때문이다. 따라서 이 값을 동일한 실제 절삭길이에 대한 마모량으로 환산해야 공구마모에 대한 이송량의 영향을 볼 수 있을 것이다. 따라서 L을 회전당 이송량으로 나누어서 공구가 피삭재를 지나간 횟수에 따른 공구의 마모경향을 Fig. 2에 나타내었다. 그림에서 볼 수 있듯이 동일한 공구패스(pass)수에 대하여 회전당 이송량에 무관하게 마모 경향은 유사하다는 것을 알 수 있다.

한편 이송량은 일반적으로 공구날끝의 파손(chipping)에 영향을 미친다고 알려져 있는데, 이에 대한 검토를 위하여 미국 MDC에서 발행한 Machining Data Handbook(3rd. Edition, 이하 '핸드북', 'MDH')<sup>[14]</sup>의 추천 이송량을 살펴보았다. Fig. 3는 탄소강과 스테인레스강에 대한 추천 이송량을 나타낸 것인데, 경도가 증가함에

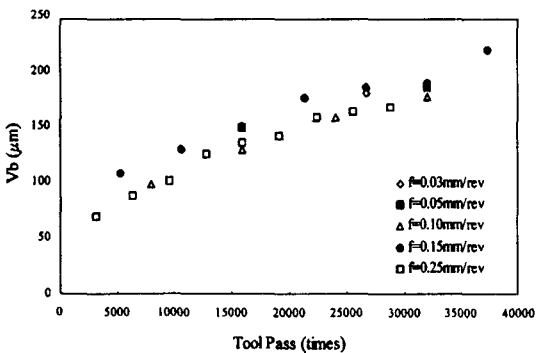
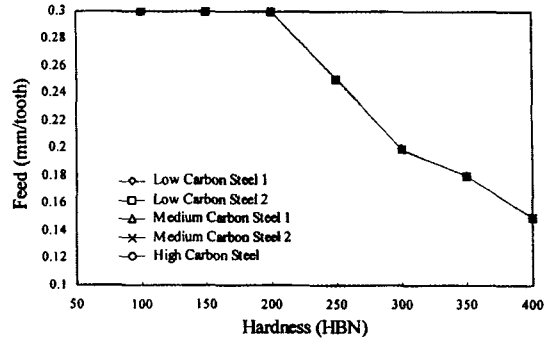
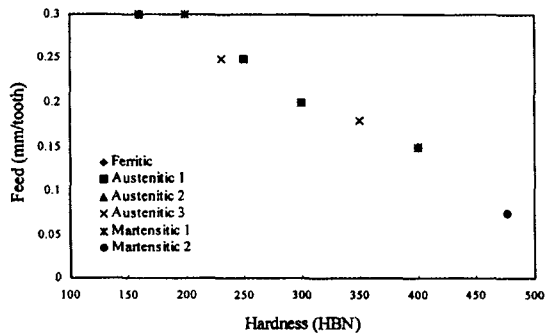


Fig. 2 Tool Wear in Various Feed Rate (V=120m/min, t=0.2mm, workpiece=SCM4)



(a) Carbon Steel



(b) Stainless Steel

Fig. 3 MDH Recommended Feed Rate in Various Workpiece Hardness

따라서 적은 이송량을 추천하고 있다. 또한 피삭재의 화학성분에 따라서는, 탄소강의 경우와 스테인레스강의 경우, 동일한 피삭재 경도에서는 화학성분 조성에 관계없이 동일한 이송량을 추천하고 있다. 단, 피삭재의 분류는 핸드북의 피삭재 구분을 기준으로 한 것인데 기본적으로 탄소강은 탄소와 망간의 함량에 의해, 스테인레스 강은 금속조직상에 의해 분류하고 있다. 이에 대해서는 뒤에 자세히 언급하기로 한다.

이러한 검토를 통해 이송량은 공구마모에는 크게 영향을 미치지 않지만, 공구 파손에 영향을 미치므로 피삭재의 경도에 따라 이송량은 다르게 적용되어야 한다는 결론을 얻을 수 있다.

#### (2) 절삭속도와 공구수명

Cook<sup>[15]</sup>에 의하면 공구수명과 절삭변수 사이의 관계는 다음과 같은 식으로 표현될 수 있다.

$$T = aV^{-b} f^{-c} t^{-d} \quad (1)$$

여기에서 T(min)는 공구수명, V(m/min)는 절삭속도, f(mm/rev)는 이송량, t(mm)는 절삭깊이이고, a,b,c,d는 실험적으로 결정되는 상수이다. 이들 사이에는  $b > c > d$ 의 관계가 성립된다. 즉 공구수명에는 절삭속도가 가장 큰 영향을 미치며, 이송량이 그 다음이고, 절삭깊이가 미치는 영향이 가장 작다. 위 식은 주로 선삭에 적용되는 식인데 일반적인 밀링 작업에서는 절삭깊이는 고정되어 있으므로 절삭깊이가 공구 수명에 미치는 영향은 무시할 수 있다. 또한 위에서 살펴본 바와 같이 이송량은 공구 수명에 직접적인 영향을 미치지 않는다고 생각되어 이송량에 대한 항 또한 무시할 수 있다.

절삭깊이와 이송량의 영향을 무시하면 위 식(1)은 Taylor<sup>[16]</sup>가 제안한 바와같이 다음과 같이 쓸 수 있다.


$$VT^n = C \quad (2)$$

여기에서 n과 C는 실험적으로 피삭재 및 공구의 재질에 따라 결정되는 상수이다. 이들 상수가 결정되면 일정한 절삭속도 하에서의 공구수명을 예측할 수 있으므로 식(2)는 실용적으로 중요한 의미를 가진다.


### 3.3 가공인자와 공구수명과의 상관관계

#### (1) 피삭재와 공구수명

일반적으로 동일한 공구를 사용한다면 피삭재의 종류에 따라 서로 다른 절삭변수를 적용하고 있는데, 이러한 차이점의 원인이 되는 인자를 추출하기 위하여 절삭실험을 행하였다. 아래 Fig. 4은 서로 다른 피삭재에 대해 동일한 절삭조건을 적용한 절삭실험의 결과이다. 절삭속도는 120m/min, 이송량은 0.15mm/rev, 절삭깊이는 2.0mm로 고정하고 건식절삭을 하였다. 피삭재는 중탄소강인 S45C(HBN 175), 크롬-몰리브덴강인 SCM4(HBN 210), 니켈-크롬-몰리브덴강인 SNCM8(HBN 212)을 시편으로 사용하였고 공구는 대한중석의 초경 P재종과 서멧재종의 인서트 두 종류를 사용하였다. 흥미로운 사실은 SCM4과 SNCM8의 경우 경도가 거의 동일함에도 불구하고 SCM4의 경우에 비하여 SNCM8의 경우 공구 수명이 극히 짧다는 사실이다. 또한 피삭재의 상온 물성치가 되는 인장강도와 항복강도는 SCM4의 경우 각각 100kgf/mm<sup>2</sup>, 85kgf/mm<sup>2</sup>, SNCM8의 경우 각각 100kgf/mm<sup>2</sup>, 90kgf/mm<sup>2</sup>으로서 크게 차이가 나지 않는데도 피삭성에서는 큰 차이를 보였다. 일반적으로 공구의 마모는 피삭재와 공구가 접촉하는 부분에서 국부적인 고온, 고압이 발생하면서 양자간의 화학반응에 의해 진행




(a) Tungsten Carbide P Grade



(b) Cermet Grade

Fig. 4 Tool Wear in Various Workpiece Material (V=120m/min, f=0.15m/rev, t=2.0mm)



(a) Carbon Steel




Fig. 5 MDH Recommended Cutting Speed in Various Workpiece Hardness

된다고 알려져 있는데<sup>[15]</sup>, 이는 위의 실험결과와도 잘 일치한다. 따라서 피삭재에서 공구수명에 영향을 미치는 가공인자로서 피삭재의 화학성분조성을 주요 인자로서 고려할 수 있다.

한편 피삭재의 경도가 절삭속도 결정에 미치는 영향을 보기 위하여 3.2절에서 사용한 핸드북의 추천 절삭조건을 탄소강과 합금강에 대하여 검토하였다. 경도에 따른 적정 절삭속도의 추이를 아래 Fig. 5에 나타내었다. 여기에서 볼 수 있듯이 피삭재의 경도가 높아짐에 따라 낮은 절삭속도를 추천하고 있다. 따라서 피삭재의 경도 또한 공구수명에 영향을 미치는 인자로서 고려할 수 있다.

## (2) 공구 재종

절삭작업이 고속화됨에 따라 고온에서의 기계적 특성이 좋은 공구재종이 계속하여 개발되어왔다. 초경재종의 개발 이후 TiC, TiAlN, PVD등의 피복을 입힌 코팅공구, 서멧(Cermet)공구등이 개발되어 왔다. 이들 상이한 공구재종에 대한 피삭성을 검토하기 위하여 절삭실험을 행한다. 아래의 Fig. 6은 서로 다른 공구재종에 대한 공구마모 추이를 나타낸 것이다. 피삭재는 SCM4(HBN 175), 절삭속도는 120m/min, 이송량은 2.0mm로 고정하였고 절삭유제는 사용하지 않았다. 공구 재종은 대한중석의 초경 P재종, 초경 K재종, PVD 코팅재종, 서멧재종을 사용하였다.

그 결과 서멧, 코팅, 초경 P재종, 초경 K재종의 순서로 공구 수명이 길었다. 즉 여기에서 공구의 재종에 따라 공구의 마모 추이가 달라진다는 사실을 알 수 있다. 본 연구에서는 소결공정에 의해서 제조되는 초경공구에 한하여

공구수명과의 관계를 고려하기로 한다. 초경공구의 공구수명을 결정하는 요소는 초경재종의 열적특성과 기계마모특성에 미치는 영향에 의존한다. 화학성분으로서 WC, TiC+TaC, Co성분의 무게비와 탄화물 WC입자의 크기에 의해서 대부분의 주요한 특성이 결정된다. 또한 코팅공구의 경우에는 코팅층의 종류와 두께 등에 의해서도 영향을 크게 받으나 본 연구에서는 MDH에서 고려한 것과 같이 코팅여부에 의한 영향만을 고려하였다<sup>[17]</sup>. 이것은 향후 복잡한 코팅의 영향을 고려해야하는 연구과제가 수행되어야 함을 의미한다.

## 4. Machining Data Handbook의 추천 절삭조건에 대한 검토

위에서 언급한 바와 같이 다양한 가공인자의 조합에 대하여 일일이 실험적으로 적정한 절삭변수를 결정하는 것은 매우 비효율적일뿐 아니라 거의 불가능하다고 할 수 있다. 따라서 기존의 적정 절삭조건 데이터를 최대한 활용하여 이를 토대로 적정 절삭조건을 예측할 필요가 있다. 이러한 기존의 적정 절삭조건 데이터베이스로서 본 연구에서는 Machining Data Handbook[14]을 이용하였다.

이 핸드북은 초경재종 개발 초기인 1980년에 발행된 것으로서 여기에서 추천하고 있는 데이터에 대한 검증이 필요하다. 이를 위하여 대한중석의 초경 P재종에 대하여 마모 실험을 행하였다. 피삭재는 SCM4(HBN 175), 이송량은 0.15mm/rev, 절삭깊이는 2.0mm로 고정하였고, 절삭유제는 사용하지 않았다. 실험은 절삭속도 80m/min, 120m/min, 250m/min의 세 가지 속도에 대하여 각각 행하였다. Fig. 7는 위 실험의 결과를 나타낸 것이다. 일반적으로 공구마모는 플랭크 마모가 선형적으로 진행되는 정상상태마모(steady state wear) 구간을 지나면 열발생량이 급격히 증가하고 이에 따라 마모 또한 급격히 진행되면서 결국에는 공구절손이 일어나게 된다. 따라서 공구의 급격한 마모가 진행되기 전의 마모량까지의 절삭시간을 공구수명으로 잡는데, 일반적으로 초경 재종에 대해서는 공구의 플랭크 마모폭 Vb가 0.3mm에 도달할 때까지의 가공시간을 공구 수명으로 잡고 있다<sup>[16]</sup>. 그러나 실험으로부터 직접 Vb=0.3mm일때의 절삭거리 L을 정확하게 얻는 것은 어려우므로 Vb=0.3mm가 되는 L을 산출하여야 한다.

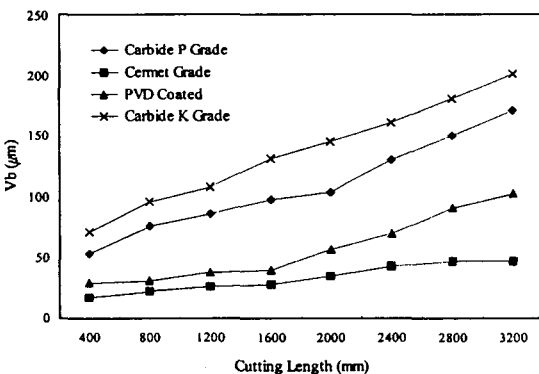


Fig. 6 Tool Wear in Various Tool Grade (V=120m/min, f=0.15mm/rev, SCM4)




Fig. 7 Tool Wear in Various Cutting Speed  
( $t=0.2\text{mm}$ ,  $f=0.15\text{mm/rev}$ , workpiece=SCM4)

Taylor<sup>(18),(19)</sup>는 공구의 정상상태에서의 마모속도가 마모면적에 비례한다고 가정하여 절삭시간에 대한 플랭크 마모폭을 다음과 같이 정하고 있다.

$$V_b = KT + V_{b0} \quad (3)$$

위에서 T는 절삭시간,  $V_{b0}$ 는 공구의 초기마모폭, 즉 공구의 예리한 날끝이 절삭력을 받아 탈락하면서 초기에 급격히 마모되는 폭이며 K는 실험적으로 구할 수 있는 상수이다. 위의 식에서 공구가 정상상태에서 마모된다면 그 마모량은 절삭시간에 비례한다는 것을 알 수 있다. 이러한 근거로 위의 절삭실험 데이터를 선형화(linear fitting)하여  $V_b=0.3\text{mm}$ 가 되는 절삭거리  $L_{V_b=0.3}(\text{mm})$ 을 찾는다. 공구의 초기마모는 400mm 절삭 이전에 모두 진행된 것으로 가정하여 400mm 절삭 이후부터 선형화를 행한다. 그 결과를 Table. 1에 나타내었다.

한편 L(mm)을 회전당 이송량 f(mm/rev)와 공구수명(즉  $V_b=0.3\text{mm}$ 에 도달할 때까지의 절삭시간)  $T_{V_b=0.3}(\text{min})$ 의 관계로 표현하면 다음과 같다.

$$L_{V_b=0.3} = \frac{1000z}{\pi D} \cdot f \cdot V \cdot T_{V_b=0.3} \quad (4)$$

여기에서 z는 커터에 장착된 날 수, D는 커터의 직경이다. 그런데 실험의 조건에서 커터에 장착한 날 수는 1개, 그리고 커터의 직경은 125mm로 고정하였으므로 이 값을 대입하여 식 (4)를  $T_{V_b=0.3}$ 에 대해 정리하면 다음과 같다.

$$T_{V_b=0.3} = \frac{\pi L_{V_b=0.3}}{8fV} \quad (5)$$

이 식으로부터 위에서 구한  $L_{V_b=0.3}$ 과 V로부터 공구수명  $T_{V_b=0.3}$ 을 구할 수 있다. 이를 Table. 1에 함께 나타내었다.

Table 1. Relationship between V,  $L_{V_b=0.3}$ ,  $T_{V_b=0.3}$

V (m/min)	( $V_b-L$ ) equation	$L_{V_b=0.3}$ (mm)	$T_{V_b=0.3}$ (min)
80	$V_b=0.0364318L+45.22723$	6993.1425	228.850
120	$V_b=0.04725L+22.318182$	5876.8638	128.213
250	$V_b=0.093667L+11.133333$	3083.9748	32.295

여기에서 식 (2)와 위에서 구한 V와 T의 관계를 이용, 최소자승법으로 오차가 최소인 V-T 관계식을 구하면 다음과 같다.

$$T = 924263.7V^{-1.854103} \quad (6)$$

위 식과 실험에서 얻은 결과는 Fig. 8에서도 알 수 있듯이 잘 일치하고 있다는 것을 알 수 있다.




Fig. 8 V-T Curve in Machining SCM4 Using Carbide P Grade

한편 MDH에서는 이와 동일한 조건 즉, 피삭재 SCM4 (HBN 170-180)를 P재종으로 건식절삭을 할 경우의 절삭속도로  $V=150\text{m/min}$ 을 추천하고 있다. 위의 V-T관계식으로부터  $V=150\text{m/min}$ 인 경우의 T를 구하면 86.3275min이 된다. 즉 이것은 현재 생산되고있는 동일 재종의 공구에 MDH의 추천 절삭속도를 적용하면 80여분 가량의 공구수명을 얻을 수 있다는 것을 의미한다. 3.2절에서 언급했듯이 MDH에서는 초경재종의 경우 공구수명이 30-60분 정도가 되는 절삭속도를 적정 절삭속도로 결정하고 있는데, 과거에 비해 초경재종의 성능이 향상되었음을 고려할 때, 80분 정도의 공구수명을 나타

내는 절삭속도는 현재의 재종에 대해 적정한 절삭속도라고 할 수 있다. 즉 공구재종의 성능향상을 고려하여 공구수명으로 산출할 수 있는 적정 절삭조건은 기존의 기준이 새롭게 적용되어야 한다는 전제 조건 하에서, 과거의 공구에 적용되는 30-60분 가량의 공구수명을 나타낼 수 있는 절삭조건은 80분 가량의 공구수명을 나타낼 수 있는 절삭조건으로 수정하여 적용할 수 있을 것이다. 즉 공구수명으로서 약 80분을 유지하는 절삭속도를 기준으로 하여 생산성과 경제성을 고려한 절삭속도를 산출할 수 있다.

이와 같은 검토는 핸드북의 추천 절삭조건을 수정함으로써 현재 생산되고 있는 공구의 적정 절삭조건 예측을 위한 신경회로망의 학습에 사용될 수 있음을 보여준다. 신경망으로부터 예측되는 절삭조건은 새로운 공구와 절삭환경에서 초기값으로서의 역할을 한다고 생각하면 큰 오차없이 적용할 수 있으리라 여겨진다.

### 5. 적정 절삭조건 예측을 위한 신경회로망의 구성

위와 같은 검토를 토대로 핸드북의 적정 절삭조건 데이터를 신경회로망 학습에 적용하여, 현재 생산되고 있는 공구에 대한 적정 절삭조건 예측을 행한다. 신경회로망 학습을 위한 입력패턴으로는 3절에서 공구마모와 상관관계가 검증된 인자들을 사용한다. 즉 입력값으로는 피삭재에 대해서는 화학성분함량(weight%)과 경도(HBN), 공구에 대해서는 화학성분함량(weight%)과 입도크기( $\mu m$ )를, 목표출력으로는 핸드북의 해당 피삭재와 재종에 대한 적정절삭속도(m/min)와 적정 이송량(mm/min)을 선정한다. 특히 핸드북에서는 코팅공구를 코팅여부뿐만 아니라 분류를 하여 절삭조건을 추천하고 있으므로 일반 초경재종을 0, 코팅공구를 1로 표현하여 입력패턴으로 사용한다. 최근에 개발되고 있는 다양한 종류의 코팅공구를 고려할 때, 이는 이후 코팅층의 종류와 그 두께를 표현하는 입력패턴으로 확장될 수 있을 것이다.

피삭재의 분류는 우선 탄소강과 합금강, 그리고 스테인레스강, 주철에 대해 행해졌다. 이들을 피삭재 (family)라고 부르기로 한다. 다시 이들 (family)를 화학성분에 따라 세분하였는데 이들을 피삭재 (group)이라고 부르기로 한다. 입력벡터 중 피삭재의 화학성분함량은 핸드북의 분류를 따라 각국 공업규격을 기초로 하여 분류된 피삭재 (group)에 대한 화학성분함량의 평균값을 취하였다. 즉 피삭재에 대한 입력벡터는 (group) 단위로 입력되었다.

신경회로망 학습은 각 피삭재 (family)에 대하여 독립

된 신경회로망을 구성하여 수행한다. Table. 2는 각 피삭재 (family)별 입력패턴의 구성을 나타낸 것이다. 여기에서 주철 (family)에 대해서 피삭재에 대한 입력벡터의 내용중 인장강도(kgf/mm<sup>2</sup>)가 추가되었는데, 이는 각국 공업규격에서 주로 인장강도를 기준으로 주철에 대한 분류를 행하고 있기 때문이다.

Table 2. Structures of Input Patterns for Neural Network Training

Workpiece	Carbon Steel	Hardness, C, Mn
	Alloy Steel	Hardness, C, Mn, Ni, Cr, Mo
	Stainless Steel	Hardness, C, Mn, P, Si, Cr, Ni
	Cast Iron	Hardness, Tensile Strength, C, Si, Mn, S, P
Tool Grade	WC, TiC+TaC, Co, Grain Size of WC, Coated/Uncoated	

각 (family)의 신경회로망은 숨은층(hidden layer)을 2개로 하는 구조를 택하였으며, 숨은층의 노드(node)수는 탄소강(family)에서 9개, 합금강 (family)에서 12개, 스테인레스강 (family)와 주철 (family)에서 각각 15개로 하였다. 이러한 신경회로망의 구조는 학습시간과 수렴오차를 최소화 하는 구조를 시행착오법에 의해 얻은 것이다. 신경망 노드 사이의 활성화 함수(activation function)는 일반적으로 가장 많이 사용되고 있는 시그모이드 함수(sigmoid function)를 사용하였으며, 학습패턴의 정규화(normalizing)범위는 0.2에서 0.8사이로 하였고, 모멘텀 계수(momentum factor)는 0.95로 설정하였다. Fig. 9에서는 이렇게 구성된 신경회로망의 구조를 도시하였다.

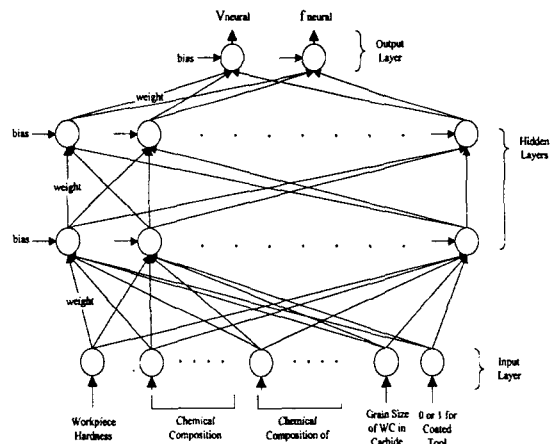


Fig. 9 Structure of Neural Network



6. 예 측 결 과

위와 같은 구성의 신경회로망을 100000epoch동안 반복학습시킨 후의 총 오차제곱의 합(Squared-Sum Error, SSE)은 아래와 같은 식으로 계산된다.

$$SSE = \frac{\sum_k (target - neural\ output)^2}{\sum_k target^2} \times 100(\%) \quad (7)$$

위 식에서 [target]는 신경회로망에 입력된 목표출력, [neural output]은 신경회로망의 출력값이다. SSE는 탄소강의 경우 0.010786%, 합금강의 경우 0.01854%, 스테인레스강의 경우 0.013798%, 주철의 경우 0.023189%로서 수렴성이 매우 양호하게 나타났다.

학습에서 얻은 신경망의 가중치(weight)와 바이어스(bias)값을 이용하여 최적화를 원하는 피삭재와 공구에 대한 데이터를 입력하여 전방향 연산(forward propagation)을 수행하면 적정 절삭속도와 적정 이송량을 얻을 수 있다. 단 신경회로망의 가설공간(hypothesis space)의 크기는 무한대가 아니라 입력값의 내용이 학습패턴의 범위에서 벗어날수록 오차가 커지게 되므로<sup>(19)</sup>, 학습되어 있는 범위에서 벗어나는 데이터를 입력하는 경우 출력값에 대한 타당성 검증 및 보정의 과정이 필요하다. 이를 위하여 우선 다양한 공구 재종과 피삭재에 대한 마모 실험을 실시하여 각각의 V-T선도를 작성한다. 그 다음으로 앞의 실험에서 얻은 V-T곡선에서 나타나는 공구 수명 80분을 나타내는 절삭속도( $V_{T=80}$ )와 신경회로망의 전방향 연산을 통해 출력되는 절삭속도( $V_{neural}$ )를 비교함으로

써 둘 사이의 오차(Error)를 산출할 수 있다. 이 오차는 신경회로망 예측의 타당성을 검증하는 근거로 이용된다.

신경회로망의 전방향 연산에는 대한중석의 초경 P재종과 PVD코팅재종, 서멧재종을 피삭재 SCM4(HBN 210)에 적용하는 경우와 대한중석의 PVD코팅재종과 TiC/Al<sub>2</sub>O<sub>3</sub>/TiN코팅재종을 회주철인 FC30(HBN 190)에 적용하는 경우의 데이터를 사용하였다. 우선 이들을 합금강 [family]와 주철 [family]에 대해 학습된 신경회로망에 입력하여 전방향 연산을 행함으로써 신경회로망에서 출력된 적정절삭조건( $V_{neural}, f_{neural}$ )을 얻는다. 그리고  $V_{neural}$ 을 실험을 통해 얻은 V-T곡선에 대입함으로써,  $V_{neural}$ 에서의 공구 수명( $T_{neural}$ )을 얻을 수 있다.

V-T선도를 작성하는데 있어서의 각 공구의 한계마모량은 일반적으로 공구 수명으로 정하고 있는 플랭크 마모량을 사용하였는데, 초경 공구는  $V_b=0.3mm$ , TiC/Al<sub>2</sub>O<sub>3</sub>/TiN코팅과 PVD코팅공구는  $V_b=0.15mm$ , 서멧공구는  $V_b=0.1mm$ 를 각각 한계마모량으로 하였다<sup>(16)</sup>. 이렇게 얻어진 V-T선도에서  $V_{T=80}$ 를 구해 이를  $V_{neural}$ 과 비교하여 오차를 산출하였다. 여기에서 사용된 각각의 V-T선도를 Fig. 10에 나타내었고, 오차 산출의 결과를 Table. 3에 나타내었다.

신경회로망은 초경재종과 일반코팅재종에 대해서 학습이 되어있으므로, 초경 P재종에 의한 SCM4가공과 초경 K재종에 의한 FC30의 가공에 대한 신경회로망의 예측 성능은 매우 우수하였다. 이는 일반적으로 신경망의 학습범위내에서는 우수한 예측을 수행함을 알 수 있다.

반면, 코팅 재종에서는 약 45% 내외, 서멧 재종에서는 약 -20%의 오차가 발생함으로써 예측의 성능이 떨어지는 것을 알 수 있다. 이는 PVD코팅재종과 TiC/Al<sub>2</sub>O<sub>3</sub>/TiN

Table. 3 Comparison of Experiment Result and Neural Network Output

Workpiece		SCM4 (HBN210)			FC30 (HBN190)	
Tool Grade		Carbide P	PVD Coated	Cermet	Carbide K	TiC/Al <sub>2</sub> O <sub>3</sub> /TiN Coated
Experiment Result	n, C at VT=C	n=0.56818 C=1917.61	n=0.71222 C=3291.85	n=0.43868 C=1600.74	n=0.20259 C=411.25	n=0.37491 C=839.50
	$V_{T=80}$ (m/min)	159.021	149.218	238.863	169.256	162.377
Neural Network Output	$V_{neural}$ (m/min)	148.548	213.7718	190.338	169.289	241.275
	$f_{neural}$ (mm/tooth)	0.2265	0.2559	0.0443	0.2167	0.1663
	$T_{neural}$ (min)	90.191	50.585	132.539	79.924	27.819
Error= $\frac{V_{neural} - V_{T=80}}{V_{T=80}} \times 100(\%)$		-6.586	43.261	-20.315	0.019	48.589

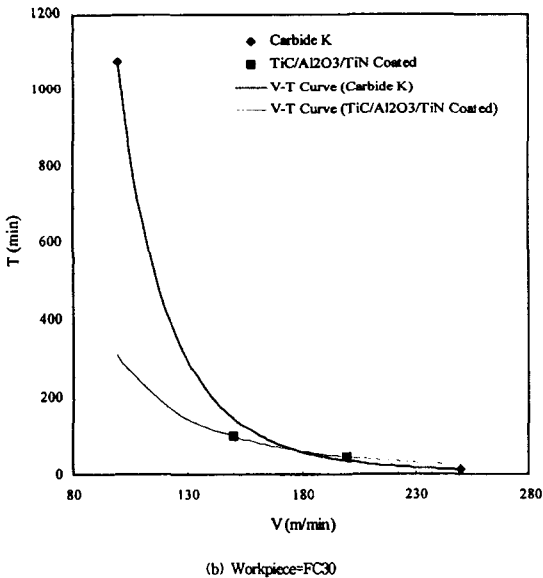



Fig. 10 V-T Curves for the Comparisons of Experiment Results and Neural Network Outputs

코팅재종의 경우 모재는 일반 초경공구와 크게 다르지 않으나 코팅공구의 경우에 공구성능은 직접적으로는 코팅의 특성에 의해서 결정되기 때문이다. 그러므로 본 연구

에서 사용된 공구재종의 성분은 일반 초경재종에 국한하여 적용이 가능하다. 또한 서멧재종은 일반 초경재종과는 그 화학성분의 함량과 기계적 특성이 전혀 다른 재종이므로 신경회로망의 예측범위를 많이 벗어나 오차가 많이 발생했다고 생각된다<sup>(13)</sup>.

## 7. 결 론

(1) 절삭가공에 관련되는 인자중 공구 마모에 영향을 미치는 요소로서 피삭재에 관한 것은 피삭재의 분류에 따른 각 경우의 화학성분과 열처리에 의한 경도이고, 공구에 관한 것은 초경공구 재종의 주요화학성분비와 탄화물 WC의 입도크기를 고려할 수 있음을 알았고, 이들이 절삭속도와 이송량에 대해 갖는 경향성을 실험을 통하여 검증하였다.

(2) 주어진 피삭재와 공구재종에 대하여 적용할 수 있는 적정절삭조건에 관한 데이터를 얻기 위하여 Machining Data Handbook에서 제시된 자료를 사용하였다. MDH 자료의 대한중석공구에 대한 적용의 타당성의 점검을 통하여 적정 공구수명이 종전의 30-60분으로부터 약80분으로 연장되었다. 절삭속도에 따른 공구마모실험을 통하여 절삭속도-공구수명선도를 얻었고, 이를 이용하여 적정 절삭조건 결정을 위해 핸드북에서 설정하고 있는 공구수명에 대한 보정을 수행하였다.

(3) 선정된 절삭가공 인자들을 입력값으로하고 MDH의 추천 절삭조건 데이터를 목표출력으로 하는 신경회로망을 학습을 통하여 구축하였다. 적정절삭조건예측은 일반 초경재종의 경우에는 매우 잘 예측하였으나 코팅공구와 서멧트 공구에서는 예측오차가 컸다.

## 참 고 문 헌

1. A. M. Abuelnaga, M. A. El-Dardiry, "Optimization Methods for Metal Cutting," Int. J. Mach. Des. Res., Vol. 24, No. 1, pp. 11-18, 1984.
2. Chen Zhou, Richard A. Wysk, "An Integrated System for Selecting optimum Cutting Speeds and Tool Replacement Times," Int. J. Mach. Manufact., Vol. 32, No. 5, pp. 695-707, 1992.
3. M. Tolouei-Rad, I. M. Bidhendi, "On the

- Optimization of Machining Parameters for Milling Operations," *Int. J. Mach. Tools Manufact.*, Vol. 37, No. 1, pp. 1-16, 1997.
4. S. Takata, M. D. Tsai, M. Inui, T. Sata, "A Cutting Simulation System for Machinability Evaluation Using a Workpiece Model," *Annals of the CIRP*, Vol. 38, pp. 417-420, 1989.
  5. T. Matsumura, T. Ihara, T. Shirakashi, E. Usui, "On the Development of Expert System for Selecting the Optimum Cutting Conditions (1st Report)," *JSPE*, Vol. 56, No. 7, pp. 108-113, 1990.
  6. T. Matsumura, T. Obikawa, T. Shirakashi, E. Usui, "Autonomous Operation Planning of Machining Process - An Adaptive Prediction with Metal Cutting Theory and Neural Network -," *JSPE*, Vol. 59, No. 10, pp. 94-100, 1993.
  7. 정성중, "적응제어 수치제어 시스템의 개발 (I) - 신경회로망에 의한 지적인 절삭계수의 선정," 대한기계학회 논문집, 제16권, 제7호, pp. 1223-1233, 1992.
  8. H. Sekiguchi, H. Komoriya, T. Deguchi, "Reasoning of the Machinability and Cutting Condition Based on the Chemical Composition of Material (1st Report)," *JSPE*, Vol. 62, No. 7, pp. 1004-1009, 1996.
  9. 고태조, 김희술, 김도균, "적응모델링과 유전알고리즘을 이용한 절삭공정의 최적화 (I)," *한국정밀공학회지*, Vol. 13, No. 11, pp. 73-81, 1996.
  10. 장병탁, "인공지능에 의한 학습 및 최적화," 제어·자동화·시스템 공학회지, 제1권, 제3호, pp. 52-61, 1995.
  11. Zbigniew Michalewicz, "Genetic Algorithms+Data Structures=Evolution Programs," Springer-Verlag
  12. 김대수, 1992, "신경망 이론과 응용 (I)," 하이테크 정보, 1996.
  13. D. E. Rumelhart, G. E. Hinton, R. J. Williams, "Learning Internal Representation by Error Propagation : In Parallel Distributed Processing," The MIT Press, Vol. 1, 1986.
  14. Machinability Data Center, "Machining Data Handbook - 3rd Edition," Vol. 1, Machinability Data Center, 1980.
  15. N. H. Cook, "Tool Wear and Tool Life," *Journal of Engineering for Industry*, Trans. of ASME, pp. 931-938, 1973.
  16. 손명환, "절삭가공론," 문운당, 1992.
  17. 한동원, 고성림, "피삭재와 공구재종에 근거한 절삭조건의 최적화 (I)," *한국정밀공학회 '97년도 춘계학술대회논문집*, pp. 1038-1043, 1997.
  18. Taylor J., *Int. J. of Mach. Tool Des. and Res.*, 2, pp. 119, 1962.
  19. Taylor J., *Int. Res. in Prod. Engng.* NY. ASME, pp. 130, 1963.