

# 조건부 계획수립을 위한 효과적인 그래프 기반의 휴리스틱

김 현 식<sup>†</sup> · 김 인 철<sup>\*\*</sup> · 박 영 택<sup>\*\*\*</sup>

## 요 약

계획 문제 명세로부터 영역-독립적인 휴리스틱을 유도해내기 위해서는 주어진 계획문제에 대한 간략화와 간략화된 계획문제에 대한 해 도출 과정이 요구된다. 본 논문에서는 초기 상태의 불확실성과 비결정적 동작 효과를 모두 포함한 조건부 계획문제를 풀기 위한 새로운 융합 계획그래프와 이것을 이용한 GD 휴리스틱 계산법을 소개한다. 융합 계획그래프는 고전적 계획 문제 풀이를 위한 휴리스틱 계산에 이용되는 간략화된 계획그래프를 조건부 계획문제에 적용할 수 있도록 확장한 자료구조이다. 융합 계획그래프에서는 감지 동작과 비결정적 동작들을 포함한 조건부 계획 문제에 대한 휴리스틱을 얻기 위해, 전통적인 삭제 간략화외에도 감지 동작과 비결정적 동작들에 대한 효과-융합 간략화를 추가로 이용한다. 융합 계획 그래프 의 진향 확장과 병행적으로 진행되는 GD 휴리스틱 계산에서는 목표조건들 간의 상호 의존성을 분석하여 전체 목표 집합에 대한 최소 도달비용을 추정할 때 불필요한 중복성을 배제한다. 따라서 GD 휴리스틱은 기존의 겹침 휴리스틱보다 더 적은 계산시간을 요구하면서도, 최대 휴리스틱이나 합산 휴리스틱보다 더 높은 정보력을 가진다는 장점이 있다. 본 논문에서는 GD 휴리스틱의 정확성과 탐색 효율성을 확인하기 위한 실험적 분석에 대해 설명한다.

키워드 : 조건부 계획수립, 믿음 상태 공간, 탐색 휴리스틱, 계획 그래프

## Effective Graph-Based Heuristics for Contingent Planning

Hyun-Sik Kim<sup>†</sup> · In-Cheol Kim<sup>\*\*</sup> · Young-Tack Park<sup>\*\*\*</sup>

## ABSTRACT

In order to derive domain-independent heuristics from the specification of a planning problem, it is required to relax the given problem and then solve the relaxed one. In this paper, we present a new planning graph, Merged Planning Graph(MPG), and GD heuristics for solving contingent planning problems with both uncertainty about the initial state and non-deterministic action effects. The merged planning graph is an extended one to be applied to the contingent planning problems from the relaxed planning graph, which is a common means to get effective heuristics for solving the classical planning problems. In order to get heuristics for solving the contingent planning problems with sensing actions and non-deterministic actions, the new graph utilizes additionally the effect-merge relaxations of these actions as well as the traditional delete relaxations. Proceeding parallel to the forward expansion of the merged planning graph, the computation of GD heuristic excludes the unnecessary redundant cost from estimating the minimal reachability cost to achieve the overall set of goals by analyzing interdependencies among goals or subgoals. Therefore, GD heuristics have the advantage that they usually require less computation time than the overlap heuristics, but are more informative than the max and the additive heuristics. In this paper, we explain the experimental analysis to show the accuracy and the search efficiency of the GD heuristics.

Keywords : Contingent Planning, Belief State Space, Search Heuristic, Planning Graph

## 1. 서 론

많은 실세계 계획문제들은 대부분 초기 상태(initial state)

의 불확실성과 동작 효과(action effect)의 불확실성을 포함하고 있다. 초기 상태 및 동작 효과에 불확실성이 존재하면 계획 실행 단계에서 에이전트가 놓이게 될 상태를 미리 명확하게 예측할 수 없어, 목표 달성을 보장하는 계획 수립에 큰 어려움이 주어진다. 이러한 불확실성에 대응하기 위해 계획에 감지 동작들(sensing actions)을 포함시키고, 계획수립 단계에서 감지 동작의 가능한 모든 실행결과들을 미리 예상하여 어떠한 경우에도 목표에 도달 가능한 해 계획

※ 본 논문은 지식경제부 산업원천기술개발사업(10035348, 모바일 플랫폼 기반 계획 및 학습 인지 모델 프레임워크 기술 개발)의 지원으로 수행되었음.

† 준 회원 : 경기대학교 컴퓨터과학과 박사후과정 연구원

\*\* 중신회원 : 경기대학교 컴퓨터과학과 교수(교신저자)

\*\*\* 정 회원 : 숭실대학교 컴퓨터학부 교수

논문접수 : 2010년 11월 29일

심사완료 : 2010년 12월 16일

(solution plan)을 구하는 문제를 일반적으로 조건부 계획문제(conditional / contingent planning problem)라 부른다. 그리고 이러한 조건부 계획문제에 대한 해는 믿음 상태 공간(belief state space) 상의 탐색을 통해 도출 가능하다. 하지만 대부분의 경우 조건부 계획수립을 위한 믿음 상태 공간은 고전적 계획수립을 위한 상태 공간(state space)에 비해 폭발적으로 큰 크기를 가진다. 따라서 조건부 계획문제의 현실적인 해결을 위해서는 믿음 상태 공간상의 탐색을 매우 효율적으로 유도할 수 있는 효과적인 휴리스틱의 개발이 절대적으로 필요하다.

일반적으로 계획 문제 명세로부터 영역-독립적인 휴리스틱을 추출하기 위해서는 원래 계획문제에 대한 간략화(relaxation)와 간략화된 계획문제에 대한 해 도출(solution extraction) 과정이 요구된다. 고전적 계획문제들(classical planning problems)을 위한 상태 공간 탐색 휴리스틱 계산에 널리 이용된 간략화 방법은 각 동작의 삭제 효과(deleting effect)들을 모두 배제하여 동작들 사이의 부정적 상호작용을 배제하는 삭제 간략화(delete relaxation)이다[1, 2]. 일반적으로 삭제 간략화된 계획문제에 대한 최적 해(optimal solution)는 허용성 있는(admissible) 양질의 탐색 휴리스틱을 제공할 수 있는 것으로 알려져 있다. 하지만 고전적인 계획문제들과는 달리 초기 상태의 불확실성과 동작 효과의 불확실성을 가정하는 조건부 계획문제들의 경우, 양질의 탐색 휴리스틱을 자동으로 얻기 위해서는 다음과 같은 문제점들을 해결하여야 한다. 첫째, 고전적 계획문제를 위한 상태 공간 탐색에서는 각 개별 상태에 대한 휴리스틱 평가치가 요구되었다. 하지만, 조건부 계획문제를 위한 믿음 상태 공간 탐색에서는 하나의 상태가 아니라 상태들의 집합인 하나의 믿음 상태에 대한 휴리스틱 평가치를 구하여야 한다. 둘째, 고전적 계획문제에서 한 상태의 휴리스틱 평가치는 그 상태에서 목표 상태까지 도달거리 즉, 해 계획의 길이(length)를 의미하며, 이때 해 계획은 OR 탐색 그래프에서 하나의 해 경로(solution path)를 구성하는 동작들의 시퀀스이다. 하지만 비결정적 동작과 감지 동작들을 포함하는 하나의 조건부 계획은 단순히 단일 해 경로를 구성하는 동작들의 시퀀스가 아니라, AND-OR 탐색 그래프에서 하나의 AND 서브 그래프(subgraph)를 구성하는 동작들의 집합으로 볼 수 있다. 따라서 조건부 계획문제 풀이를 위한 믿음 상태의 휴리스틱 계산을 위해서는 여러 AND 분기가지(branch)를 포함한 해 그래프에 대한 비용 추정이 필요하다. 마지막으로, 초기 믿음 상태에서 각 개별 목표조건을 만족하는 믿음 상태까지 도달비용들을 추정할 수 있다면, 이들로부터 목표조건들 사이의 상호작용을 고려한 보다 정보력이 높은 휴리스틱을 어떻게 효율적으로 계산해낼 수 있는나 하는 문제가 남아있다.

본 논문에서는 초기 상태의 불확실성과 비-결정적 동작 효과를 모두 포함한 조건부 계획문제를 풀기 위한 새로운

융합 계획그래프(Merged Planning Graph, MPG)와 이것을 이용한 GD(Goal Dependency) 휴리스틱 계산방법을 소개한다. 융합 계획그래프는 고전적 계획문제 풀이를 위한 휴리스틱 계산에 이용되는 간략화된 계획그래프(Relaxed Planning Graph, RPG)를 조건부 계획문제에 적용할 수 있도록 확장한 자료구조이다. 융합 계획그래프에서는 감지 동작(sensing action)과 비결정적 동작(non-deterministic action)들을 포함한 조건부 계획 문제에 대한 휴리스틱을 얻기 위해, 전통적인 삭제 간략화외에도 감지 동작과 비결정적 동작들에 대한 효과-융합 간략화(effect-merge relaxation)를 추가로 이용한다. 융합 계획그래프의 계층별 전개과정과 병행적으로 진행되는 GD 휴리스틱 계산에서는 계획 그래프의 새로운 계층에서 달성되는 목표(goal) 및 부속 목표(subgoal)들 간의 상호 의존성을 분석함으로써 중복성이 배제된 목표 집합들의 최소 도달비용을 추정한다. 따라서 GD 휴리스틱 계산법은 기존의 겹침 휴리스틱(overlap heuristics)에 비해 더 적은 계산시간을 요구하면서도, 최대 휴리스틱(max heuristics)과 합산 휴리스틱(additive heuristics) 보다 더 높은 정보력을 가진다는 장점이 있다. 본 논문에서는 융합 계획그래프와 GD 휴리스틱에 대한 소개에 이어, GD 휴리스틱의 정확도와 탐색 효율성을 분석하기 위한 비교실험 결과를 설명한다.

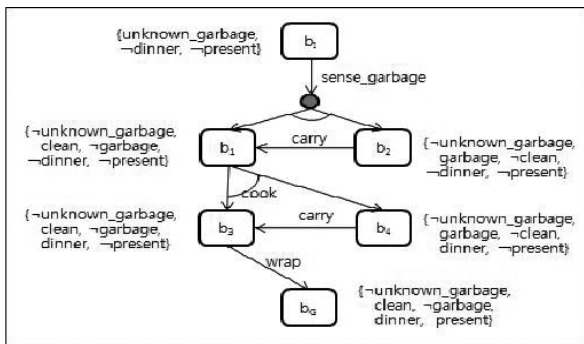
## 2. 조건부 계획문제의 표현

본 논문에서는 비결정적 동작과 감지 동작을 포함하는 조건부 계획문제를 다룬다. 조건부 계획문제의 믿음 상태를 표현하기 위한 다양한 방법들이 그동안 시도되어 왔으나, 본 논문에서는 참, 거짓을 알 수 없는 하나의 사실을 나타내기 위해 메타 술어(meta predicate)를 이용한다. 즉, 본 논문에서는 일반 술어(predicate term<sub>1</sub>, ..., term<sub>k</sub>)에 대응하는(unknown\_predicate term<sub>1</sub>, ..., term<sub>k</sub>) 형식의 메타 술어를 정의하고, 이것을 이용해 불확실한 사실들을 포함한 임의의 한 믿음 상태를 표현한다. <표 1>은 [예 1]에서 설명하는 조건부 계획문제의 초기 믿음 상태와 목표, 그리고 적용 가능한 동작들을 나타내고 있다. 초기 믿음 상태를 표현하는 메타 술어 unknown\_garbage는 치워야 할 쓰레기가 있는지 알지 못한다는 하나의 사실을 나타낸다.

[예 1] <표 1>은 남편이 아내의 생일을 맞아 아내를 위해 쓰레기를 치우고 저녁식사와 선물을 준비하는 계획 문제를 나타낸다. 남편은 쓰레기가 있는지 알지 못하는 상태에서 시작하여 저녁식사와 선물을 준비하고 쓰레기를 치우기 위한 조건부 계획을 수립하려고 한다. 동작 sense\_garbage는 쓰레기가 있는지 확인하는 감지 동작이며, 동작 cook은 저녁식사 준비를 나타내는 비결정적 동작이다. 동작 carry와 wrap은 각각 쓰레기를 치우고 선물을 포장하는 결정적 동작을 나타낸다.

〈표 1〉 조건부 계획문제의 예

$b_1 = \{unknown\_garbage, \neg dinner, \neg present\}$ $G = \{dinner, present, clean\}$		
Action	Preconditions	Effects
cook	{clean}	{dinner} {dinner, garbage, $\neg$ clean}
carry	{garbage}	{clean, $\neg$ garbage} {garbage, $\neg$ clean $\neg$ unknown\_garbage}
sense_garbage	{unknown_garbage}	{clean, $\neg$ garbage $\neg$ unknown\_garbage}
wrap	{clean}	{present}



(그림 1) 그래프 형태의 조건부 계획

[예 1]의 조건부 계획문제에 대한 해 계획은 (그림 1)과 같이 모든 AND 분기가지(branch)가 목표에 도달할 수 있는 하나의 그래프로 표현 가능하다.

### 3. 믿음 상태 공간 탐색 휴리스틱


고전적 계획문제 풀이를 위한 상태 공간상의 효과적인 탐색 휴리스틱을 얻기 위한 한 가지 방법으로서는, 그동안 삭제 간략화(delete relaxation) 방법이 폭넓게 이용되어 왔다 [1, 2]. 삭제 간략화란 STRIPS 형태로 주어진 각 동작의 명세에서 삭제 효과(deleting effect)들을 모두 배제함으로써 동작들 사이에 있을 수 있는 부정적 상호작용을 미리 제거시키는 계획문제 간략화 방법을 말한다. 삭제 간략화를 통해 각 목표조건까지 최단 도달거리를 쉽게 추정할 수 있도록 도와주는 대표적인 자료구조로 간략화된 계획그래프(relaxed planning graph)가 있다. 간략화된 계획그래프는 Graphplan[3]에서 처음 소개된 원래의 계획그래프처럼, 리터럴 층(literal layer)과 동작 층(action layer)이 교대로 펼쳐지는 하나의 계층화된 자료구조이다. 다만 원래의 계획그래프와 다른 점은 각 동작 층에 삭제 효과가 제거된 동작들만 등장할 수 있으며, 동작들 사이의 상호배제(mutex) 관계는 검사하지 않는다. 따라서 초기 리터럴 층에서 시작하여 하나의 목표 조건이 최초로 등장하는 리터럴 층까지 펼쳐지는 간략화된

계획그래프는, 임의의 한 상태 s에서 단위 목표조건 g를 만족하는 상태까지의 최단 도달거리를 추정할 수 있는 충분한 정보를 제공한다.

삭제 간략화를 이용하는 간략화된 계획그래프는 고전적 계획문제 풀이를 위한 상태 공간 탐색에는 매우 효과적인 휴리스틱을 제공할 수 있으나, 초기 상태의 불확실성과 동작 효과의 불확실성이 포함된 조건부 계획문제 풀이를 위한 믿음 상태 공간 탐색에 성공적으로 적용되기 위해서는 다음과 같은 문제점들을 해결하여야 한다. 첫째, 고전적 계획문제 풀이를 위한 상태 공간 탐색에서는 각 개별 상태에 대한 휴리스틱 평가치가 요구되었다. 하지만, 조건부 계획문제 풀이를 위한 믿음 상태 공간 탐색에서는 하나의 상태가 아니라 상태들의 집합인 하나의 믿음 상태에 대한 휴리스틱 평가치를 구하여야 한다. 이 문제는 하나의 믿음 상태를 어떻게 표현하느냐 하는 믿음 상태 표현법과도 밀접히 관련되어 있다. 믿음 상태 공간상의 탐색 휴리스틱에 관한 기존 연구들에서는 하나의 믿음 상태를 그 믿음 상태에 포함된 상태들을 모두 명시적으로 열거하는 상태 나열법(state enumeration)과 하나의 믿음 상태를 CNF, DNF, BDD 등 하나의 복합 논리식(complex logic formula)으로 표현하는 방법, 하나의 믿음 상태를 unknown 메타술어를 포함한 리터럴들의 집합으로 표현하는 방법 등 다양한 방법들이 제시되었다. 상태 나열법을 이용하는 대표적인 조건부 계획기로는 GPT[5, 6]가 있으며, 믿음 상태를 하나의 CNF로 표현하는 조건부 계획기는 Contingent-FF[7], 하나의 BDD로 표현하는 조건부 계획기로는 POND[4]와 MBP[8], unknown 메타술어를 이용하는 조건부 계획기로는 PKS[9], P4J-CP[10] 등이 있다.


(그림 2)는 믿음 상태들 간의 거리 계산을 나타내고 있다. (그림 2)의 (a)는 믿음 상태  $b_i, b_{i+1}, b_{i+2}$  각각에 포함된 실제 상태들을 고려하여 (그림 2)의 (b)에 나타난 것과 같이 믿음 상태  $b_i$ 와  $b_{i+1}$  간의 거리  $d'(b_i, b_{i+1})$ , 믿음 상태  $b_i$ 와  $b_{i+2}$  간의 거리  $d'(b_i, b_{i+2})$ 를 각각 계산하는데 포함되는 상태들 간의 거리 계산과정을 나타내고 있다. 예컨대, 믿음 상태  $b_i$ 와  $b_{i+1}$  간의 거리  $d'(b_i, b_{i+1})$ 는 두 믿음 상태에 포함된 상태들 간의 거리인  $d(s_{11}, s_{21}), d(s_{11}, s_{22}), d(s_{12}, s_{21}), d(s_{12}, s_{22})$  등을 결합함으로써 구할 수 있다. 가능한 결합방식으로는 상태들 간의 거리값(state-to-state distance) 중 임의값(random), 최소값(min), 혹은 최대값(max)을 선택하거나, 이들의 전체 혹은 부분적인 합산값(sum)을 구할 수도 있다. 기존의 연구들 중 GPT[5, 6]에서는 (그림 2)와 같은 하나의 믿음 상태  $b_i$ 에 대한 휴리스틱 평가치를 계산할 때 믿음 상태  $b_i$ 에 포함된 상태  $s_{11}$ 과  $s_{12}$ 에서 각각 출발하여 단위 목표 g까지 최단 도달거리들인  $d(s_{11}, g)$ 와  $d(s_{12}, g)$ 를 구한 다음, 이들의 최소값을 믿음 상태  $b_i$ 에서 단위 목표 g까지 도달거리  $d'(b_i, g)$ 에 대한 추정치로 삼는 방식을 채택하였다. 간략화된 계획그래프를 이용하는 POND[4]에서는 믿음 상태  $b_i$

에 포함된 상태  $s_{11}$ 과  $s_{12}$  각각에 대해 목표까지 별도의 간략화된 계획그래프를 전개하는 복수 계획그래프(multiple planning graphs) 생성방식과 레이블(label)을 부착한 하나의 통합 계획그래프인 LUG(Labeled Uncertainty Graph)를 이용하는 방식 등을 시도하였다.



(그림 2) 믿음 상태들 간의 거리 계산

조건부 계획문제 풀이를 위한 믿음 상태 공간상의 탐색 휴리스틱을 얻기 위해 해결해야 할 두 번째 문제점은, 비결정적 동작과 감지 동작들을 포함하는 하나의 조건부 계획은 단순히 OR 탐색 그래프 위에서 단일 해 경로를 구성하는 동작들의 시퀀스가 아니라 AND-OR 탐색 그래프에 포함된 하나의 AND 서브 그래프(subgraph)를 구성하는 동작들의 집합으로 볼 수 있다. 따라서 조건부 계획문제 풀이를 위한 믿음 상태의 휴리스틱 평가를 위해서는 여러 AND 분기가지들을 포함한 해 그래프에 대한 비용 추정이 필요하다.



(그림 3) 일반 동작 및 감지 동작에 의한 믿음 상태 전이

(그림 3)은 조건부 계획 수립을 위한 믿음 상태 공간상의 탐색과정 중 일반 동작 및 감지 동작에 의한 믿음 상태 전이를 나타내고 있다. (그림 3)의 (a)는 한 믿음 상태  $b_i$ 에서 결정적 혹은 비결정적 일반 동작  $a_1$  또는  $a_2$ 가 실행되면, 그 결과로 각기 다른 하나의 믿음 상태  $b_{i+1}$  또는  $b_{i+2}$ 로 전이됨을 표현하고 있다. 반면에, (그림 3)의 (b)는 믿음 상태  $b_i$ 에서 하나의 감지 동작  $sense\_A$ 가 수행되었을 때, 그 결과로 두 가지 서로 다른 믿음 상태  $b_{i+1}$  또는  $b_{i+2}$ 로 전이됨을 표현하고 있다. 이때  $sense\_A+$ 는 감지 동작  $sense\_A$ 를 실행한 결과 unknown이었던 하나의 사실  $A$ 가 참으로 확인된 경우를,  $sense\_A-$ 는 거짓으로 확인된 경우를 각각 나타

낸다. 따라서 (그림 3)을 통해 조건부 계획수립을 위한 믿음 상태 공간상의 탐색과정은 초기 믿음 상태에서 출발하여 일반 동작이나 감지 동작들 중 하나를 선택하는 OR 분기와 감지 동작의 서로 다른 실행결과를 나타내는 AND 분기들로 이루어진 AND-OR 그래프 탐색 과정임을 이해할 수 있다. 따라서 한 믿음 상태에 대한 휴리스틱 평가치를 계산할 때, 그 믿음 상태가 AND-OR 탐색 그래프상의 OR 노드인지, 아니면 AND 노드인지에 따라 목표 도달비용에 대한 추정방법이 달라질 수 있다. 기존의 계획기들 중 GPT[6], POND[4], Contingent-FF[7] 등은 AND 분기가지들의 목표 도달비용 중 최소값을 AND 노드 믿음 상태의 휴리스틱 평가치로 채택하고 있으나, 대부분의 MDP 계획기 혹은 확률 계획기들에서는 각 AND 분기가지의 발생 확률과 목표 도달비용을 기초로 계산된 평균값을 휴리스틱 평가치로 채택하고 있다.

믿음 상태 공간상의 효과적인 탐색 휴리스틱을 얻기 위해 고려해야 할 또 다른 문제점은, 초기 믿음 상태에서 각 개별 목표조건을 만족하는 믿음 상태까지 도달비용들을 추정할 수 있다면, 이들로부터 보다 정보력이 높은 휴리스틱을 어떻게 효율적으로 계산해낼 수 있느냐 하는 것이다. 이 문제점을 해결하기 위해 고전적 계획 문제 휴리스틱 계산에 이용된 최대 휴리스틱(max heuristic)과 합산 휴리스틱(additive heuristic) 방식을 이용할 수도 있다. 하지만 각 목표조건 도달비용들의 최대값 혹은 합산값을 목표집합 전체의 최소 도달비용으로 삼는 최대 휴리스틱과 합산 휴리스틱은 비교적 휴리스틱 계산이 쉽고 간편하지만, 휴리스틱의 정보력이 너무 낮다는 공통점이 있다. 반면에 목표집합 전체의 최소 도달비용을 추정하기 위해 완전한 하나의 간략화된 해 계획을 구해내는 겹침 휴리스틱(overlap heuristic)은 휴리스틱의 정보력은 비교적 높으나, 휴리스틱 계산을 위해 너무 많은 노력이 요구된다는 단점이 있다. 따라서 목표조건들 사이의 상호의존성을 보다 효율적으로 분석하여 겹침 휴리스틱보다 적은 계산노력으로도 정보력이 높은 휴리스틱을 얻을 수 있는 방법에 대한 연구가 필요하다.

#### 4. 융합 계획그래프 기반의 탐색 휴리스틱

##### 4.1 융합 계획그래프

일반적으로 초기 상태의 불확실성과 동작효과의 비결정성이 포함된 하나의 조건부 계획문제  $P_{pond} = (b_i, G, O_d \cup O_{nd} \cup O_s)$ 는 초기 믿음 상태  $b_i$  와 목표  $G$ , 그리고 동작들의 집합  $O_d \cup O_{nd} \cup O_s$  으로 주어진다. 이때  $O_d$ 는 결정적 일반 동작들(deterministic effective operators)의 집합을,  $O_{nd}$ 는 비결정적 일반 동작들(non-deterministic effective operators)의 집합을,  $O_s$ 는 감지 동작들(sensing operators)의 집합을 각각 나타낸다. 하나의 비결정적 동작은 실행 결과로 여러

가지 효과를 가질 수 있다. 또, 하나의 미확인 사실에 대한 감지 동작은 그 사실의 참, 거짓을 각각 효과로 가진다고 볼 수 있다. 따라서 하나의 비결정적 동작(non-deterministic operator)  $O_{nd}$ 는 하나의 전-조건 집합  $pre(O_{nd})$ 과  $k$  개의 서로 다른 효과 집합들  $effect_j(O_{nd}), j = 1, \dots, k$  로 표현된다. 또한, 하나의 사실  $f$ 의 참, 거짓 여부를 판별하는 감지 동작(sensing operator)  $O_{s_f}$ 는  $unknown_f$ 를 포함하는 전-조건 집합  $pre(O_{s_f})$  과 2개의 서로 다른 효과 집합들  $effect_1(O_{s_f})=\{f, \neg unknown_f\}, effect_2(O_{s_f})=\{\neg f, \neg unknown_f\}$ 로 표현된다. 본래 결정적 동작들만을 포함하는 고전적 계획문제를 위한 (간략화된) 계획그래프를 비결정적 동작과 감지 동작을 포함하는 조건부 계획문제에 적용하기 위해서는 비결정적 동작들과 감지 동작에 대한 간략화가 요구된다. 기존 연구들에서는 비결정적 동작을 위한 간략화 방법으로 하나의 비결정적 동작을 다수의 결정적 동작들로 나누는 효과-결정화(effect-determinization) 방법을 이용하였으나, 본 논문에서는 새로운 간략화 방법인 효과-융합(effect-merge) 방법을 제안한다.

- 비결정적 동작(non-deterministic action)의 효과-융합:  $k$  개의 서로 다른 효과 집합들  $effect_j(O_{nd}), j = 1, \dots, k$  을 갖는 하나의 비결정적 동작  $O_{nd}$ 을 단하나의 효과집합  $effect(O_{nd\_merge}) = \bigcup_{j=1, \dots, k} effect_j(O_{nd})$ 을 갖는 결정적 동작  $O_{nd\_merge}$ 으로 변환하는 것을 비결정적 동작  $O_{nd}$ 에 대한 효과-융합이라 한다. 또, 이러한 동작  $O_{nd\_merge}$ 를 효과-융합된 비결정적 동작이라 부른다.
- 감지 동작(sensing action)의 효과 융합: 2개의 서로 다른 효과 집합들  $effect_1(O_{s_f})=\{f\}, effect_2(O_{s_f})=\{\neg f\}$ 을 갖는 하나의 감지 동작  $O_{s_f}$ 을 단하나의 효과집합  $effect(O_{s\_f\_merge}) = effect_1(O_{s_f}) \cup effect_2(O_{s_f}) = \{f, \neg f, \neg unknown_f\}$ 을 갖는 결정적 동작  $O_{s\_f\_merge}$ 으로 변환하는 것을 감지 동작  $O_{s_f}$ 에 대한 효과-융합이라 한다. 또, 이러한 동작  $O_{s\_f\_merge}$ 를 효과-융합된 감지 동작이라 부른다.

위에서 정의한 효과-융합 간략화를 이용하면, 계획문제를 구성하는 비결정적 동작들과 감지 동작들은 모두 하나의 전-조건 집합과 하나의 효과 집합만을 갖는 효과-융합된 비결정적 동작들과 감지 동작들로 변환 가능하다. 본 논문에서는 조건부 계획문제 풀이를 위한 효과적인 휴리스틱 계산을 위해 비결정적 동작과 감지 동작을 포함할 수 있도록 효과-융합 간략화를 이용한 새로운 계획그래프를 정의한다. 휴리스틱 계산을 위한 기존의 간략화된 계획그래프에서는 단지 삭제 간략화된 결정적 동작들만을 이용하여 계획그래프를 전개하였다. 하지만 새로 정의되는 계획그래프에서는 조건부 계획문제에 포함된 본래의 비결정적 동작과 감지 동작 대신 효과-융합된 비결정적 동작과 감지 동작을 이용하여

계획그래프를 전개한다. 따라서 이 융합 계획그래프(Merged Planning Graph, MPG)는 효과-융합 간략화와 삭제 간략화를 함께 적용하는 새로운 자료구조로 볼 수 있다.

- 융합 계획그래프(Merged Planning Graph): 조건부 계획문제  $P_{pond} = (b_i, G, O_d \cup O_{nd} \cup O_s)$ 를 풀기 위한 믿음 상태 공간상의 한 믿음 상태  $b_m$ 에 대한 융합 계획그래프  $MPG(b_m)$ 는 아래와 같은 조건들을 만족하는 리터럴 층(literal layer)과 동작 층(action layer)들로 구성된다.
  - 0번째 리터럴 층, 즉, 초기 리터럴 층  $L_0$ 은 믿음 상태  $b_m$ 를 나타내는 리터럴들의 집합으로 구성된다. 따라서 초기 리터럴 층  $L_0$ 에는 믿음 상태  $b_m$ 의 불확실한 사실을 표현하는데 쓰이는  $unknown$  메타 리터럴들이 포함될 수 있다.
  - $k$ 번째 동작 층  $A_k$ 는  $k$ 번째 리터럴 층  $L_k$ 에 의해 전-조건들이 만족되는 모든 동작  $o \in O_d \cup O_{nd\_merge} \cup O_s\_merge$ 들과 리터럴 유지동작(literal persistence)들로 구성된다. 이때, 동작들의 집합  $O_{nd\_merge}$ 와  $O_s\_merge$ 는 집합  $O_{nd}$ 와  $O_s$ 에서 얻어진 효과-융합된 비결정적 동작들의 집합과 효과-융합된 감지 동작들의 집합을 각각 의미한다.
  - $k+1$ 번째 리터럴 층  $L_{k+1}$ 은 리터럴 층  $L_k$ 에 속한 리터럴들과 동작 층  $A_k$ 에 속한 각 동작의 삭제 간략화된 효과를 나타내는 리터럴들로 구성된다.
  - $k+1$ 번째 리터럴 층인  $L_{k+1}$ 가 목표조건  $G$ 에 속한 모든 리터럴들을 포함하거나  $k$ 번째 리터럴 층인  $L_k$ 와 동일하다면, 이 리터럴 층이 융합 계획그래프의 마지막 층이 된다.

이와 같은 융합 계획그래프는 하나의 믿음 상태에 포함된 모든 상태들을 열거하고 이들 각각을 초기 리터럴 층으로 삼아 다수의 독립된 계획그래프들을 확장하는 종래의 방식들과는 달리,  $unknown$  메타 리터럴들을 포함하는 하나의 초기 리터럴 층에서 시작하여 단일 계획그래프를 확장한다. 또한, 새로운 효과-융합 간략화를 이용함으로써, 비결정적 동작이나 감지 동작들로 인한 계획그래프의 분기가지 생성과 분기가지들 사이의 복잡한 상호작용에 대한 분석을 피할 수 있다.

#### 4.2 휴리스틱 계산 알고리즘

앞서 소개한 융합 계획그래프를 이용하여 하나의 믿음 상태에 대한 휴리스틱 평가치를 계산하는 방법을 설명한다. 주어진 믿음 상태에 대응하는 하나의 초기 리터럴 층에서 시작하여 목표조건들이 모두 만족되는 마지막 리터럴 층까지 전개된 융합 계획그래프는 각 개별 목표조건들이 최초로 만족되는 리터럴 층과 이들을 위한 지지동작(supporting action)들을 포함하고 있어, 각 개별 목표조건에 대한 최소 도달비용을 추정할 수 있다. 따라서 융합 계획그래프를 이

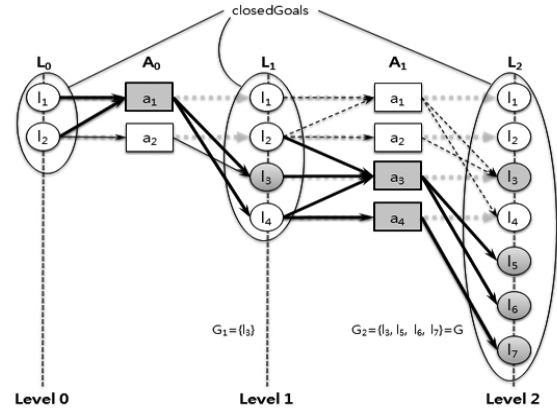
용한 휴리스틱 평가치 계산법은 이 개별 목표조건들의 최소 도달비용 추정치들을 기초로 어떻게 목표 집합 전체에 대한 최소 도달비용을 추정할 것이냐 하는 방법을 의미한다. 개별 목표조건들 간의 독립성 혹은 종속성에 대한 가정에 따라 다양한 추정방법이 제안될 수 있다. 본 연구의 목표는 목표조건들 간에 잠재되어 있는 긍정적 상호작용을 보다 효율적으로 분석하여 정확도가 높은 휴리스틱 추정치를 계산하는 것이다.

앞서 소개한 종래의 최대(max), 합산(additive), 겹침(overlap) 휴리스틱 계산방법들은 모두 계획그래프 전개가 완전히 완료된 후 별도로 진행되는 계산과정을 요구하지만, 본 논문에서 제안하는 휴리스틱 계산법은 융합 계획그래프의 계층별 전개과정과 함께 진행되어, 융합 계획그래프의 전개가 끝남과 동시에 계산이 완료됨으로써 계산과정이 매우 효율적이다. 이 휴리스틱 계산방법은 융합 계획그래프가 단계적으로 전개될 때마다 새로운 리터럴 층  $L_k$ 에 등장하는 목표 리터럴들의 집합  $G_k \subset G$ 을 찾아내고, 현재 믿음 상태에서 목표 리터럴들의 집합  $G_k$ 에 도달하기 위한 최소 도달비용을 추정하여 계층별로 누적 합산해가는 방식으로 진행된다. 집합  $G_k$ 의 최소 도달비용을 효과적으로 추정하기 위해서는, 집합  $G_k$ 에 포함된 각 개별 목표를 위한 이전 계층의 부속 목표(subgoal)나 부분 계획(subplan) 사이의 중복이나 겹침 현상을 분석해낼 수 있어야 한다. 이것을 위해 본 논문의 GD(Goal Dependency) 휴리스틱 계산방법에서는 융합 계획그래프를 단계적으로 전개하면서 이전의 동작 층  $A_{k-1}$ 에서 계획의 일부로 선택된 동작들이 새로운 리터럴 층  $L_k$ 에서 어떤 목표나 부속 목표들을 추가적으로 달성하였는지 별도의 자료구조(closedGoals)에 기록해간다.

(그림 4)는 목표 집합이  $G = \{l_3, l_5, l_6, l_7\}$ 로 주어진 조건부 계획문제에서, 한 믿음 상태  $b_m$ 의 GD 휴리스틱을 계산하기 위한 융합 계획그래프의 확장과정과 목표 리터럴 도달비용 계산과정의 일부를 나타내고 있다. 0번째 리터럴 층  $L_0$ 와 집합 closedGoals는 초기 믿음 상태를 표현하는 리터럴들의 집합  $\{l_1, l_2\}$ 와 동일하다. 융합 계획그래프가 새로운 리터럴 층인  $L_1$ 까지 전개되면,  $L_1$ 에 등장하는 목표들의 집합  $G_1$ 에는 리터럴  $l_3$ 가 포함되는 것을 알 수 있다. 일반적으로 새로운 계층의 목표 집합  $G_k$ 의 최소 도달비용은 식 (1)과 같이  $G_k$ 에 포함된 각 목표 리터럴  $g$ 의 최소 도달비용의 합과 같다.

$$cost_{bm}(G_k) = \sum_{g \in G_k} cost_{bm}(g) \tag{1}$$

따라서 믿음 상태  $b_m$ 에서 목표 집합  $G_1$ 까지 최소 도달비용  $cost_{bm}(G_1)$ 은 단위 목표 리터럴인  $l_3$ 까지 최소 도달비용과 같다. 단위 목표 리터럴  $l_3$ 까지 최소 도달비용은 아래의 식 (2)와 같이 0번째 동작 층에 속한 동작 중  $l_3$ 를 효과(effect)



(그림 4) 융합 계획그래프를 이용한 목표 도달비용 추정

로 갖는 동작  $o$ 의 비용과 전-조건 집합  $pre(o)$ 의 비용을 합산하여 추정할 수 있다.

$$cost_{bm}(g) = \min \{ cost(o) + cost_{bm}(pre(o)) \mid g \in effect(o) \text{ and } o \in A_{k-1} \}, \text{ for each } g \in G_k \tag{2}$$

(그림 4)의 경우, 목표 리터럴  $l_3$ 를 위한 동작  $a_1$ 의 전-조건들  $\{l_1, l_2\}$ 은 이미 달성된 목표들의 집합 closedGoals에 포함되어 있으므로, 별도의 비용이 필요치 않은 것으로 판단하여 전-조건 집합의 도달비용은  $cost_{bm}(pre(a_1)) = 0$ 가 된다. 따라서 이 경우, 믿음 상태  $b_m$ 에서 목표 집합  $G_1$ 까지 최소 도달비용  $cost_{bm}(G_1)$ 은 단순히 동작  $a_1$ 의 실행비용인  $cost(a_1)$ 과 같다. 그리고 이미 달성된 목표들의 집합 closedGoals에는 동작  $a_1$ 의 효과로 새롭게  $L_1$  계층에서 만족되는 목표 리터럴  $l_3$ 뿐만 아니라 리터럴  $l_4$ 도 함께 추가된다.

융합 계획그래프가  $L_2$  계층까지 전개되었다고 가정해보자. 이때 이 계층의 목표 집합  $G_2$ 의 최소 도달비용은 이미  $L_1$  계층에서 달성되어 집합 closedGoals에 포함되어 있는  $l_3$ 를 제외한 리터럴들  $l_5, l_6, l_7$  각각의 최소 도달비용의 합으로 볼 수 있다. 즉,  $cost_{bm}(G_2) = cost_{bm}(\{l_5, l_6, l_7\}) = cost_{bm}(l_5) + cost_{bm}(l_6) + cost_{bm}(l_7)$  하지만 리터럴  $l_5$ 와  $l_6$ 는 동일 동작  $a_3$ 의 실행으로 동시에 달성 가능한 목표들이므로, GD 휴리스틱 계산에서는 두 목표 리터럴들의 최소 도달비용은 어느 한쪽의 도달비용과 동일한 것으로 간주한다. 즉,  $cost_{bm}(\{l_5, l_6\}) = cost_{bm}(l_5) = cost_{bm}(l_6)$ 이다. 다만, 이 경우 동작  $a_3$ 의 전-조건들  $pre(a_3)$  중 일부인  $l_3$ 와  $l_4$ 만 closedGoals에 포함되어 있는 상태여서, 전-조건들의 집합  $pre(a_3)$ 의 최소 도달비용은 별도로 추정하여야 한다. GD 휴리스틱에서는 이와 같이 동작의 전-조건들이 이미 달성된 목표들의 집합에 포함되어 있지 않은 경우, 이 전-조건들의 최소 도달비용을 현재까지 각 전-조건들이 달성되는 계층의 레벨 중 최대치(max)로 대신한다. 따라서 목표 리터럴  $l_5$  및  $l_6$ 의 도달비용은 아래와 같이 계산된다.

$$\begin{aligned} \text{cost}_{\text{bm}}(l_5) &= \text{cost}_{\text{bm}}(l_6) = \text{cost}(a_3) + \text{cost}(\text{pre}(a_3)) \\ &= \text{cost}(a_3) + \text{max\_level}(\text{pre}(a_3)) \end{aligned}$$

(그림 4)의 경우, 전-조건들  $\text{pre}(a_3)=\{l_2, l_3, l_4\}$ 의 최소 도달비용은  $l_3$ 와  $l_4$ 가 만족되는 계층의 레벨치인 1이 된다. 한편, 동작  $a_4$ 의 전-조건인  $l_4$ 는 이미  $\text{closedGoals}$ 에 포함되어 있으므로 목표 리터럴  $l_7$ 의 최소 도달비용에는 단순히 동작  $a_4$ 의 실행비용만을 포함된다. 즉,  $\text{cost}_{\text{bm}}(l_7) = \text{cost}(a_4) + \text{cost}(\text{pre}(a_4)) = \text{cost}(a_4)$ 이다. 한편, 집합  $\text{closedGoals}$ 에는 동작  $a_3$ 와  $a_4$ 의 효과들인  $l_5, l_6, l_7$  등이 신규로 추가된다.

융합 계획그래프의 현재 계층의 목표 집합인  $G_2$ 는 최종 목표 집합  $G=\{l_3, l_5, l_6, l_7\}$ 과 같다. 따라서 융합 계획그래프는 더 이상 전개를 계속할 필요가 없고, 앞서 계산한 목표 집합  $G_1$ 의 최소 도달비용에 새로 계산되는 목표 집합  $G_2$ 의 최소 도달비용의 합이 최종적으로 믿음 상태  $b_m$ 의 GD 휴리스틱 값이 된다. 즉,  $h_{\text{GD}}(b_m) = \text{cost}_{\text{bm}}(G_1) + \text{cost}_{\text{bm}}(G_2)$ 이다. 일반적으로 한 믿음 상태  $b_m$ 에 대한 GD 휴리스틱 평가치는 식 (3)과 같이  $b_m$ 을 기초로 전개되는 융합 계획그래프의 각 계층 목표 집합  $G_k$ 의 최소 도달비용의 누적 합산으로 계산된다.

$$h_{\text{GD}}(b_m) = \sum_{k=0}^n \text{cost}_{\text{bm}}(G_k) \quad (3)$$

〈표 2〉 GD 휴리스틱 계산 알고리즘

1.	GD_Heuristics(bm, G, O)
2.	/* $b_m$ : a belief state, $G$ : the set of goals
3.	$O$ : the set of effect-merged actions, i.e.
4.	$O = O_d \cup O_{nd\_merge} \cup O_s\_merge$ */
5.	Begin
6.	total_cost = 0;
7.	$L_0 = \text{closedGoals} = b_m$ ;
8.	k = 1;
9.	while ( $G \not\subset L_{k-1}$ ) {
10.	$(A_{k-1}, L_k) = \text{MPG\_Expand\_Level}(L_{k-1}, O)$ ;
11.	$G_k = \text{Find\_Goals}(L_k, G)$ ;
12.	(goal_cost, closedGoals) =
13.	Estimate_Cost( $G_k, A_{k-1}, \text{closedGoals}$ );
14.	total_cost += goal_cost;
15.	k = k + 1;
16.	}
17.	return total_cost;
18.	end

〈표 2〉는 조건부 계획문제  $P_{\text{pond}} = (b_i, G, O_d \cup O_{nd} \cup O_s)$ 를 풀기 위한 한 믿음 상태  $b_m$ 에 대한 GD 휴리스틱 계산 알고리즘을 나타내고 있다. 이 알고리즘은 목표 집합  $G$ 와 효과-융합된 동작들(effect-merged actions)의 집합  $O$ 를 기초로 새로운 리터럴 계층  $L_k$ 에 목표 집합  $G$ 가 모두 포함될 때까지 융합 계획그래프를 한 레벨 더 확장하고(MPG\_Expand\_Level), 새로운 계층의 목표 집합  $G_k$ 를 결정한 뒤

〈표 3〉 Estimate\_Cost 함수

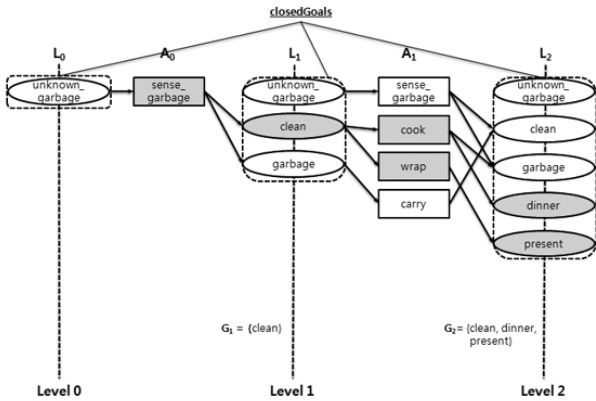
1.	Estimate_Cost( $G_k, A_{k-1}, \text{closedGoals}$ )
2.	Begin
3.	goal_cost = 0;
4.	For each $g \in G_k$ s.t. $g \notin \text{closedGoals}$ do
5.	Select an action $o$ from $A_{k-1}$ s.t. $g \in \text{effect}(o)$ ;
6.	If $\text{pre}(o) \subset \text{closedGoals}$ then
7.	goal_cost += cost(o);
8.	else
9.	goal_cost += cost(o) + max_level(pre(o));
10.	closedGoals = closedGoals $\cup$ effect(o);
11.	End
12.	Return (goal_cost, closedGoals);
13.	End

(Find\_Goals), 목표 집합  $G_k$ 의 최소 도달비용 goal\_cost를 구해(Estimate\_Cost) 누적 합산하는 단계들로 이루어져 있다(〈표 2〉의 line 9~16). 이렇게 계산된 계층별 목표 집합들의 최소 도달비용의 누적 합산치가 믿음 상태  $b_m$ 의 최종 GD 휴리스틱 평가치가 된다(〈표 2〉의 line 17). 한편, 달성된 목표들의 집합을 나타내는 closedGoals는 처음에 믿음 상태  $b_m$ 의 리터럴들로 초기화한 후(〈표 2〉의 line 7), 함수 Estimate\_Cost에 의해 새로 달성된 목표들이 추가됨으로써 지속적으로 확장된다(〈표 2〉의 line 12~13).

〈표 3〉은 GD 휴리스틱 계산에 사용되는 Estimate\_Cost 함수를 기술하고 있다. Estimate\_Cost 함수는 새로운 계층의 목표 집합  $G_k$ 에 포함된 목표들 중 이미 closedGoals에 포함되어 있지 않은 각 목표  $g$ 에 대해,  $g$ 를 효과로 갖는 동작  $o$ 를 선택하고 동작  $o$ 의 실행비용 cost(o)와 동작  $o$ 의 전-조건 집합 pre(o)의 도달비용 cost(pre(o))의 합으로 목표  $g$ 의 최소 도달비용 goal\_cost를 계산한다(〈표 3〉의 line 4~11). 이때, 전-조건 집합 pre(o)가 모두 closedGoals에 이미 포함되어 있으면 cost(pre(o)) = 0로 계산하고(〈표 3〉의 line 6~7), 그렇지 않으면 cost(pre(o))는 전-조건들이 등장하는 최대 레벨치(max\_level(pre(o)))가 된다(〈표 3〉의 line 8~9). 선택된 동작  $o$ 의 모든 효과들은 새로 달성된 목표 또는 부속 목표들로서 closedGoals에 추가된다(〈표 3〉의 line 10).

(그림 5)는 앞서 소개한 [예 1]의 조건부 계획문제 풀이를 위한 초기 믿음 상태  $b_i$ 에 대한 융합 계획그래프 전개과정과 GD 휴리스틱 계산과정을 자세히 나타내고 있다.

융합 계획그래프에 기초한 GD 휴리스틱 계산법은 계획 그래프의 새로운 계층에서 달성되는 목표(goal) 및 부속 목표(subgoal)들 간의 상호 의존성을 분석함으로써 중복성이 배제된 목표 집합들의 최소 도달비용을 추정할 수 있다. 따라서 이러한 GD 휴리스틱 계산법의 특성으로 인해 각 개별 목표들 사이의 완전 중복성 혹은 완전 독립성을 가정하는 최대 휴리스틱 계산법이나 합산 휴리스틱 계산법에 비해 일반적으로 정확성이 더 높은 휴리스틱 평가치를 도출할 수 있다.



(그림 5) [예 1]의 초기 믿음 상태  $b_0$ 에 대한 GD 휴리스틱 계산

### 5. 실험 및 평가

본 논문에서 제안한 GD 휴리스틱의 정확성과 탐색 효율성, 그리고 휴리스틱 계산 효율성을 분석하기 위해, 몇 가지 서로 다른 계획문제 도메인을 이용한 비교 실험을 전개하였다. GD 휴리스틱과 비교하는 다른 휴리스틱들로는 앞서 소개한 최대 휴리스틱(max heuristic), 합산 휴리스틱(additive heuristic), 겹침 휴리스틱(overlap heuristic) 등이다. 본래 고전적 계획문제 풀이를 위해 간략화된 계획그래프를 이용하는 이 휴리스틱들을 비결정적 동작과 감지 동작을 포함한 조건부 계획문제 풀이에 적용하기 위해 본 논문에서 제안한 융합 계획그래프를 이용하도록 확장하였다. 실험에는 로봇 도메인(robot domain), 블록 도메인(blocks domain), 그리고 저녁준비 도메인(dinner domain), 트럭 도메인(truck domain) 등 4 가지 서로 다른 도메인에서 임의로 생성한 총 15개의 계획문제들을 이용하였다. 저녁준비 도메인은 앞서 [예 1]에서 이미 소개한 바와 같고, 로봇 도메인은 여러 개의 방들로 구성된 가정환경에서 로봇이 방과 방 사이를 옮겨 다니며 짐을 나르는 계획 문제 도메인으로서, 방 사이에 놓인 문의 개폐여부를 확인하는 감지 동작인 sense-door-open, 짐을 집어 들고 나르는 비결정적 동작인 carry, 짐을 내려놓는 결정적 동작인 putdown, 로봇 혼자 이동하는 결정적 동작인 move 등을 포함한다. 블록 도메인은 블록 쌓기 도메인으로도 불리며, 두 블록간의 위치 관계를 확인하는 감지 동작인 sense-on-block, 블록을 집어 드는 비결정적 동작들인 pickup과 pickup-table, 그리고 블록을 내려놓는 결정적 동작들인 putdown과 putdown-table 등을 포함한다. 트럭 도메인은 트럭이 도시들을 연결하는 도로를 따라 도시에서 도시로 화물을 배달하는 계획 문제 도메인으로서, 도시간의 도로 연결 여부를 확인하는 감지 동작인 sense-connect, 트럭에 화물을 싣는 비결정적 동작인 load, 화물을 내려놓는 결정적 동작인 unload, 트럭이 두 도시 사이를 이동하는 결정적 동작인 move 등을 포함한다. 또한,

<표 4> 휴리스틱 정확성 비교: 최소도달비용과 휴리스틱 평가치


계획문제 휴리스틱	로봇 도메인					블록 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
최소 도달비용	5	6	8	9	11	3	5	7	10	14
최대 휴리스틱	3	4	7	5	8	3	3	4	3	4
합산 휴리스틱	7	9	16	13	20	8	10	17	20	34
겹침 휴리스틱	5	6	9	8	10	5	5	8	10	16
GD 휴리스틱	5	6	10	8	13	8	9	11	18	22
계획문제 휴리스틱	저녁준비 도메인					트럭 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
최소 도달비용	4	5	6	7	8	4	6	8	9	10
최대 휴리스틱	2	2	3	4	4	3	4	5	6	7
합산 휴리스틱	7	6	9	11	14	5	9	12	14	17
겹침 휴리스틱	3	5	6	7	8	4	6	8	8	9
GD 휴리스틱	4	5	6	8	9	4	6	8	9	11

실험을 위해 선행연구를 통해 본 연구팀이 개발한 HSCP (Heuristic Search for Contingent Planning) 탐색 알고리즘을 이용하였다.

<표 4>는 GD 휴리스틱의 정확성을 알아보기 위한 실험의 결과로서, 각 문제의 초기 믿음 상태에서 목표까지 실제 최소 도달비용과 이것을 추정한 각 휴리스틱 평가치들을 비교하고 있다. 목표까지 실제 최소 도달비용과의 차이를 비교해보면, GD 휴리스틱 평가치가 최대 휴리스틱과 합산 휴리스틱에 비해 상대적으로 더 정확하다는 것을 확인할 수 있다. 또, 계획그래프에 대한 전역적 분석을 통해 간략화된 계획(relaxed plan)을 계산하는 겹침 휴리스틱에 비해서도 블록 도메인을 제외하면 정확성의 큰 차이가 없다는 것을 알 수 있다. 실험에 사용된 도메인의 특성을 감안하면, 목표와 동작들 사이에 서로 중복과 겹침 현상 등 긍정적 상호작용(positive interaction)이 많은 계획문제 도메인들에서 특히 GD 휴리스틱의 정확성이 더 높은 것을 알 수 있다. 반대로 블록 도메인과 같이 목표와 동작들 사이에 부정적 상호작용이 상대적으로 더 많은 계획문제 도메인에서는 GD 휴리스틱의 정확도가 낮아지는 것을 알 수 있다. 이것은 효과-융합 간략화와 삭제 간략화 등을 통해 계획문제에 내재된 부정적 상호작용을 배제하는 GD 휴리스틱의 특성이 반영된 것으로 판단된다.

(그림 6)은 GD 휴리스틱이 탐색에 미치는 효율성을 분석하기 위한 실험의 결과로서, 탐색과정 동안 각 휴리스틱에 의해 생성된 믿음 상태 공간의 크기를 비교하고 있다. 생성된 믿음 상태의 수를 비교해 보면, GD 휴리스틱과 겹침 휴리스틱이 최대 휴리스틱이나 합산 휴리스틱에 비해 적은 수의 믿음 상태들을 생성하였음을 확인할 수 있다. 이것은 최대 휴리스틱과 합산 휴리스틱에 비해 정보력이 높은 GD 휴리스틱과 겹침 휴리스틱이 탐색을 보다 더 효율적으로 유도함으로써 문제를 쉽게 풀 수 있었음을 의미한다.





(그림 6) 탐색 효율성 비교: 생성된 믿음상태공간의 크기

<표 5> 휴리스틱 계산 효율성 비교: 생성된 부속목표조건들의 수

계획문제 휴리스틱	로봇 도메인					블록 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
겹침 휴리스틱	11	13	17	19	23	13	13	17	26	34
GD 휴리스틱	3	3	3	3	3	6	6	8	12	16

계획문제 휴리스틱	저녁준비 도메인					트럭 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
겹침 휴리스틱	8	9	14	14	18	8	12	16	16	18
GD 휴리스틱	5	4	5	4	5	3	3	3	3	3

<표 6> 휴리스틱 계산 효율성 비교: 검사한 지지 동작들의 수

계획문제 휴리스틱	로봇 도메인					블록 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
겹침 휴리스틱	5	6	8	9	11	8	12	14	24	28
GD 휴리스틱	3	3	3	3	3	4	6	8	12	16

계획문제 휴리스틱	저녁준비 도메인					트럭 도메인				
	p1	p2	p3	p4	p5	p1	p2	p3	p4	p5
겹침 휴리스틱	6	6	10	10	13	4	6	8	8	9
GD 휴리스틱	5	4	5	4	5	3	3	3	3	3

일단 융합 계획그래프의 확장이 완료되고 나면, 최대 휴리스틱과 합산 휴리스틱은 각 목표조건이 만족되는 최초의 리터럴층 레벨값을 알아내는 것 이외에는 특별히 추가적인 계산을 요구하지 않는 반면, 이들에 비해 정보력이 높은 겹침 휴리스틱과 GD 휴리스틱은 확장된 융합 그래프위에서 목표조건들과 이들을 만족시켜줄 수 있는 지지 동작들 (supporting actions)들에 대한 상호 작용 분석 작업을 요구한다. 따라서 본 논문에서는 겹침 휴리스틱과 GD 휴리스틱에 한하여 휴리스틱 계산 효율성을 비교하여 보았다. <표 5>와 <표 6>은 각 실험문제의 초기상태에 대한 휴리스틱 계산과정동안 생성된 부속목표조건들의 수와 이 조건들을 달성할 수 있는 지지 동작들의 검사 횟수를 각각 비교하고 있다. 우리는 <표 5>와 <표 6>을 통해 융합 계획그래프 위에서 하나의 완전한 해 계획을 도출하여야 하는 겹침 휴리

스틱이 GD 휴리스틱에 비해 훨씬 더 많은 부속목표조건들의 검사와 지지 동작들에 대한 검사를 요구하였음을 알 수 있다. 따라서 본 논문에서 제안하는 GD 휴리스틱이 겹침 휴리스틱에 비해 실험 도메인들에서 휴리스틱 계산 효율성이 상대적으로 더 우수함을 확인할 수 있었다.

## 6. 결론

본 논문에서는 불확실한 초기 상태와 비결정적 동작들을 포함하는 조건부 계획문제의 명세로부터 양질의 탐색 휴리스틱을 자동으로 도출해내기 위해서 해결해야 할 몇 가지 문제점들을 제시하였다. 그리고 이러한 문제점들에 대한 효과적인 접근방안으로서, unknown 메타술어를 이용한 믿음 상태 표현법과 이것에 기초한 융합 계획 그래프, 그리고 GD 휴리스틱 계산법 등을 제안하였다. unknown 메타 술어를 이용한 믿음 상태 표현법은 믿음 상태를 하나의 리터럴들의 집합으로 표현할 수 있어, 기존의 많은 조건부 계획 시스템들과는 달리 하나의 믿음 상태에 포함된 다수의 상태들을 모두 열거한 다음, 이들 각각에서 목표 상태까지 도달비용을 모두 계산할 필요가 없다. 또한, 융합 계획 그래프는 고전적 계획 문제의 탐색 휴리스틱 도출에 적용되었던 동작의 삭제 간략화 이외에 추가적으로 효과-융합 간략화를 적용함으로써, 감지 동작과 비결정적 동작들을 포함하는 조건부 계획 문제들까지도 단 하나의 간략화된 계획 그래프의 전개만으로 목표 도달비용의 추정이 가능하다. 또, 융합 계획 그래프의 전개와 함께 병행적으로 진행되는 GD 휴리스틱 계산은 융합 계획 그래프의 각 리터럴 계층에 등장하는 목표 조건들 간의 긍정적 상호 의존성을 매우 효율적인 방식으로 분석함으로써, 적은 계산노력으로도 정확성이 높은 휴리스틱 평가치를 구할 수 있는 장점이 있다. 본 논문에서는 비교실험을 통해 목표조건들 간의 상호 의존성을 분석하지 않는 최대 휴리스틱이나 합산 휴리스틱에 비해 GD 휴리스틱이 더 높은 정확성과 탐색 효율성을 보인다는 것을 확인하였다. 또한, 같은 비교실험을 통해 비슷한 정확성과 탐색 효율성을 보인 겹침 휴리스틱에 비해 본 논문에서 제안한 GD 휴리스틱이 훨씬 높은 휴리스틱 계산 효율성을 나타냄을 확인할 수 있었다.

## 참고 문헌

- [1] B. Bonet and H. Geffner "Planning as Heuristic Search", Artificial Intelligence, Vol. 129, pp.5-33, 2001.
- [2] J. Hoffmann and B. Nebel, "The FF Planning System: Fast Plan Generation through Heuristic Search", Journal of AI Research, Vol.14, pp.253-302, 2001.
- [3] A. Blum and M. Furst, "Fast Planning through Planning Graph

Analysis”, Proc. of IJCAI-95, 1995.

[4] D. Bryce, S. Kambhampati and D. Smith, "Planning Graph Heuristics for Belief Space Search", Journal of Artificial Intelligence Research, Vol.26, pp.35-99, 2006.

[5] B. Bonet and H. Geffner, "mGPT: A Probabilistic Planner based on Heuristic Search", Proc. of ICAPS-04, 2004.

[6] B. Bonet and H. Geffner, "GPT: A Tool for Planning with Uncertainty and Partial Information", Proc. of IJCAI-01, pp.82-87, 2001.

[7] J. Hoffmann and R. Brafman, "Contingent Planning via Heuristic Forward Search with Implicit Belief States", Proc. of ICAPS-05, 2005.

[8] P. Bertoli, A. Cimatti, M. Roveri and P.Traverso, "Strong Planning under Partial Observability", Artificial Intelligence, Vol.170, No.4-5, pp.337-384, 2006.

[9] R. Petrick and F. Bacchus, "PKS: Knowledge-Based Planning with Incomplete Information and Sensing", Proc. of ICAPS-04, 2004.


[10] A. Mediratta and B. Srivastava, "Applying Planning in Composition of Web Services with a User-Driven Contingent Planner", IBM Research Report RI 06002, February 2006.



**김 현 식**

e-mail advance7@kyonggi.ac.kr  
 2001년 경기대학교 전자계산학과(학사)  
 2004년 경기대학교 일반대학원 전자계산학과(이학석사)  
 2010년 경기대학교 일반대학원 전자계산학과(이학박사)

현 재 경기대학교 컴퓨터과학과 박사후과정 연구원  
 관심분야: 자동계획, 시맨틱 웹 서비스, 지능로봇, 에이전트



**김 인 철**

e-mail : kic@kyonggi.ac.kr  
 1985년 서울대학교 수학과(학사)  
 1987년 서울대학교 전산학과(이학석사)  
 1995년 서울대학교 전산학과(이학박사)  
 1996년~현 재 경기대학교 컴퓨터과학과 교수

관심분야: 자동계획, 기계학습, 지능로봇, 에이전트



**박 영 택**

e-mail : park@ssu.ac.kr  
 1978년 서울대학교 전자공학과(학사)  
 1980년 KAIST 전산학과(공학석사)  
 1992년 Computer Science, University of Illinois(공학박사)  
 1993년~현 재 숭실대학교 컴퓨터학부 교수

관심분야: 인공지능, 시맨틱 웹, 유비쿼터스 에이전트