

자동 계획수립을 위한 기계학습

경기대학교 | 김인철*

1. 서론

본 논문에서는 오랜 역사를 지닌 인공지능 자동 계획수립(automated planning) 분야에 적용되어온 대표적인 기계학습 방법들을 몇 가지 분류기준들을 중심으로 고찰해보고, 이 분야의 향후 연구 진행방향을 가늠해보고자 한다. 일반적으로 **자동 계획수립은 목표 달성을 위한 일련의 동작들을 스스로 결정할 수 있는 문제 해결 능력을 말하고, 학습은 과거의 경험들을 기초로 더 잘 행동할 수 있도록 스스로 성능을 개선해 나가는 능력**을 말한다. 따라서 이 두 가지 능력 모두 지능 존재에 요구되는 필수적인 지능 요소임에 틀림이 없다. 특히 기계학습 기술은 에이전트가 직면할 세계에 대해 설계자의 지식이 불완전할 때 이것을 보완해 줄 수 있으며, 에이전트에 대한 지속적인 관찰과 통제에 부담을 경감시켜줄 수 있기 때문에 에이전트에게 보다 큰 자율성과 유연성을 부여하는 수단으로 인식되고 있다. 이러한 기계학습 기술은 다른 기술들과 결합되거나 혹은 독립적으로 에이전트의 다양한 지능 행위를 구현하는데 적용되어 왔다.

약 40년 가까이 연구되어온 인공지능 자동 계획수립 분야에서도 이러한 기계학습 기술을 적용하기 위한 다양한 시도들이 이루어져 왔다. 불과 1990년대 초반 까지도 많은 전통적인 인공지능 계획수립기들은 약 10여개의 블록들을 포함하는 블록쌓기 문제들조차 쉽게 풀지 못하는 낮은 성능을 보였다. 따라서 이 당시에는 이러한 전통적인 계획수립기들의 성능을 향상시키기 위한 기계학습 기술에 대한 관심은 연구자들 사이에 매우 높았다. 이후 1990년대 중반부터는 자체적으로 최적화 기능을 포함한 높은 성능의 새로운 계획수립기들이 등장함에 따라 기계학습 기술에 대한 관심이 이전에 비해 낮아졌으나, 새로운 계획수립 패러다임에 맞는 기계학습의 역할과 접근방법에 대한 연구는 부단히 계속되고 있다.

* 종신회원

본 논문에서는 먼저 자동 계획수립을 지원하는 **기계학습 기술에 대한 몇 가지 분류기준을 소개한다.** 첫째는 해결하려고 하는 계획문제의 유형과 이를 위해 이용할 계획수립 방식이다. 둘째는 계획수립을 위해 기계학습이 수행하는 역할과 기계학습이 적용되는 시점이다. 셋째는 학습을 위해 이용하는 구체적인 기계학습 기법의 종류이다. 본 논문에서 이들 각각의 분류기준에 대한 설명과 더불어 해당 범주에 속하는 연구 사례들을 간략히 소개한 뒤, **향후 진행될 연구방향을 가늠해본다.**

2. 계획문제 유형과 계획수립 방법

인공지능의 한 연구 분야로서 자동 계획수립의 역사는 1960년대 대표적인 문제풀이기인 Newell과 Simon의 GPS로부터 시작되었다. 이것은 곧 인공지능 초기에는 계획수립과정을 하나의 문제풀이과정 혹은 정리증명과정으로 간주하였다는 것을 의미한다. 그러나 이후에는 계획수립과정을 하나의 탐색과정 혹은 모델체킹 과정으로 보는 관점으로 확장되었다.

초기의 계획수립기들은 정적인 세계와 완전한 인식, 동작의 결정성 등 매우 이상적인 환경을 가정한 계획 문제들을 취급하였다. 그러나 최근의 계획수립기들은 실세계의 불확실성과 가변성을 충분히 포함한 계획문제를 풀어보려고 노력중이다. 그림 1은 이상적인 가정에 기초한 전통적인 계획문제들에서 출발하여 실세계의 불확실성과 가변성을 모두 포함한 비전통적 계획문제들에 이르는 다양한 유형의 계획문제들이 존재함을 나타내고 있다.

그동안 개발된 많은 계획수립기들은 탐색의 관점에서 보면, 크게 상태공간상의 탐색(state space search)과 계획공간상의 탐색(plan space search)으로 나눌 수 있다. 일반적으로 상태공간 탐색을 이용한 계획수립에서는 초기 월드상태에서 출발하여 상태전이를 통해 목표 상태에 도달할 수 있는 일련의 동작들을 찾아간다. 반면에, 계획공간 탐색을 이용한 계획수립에서는

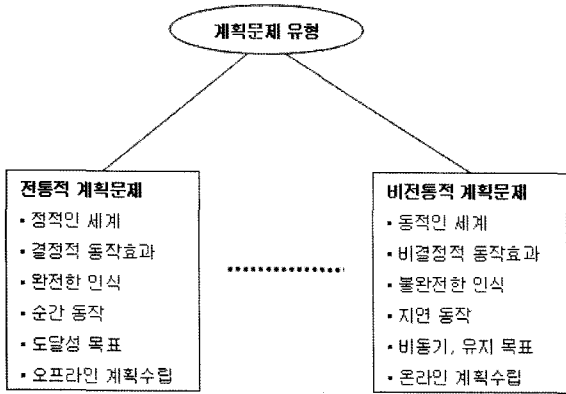


그림 1 제한적 가정에 기초한 전통적인 계획문제에서 실세계의 현실성을 고려한 비전통적 계획문제에 이르는 다양한 유형의 계획문제들

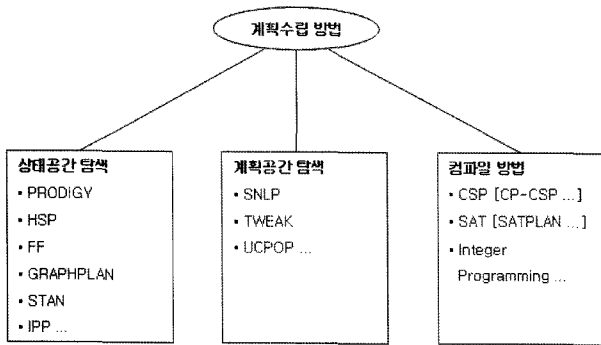


그림 2 계획수립 방법들과 계획수립기들

무 계획(null plan) 상태에서 출발하여 계획변경 동작들을 거듭 적용함으로써 하나의 완전 계획 상태를 찾아간다. 한편, 계획수립을 하나의 모델체킹 과정으로 취급하는 계획수립기들은 주어진 계획문제를 특정 문제해결엔진에 적합한 표현법으로 변환하는 컴파일러를 포함한다. 이러한 계획수립기들은 제약 만족성(CSP) 기반, 만족성(SAT) 기반, 정수 프로그래밍(integer programming) 기반 등으로 크게 나눌 수 있다.

그림 2는 계획수립 방식을 크게 상태공간 탐색과 계획공간 탐색, 그리고 컴파일 방식 등으로 나누고, 각각의 범주에 속한 대표적인 계획수립기들을 열거하고 있다. 일반적으로 자동 계획수립을 지원하는 기계학습 기술은 기초가 되는 계획수립기가 어떤 계획문제를 다루어야 하는지, 어떤 계획수립 방식을 쓰는지에 매우 의존적이다. 따라서 계획문제의 유형과 계획수립 방식은 많은 계획수립 지원 기계학습 연구들을 분류하는 중요한 기준이 된다.

3. 기계학습의 역할과 적용시점

계획수립기에서 기계학습 모듈은 계획수립과정을 가

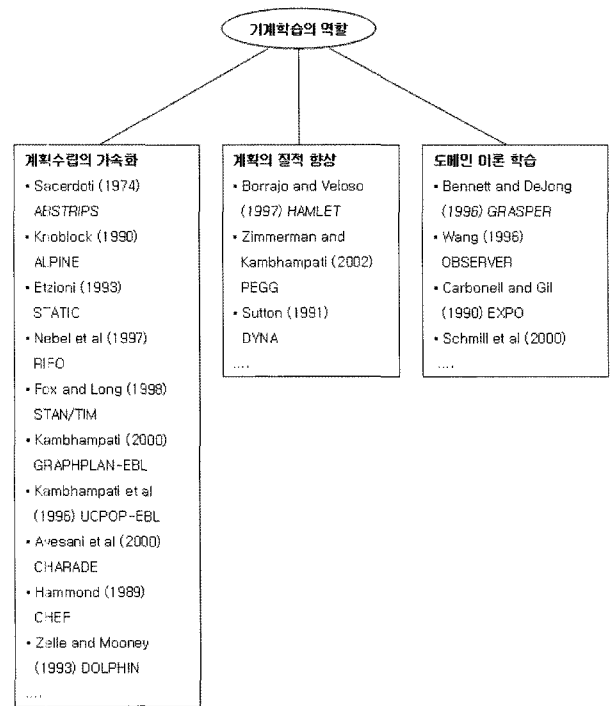


그림 3 자동 계획수립을 위한 기계학습의 역할별 관련 연구들

속화할 탐색 제어 규칙을 학습하거나, 사용자의 선호도에 맞는 계획을 찾도록 하거나, 혹은 불완전한 도메인 지식을 개선시키는 등 다양한 목적으로 이용되어 왔다. 그동안 진행되어온 연구들을 토대로 계획수립기에서 수행하는 기계학습 모듈의 주된 역할들을 살펴보면 그림 3과 같이 크게 세 가지로 나눌 수 있다.

첫째는 계획수립의 가속화이고, 둘째는 계획 도메인 지식의 개선이며, 셋째는 계획의 질적 향상이다. 그림 3은 자동 계획수립을 위해 기계학습이 수행하는 역할별로 관련 연구들을 분류해 놓고 있다. 대부분의 계획수립기는 주어진 계획문제에 대한 해를 얻기까지 상당히 많은 양의 탐색을 펼쳐야 하고, 이 과정동안 여러 차례 후진도 해야 한다. 따라서 가속화를 위한 기계학습의 주된 목표는 불필요한 탐색을 피하고 양질의 계획을 얻을 수 있는 방향으로 탐색을 유도하는 것이다. 성능이 높지 않은 전통적인 계획수립기들에서 가장 많은 연구가 이루어진 것이 바로 가속화를 위한 기계학습 기술이었다.

자동 계획수립기는 계획수립에 앞서 이용 가능한 동작들에 대한 정의를 필요로 하며, 이것을 일반적으로 도메인 이론(domain theory)라고 부른다. 각 동작이 환경에 미치는 효과에 대한 정확한 모델을 미리 확보하지 못하는 경우, 계획수립기 스스로 학습을 통해 자신의 도메인 이론을 개선시켜 나갈 수 있다면 매우 유리할 것이다. 실제로 불확실성과 가변성이 높은 많은 실

세계 계획문제들에서 동작들에 대한 완전한 모델링은 사실상 불가능하다. 따라서 주어진 도메인 이론에 기초하여 최적의 계획을 구한다고 하더라도 실행에 성공하지 못하는 경우가 자주 발생한다. 이와 같은 사례들은 현재의 도메인 이론을 좀 더 실세계에 가깝도록 개선시킬 수 있는 학습의 기회를 제공할 수 있다. 또 다른 기계학습의 중요한 역할은 계획의 질을 향상시키는 것이다. 기계학습 기술은 특별한 성질을 만족하는 계획을 찾아낼 수 있도록 계획수립기의 탐색을 유도하거나, 사용자와의 상호작용을 통해 사용자가 어떤 계획들을 선호하는지 학습하여 계획수립에 반영하는 방식으로 계획의 질적 향상에 기여할 수 있다.

계획수립을 위한 기계학습의 역할뿐만 아니라, 학습이 이루어지는 시점도 관련 연구들을 분류하는 중요한 기준이 된다. 학습이 이루어지는 시점은 그림 4와 같이 계획수립 이전, 계획수립시, 계획실행시 등으로 크게 나눌 수 있다. 그림 4는 학습이 이루어지는 시점별로 관련 시스템과 연구들을 분류하고 있다. 기존의 많은 연구들이 대부분 계획수립 과정동안에 학습이 이루어지는 방식을 채택하고 있으나, 계획수립 이전에 도메인 지식을 분석하여 탐색제어 지식을 얻거나 계획실행시에 학습을 통해 도메인 이론을 개선하려는 연구들도 시도되었다.

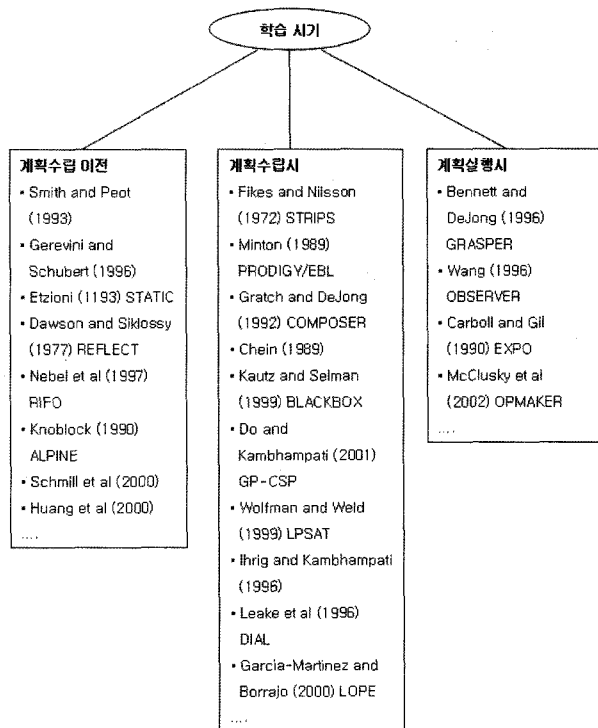


그림 4 자동 계획수립에 기계학습이 적용되는 시점별 관련 연구들

4. 기계학습 방법

자동 계획수립을 위해 적용할 수 있는 기계학습 기법에도 여러 가지 유형이 존재한다. 가장 널리 쓰이는 기계학습 기법들로는 그림 5와 같이 귀납적 기법들(inductive learning), 분석적 기법들(analytic learning), 그리고 이들을 결합한 복수전략 기법들(multistrategy learning)로 나누는 것이다. 귀납적 학습기법에서는 학습문제를 다음과 같이 정의한다. 하나의 가설 공간 H 와 훈련예제들의 집합 D 가 학습자에게 주어지면, 훈련예제들과 일치성을 보이는 하나의 가설 h 를 가설공간 H 로부터 찾아내는 것이다. 분석적 학습기법에서는 귀납적 학습기법의 경우와 마찬가지로 학습자에게 하나의 가설공간 H 와 훈련예제들의 집합 D 가 주어지는 외에, 훈련예제들을 설명하는데 도움이 되는 배경지식들로 이루어진 도메인 이론 B 가 추가 입력으로 주어진다. 이에 대해 학습자는 훈련예제들과 도메인 이론 모두에 일치성을 보이는 하나의 가설 h 를 가설공간 H 로부터 찾아야 한다.

그림 5는 자동 계획수립을 위한 분석적 학습기법, 귀납적 학습기법, 그리고 복수전략 학습기법들 각각에 대한 세부 분류체계와 해당 연구들을 제시하고 있다. 그동안 연구가 활발히 이루어진 분석적 학습기법들로는 도메인 분석을 통한 추상화, 설명기반의 학습(Explanation-Based Learning, EBL), 사례기반의 추론(Case-Based Reasoning, CBR) 등이 있다. 추상화는 간략화 과정을 통해 계획문제의 복잡도를 낮추고 계획수립을 가속화하기 위한 시도로서, 인공지능 초기 시스템인 ABSTRIPS에서부터 ALPINE을 거쳐 오늘날에 이르기까지 많은 연구가 이루어져 온 대표적인 분석적 학습기법이다. 설명기반의 학습(EBL)은 도메인 이론을 바탕으로 소수의 훈련예제에 대한 설명을 찾는 과정을 통해, 가속화에 도움이 되는 새로운 탐색제어 지식을 발견하거나 도메인 이론을 향상시키는 학습기법이다. 이 학습기법은 그동안 계획수립분야에서 가장 폭넓게 적용되어온 기계학습 기법의 하나이다. 사례기반의 추론은 과거 사례와 현재 계획문제간의 유사성을 이용하는 기계학습 기법이다. 과거에 풀어본 계획문제들에 대한 해를 사례들로 저장하고 있다가 이들을 현재의 계획문제 해결에 재활용함으로써 처음부터 계획수립을 다시 해야 하는 노력을 줄이고자 하는 시도이다. 이 학습기법은 사례저장 구조와 인덱싱, 유사성 척도, 사례적용 방법 등의 요소가 성능에 큰 영향을 미친다.

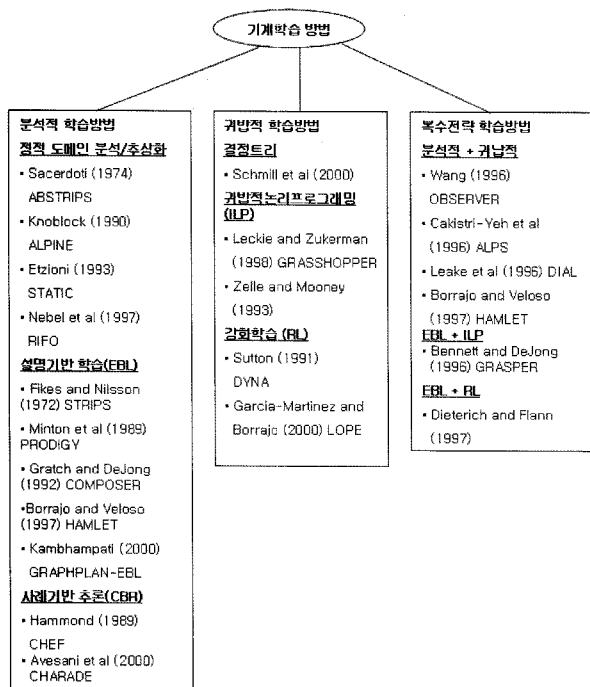


그림 5 자동 계획수립에 적용된 기계학습 방법들과 관련 연구들

자동 계획수립분야에서 귀납적 학습기법들에 대한 연구는 분석적 학습기법들에 대한 연구만큼 활발하지는 않았다. 그림 5에서 보듯이, 결정트리(decision tree) 학습과 귀납적 논리 프로그래밍(Inductive Logic Programming, ILP)과 같은 귀납적 학습기법들이 주로 계획수립을 위해 이용되어 왔다. 본 논문에서는 강화학습(Reinforcement Learning, RL)을 귀납적 학습기법의 범주에 분류해두었으나, 본래 강화학습은 특정 기계학습 기법을 나타내는 개념이 아니고 환경에 놓여진 에이전트가 풀어야 할 하나의 계획문제이자 학습문제를 의미한다. 강화학습은 에이전트가 환경과 상호작용을 통해 환경으로부터 받는 보상값의 합을 최대화할 수 있는 행동정책을 찾아야 하는 최적화 문제이다. 상태전이함수와 보상함수와 같은 환경 모델이 에이전트에게 미리 주어지는 경우, 강화학습은 하나의 계획문제에 간주되며 정책 반복(policy iteration), 가치 반복(value iteration)과 같은 다양한 동적 프로그래밍(dynamic programming) 방법을 적용하여 문제를 해결한다. 하지만 환경 모델이 미리 주어지지 않는 경우, 강화학습은 에이전트 스스로 경험을 통해 최적의 행동정책을 찾아야 하는 하나의 학습문제로 볼 수 있으며 Q 학습이나 SARSA 학습과 같은 시간 차(Time Difference, TD) 학습기법들을 많이 이용한다. 따라서 강화학습은 계획수립과 학습이 하나로 결합된 특수한 유형의 문제로 파악할 수 있다.

한편, 분석적 기법과 귀납적 기법을 적절히 혼용함으로써 양자의 장점을 모두 취하려는 복수전략 기법들에 대한 연구들도 계속되어 왔다. OBSERVER, ALPS, DIAL, HAMLET, GRASPER 등은 이러한 노력의 대표적인 예들로 볼 수 있다.

5. 결론

앞서 본 논문에서는 자동 계획수립 분야에 적용되어 온 기계학습 기술들을 고찰하기 위한 하나의 방법으로서, 이들을 분류하기 위한 하나의 분류체계를 소개하였다. 계획문제의 유형, 계획수립 방법, 기계학습의 역할, 기계학습의 적용시점, 기계학습 기법 등을 분류의 축으로 삼아 각 범주에 속하는 몇 가지 관련 연구들을 분류해보았다. 이와 같은 분류과정을 통해 우리는 다음과 같은 사실들을 발견할 수 있다. 먼저, 기존의 연구들은 주로 전통적인 계획문제와 계획방식을 위한 기계학습 기술에 집중되어 왔다는 점이다. 또 기존 연구들은 주로 계획수립 이전이나 계획수립 단계에 학습을 적용함으로써 계획수립을 가속화할 수 있는 탐색제어 지식을 학습하거나 도메인 이론을 개선시키는데 초점이 맞추어져 왔다는 점이다. 그리고 기계학습 기법 면에서는 다수의 혼련예제를 요구하는 귀납적 학습보다는 별도의 도메인 이론과 이것에 대한 분석을 필요로 하는 설명기반의 학습(EBL)이나 추상화와 같은 분석적 학습이 주로 적용되어 왔다는 점도 쉽게 알 수 있다.

이와 같은 고찰을 기초로 향후 진행 가능한 계획수립 지원 기계학습의 연구방향과 연구주제들을 다음과 같이 추정해 볼 수 있을 것이다. 먼저 그동안의 연구는 논리적으로 올바른 제어 지식을 학습할 수 있다는 장점 때문에 분석적 학습기법에 치중하였으나, 향후에는 다수의 혼련예제들로부터 근사 지식을 학습하는 귀납적 학습기법이나 혼합형 학습기법들에 대한 연구가 필요할 것으로 본다. 특히 설명기반의 학습(EBL)과 귀납적 논리 프로그래밍(ILP)과의 결합은 이러한 연구방향의 좋은 본보기가 될 것으로 판단한다. 또한 앞으로는 특정 도메인과 계획문제로부터 학습한 탐색 제어 지식을 다른 도메인과 계획문제에도 쉽게 이용할 수 있는 연구가 필요할 것으로 판단한다. 예컨대, 한 물류 도메인에서 학습한 지식을 다른 유사 도메인의 시스템에도 적용할 수 있을 것이다. 현재의 사례기반 추론(CBR) 기술은 저장된 사례들과 현재 계획문제 사이의 매우 제한적인 유사성만을 인식할 수 있으나 향후에는 보다 광범위한 유사성 추론이 가능하도록 확장할 필요가 있을 것이다. **마지막으**

로, 향후에는 비전통적 계획문제와 계획수립방식을 지원하는 기계학습 연구가 이루어져야 할 것으로 판단한다. 특히 각 동작의 소요시간과 자원을 고려하는 시간 자원 계획문제나 실제계의 비결정성과 불확실성을 반영하는 조건부 계획문제 및 확률 계획문제 등은 과거의 전통적 계획문제들에 비해 복잡도가 더욱 높다. 따라서 이들 비전통적인 계획문제와 계획수립방식에 효과적으로 적용할 수 있는 기계학습 기법이 시급히 개발되어야 할 것이다.

참고문헌

- [1] Avesani, P., Perini, A., and Ricci F., "Interactive Case-Based Planning for Forest Fire Management," *Applied Intelligence*, 13(1): 41-57, 2000.
- [2] Bennett, S. W. and DeJong, G. F., "Real-World Robotics: Learning to Plan for Robust Execution," *Machine Learning* 23(2-3): 121-161.
- [3] Bergmann, R. and Wilke, W., "On the Role of Abstractions in Case-Based Reasoning," *Proc. of EWCBR-96*, 28-43, 1996.
- [4] Bhatnagar, N. and Mostow, J., "Online Learning from Search Failures," *Machine Learning* 15(1): 69-117, 1997.
- [5] Borrajo D. and Veloso, M., "Lazy Incremental Learning of Control Knowledge for Efficiently Obtaining Quality Plans," *Artificial Intelligence Review* 11(1-5): 371-405, 1997.
- [6] Carbonell, Y. G. and Gil, Y., "Learning by Experimentation: The Operator Refinement Method," *Machine Learning: An Artificial Intelligence Approach*, Vol. 3, 191-213, 1990.
- [7] Dawson, C. and Siklossy, L., "The Role of Preprocessing in Problem-Solving Systems," *Proc. of 5th Int. Joint Conf. on Artificial Intelligence*, 465-471, 1997.
- [8] Dietterich, T. G. and Flann, N. S., "Explanation-Based Learning and Reinforcement Learning: A Unified View," *Machine Learning* 28: 169-210, 1997.
- [9] Do, B. and Kambhampati, S., "Planning as Constraint Satisfaction: Solving the Planning Graph by Compiling It into a CSP," *Artificial Intelligence* 132: 151-182, 2003.
- [10] Estlin, T. A. and Mooney, R. J., "Multi-Strategy Learning of Search Control for Partial-Order Planning," *Proc. of 13th Nat. Conf. on Artificial Intelligence*, 843-848, 1996.
- [11] Etzioni, O., "Acquiring Search-Control Knowledge via Static Analysis," *Artificial Intelligence* 62(2): 265-301, 1993.
- [12] Fikes, R. E., Hart, P., and Nilsson, N. J., "Learning and Executing Generalized Robot Plans," *Artificial Intelligence* 3: 251-288, 1972.
- [13] Fox, M and Long, D., "Automatic Inference of State Invariants in TIM," *Journal of Artificial Intelligence Research* 9: 317-371, 1998.
- [14] Garcia-Martinez, R. and Borrajo, D., "An Integrated Approach of Learning, Planning, and Execution," *Journal of Intelligent and Robotic Systems* 29(1): 47-78, 2000.
- [15] Gerevini, A. and Schbert, L., "Accelerating Partial-Order Planners: Some Techniques for Effective Search Control and Pruning," *Journal of Artificial Intelligence Research* 5: 95-137, 1996.
- [16] Gil, Y., "Learning by Experimentation: Incremental Refinement of Incomplete Planning Domains," *Proc. 11th Int. Conf. on Machine Learning*, 1994.
- [17] Gratch, J. and DeJong, G., "COMPOSER: A Probabilistic Solution to the Utility Problem in Speed-Up Learning," *Proc. 10th Nat. Conf. on Artificial Intelligence*, 235-240, 1992.
- [18] Hammond, K., *Case-Based Planning: Viewing Planning as a Memory Task*, Academic Press, 1989.
- [19] Hanks, S. and Weld, D., "A Domain-Independent Algorithm for Plan Adaptation," *Journal of Artificial Intelligence Research* 2: 319-360, 1995.
- [20] Huang, Y., Kautz, H. and Selman, B., "Learning Declarative Control Rules for Constraint-Based Planning," *Proc. 7th Int. Conf. on Machine Learning*, 2000.
- [21] Ihrig, L. and Kambhampati, S., "Storing and Indexing Plan Derivations through Explanation-

- Based Analysis of Retrieval Failures," *Journal of Artificial Intelligence Research* 7: 161-198, 1997.
- [22] Kambhampati, S., "Planning Graph as Dynamic CSP: Exploiting EBL, DDB, and Other CSP Techniques in GRAPHPLAN," *Journal of Artificial Intelligence Research* 12: 1-34, 2000.
- [23] Kambhampati, S and Hendler, J., "A Validation Structure-Based Theory of Plan Modification and Reuse," *Artificial Intelligence* 55(23) 193-258, 1992.
- [24] Kambhampati, S and Katukam, Y. Q., "Failure-Driven Dynamic Search Control for Partial Order Planners: An Explanation-Based Approach," *Artificial Intelligence* 88(1-2): 253-315, 1996.
- [25] Kautz, H. and Selman, B., "BLACKBOX: Unifying SAT-Based and Graph-Based Planning," *Proc. 16th Int. Conf. on Artificial Intelligence*, 318-325, 1999.
- [26] Knoblock, C., "Learning Abstraction Hierarchies for Problem Solving," *Proc. 8th Nat. Conf. on Artificial Intelligence*, 923-928, 1990.
- [27] Leake, D., Kinley, A., and Wilson, D., "Acquiring Case Adaptation Knowledge: A Hybrid Approach," *Proc. 13th Nat. Conf. on Artificial Intelligence*, 684-689, 1996.
- [28] Leckie, C. and Zuckerman, I., "Inductive Learning of Search Control Rules for Planning," *Artificial Intelligence* 101(1-2): 63-98, 1998.
- [29] Minton, S., Carbonell, J., Knoblock, C., Kuokka, D. R., Etzioni, O., and Gil, Y., "Explanation-Based Learning: A Problem-Solving Perspective," *Artificial Intelligence* 40: 63-118, 1989.
- [30] Nebel, B., Dimopoulos, Y., and Koehler, J., "Ignoring Irrelevant Facts and Operators in Plan Generation," *Proc. 4th European Conf. on Planning*, 24-26, 1997.
- [31] Reddy, C. and Tadepalli, P., "Learning Horn Definitions: Theory and an Application to Planning," *New Generation Computing* 17(1): 77-98, 1999.
- [32] Sacerdoti, E., "Planning in a Hierarchy of Abstraction Spaces," *Artificial Intelligence* 5(2): 115-135, 1974.
- [33] Schmill, M., Oates, T., and Cohen, P., "Learning Planning Operators in Real-World, Partially Observable Environments," *Proc. 5th Conf. on Artificial Intelligence Planning Systems*, 14-17, 2000.
- [34] Smith, D. and Peot, M., "Postponing Threats in Partial-Order Planning," *Proc. 11th Nat. Conf. on Artificial Intelligence*, 500-506, 1993.
- [35] Sutton, R., "Planning by Incremental Dynamic Programming," *Proc. 8th Int. Conf. on Machine Learning*, 353-357, 1991.
- [36] Veloso, M. and Carbonell, J., "Derivational Analogy in PRODIGY: Automating Case Acquisition, Storage, and Utilization," *Machine Learning* 10(3): 249-278, 1993.
- [37] Wang, X., "A Multistrategy Learning Systems for Planning Operator Acquisition," *Proc. 3rd Int. Workshop on Multistrategy Learning*, 23-25, 1996.
- [38] Zimmerman, T. and kambhampati, S., "Exploiting Symmetry in the Planning Graph via Explanation-Guided Search," *Proc. 16th Nat. Conf. on Artificial Intelligence*, 18-22, 1999.



김인철

1987. 2 서울대학교 계산통계학과(석사)
 1995. 2 서울대학교 계산통계학과(박사)
 1996. 3~현재 경기대학교 컴퓨터과학과 교수
 2003. 2~2004. 1 미시간주립대학교 방문교수
 관심분야 : 계획시스템, 기계학습, 지능형에이전트,
 지능로봇제어구조, 바이오의료정보학
 E-mail : kic@kyonggi.ac.kr