

기계 학습을 이용한 치구 공정 계획 모듈의 개발

김선우*, 이수홍**

A Development of Fixture Planning Module using Machine Learning

Sun-Woo Kim* and Soo-Hong Lee**

ABSTRACT

This study intends to develop a fixture planning module as a part of the planning system for cutting. The fixture module uses machine learning method to reuse previous failure results so that the system can reduce the repeated failures. Machine learning is one of efforts to incorporate human reasoning ability into a computerized system. A human expert designs better than a novice does because he has a wide experience in a specific area. This study implements the machine learning algorithm to have a wide experience in the fixture planning area as a human expert does. When the fixture planner finds a setup failure for the suggested operations by a process planner, it makes the process planner store its attributes and other information for the failed setup. Then the process planner applies the learned knowledge when it meets a similar case so that the planner can reduce possibility of setup failure. Also the system can teach a novice user by showing a failed setup with a modified setup.

Key words : 동시공학, 치구 설계, 기계 학습, 사례 기반 학습, 해시 테이블, 설계 정보의 재사용

1. 서 론

치구 설계는 절삭 가공물의 생산에 있어서 반드시 고려되어야 하는 부분이다. 그러나, 치구 설계 관련 연구는 활발하게 진행되지 못했는데, 그 원인으로는 치구 설계와 상호 작용이 많은 공정 설계 등의 연관 정보를 다루는 적당한 추론 방법을 찾기가 어려웠기 때문이다. 이러한 문제를 해결하기 위해서 분야별 전문 모듈로 구성된 동시 공학적 설계 시스템의 개발이 연구 되었다. 90년대에 들어서 Fuh와 Chang^[1], Prombanpong 등^[2]은 CADAM, OFDS과 같은 시스템을 이용하여 치구 설계와 공정 설계간의 적절한 통합을 시도함으로써 치구 설계의 중요성을 강조했다.

치구 설계시 필요한 기하학적, 기구학적 해석은 많은 저자들에 의해 연구, 제시되었는데, 대부분의

연구가 가공물을 정확한 위치에 고정시키는 치구 배열을 결정하는 데 중점을 두었다^[3,4]. Hayes^[5]와 Voelcker^[6]는 Machinist라는 시스템을 제안하였는데, 이 시스템은 입력된 세부 사양을 바탕으로 사각 모체를 가공하는 치구 및 공정 계획을 생성한다. 이밖에 각형 모체를 가공하는 지식 기반 치구 계획 시스템들이 많이 제시되었는데, 이들 대부분이 기하학적, 기구학적 해석을 기본으로 하고 있다. Engler^[7]는 가공시 고려해야 하는 여러 조건들을 비교, 분석함으로써 보다 안전한 치구 배열을 제시하고자 하였다. Chen^[8] 등은 치구 고정점의 기하학적 위치에 따른 역학적 해석을 바탕으로 가공물의 고정 순서의 중요성을 인식시켰다. 실제 설계 작업시 각 단계 간의 상호 작용은 빈번하며 신중히 고려해야 한다. 그러나, 앞서 언급한 연구들은 단계 간의 상호 작용을 충분히 다루지 못했다. 이에 본 연구는 동시 설계 시스템에서 치구 설계를 담당하는 모듈이 타 모듈과 상호 작용하며 보다 능동적으로 작업을 수행하도록 유도함으로써 전반적인 설계의 효율성 향상을 얻고자 하였다.

본 연구는 한국과학재단(KOSEF) 95핵심전문연구 과제비(과제번호: 951-1004-020-2)에 의하여 연구되었음.

*연세대학교 기계공학과 대학원

**중신회원, 연세대학교 기계공학과

동시공학 기법을 적용한 절삭 가공용 공정 계획 시스템에서 치구 모듈과 공정 계획 모듈은 설계시 많은 상호 작용을 주고 받는다. 모든 설계는 항상 재설계를 필요로 하므로, 설계 사양 변경에 대하여 새로운 결과를 신속히 제시해 줄 필요가 있다. 이 때, 작업 시간 단축의 측면에서 이전 결과의 재사용이 요구된다. 본 연구에서는 공정 계획 모듈이 수행한 공정 설계 결과들, 특히 치구 계획 실패를 유도하는 사례들을 이용하여 기계 학습을 수행하고 학습 결과를 지식 베이스에 저장함으로써 이후 공정 계획에서는 같은 실패를 반복하지 않도록 하고자 한다. 사례 기반 학습 방법을 적용하여 보다 체계적이고 완전한 지식 베이스를 구축하고 이를 이용하는 지능적인 공정 계획 모듈을 개발하고자 한다.

2. 기계 학습

인공 지능은 다양한 방식으로 환경에 유연한 시스템을 구현하는 것을 주 목적으로 한다. 이러한 기능을 위해서 기계 학습의 도움은 필연적이다. 기계 학습은 컴퓨터 프로그램의 유연성 및 인공 지능 구현 시 부딪히는 지식 습득 문제 해결에 중요한 방향을 제시할 수 있을 것으로 기대되어서 이에 관한 연구는 인공 지능 초기부터 꾸준히 이어져 왔다. 1980년대 중반까지는 귀납적 학습 방식에 대한 연구가 활발하게 진행 되었으며, 1990년대 초반에 들어서 연역적 방식, 사례 기반 학습 등 다양도로 연구되었다. 현재는 앞선 방법론들의 장단점을 보완, 수용하는 새로운 방식의 학습 방법이 제시되고 있는데, 지식 기반 학습이 그것이다.

인공 지능 구현 시스템이 보유해야 할 가장 중요한 기능은 상황에 적절히 대응하면서 같은 실수를 되풀이하지 않아야 한다는 점이다. 이를 위해서 기계 학습 프로그램은 추론 기관과의 상호 작용이 요구된다. 지식 베이스는 특성상 완전할 수 없고 모순적이며 부정확한 지식을 가질 수 있으므로, 이를 기반으로 문제 해결을 시도하는 추론 기관은 실패를 경험한다. 이러한 실패를 분석하고 지식 베이스를 수정, 보완하는 역할을 기계 학습 프로그램이 수행한다. 또한, 인공 지능 시스템은 처음 문제를 해결하는 과정보다 같은 문제를 두 번째 해결할 때는 보다 효율적이어야 하는데, 이러한 기능을 기계 학습이 제공할 수 있다^{[6],[7]}.

2.1 사례 기반 학습

사례 기반 학습은 일정한 분야에 적용할 수 있는

대표적인 사례들을 기억하고 있다가 새로운 문제를 해결하는 과정에서 유사한 사례를 이용하여 문제를 해결한다. 만약 문제를 해결하지 못하는 경우에는 그 문제를 새로운 사례로 기억하였다가 이후에 다시 이용한다. 사례 기반 학습에서는 주어진 문제가 어떤 사례와 유사한가를 알아내는 인덱싱 기능 및 유사성 비교 과정이 중요하다.

사례 기반 학습 방법에서는 다음 세가지 형태의 학습이 가능하다.

- ① 문제 발생을 피하는 새로운 문제 해결 전략 학습.
- ② 문제 발생을 예측하게 하는 특징 학습.
- ③ 현재 문제가 다른 상황에서 다시 발생하는 경우에 취해지는 해결책 학습.

사례 기반 학습의 특징은 시스템의 요구에 의해서만 학습한다는 것이다. 즉, 시스템이 문제 해결에 실패하는 경우에만 학습의 필요성을 인식하여 새로운 지식을 보완하고 이에 따라 문제 해결 전략을 수정한다.

2.2 치구 설계에의 적용

모체의 한 면을 가공하기 위해 요구되는 치구의 형태는 가공 특징 형상의 위치, 크기 및 정밀도 등에 따라 다양하다. 따라서, 몇 개의 기본적인 규칙으로 임의의 가공에 적절한 치구 형태를 제시하는 것은 불가능하다. 반면에 이 분야의 전문가는 다년간의 경험을 바탕으로 가공 상황에 따라 적절한 치구 형태를 설계할 수 있다. 이는 다양한 성공과 실패의 경험을 통해 문제 해결에 필요한 경험 법칙을 학습한 결과이다.

본 연구에서는 이같은 사실을 바탕으로 치구 모듈에 학습 기능을 추가하여 설계 실패로 인한 반복 작업을 줄이고 전반적인 설계의 효율성 향상을 추구한다. 학습 방법은 사례 기반 학습 방법을 이용하는데, 실패한 치구 계획과 수정된 치구 계획을 기억하였다가 이후 유사한 상황에 적용하여 설계 실패를 방지한다.

3. 절삭 가공용 공정 계획 시스템의 구성

절삭 공정 설계 작업은 특징 형상간의 간섭을 검사하고 그 결과로 얻는 공구 접근 방향을 토대로 특징 형상을 통합하여 가공 공정 계획을 생성하는 순서로 진행된다. 또한, 가공 중에 모체가 흔들리지 않게 고정하기 위한 치구 계획을 세운다. 그러나, 실제 설계 작업 시에는 잦은 설계 변경 및 가공 공정 형성

을 불가능하게 하는 많은 문제들로 인해서 위와 같은 설계 순서는 지키기 어렵다. 이러한 환경에서 시스템을 유연하게 유지하기 위해서 상호작용 및 공동 작업이 가능한 독립적인 전문 모듈로 구성한다.

3.1 시스템의 구성 모듈

본 연구에서는 Cutkosky^[11] 등에 의해 개발된 동시 공학적 설계 시스템인 NEXT-CUT의 각 모듈에 기계 학습 알고리즘을 적용하여 설계의 효율성을 향상시키려고 하였다. NEXT-CUT시스템은 중앙 지식 베이스와 세분화된 전문 모듈들로 구성된다. 중앙 지식 베이스는 공유 지식을 제공하는 지식 베이스 일 뿐만 아니라 모듈간의 정보 교환이 일어나는 장소이기도 하다. NEXT-CUT 모듈들은 설계, 공정 계획, 재료 및 공구 등에 대한 상세 정보를 공유하여 상호 작용한다. 다음에 대표적인 세 모듈을 설명한다.

3.1.1 기하학적 모듈

기하학적 모듈은 먼저 각 특징 형상의 공구 접근 방향 중에서 최종 가공물과 간섭을 일으키는 것을 제외시킨다. 이 때, 바운딩 박스 근사법을 이용하여 공구가 가공시 실제로 제거하는 모체의 양과 공구의 경로에 의해 교차되는 모체의 총 부피를 구한다. 다음 단계는 전 과정에서 얻은 실행 가능한 공구 경로 중에서 다른 특징 형상과 교차하는 것이 있는지 검토한다.

이와 같은 단계를 통해 기하학적 모듈은 간섭을 일으키지 않는 공구 경로를 선택하고 이에 따른 가공 작업의 순서를 결정하는데 필요한 제약 조건들을 얻는다. 따라서, 각 특징 형상에 대하여 단 하나의 공구 경로만을 선택함으로써 간섭 및 가공 작업 순서를 결정하는 제약 조건들을 최소화한다.

기하학적 모듈의 작업 결과는 기하학적 상호 작용 그래프의 형태로 각 모듈에 전해진다.

3.1.2 공정 계획 모듈

공정 계획 모듈은 특징 형상 가공시 공구가 접근 가능한 방향과 기하학적 모듈로부터 얻은 기하학적 상호 작용 그래프를 이용하여 가공 순서를 생성한다. 공정 계획 모듈의 중요한 특성은 문제가 발생하는 경우에만 이를 해결하기 위해 제약 조건을 부가하여 설계를 진행하는 것이다. 그러므로, 각 모듈은 설계 변경시 요구되는 백트래킹을 줄일 수 있다. 작업 결과는 부분별 공정 순서 그래프로 표현한다.

3.1.3 치구 공정 계획 모듈

동일한 공구 접근 방향을 가지는 일련의 가공 작업들은 하나의 치구 공정을 형성한다. 치구 모듈은 작업 통합으로 생성된 부분별 치구 공정 그래프에서

제시하는 치구 공정간의 순서를 만족시키는 전체 치구 공정 순서를 하나 선택하여 각 치구 공정에 적절한 치구 배열을 찾는다. 그리고, 기하학적 모듈로부터 모체의 기하학적 정보를 받아 기본 치구 형식을 결정한다. 치구 모듈은 마지막으로 공구의 가공 접근 방향 및 공구 고정구의 가공 경로와의 간섭 정보를 바탕으로 정확한 고정구의 위치를 결정한다.

3.2 설계 정보의 재사용

실제 설계 중에는 설계 변경 및 추가 사항들을 반영하기 위해 이전 결과를 수정하는 경우가 자주 발생한다. 그러한 환경에서 빠른 응답성은 매우 중요한 특성으로, 각 모듈은 이를 위해 가능하면 이전 결과들을 재사용한다. 따라서, 각 모듈들은 설계 계획과 해석 결과 및 작업 진행 상황을 잘 알아야 한다. 예를 들어, 치구 모듈은 가공물의 치구 공정, 특징 형상, 가공면 및 그 상호 관계에 대한 정보를 가지고 있어서, 설계 변경이 일어나는 경우에 어떤 치구 공정을 수정해야 하는지 쉽게 알 수 있다. 이로부터 설계 변경의 영향이 없는 다른 치구 공정에 관한 정보는 재사용한다.

한편 치구 계획이 실패하는 경우 시스템은 문제 해결 전략에 따라서 치구 계획을 수정한다. 앞에서도 언급했듯이 임의의 가공에 요구되는 기하학적, 기구학적, 역학적 제약 조건 및 그들의 복합적인 관계를 만족하는 치구 배열을 찾는 것은 쉽지 않다. 본 연구에서는 설계 경험을 바탕으로 좀더 정확하고 안전한 치구 계획을 보장하기 위해서 치구 계획 결과, 특히 실패한 결과를 재사용하는 방법을 치구 모듈에 추가하고자 한다. 치구 공정이 실패하면 치구 모듈은 문제 해결 과정을 거쳐 치구 공정을 수정한 후 실패한 치구 공정 및 그 수정안을 기억하였다가 다음 설계부터는 치구 공정 초기에 미리 유사한 치구 공정 존재 여부를 검사해서 수정함으로써 백트래킹을 줄인다. 이전 설계 결과를 이용하여 불필요한 반복 작업을 줄인다는 측면에서 또 다른 형태의 정보 재사용이라 할 수 있다.

3.3 치구 문제 영역

치구 계획을 수행하기 위해 요구되는 설계 정보는 다음과 같다.

- 1) 공정 계획 모듈로부터 전달되는 공정 계획.
 - 2) 모체의 형태 및 세부 사양에 따른 CAD 모델.
 - 3) 공구 경로에 관한 정보.
 - 4) 현 가공에 적용 가능한 치구 요소들에 관한 정보.
- 위와 같은 정보를 이용하여 치구 모듈은 작업을




Fig. 3-1. Determination of "clampable regions"




Fig. 3-2. Refined clampable region when features are partially located.

수행하며, 그 결과로 제시하는 치구 계획으로부터 설계자는 모체를 고정하기 위해 요구되는 치구 관련 정보를 얻는다. 즉, 모체의 정확한 위치 고정을 위한 치구 배열, 각 치구 요소에 적절한 고정력, 그리고 치구 비용 등의 정보가 치구 계획에 포함된다.

본 연구에서는 치구 공정 계획이 실패하는 유형을 다음과 같이 분류한다.

1) 고정 가능 영역의 부족.

가공할 특징 형상이 지나치게 많아서 치구 요소들 고정할만한 공간이 가공면에 존재하지 않는다. 치구 형태가 스트랩 클램프인 경우 Fig. 3-1에서 보는 것과 같이 실질적인 고정 가능 영역은 가공면의 바깥쪽이다. 따라서, 특징 형상이 바깥쪽으로 치우쳐 위치하면 전체적인 가공 면적대 특징 형상 면적의 비는 작지만 실제 적용 가능한 고정 가능 영역 비는 작다.

2) 특징 형상들이 임의의 방향으로 치우침으로 인한 기구학적 제약 조건 위배.

특징 형상들이 가공면의 한쪽으로 치우쳐서 위치한 경우 앞서 언급한 고정 가능 영역은 부족하지 않다. 그러나, 기구학적 제약 조건을 충분히 만족시키지 못하므로 이때 얻어진 치구 배열은 그 안정성이 떨어진다. 이로 인해 가공 중에 흔들림이나 미끄러짐이 발생할 수 있으므로 바람직하지 않다(Fig. 3-2).

4. 기계 학습 적용 알고리즘

설계 정보의 재사용으로 최적의 설계를 하기 위해서는 우선 설계 정보를 효율적으로 다루어야 한다. 나중에 기존 정보를 가진 지식 베이스에 접근하였을 때, 이 정보를 쉽게 현재 상태에 적용할 수 있는 것이 중요하다. 또한, 기존의 설계 정보를 최대한 이용하는 알고리즘 또한 필수적인 것이다. 그러나, 무리한 설계 정보의 재사용은 오히려 시스템의 성능 및 작업 속도를 저하시킬 수 있다.

따라서, 치구 설계시 설계 정보의 재사용은 다음 두 가지 측면으로 나눌 수 있다.

1) 이전 설계 정보의 효율적인 사용을 위한 저장 방법 모색.

2) 설계 정보를 적절히 이용하여 최적의 설계를 하기 위한 방법 모색.

(1) 설계 정보 저장 방법

셋업의 성공 여부에 따라서 이 셋업에 대한 정보 저장 필요 여부를 판단하는 방법을 이용한다. 실제 사례 기반 학습에서는 실패한 사례 외에 성공한 사례에 대한 정보도 또한 이용한다. 즉, 성공 사례에 대한 정보를 저장해서 이후 유사한 문제에 그 해결책을 수정, 적용하여 문제 해결을 유도한다. 그러나, 현재의 학습 적용 범위인 치구 설계에서는 성공 사례에 대한 정보 이용은 과도한 정보 저장 및 불필요한 정보 재사용으로 인해 오히려 설계 시간의 낭비 및 설계 실패를 유발할 수 있다. 셋업이 실패하면 먼저 문제 해결 프로세스를 이용하여 해결하고, 실패한 셋업을 설계 변경된 셋업과 비교, 검토함으로써 실패한 원인을 찾아 문제 해결 방법과 함께 저장한다.

(2) 설계 정보의 효율적인 사용 방법

일단 공정 계획 모듈에서 모체를 가공하기 위해 필요한 작업들을 통합하여 셋업을 구성하면, 우선적으로 셋업의 실패 여부를 검증하는 과정을 진행한

다. 이는 기타 작업 후에 검증 과정을 거치는 것보다 작업 효율면에서 유리한데, 그 이유는 실패한 셋업이 발생하면 이를 수정하여 기타 작업을 진행함으로써 기타 작업의 불필요한 반복을 피할 수 있기 때문이다. 검증 과정 중에는 실패한 원인에 대한 설명을 덧붙임으로써 설계자가 쉽게 문제를 인식, 이해할 수 있다. 따라서, 이후 설계에서는 같은 실수를 반복하지 않도록 미연에 방지할 수 있다.

이러한 과정은 동시 공학의 관점에서도 타당한데, 첫째로 가공 공정 설계 과정에서 미리 치구 설계시에 발생하는 문제점들을 적용하여 설계 실패를 방지할 수 있고, 둘째로 이전 정보의 재사용으로 불필요한 반복 작업을 줄일 수 있다는 점이다.

다음 절들에서는 셋업 정보의 재사용을 위한 기계 학습 알고리즘을 단계별로 상세히 다룬다.

4.1 실패한 셋업 정보의 저장

기존의 치구 계획 모듈은 공정 계획 모듈에서 결정한 셋업을 검토하여 실제 가공에 부적당하면, 셋업의 실패를 알리고 문제 해결 알고리즘에 따라서 셋업을 재구성한다. 본 연구에서 개발하는 치구 계획 모듈은 여기에 기계 학습을 적용하기 위한 알고리즘을 추가하여 설계의 효율 향상을 도모한다.

4.1.1 셋업 정보 저장

실패한 셋업에 대한 정보를 실패 사례 데이터 베이스에 저장한다. 셋업 정보는 치구 설계에 필수적인 수치 값으로, 일련의 계산 과정을 통해서 얻는다. 예를 들면, 현 셋업이 가공해야 하는 특징 형상의 개수 및 각각의 넓이, 현 셋업의 고정 가능 영역 등은 치구 설계시 요구되는 중요한 데이터이므로 설계 정보로서의 저장은 필수 불가결하다. 이러한 정보 외에 사례 기반 학습에서 가장 중요한 인덱스가 저장된다. 이 인덱스는 설계 정보의 독립성 및 이후 수정된 셋업 정보와의 연계성을 생성하는 역할을 한다. 본 연구자가 치구 실패 사례의 인덱스로 선정한 것은 시스템이 셋업을 검토하는 시간 데이터이다. 이로써 각 사례 정보는 타 사례와 명확히 구분될 수 있다.

4.1.2 실패 셋업의 수정 및 Main Attribute의 결정

셋업이 실패한 경우 실패의 원인에 따라서 문제를 해결한다. 스트랩 클램프로 모체를 고정하는 경우에 가장 대표적인 실패의 원인은 클램프 고정에 필요한 최소한의 영역을 확보하지 못하는 것이다. 이 경우 해결 방법은 "셋업 분리"이다. 즉, 하나의 셋업을 다수의 셋업으로 나눔으로써 고정 가능 영역을 이전보다 크게 한다.

실패한 셋업 및 수정된 셋업 정보를 바탕으로 셋업 실패를 유도한 가장 지배적인 특성치, Main Attribute을 결정한다. 본 연구에서는 해시 테이블¹²⁾을 구성, 적용하여 보다 신속하게 Main Attribute를 결정하였다.

해시 테이블은 1차원 배열로서, 배열의 각 요소는 하나의 정보와 연결된다. 주어진 정보와 연관된 요소를 찾기 위해서는, 각 정보와 연관된 정보들의 배열번호를 기억하여 필요 시에 연관정보들을 찾을 수 있는 인덱싱정보를 이용한다. 이러한 배열번호가 정보의 키가 되며, 해시테이블은 이러한 연관정보들의 상관관계를 기억하여 필요정보를 제공한다. 일단 키가 정해지면, 이 키를 이용하여 해시 테이블의 번지를 얻는데 사용한다. 이러한 키는 해시 함수라고 부르는 함수에 적용시킴으로써 얻어진다.

이와 같이 해시 테이블을 이용한 탐색 알고리즘은 정보와 관계된 키를 변수로 이용하는 방법으로 정보를 체계화하여 입력과 추출을 쉽게 하기 위한 방법의 하나이다. 따라서, 이 알고리즘은 정보와 관계된 키들을 이미 알고 있거나 그 범위가 한정되어 있는 경우에 다른 탐색 알고리즘보다 빠르게 탐색하여 원하는 정보를 얻을 수 있다.

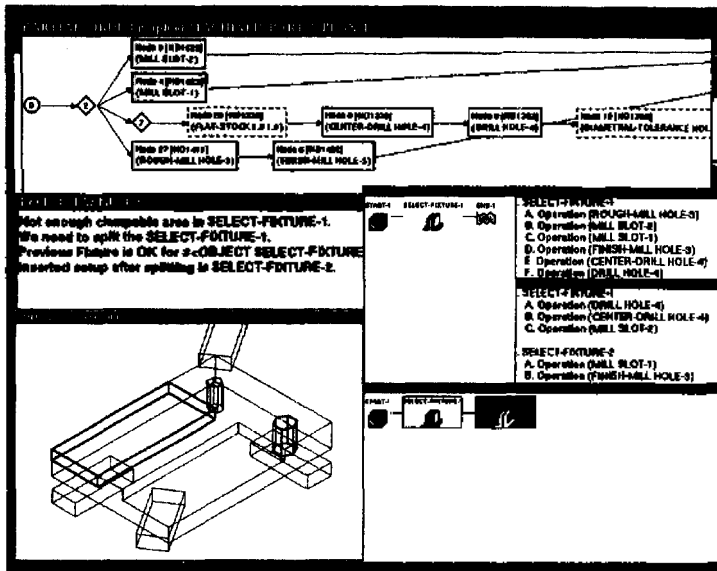
본 연구에서 개발된 치구 모듈이 치구 설계시 중요하게 고려하는 변수들은 각 특징 형상이 모체에서 차지하고 있는 위치 및 그 넓이를 들 수 있다. 따라서, 이들을 키로 하여 해시 테이블을 구성함으로써 보다 신속하게 원하는 정보를 얻을 수 있다. Fig. 4-2는 치구 설계시 정보를 체계화하여 구성한 해시 테이블의 예를 보여주고 있다. 해시 테이블의 구조를 이용하여 실패한 셋업 정보와 그것을 수정한 셋업 정보를 비교, 검색한 결과로써 Main Attribute을 선정한다.

4.1.3 수정된 셋업 정보 저장

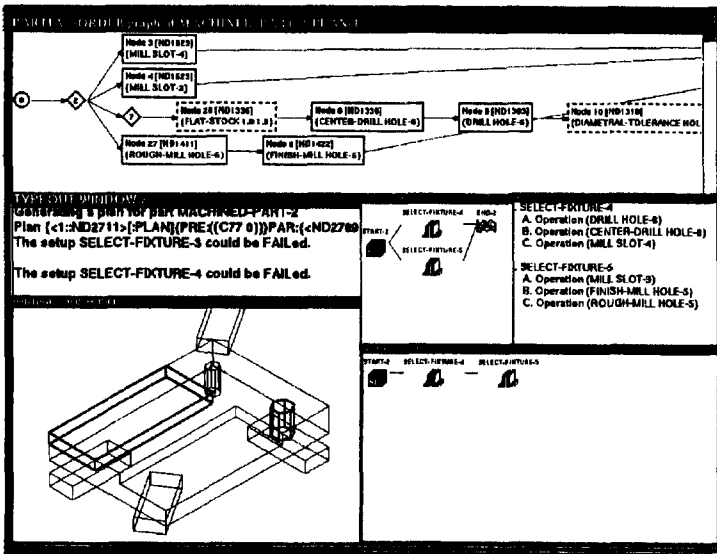
수정된 셋업에 대한 정보를 실패 셋업 정보와 동일한 방법으로 저장한다. 기본 정보 외에 실패의 원인에 따른 해결책을 제시하는 정보를 저장하여 정보 재사용을 유도한다. 인덱스 값은 실패 셋업과 같은 값으로 저장함으로써 앞서 저장한 실패 정보와의 연결을 원활히 한다. 또한, 실패한 셋업 정보에 추가로 이전 과정에서 결정된 Main Attribute을 저장하여 이후 임의의 설계 과정에서 이 셋업의 실패 원인을 쉽게 알 수 있도록 한다.

4.2 실패한 셋업 정보의 재사용

공정 설계 모듈은 가공 공정들을 통합하여 셋업을 구성한다. 이때, 이 셋업의 실현 가능성을 검토하는 것이 바람직하다. 셋업 실패로 인한 재설계를 사전



(a) before machine learning



(b) after machine learning

Fig. 4-1. An example of setup split. Once planner fails setup planning, it replans and runs machine learning algorithm. Then it successfully plans similar cases.

에 방지할 수 있기 때문이다. 셋업의 성공 여부는 현 셋업과 실패 사례 데이터 베이스의 셋업을 비교, 판단한다. 다음에서 이 과정을 보다 자세히 다룬다.

4.2.1 셋업 정보 비교

검토하고자 하는 셋업의 정보를 해시 테이블로 구조화한다. 해시 테이블로 구성함으로써 정보에 대한 접근이 보다 원활해지며 또한 다루기도 쉽다. 해시

테이블에 포함하는 정보는 실패 셋업 정보와 동일하게 구성하여 정보 비교를 수월하게 한다.

그리고, 사례 데이터 베이스의 실패 셋업 정보들을 다스 추출하여 해시 테이블로 구성된 후 두 해시 테이블을 비교한다. 여기서 실패 셋업의 Main Attribute 정보를 추출하여 현 셋업의 값과 비교하는 것이 중요하다. 넓이 정보에 대한 Main Attribute의 예에서 실패 셋

**** THE NODE DIFF-28 DOES NOT EXIST****

DIFF-28=DIFFERENCE DIFF-26 CUBE-4
 FAILED SETUP SPECIFICATIONS :

SLOT-1	5.9
CLAMPABLE-AREA-RATE	1.0
PRIMITIVE-AREA	35.0
SLOT-3	5.9
REFINED-CLAMPABLE-AREA	35.0
FEATURE-COUNT	4
SLOT-4	3.9
SLOT-2	3.9
TOTAL-OCCUPIED-AREA	19.6
TOTAL CLAMPABLE-AREA	20.0

MODIFIED SETUP-1 SPECIFICATIONS :

CLAMPABLE-AREA-RATE	0.4
PRIMITIVE-AREA	35.0
REFINED-CLAMPABLE-AREA	12.0
FEATURE-COUNT	2
SLOT-4	3.9
SLOT-2	3.9
TOTAL-OCCUPIED-AREA	7.8
TOTAL-CLAMPABLE-AREA	20.0

MODIFIED SETUP-2 SPECIFICATIONS :

SLOT-1	5.9
CLAMPABLE-AREA-RATE	0.6
PRIMITIVE-AREA	35.0
SLOT-3	5.9

Fig. 4-2. Hash tables of a failed setup and its modified setups.

는 의미이므로, 실패 셋업과 현 셋업 간의 고정 가능 영역에 대한 정보를 비교한다. 만약 현 셋업이 실패하는 사례로 판정되면, 기존의 실패 셋업을 해결한 방법을 적용한다. 반대의 판정을 받으면, 실패 사례 데이터 베이스의 다음 셋업과 비교한다. 이와 같은 작업을 실패 사례 데이터 베이스의 모든 셋업에 대해 반복하여 현 셋업의 성공 여부를 판정한다.

4.2.2 실패 판정 후 셋업 재구성

비교한 실패 셋업 정보를 바탕으로 셋업을 재구성한다. 실패 셋업을 재구성한 수정된 셋업 정보에 접근하여 셋업 재구성의 해결 방법을 찾는다. 수정된 셋업 정보는 실패 셋업과 인덱스가 같으므로 이를 이용하여 데이터 베이스로부터 쉽게 찾을 수 있다. 수정된 셋업의 해결책에 대한 정보에 접근함으로써 이를 바탕으로 현 셋업을 재구성한다. 해결책이 "셋업 분리" 인 경우 이를 수행하는 알고리즘에 따라서 현 셋업을 나눈다.

또한, 실패 셋업과 수정된 셋업의 정보를 비교, 제시하여 사용자가 쉽게 실패의 내용을 인식하도록 한다. 이 과정을 통해 사용자에게 셋업 설계에 대한 지식을 전달함으로써 잠재적으로 사용자가 이후에 같은 실패를 되풀이하지 않는 효과도 얻기를 기대 한다.

5. 시스템의 구현

업의 Main Attribute가 고정 가능 영역이라면 이 셋업의 실패는 치구를 고정시킬 영역이 없음에 기인한다

본 연구에서 개발한 모듈은 Sun-Sparc 2 워크스테




Fig. 5-1. Given four slot features, only two SLOT features (bold line slots in window I) will be machined in SELECT-FIXTURE-2, which are added after setup splitting.




Fig. 5-2. Setup split when features are located in one-side.




Fig. 5-3. As shown in WINDOW 1, Fixture agent splits setups by reusing previous failed setup information.

이션에 전문가 셸인 Hyperclass 시스템을 이용하여 구축되었으며 사용 언어는 Common-Lisp이다. Hyperclass 시스템은 자체 내장 솔리드 모델러가 없으므로 CMU에서 개발한 Vantage 시스템과의 Interface를 통해 CAD를 지원한다.

5.1 치구 계획 실패시 이전 설계 정보의 저장

치구 계획이 고정 가능 영역의 부족으로 실패한

경우 치구 모듈은 문제 해결 알고리즘에 따라서 치구 계획을 수정한 후 실패한 셋업 등의 정보를 해시 테이블을 이용하여 체계적으로 저장한다. 이 작업의 결과는 Fig. 5-1에서 보여진다.

Fig. 5-2는 또 다른 치구 계획 실패의 예를 보여준다. 그림에서 특징 형상이 한 쪽에 치우쳐 있으므로 특징 형상 세 개를 하나의 셋업으로 구성하는 경우 치구 요소를 적절히 배치할 수 없다. 즉, 기구학적




Fig. 5-4. Planner represents two setups for four slots. Even if features occupy relatively small areas, there is no enough clampable region for strap clamps.

제약 조건을 만족시키지 못하므로 안정된 치구 배열을 제시할 수 없다. 따라서, 두 개의 셋업으로 나누어 치구 계획을 진행하는 것이 바람직하다.

5.2 새로운 치구 설계시 이전 정보의 재사용

치구 설계에 관한 학습 과정을 수행한 후 새로운 설계 작업시에 공정 계획 모듈은 작업 통합 직후에 이전 셋업 정보를 바탕으로 각 셋업의 성공 여부를 판단한다. 이 때, 셋업이 실패하면 공정 계획 모듈은 저장된 이전 정보에서 제시하는 문제 해결 방법에 따라 셋업을 수정하고 설계를 진행한다. Fig. 5-3은 공정 계획 모듈이 학습을 통해서 미리 두 개의 셋업

으로 나누어 제시한 경우이다.

앞서 실패한 치구 계획을 저장한 정보는 치구 실패를 주도하는 Main Attribute 및 관련 정보를 함께 가지고 있어서 현재 공정 계획 모듈이 제시하는 셋업의 성공 여부를 쉽게 판단할 수 있게 한다. 그러므로 Fig. 5-4에서는 공정 계획 모듈이 앞선 치구 계획 정보를 바탕으로 셋업의 실패를 미리 예측하여 셋업을 두 개로 나누어 제시함으로써 치구 모듈이 성공적으로 치구 계획을 수행한 예를 보여준다. 또한 Fig. 5-5에서는 8개의 슬롯 특징 형상을 가공하기 위해서는 두 개의 셋업이 필요하다는 사실을 기계 학습을 통해서 인식, 적용함으로써 백트래킹없이 효율적




Fig. 5-5. Setup plan for more complicated case. Planner anticipates all the features are impossible to be cut with one setup (WINDOW I, WINDOW II) and makes up two setups for features.

으로 설계를 진행한 예를 보여준다.

6. 결론 및 고찰

한 분야의 전문가는 비전문가보다 많은 설계 경험을 가지고 있어서 보다 나은 설계를 할 수 있다. 이는 경험을 바탕으로 새로운 사실 혹은 규칙을 학습하고 체계화함으로써 자신의 지식을 늘린 결과이다. 만약 설계 시스템이 사람과 같은 학습 능력을 가지고 있다면 컴퓨터의 기본 기능인 방대한 양 처리와 인텔싱 기능의 이용으로 사람보다 월등히 뛰어난 작업을 수행할 것은 자명하다.

본 연구에서는 치구 공정 계획 모듈에 학습 능력

을 부여함으로써 이전 정보를 체계적으로 구축함과 동시에 이전보다 좋은 치구 설계를 할 수 있고 나아가 설계의 효율성 향상을 도모하는 치구공정계획 방법론을 제시하였다.

본 연구에서 얻어진 결론은 다음과 같이 요약할 수 있다. 첫째, 인공지능 기법인 사례 기반 학습 방법을 치구 공정 설계에 적용하여 시스템의 지능화를 구현하였고, 둘째, 치구공정계획 실패 시에 이전 정보를 체계적으로 저장하고 이를 효과적으로 재사용함으로써 불필요한 반복 작업을 줄여 설계의 효율성을 향상시켰다. 아울러 치구 계획 실패에 관한 정보를 저장하여 사용자에게 잠재적인 학습 효과를 얻을 수 있도록 하였다.

본 연구에서는 치구 설계시 발생할 수 있는 설계 변경 문제들을 중점적으로 다루었다. 그러나, 보다 완벽한 설계 시스템을 개발하기 위해서는 치구 모듈 뿐아니라 공정 설계 모듈 및 시스템을 구성하는 기타 다른 모듈들의 문제를 모두 고려해야 하며 각 모듈의 설계 변경시 타 모듈에 미치는 상호 작용을 효과적으로 다루어야 한다. 향후 이러한 주제들에 대한 추후 연구가 요구된다.

참고문헌


1. Fuh, J.Y.H., Chang, C.H. and Melkanoff, M.A., "An Integrated fixture planning and analysis system for machining processes", *Robotics & Computer-Integrated Manufacturing*, Vol. 10, No. 5, pp. 339-353, 1993.
2. Prombangpong, S., Lewis, R.L. and Bishop, A.B., "A computer-aided fixture design system with process planning integration for prismatic parts manufactured on CNC machining centers", *In Proc. of the 1992 ASME International Computers in Engineering Conference and Exposition*, Vol. 1, pp. 369-380, Aug. 1992.
3. Asada, H. and By, A.B., "Kinematic analysis of workpart fixturing for flexible assembly with automatically reconfigurable fixture", *IEEE J. of Robotics and Automation*, pp. 86-94, 1985.
4. Chou, Y.C., Chandru, V. and Barash, M.M., "A mathematical approach to automatic configuration of machining fixtures: Analysis and synthesis", *J. of Eng. for Industry*, Vol. 111, pp. 299-306, 1989.
5. Hayes, C.C. and Wright, P.K., "Automating process planning: Using feature interactions to guide search", *J. of Manufacturing Systems*, Vol. 8, pp. 1-15, 1989.
6. Sungurtekin, U.A. and Voelcker, H.B., "Graphic simulation and automatic verification of NC machining programs", *In Proc. of 1986 IEEE International Conf. on Robotics and Automation*, pp. 156-165, 1986.
7. Engert, P.J., *Principles for part setup and workholding in automated manufacturing*, Ph.D. Diss-

- ertation, Carnegie Mellon University, 1988.
8. Chen, Y.C. and Chen, C.L.P., "The importance of sequence in clamping prismatic workpieces in fixturing processes", *In Proc. of 1996 IEEE International Conf. on Robotics and Automation*, pp. 503-508, 1996.
9. 박영택, 이강로, "ID3 계열의 귀납적 기계 학습", 정보과학회지, 제 13권 제 5호, pp. 6-19, 1995.
10. Simon, H.A., "Why should machines learn?", *In Machine Learning: An Artificial Intelligence Approach*, pp. 25-37, 1983.
11. Cutkosky, M.R. and Tenenbaum, J.M., "A methodology and computational framework for concurrent product and process design", *Mechanism and Machine Theory*, Vol. 25, pp. 365-381, 1990.
12. 김재희, 인공지능의 기법과 응용, 교학사, pp. 12-14, 1992.



김 선 우

1994년 ~ 1996년 연세대학교 기계공학과 석사
 1997년 미국 미시간 주립대학 유학
 관심분야 : 컴퓨터를 이용한 설계 및 생산 분야에 관심이 있음. AI(인공지능)를 설계 분야에 적용하여 보다 효율적인 설계를 추구하고자 함.



이 수 홍

1981년 서울대 기계공학과 학사
 1983년 서울대 기계설계학과 석사
 1991년 Stanford 대학 Design Division Concurrent Engineering 전공, 박사
 1991년 ~ 1992년 Lockheed Missile and Space Co. Cable Harness Design System 개발 Post-Doc.
 1983년 ~ 1994년 KIMM CAD/CAM실, 선임 연구원
 1994년 ~ 현재 연세대학교 기계공학과, 부교수
 관심분야 : 동시공학설계, 지식기반시스템 설계, DFM