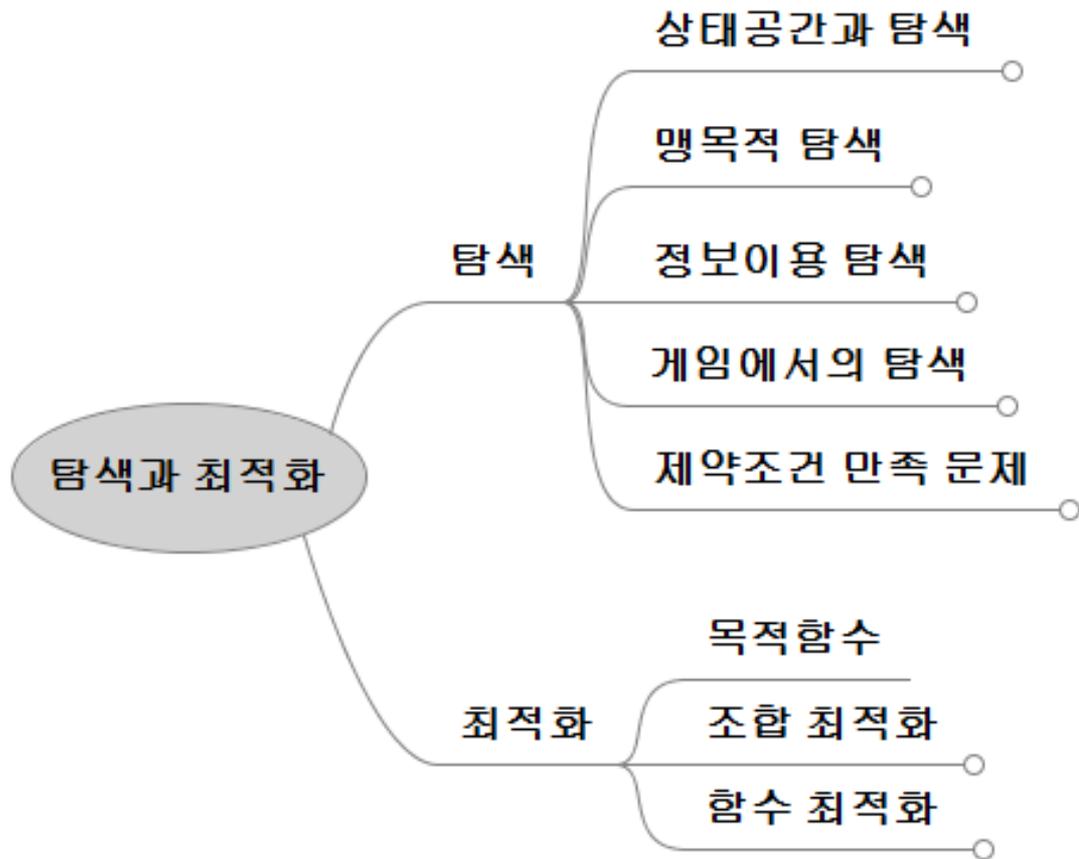


# 탐색과 최적화

1. 상태 공간과 탐색
2. 맹목적 탐색
3. 정보이용 탐색
4. 게임 탐색
5. 제약조건 만족 문제
6. 최적화



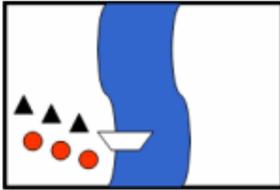
# 1. 상태 공간과 탐색

## ❖ 탐색 (探索, search)

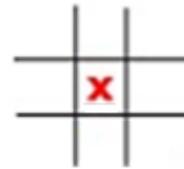
- 문제의 **해(solution)**이 될 수 있는 것들의 **집합**을 **공간(space)**으로 간주하고, 문제에 대한 **최적의 해**를 찾기 위해 공간을 **체계적으로 찾아 보는 것**

## ❖ 탐색문제의 예

- 선교사-식인종 강건너기 문제



- 틱-택-토(tic-tac-toe)



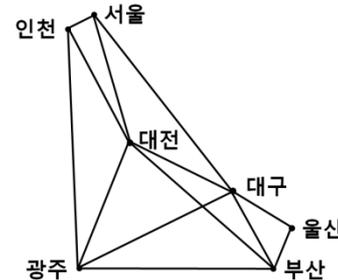
- 루빅스큐브 (Rubik's cube)



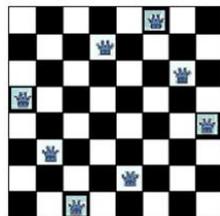
- 8-퍼즐 문제



- 순회 판매자 문제 (traveling salesperson problem, TSP)



- 8-퀸(queen) 문제



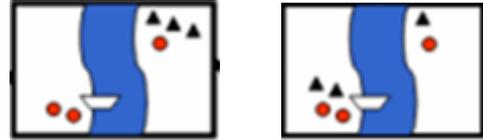
- 해(解, solution)**

일련의 동작으로 구성되거나 하나의 상태로 구성

# 상태 공간과 탐색

## ❖ 상태(state)

- 특정 시점에 문제의 세계가 처해 있는 모습



## ❖ 세계(world)

- 문제에 포함된 대상들과 이들의 상황을 포괄적으로 지칭

## ❖ 상태 공간(state space)

- 문제 해결 과정에서 초기 상태에서부터 도달할 수 있는 모든 상태들의 집합
- 문제의 해가 될 가능성이 있는 모든 상태들의 집합

- 초기 상태(initial state)

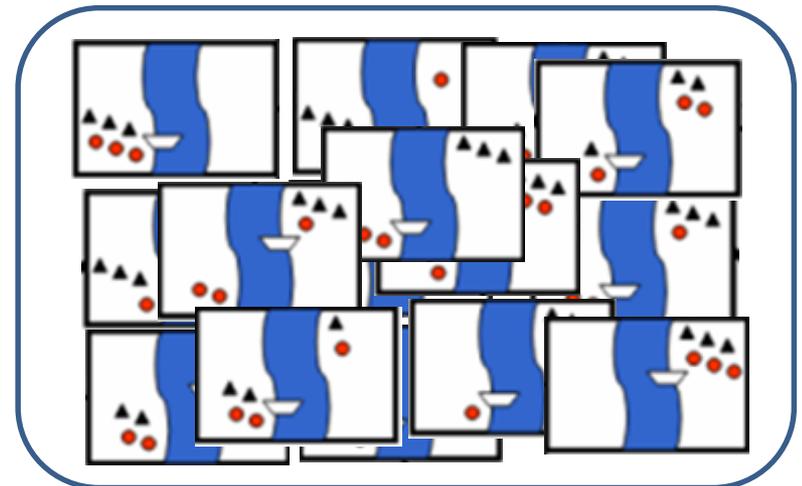


- 문제가 주어진 시점의 시작 상태

- 목표 상태(goal state)



- 문제에서 원하는 최종 상태



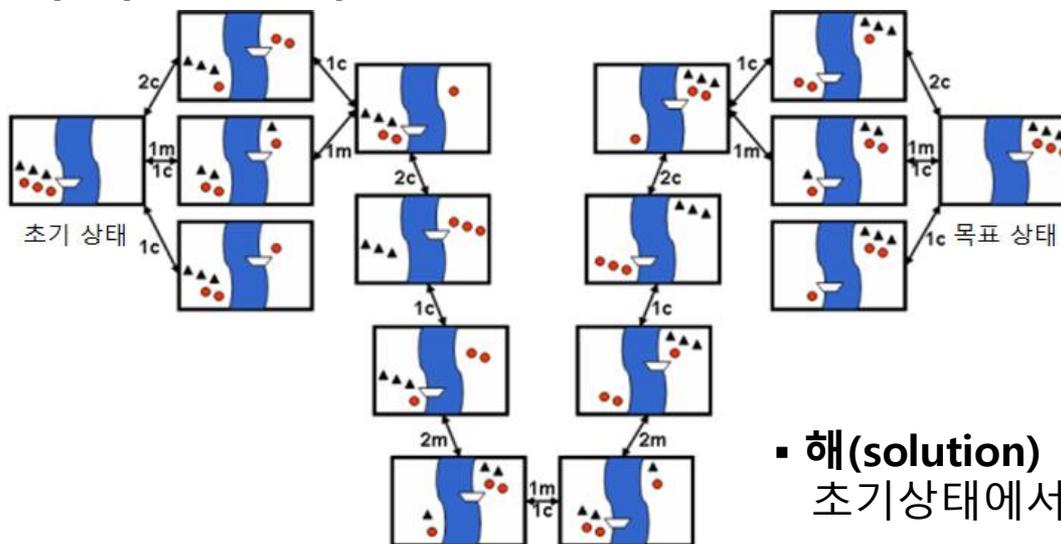
# 상태 공간과 탐색

## ❖ 상태 공간 그래프(state space graph)

- 상태공간에서 각 행동에 따른 상태의 변화를 나타낸 그래프

- 노드 : 상태
- 링크 : 행동

### ▪ 선교사-식인종 문제



### ▪ 해(solution)

초기상태에서 목표 상태로의 경로(path)

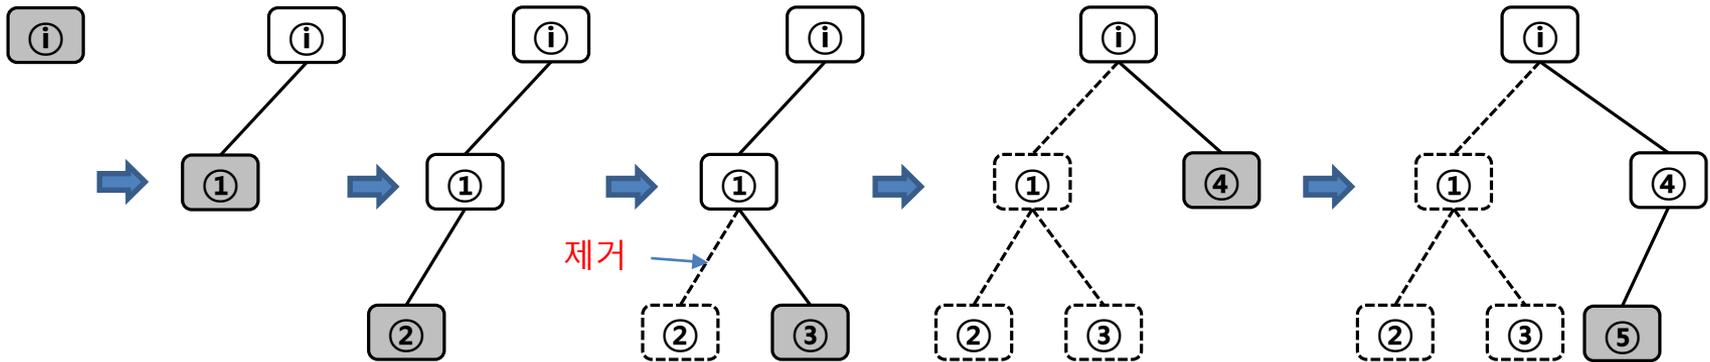
- 일반적인 문제에서는 상태공간이 매우 큼

- 미리 상태 공간 그래프를 만들기 어려움
- 탐색과정에서 그래프 생성

## 2. 맹목적 탐색

### ❖ 맹목적 탐색(blind search)

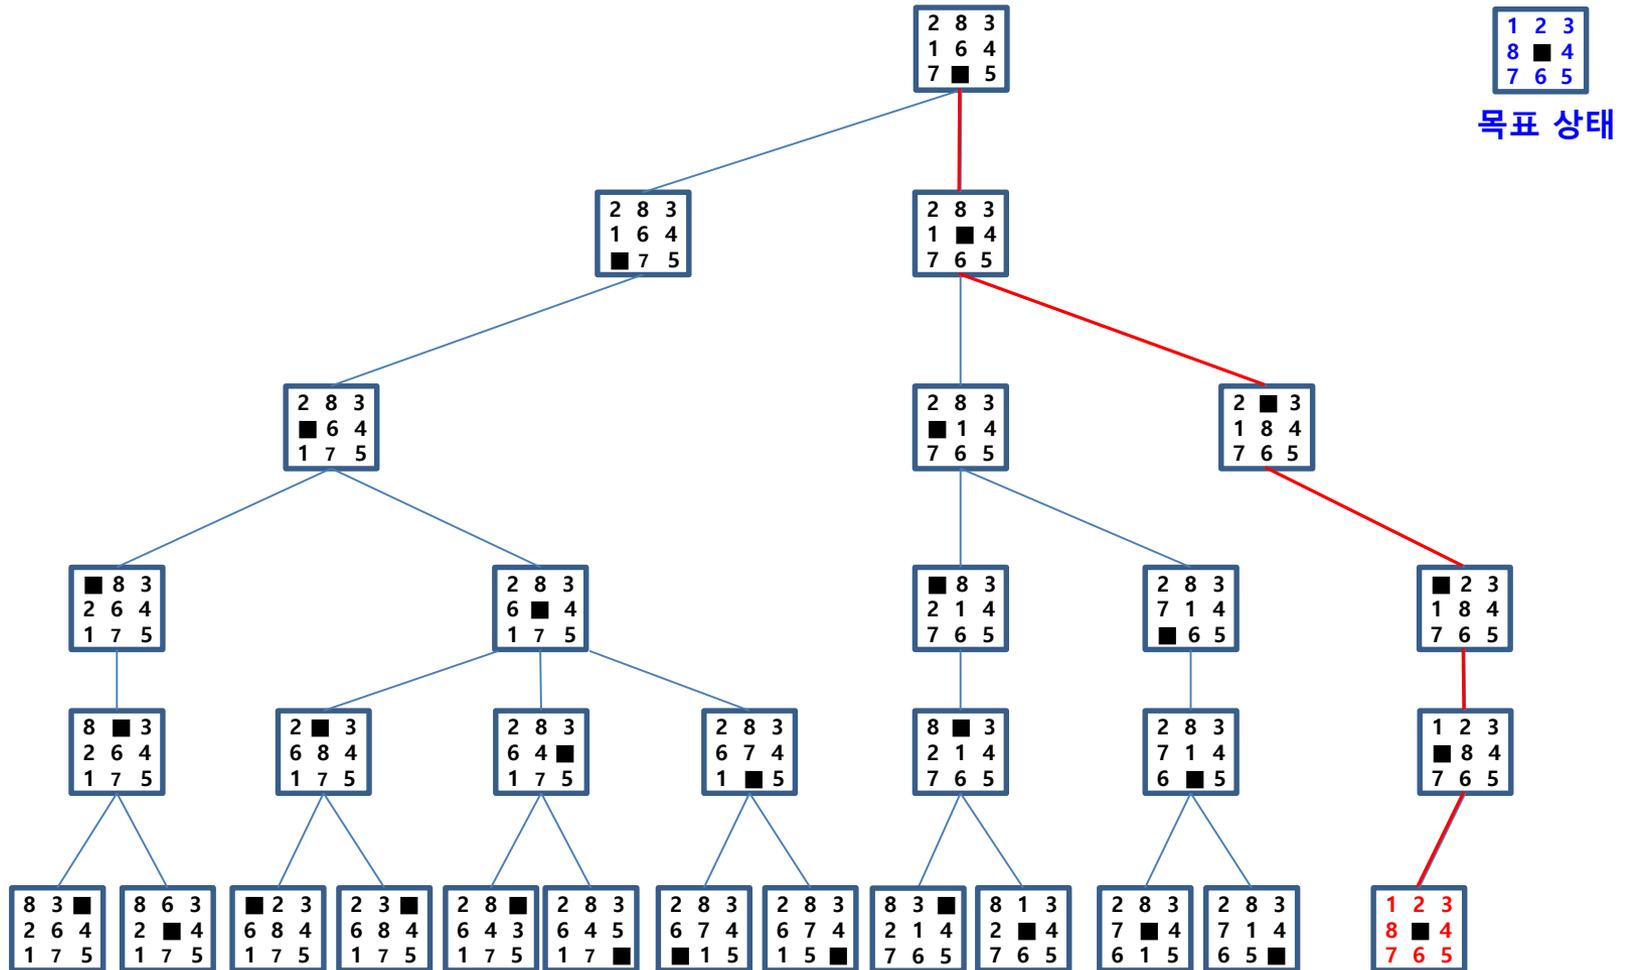
- 정해진 순서에 따라 상태 공간 그래프를 점차 생성해 가면서 해를 탐색하는 방법
- 깊이 우선 탐색(depth-first search, DFS)
  - 초기 노드에서 시작하여 깊이 방향으로 탐색
  - 목표 노드에 도달하면 종료
  - 더 이상 진행할 수 없으면, 백트래킹(backtracking, 되짚어가기)
  - 방문한 노드는 재방문하지 않음



# 맹목적 탐색

## ❖ 8-퍼즐 문제의 깊이 우선 탐색 트리

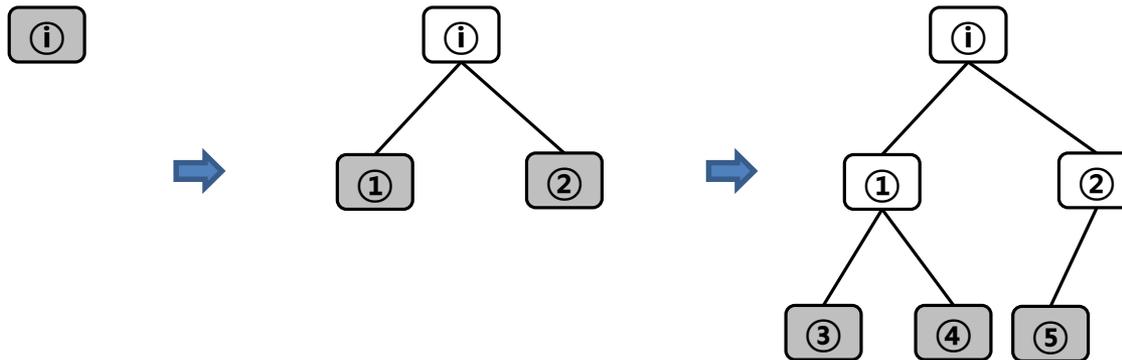
- 루트 노드에서 현재 노드까지의 경로 하나만 유지



# 맹목적 탐색

## ❖ 너비 우선 탐색(breadth-first search, BFS)

- 초기 노드에서 시작하여 모든 자식 노드를 확장하여 생성
- 목표 노드가 없으면 단말노드에서 다시 자식 노드 확장





# 맹목적 탐색

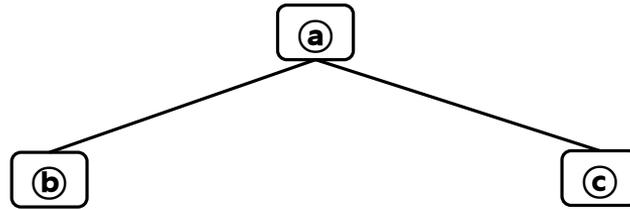
- ❖ 반복적 깊이심화 탐색(iterative-deepening search)
  - 깊이 한계가 있는 깊이 우선 탐색을 반복적으로 적용



깊이 0: ①

# 맹목적 탐색

- ❖ 반복적 깊이심화 탐색(iterative-deepening search)
  - 깊이 한계가 있는 깊이 우선 탐색을 반복적으로 적용

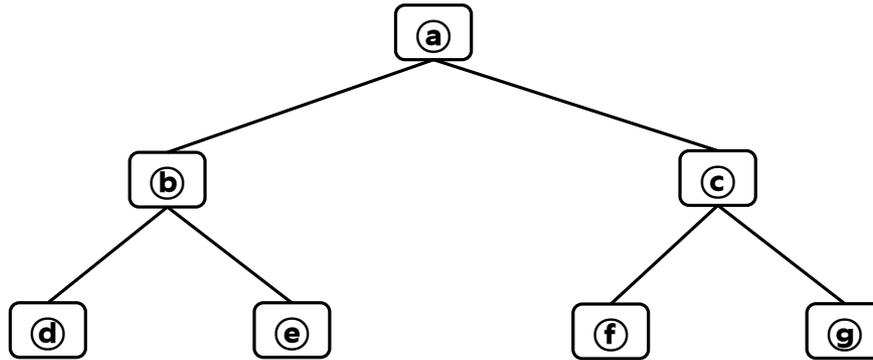


깊이 0: a

깊이 1: a, b, c

# 맹목적 탐색

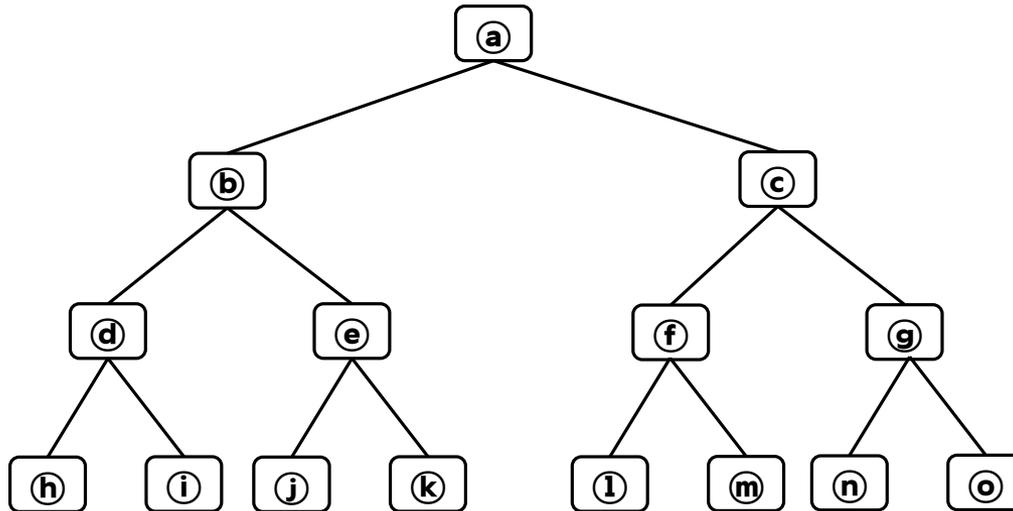
- ❖ 반복적 깊이심화 탐색(iterative-deepening search)
  - 깊이 한계가 있는 깊이 우선 탐색을 반복적으로 적용



깊이 0: a  
깊이 1: a, b, c  
깊이 2: a, b, d, e, c, f, g

# 맹목적 탐색

- ❖ 반복적 깊이심화 탐색(iterative-deepening search)
  - 깊이 한계가 있는 깊이 우선 탐색을 반복적으로 적용



깊이 0: a

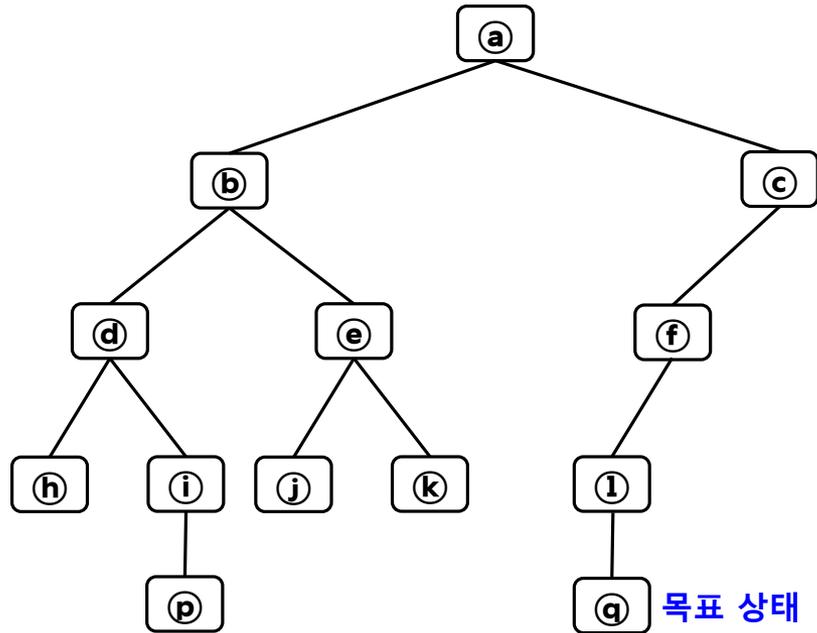
깊이 1: a, b, c

깊이 2: a, b, d, e, c, f, g

깊이 3: a, b, d, h, i, e, j, k, c, f, l, m, g, n, o

# 맹목적 탐색

- ❖ 반복적 깊이심화 탐색(iterative-deepening search)
  - 깊이 한계가 있는 깊이 우선 탐색을 반복적으로 적용



깊이 0: a

깊이 1: a, b, c

깊이 2: a, b, d, e, c, f, g

깊이 3: a, b, d, h, i, e, j, k, c, f, l, m, g, n, o

깊이 4: a, b, d, h, i, p, e, j, k, c, f, l, q

# 맹목적 탐색

## ❖ 맹목적 탐색 방법의 비교

### ▪ 깊이 우선 탐색

- 메모리 공간 사용 효율적
- 최단 경로 해 탐색 보장 불가

### ▪ 너비 우선 탐색

- 최단 경로 해 탐색 보장
- 메모리 공간 사용 비효율

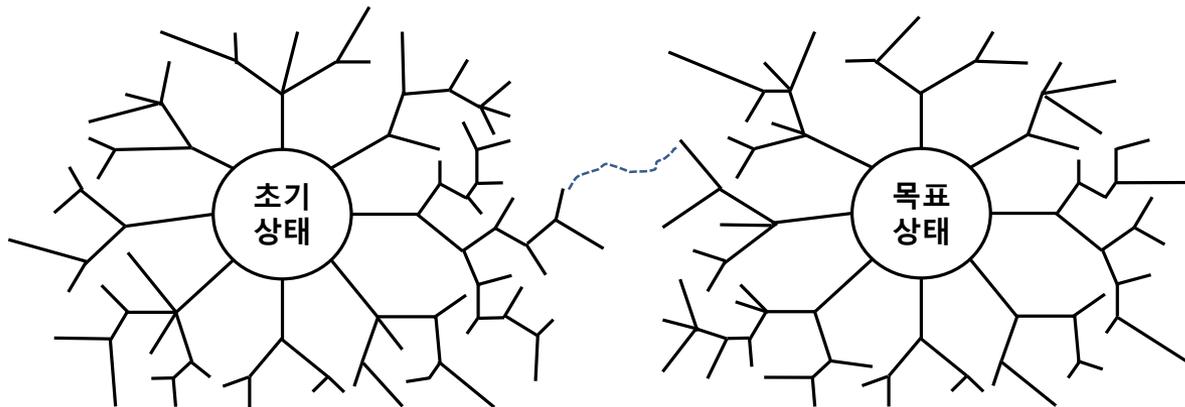
### ▪ 반복적 깊이심화 탐색

- 최단 경로 해 보장
- 메모리 공간 사용 효율적
- 반복적인 깊이 우선 탐색에 따른 비효율성
  - 실제 비용이 크게 늘지 않음
  - 각 노드가 10개의 자식노드를 가질 때,  
너비 우선 탐색 대비 약 11%정도 추가 노드 생성
- 맹목적 탐색 적용시 우선 고려 대상

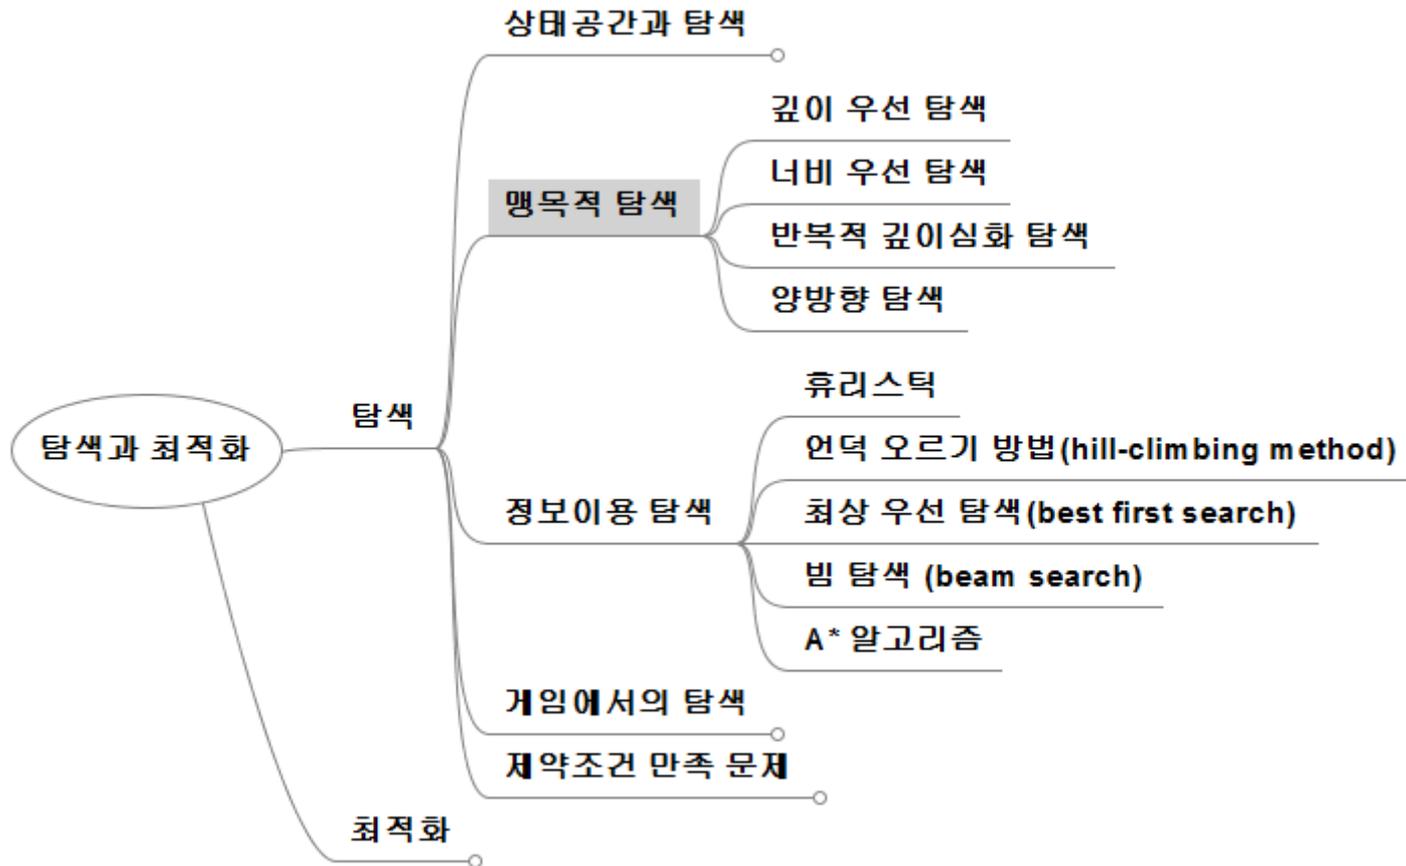
# 맹목적 탐색

## ❖ 양방향 탐색(bidirectional search)

- 초기 노드와 목적 노드에서 동시에 너비 우선 탐색을 진행
- 중간에 만나도록 하여 초기 노드에서 목표 노드로의 최단 경로를 찾는 방법



# 맹목적 탐색



# 3. 정보이용 탐색

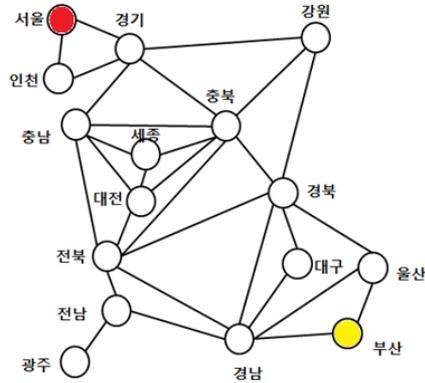
- ❖ 정보이용 탐색(informed search)
  - 휴리스틱 탐색(heuristic search)
  - 언덕 오르기 방법, 최상 우선 탐색, 빔 탐색, A\* 알고리즘 등
  - **휴리스틱**(heuristic)
    - 그리스어 Εὐρίσκω (Eurisko, 찾다, 발견하다)
    - 시간이나 정보가 불충분하여 합리적인 판단을 할 수 없거나, 굳이 체계적이고 합리적인 판단을 할 필요가 없는 상황에서 **신속하게 어림짐작하는 것**
    - 예.
      - 최단 경로 문제에서 목적지까지 남은 거리
        - » 현재 위치에서 목적지(목표 상태)까지 지도상의 직선 거리

# 정보이용 탐색

## ❖ 휴리스틱 비용 추정 의 예

### ▪ 최단경로 문제

- 현재 위치에서 목적지까지 직선 거리



### ▪ 8-퍼즐 문제

- 제자리에 있지 않는 타일의 개수

2	8	3
1	6	4
7		5

현재 상태

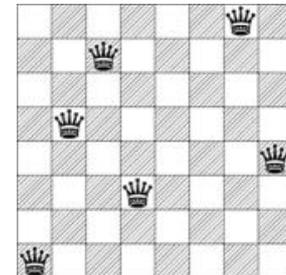
1	2	3
8		4
7	6	5

목표 상태

추정비용 : 4

### ▪ 8-퀸 문제

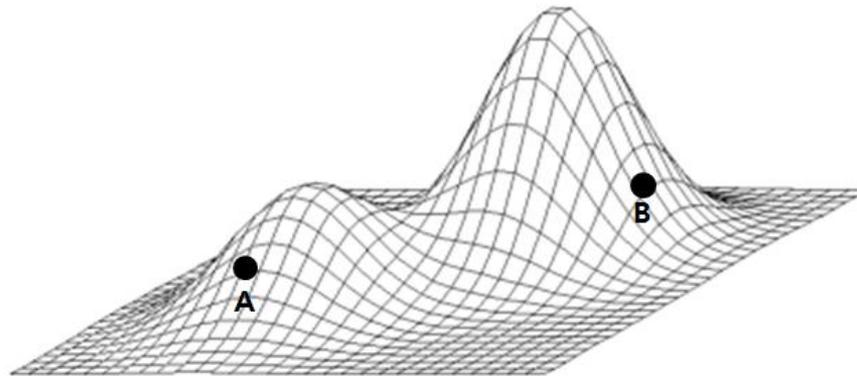
- 충돌하는 회수



# 정보이용 탐색

## ❖ 언덕 오르기 방법(hill climbing method)

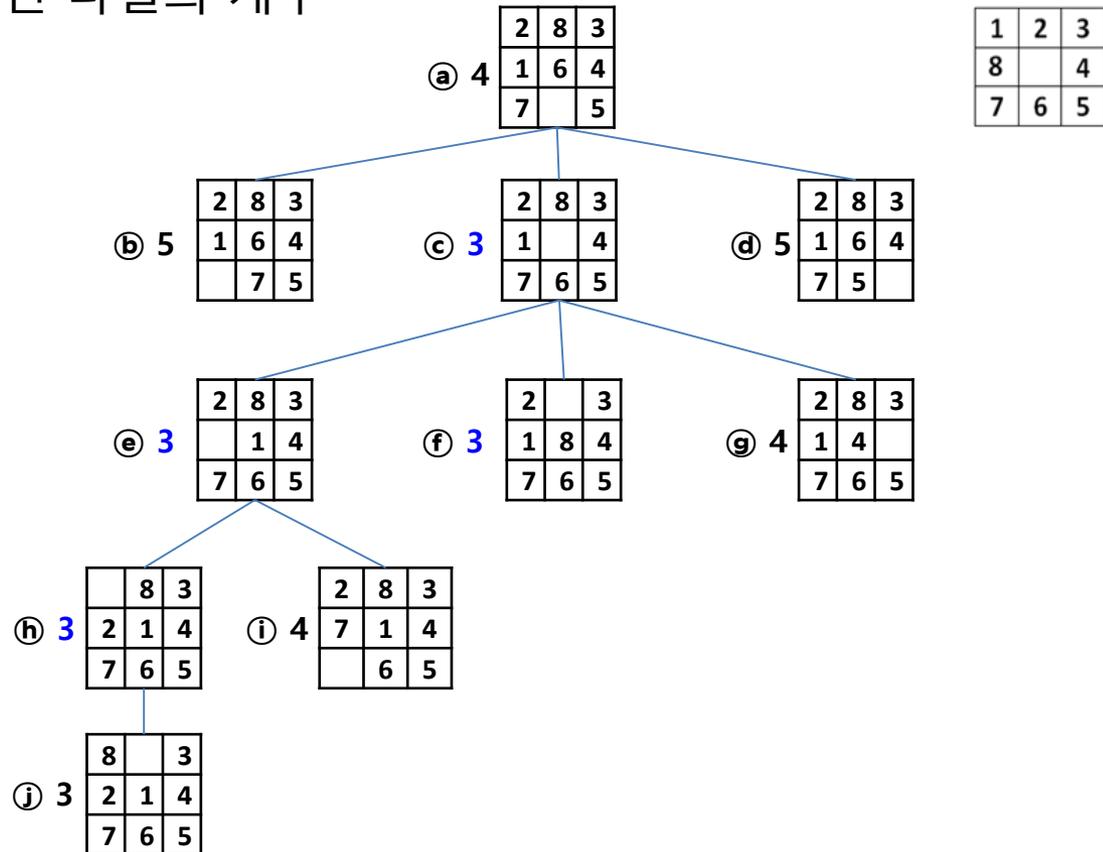
- 지역 탐색(local search), 휴리스틱 탐색(heuristic search)
- 현재 노드에서 휴리스틱에 의한 평가값이 가장 좋은 이웃 노드 하나를 확장해 가는 탐색 방법
- 국소 최적해(local optimal solution)에 빠질 가능성



# 정보이용 탐색

## ❖ 최상 우선 탐색(best-first search)

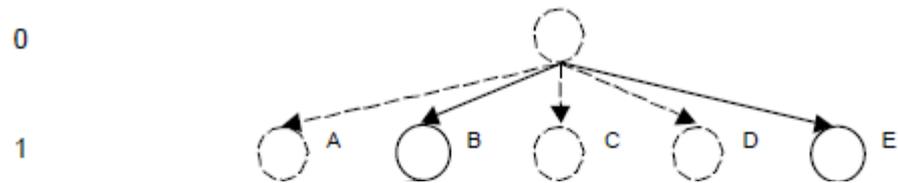
- 확장 중인 노드들 중에서 목표 노드까지 남은 거리가 가장 짧은 노드를 확장하여 탐색
- 남은 거리를 정확히 알 수 없으므로 휴리스틱 사용
  - 제자리가 아닌 타일의 개수



# 정보이용 탐색

## ❖ 빔 탐색 (beam search)

- 휴리스틱에 의한 평가값이 우수한 **일정 개수의 확장 가능한 노드**만을 메모리에 **관리하면서 최상 우선 탐색**을 적용



# 정보이용 탐색

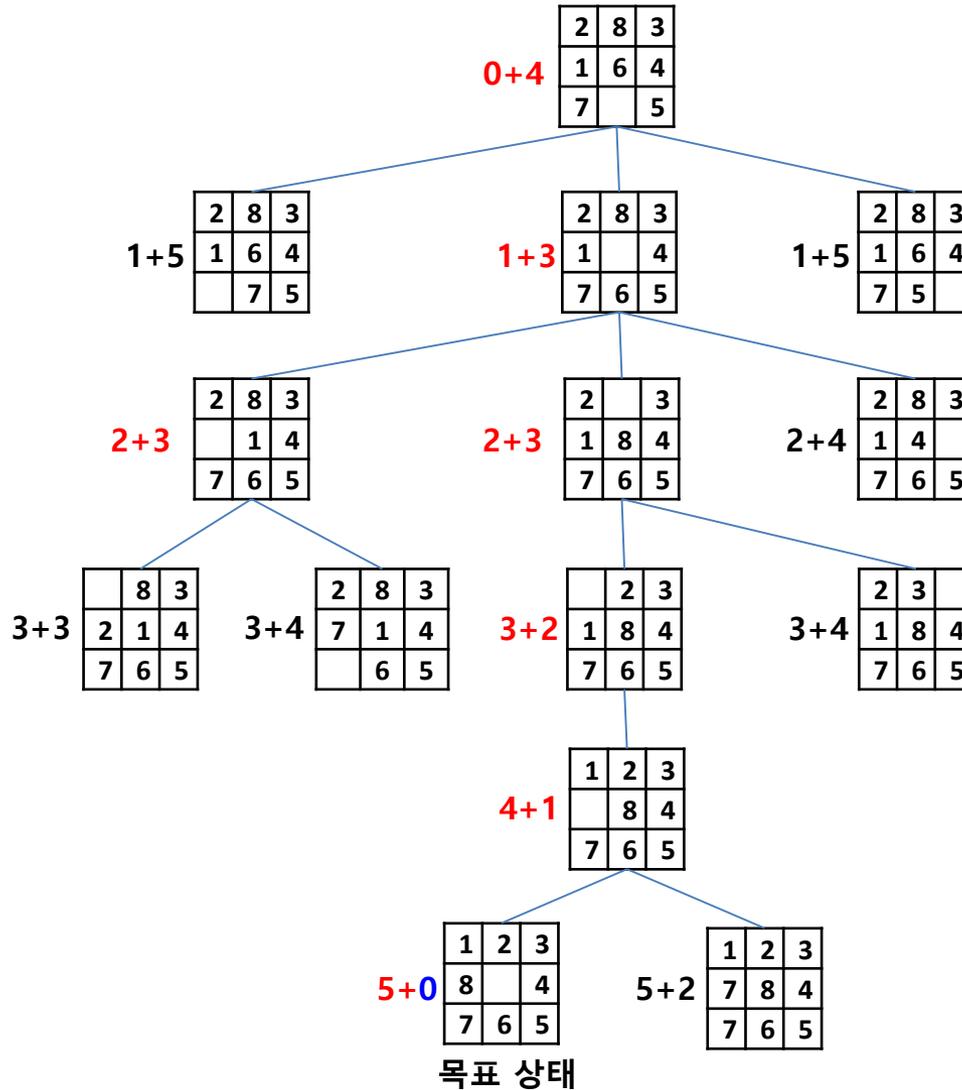
## ❖ A\* 알고리즘

- 추정한 전체 비용  $\hat{f}(n)$ 을 최소로 하는 노드를 확장해 가는 방법
- $f(n)$  : 노드  $n$  을 경유하는 전체 비용
  - 현재 노드  $n$ 까지 이미 투입된 비용  $g(n)$ 과 목표 노드까지의 남은 비용  $h(n)$ 의 합
  - $f(n) = g(n) + h(n)$
- $h(n)$  : 남은 비용의 정확한 예측 불가
  - $\hat{h}(n)$  :  $h(n)$ 에 대응하는 휴리스틱 함수(heuristic function)
- $\hat{f}(n)$  : 노드  $n$  을 경유하는 추정 전체 비용
  - $\hat{f}(n) = g(n) + \hat{h}(n)$

# 정보이용 탐색

## ❖ 8-퍼즐 문제의 A\* 알고리즘 적용

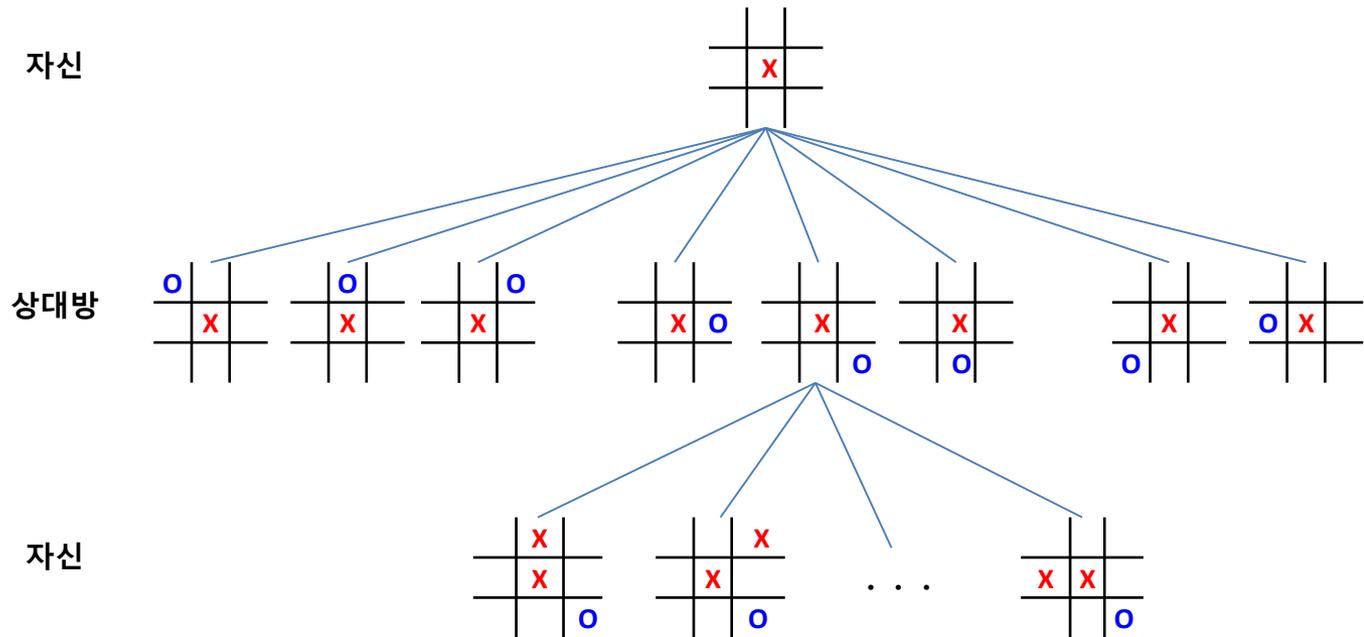
$$f(n) = g(n) + h(n)$$



# 4. 게임에서의 탐색

## ❖ 게임 트리(game tree)

- **상대가 있는 게임**에서 자신과 상대방의 가능한 게임 상태를 나타낸 트리
  - 틱-택-톡(tic-tac-toe), 바둑, 장기, 체스 등
- 게임의 결과는 마지막에 결정
- 많은 수(**lookahead**)를 볼 수록 유리



# 게임에서의 탐색

## ❖ mini-max 알고리즘(mini-max algorithm)

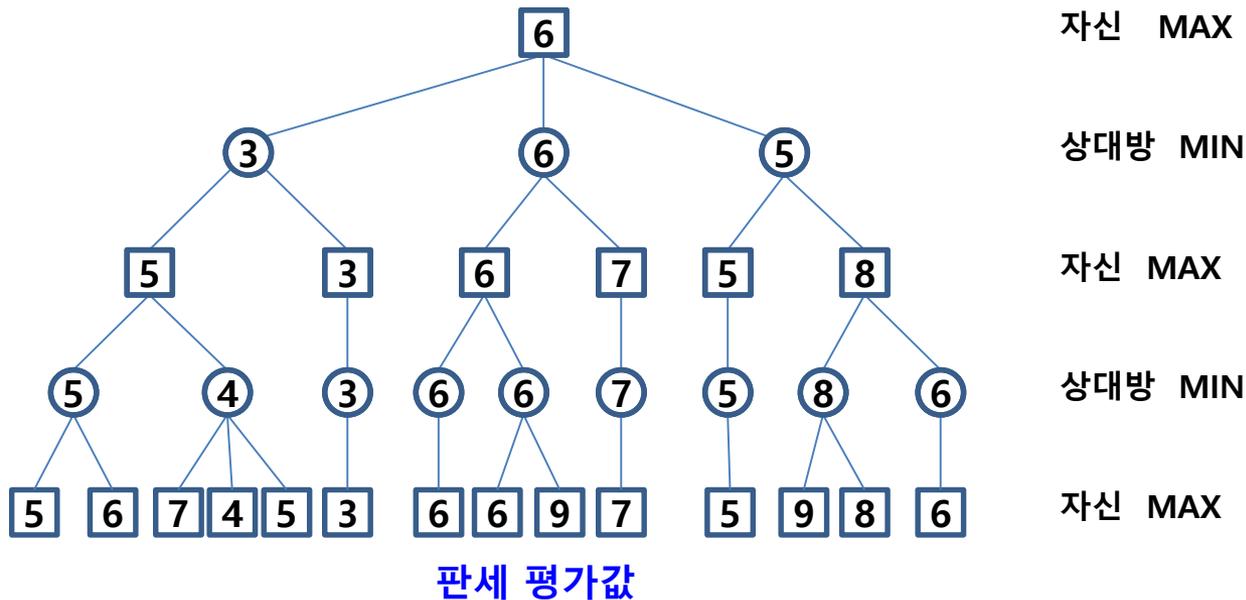
### ▪ MAX 노드

- 자신에 해당하는 노드로 자기에겐 유리한 최대값 선택

### ▪ MIN 노드

- 상대방에 해당하는 노드로 최소값 선택

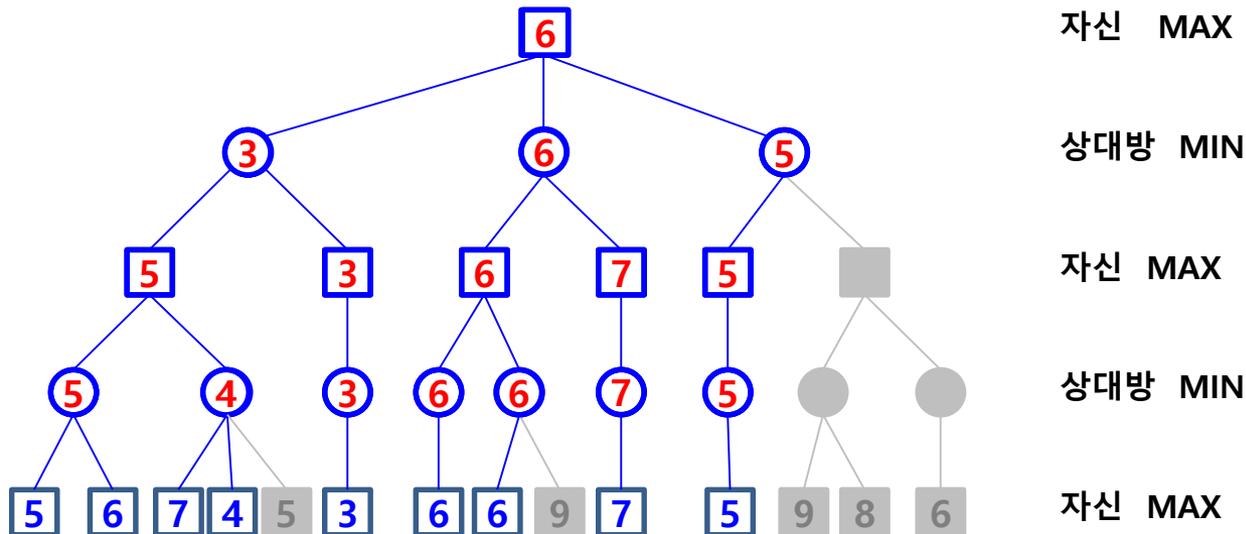
- 단말 노드부터 위로 올라가면서 최소(minimum)-최대(maximum) 연산을 반복하여 자신이 선택할 수 있는 방법 중 가장 좋은 것은 값을 결정



# 게임에서의 탐색

## ❖ $\alpha$ - $\beta$ 가지치기 (pruning)

- 검토해 볼 필요가 없는 부분을 탐색하지 않도록 하는 기법
- 깊이 우선 탐색으로 제한 깊이까지 탐색을 하면서, MAX 노드와 MIN 노드의 값 결정
  - **$\alpha$ -자르기(cut-off)** : MIN 노드의 현재값이 부모노드의 현재 값보다 작거나 같으면, 나머지 자식 노드 탐색 중지
  - **$\beta$ -자르기** : MAX 노드의 현재값이 부모노드의 현재 값보다 같거나 크면, 나머지 자식 노드 탐색 중지

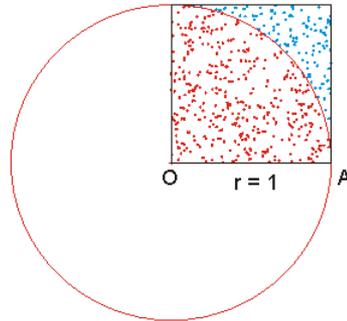


간단한 형태의  $\alpha$ - $\beta$  가지치기 예

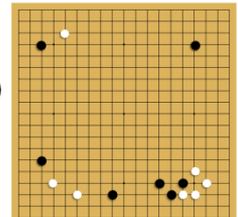
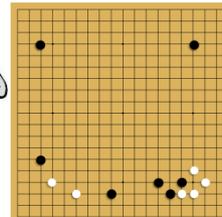
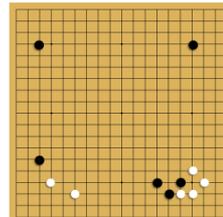
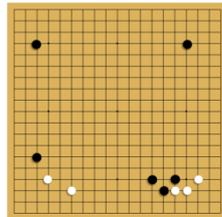
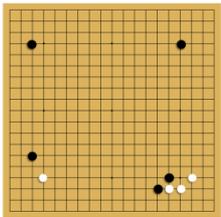
# 게임에서의 탐색

## ❖ 몬테카를로 시뮬레이션 (Monte Carlo Simulation)

- 특정 확률 분포로부터 무작위 표본(random sample)을 생성하고,
- 이 표본에 따라 행동을 하는 과정을 반복하여 결과를 확인하고,
- 이러한 결과확인 과정을 반복하여 최종 결정을 하는 것

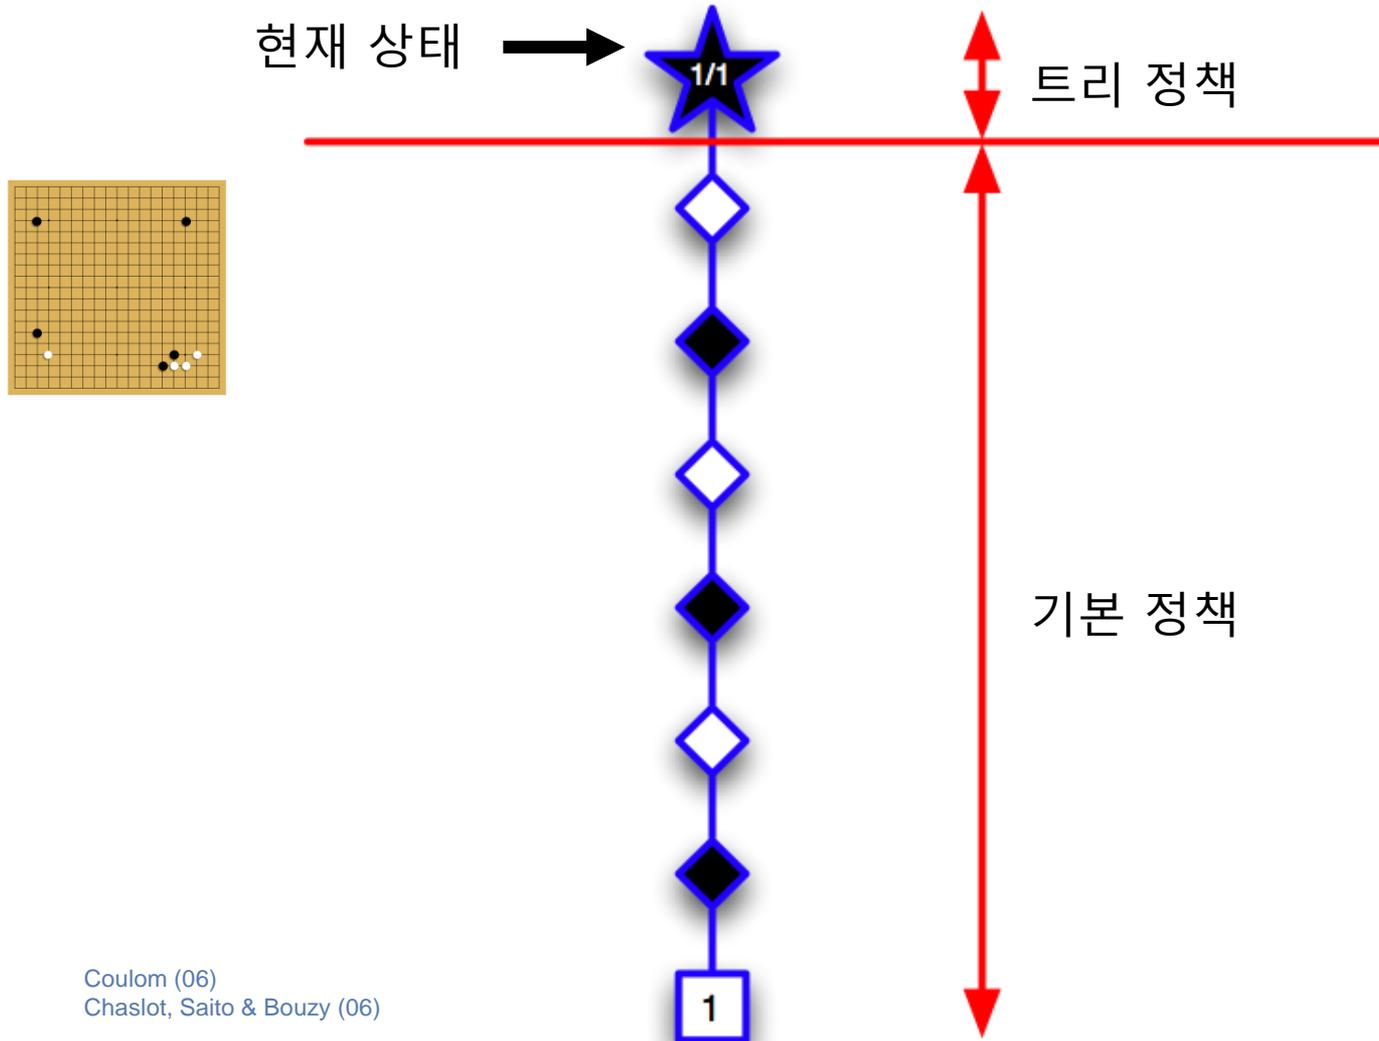


$$\frac{\text{원 안의 샘플 개수}}{\text{전체 샘플의 개수}} \rightarrow \frac{\pi}{4}$$

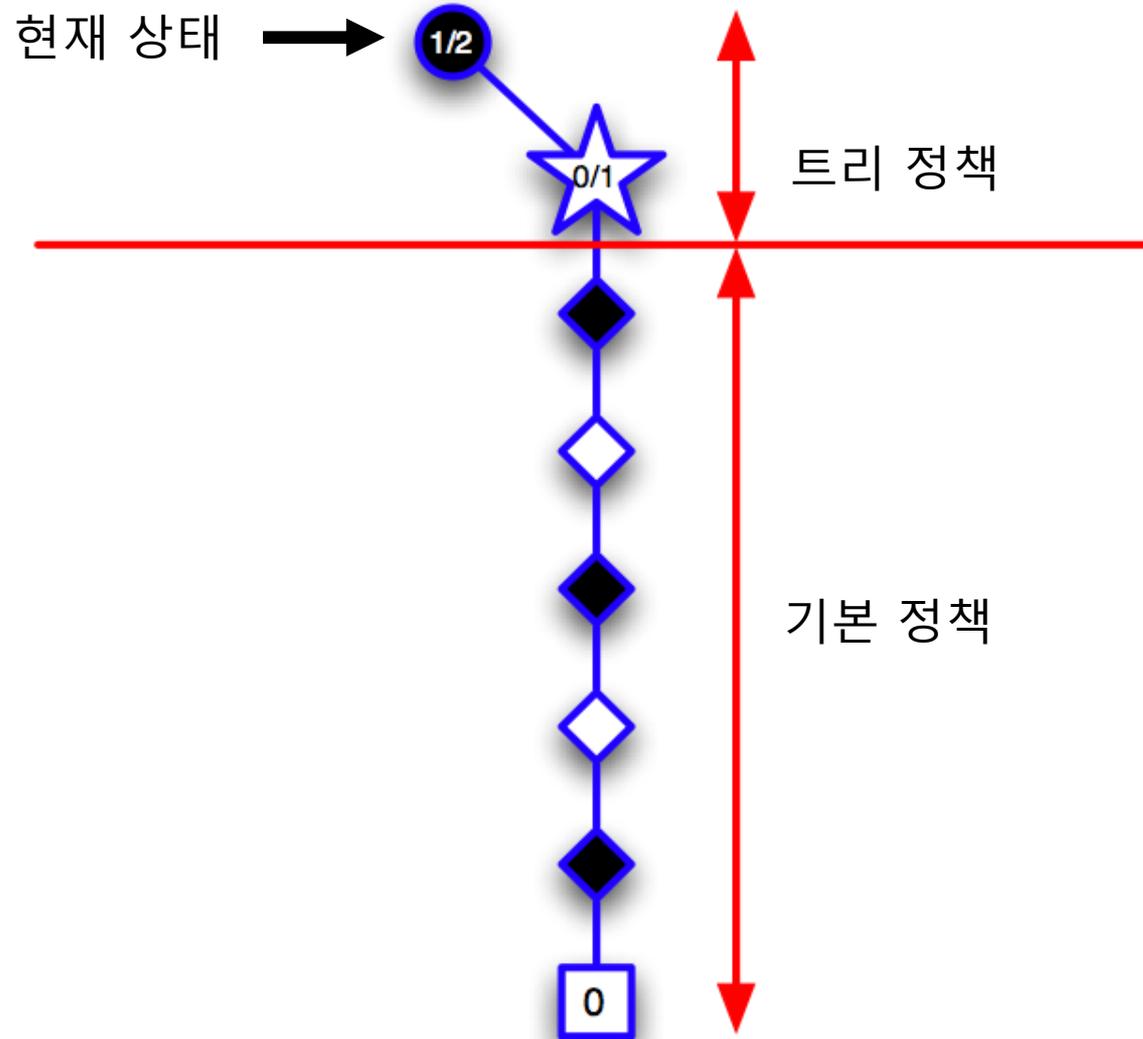


# 몬테카를로 트리 탐색

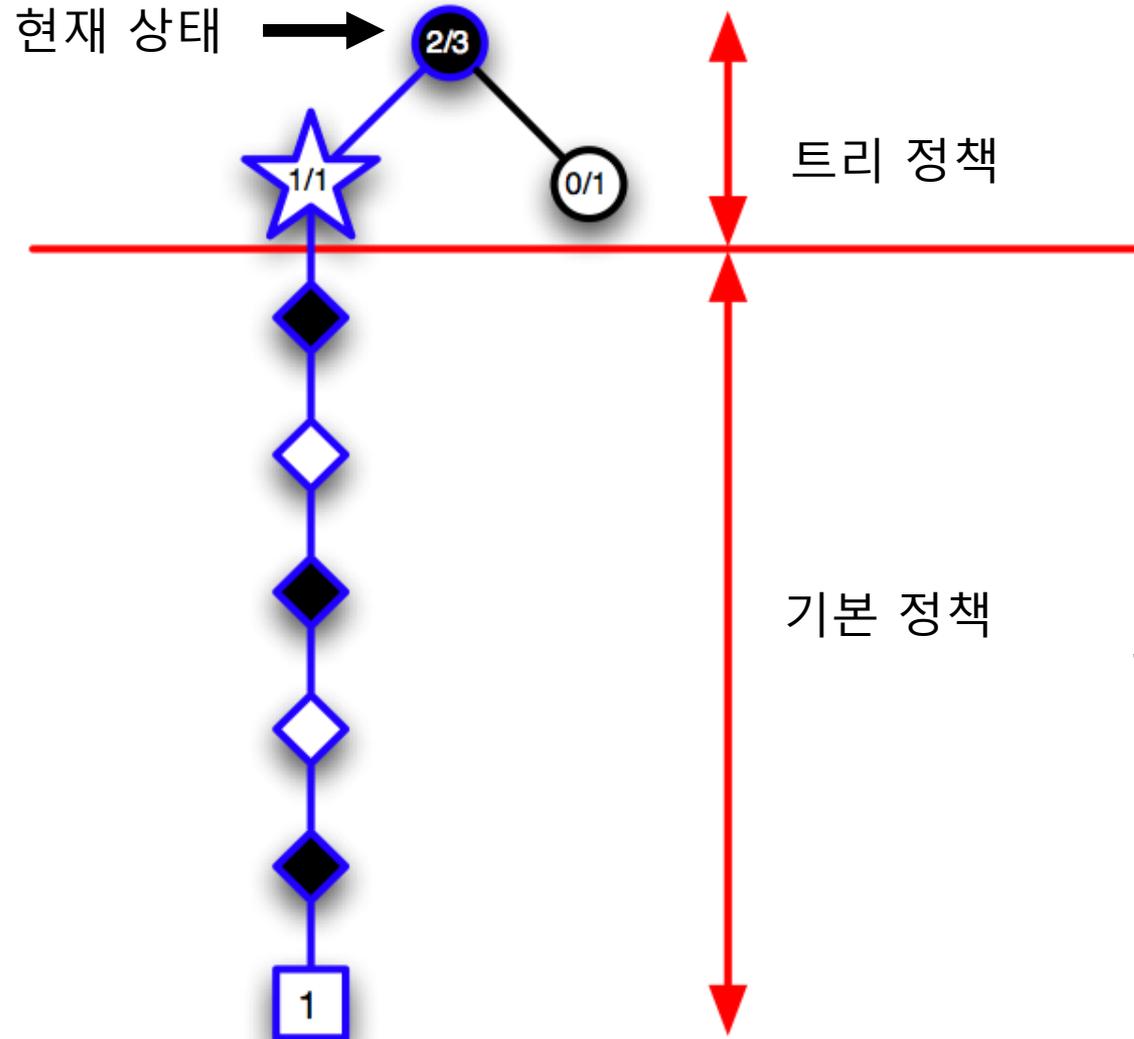
## ❖ 몬테카를로 트리 탐색(Monte Carlo Tree Search, MCTS)



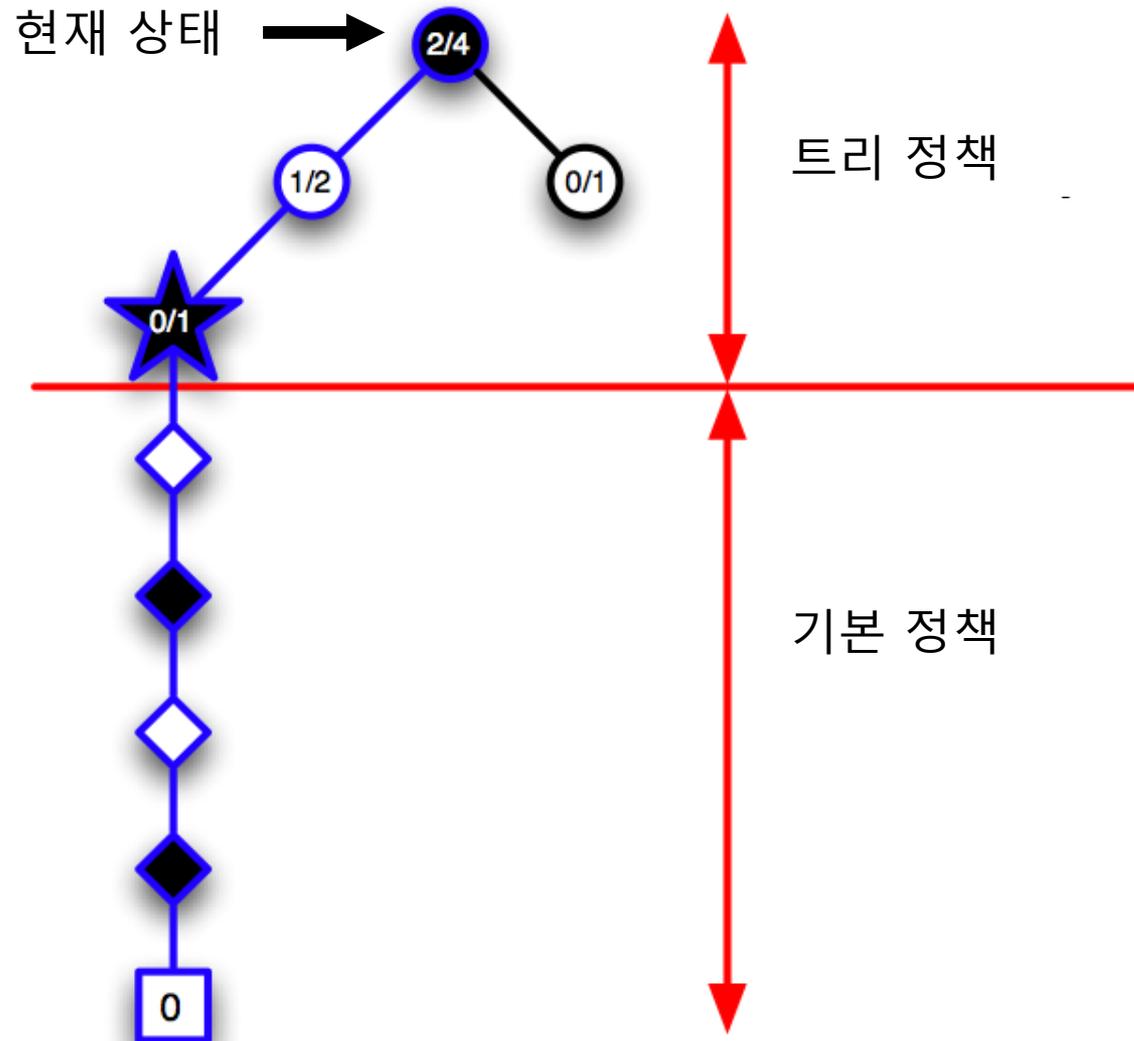
# 몬테카를로 트리 탐색



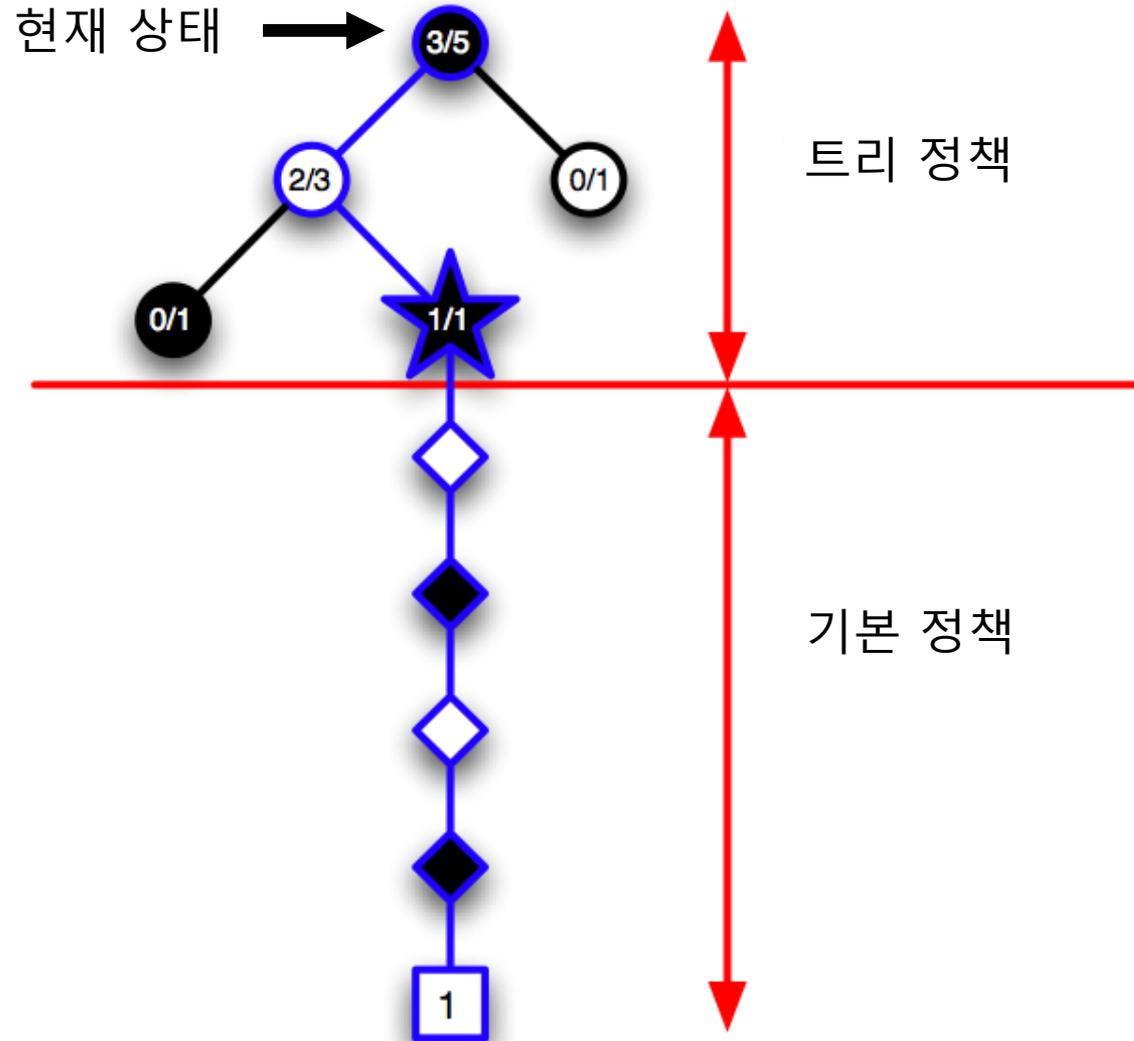
# 몬테카를로 트리 탐색



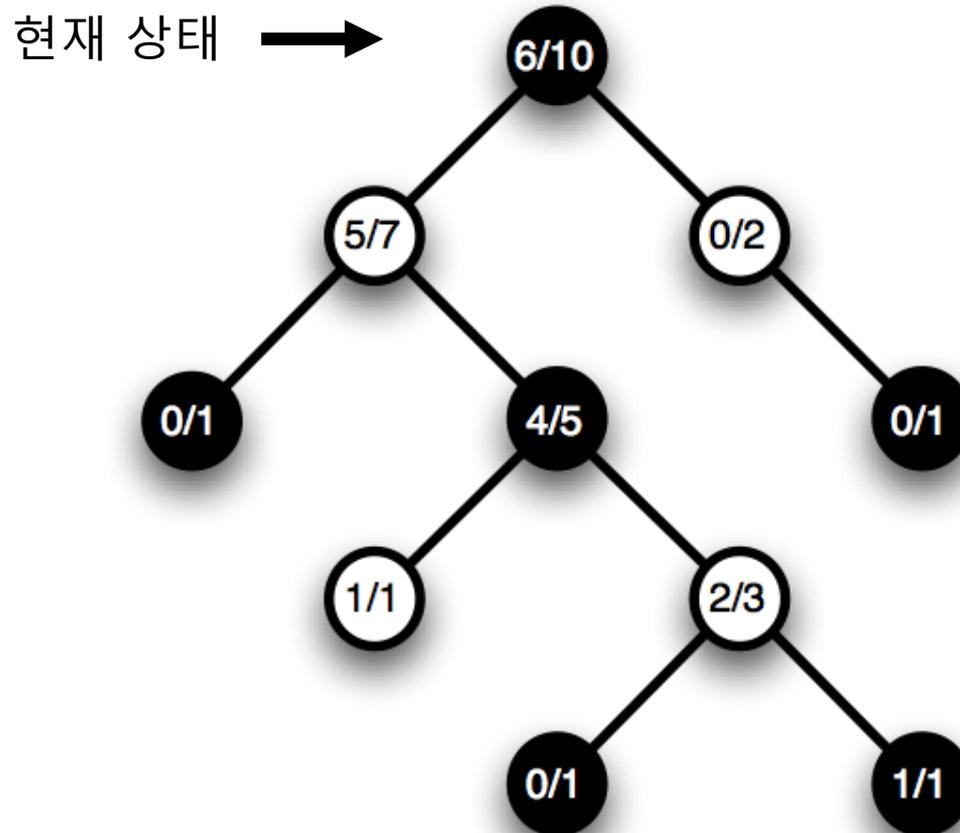
# 몬테카를로 트리 탐색



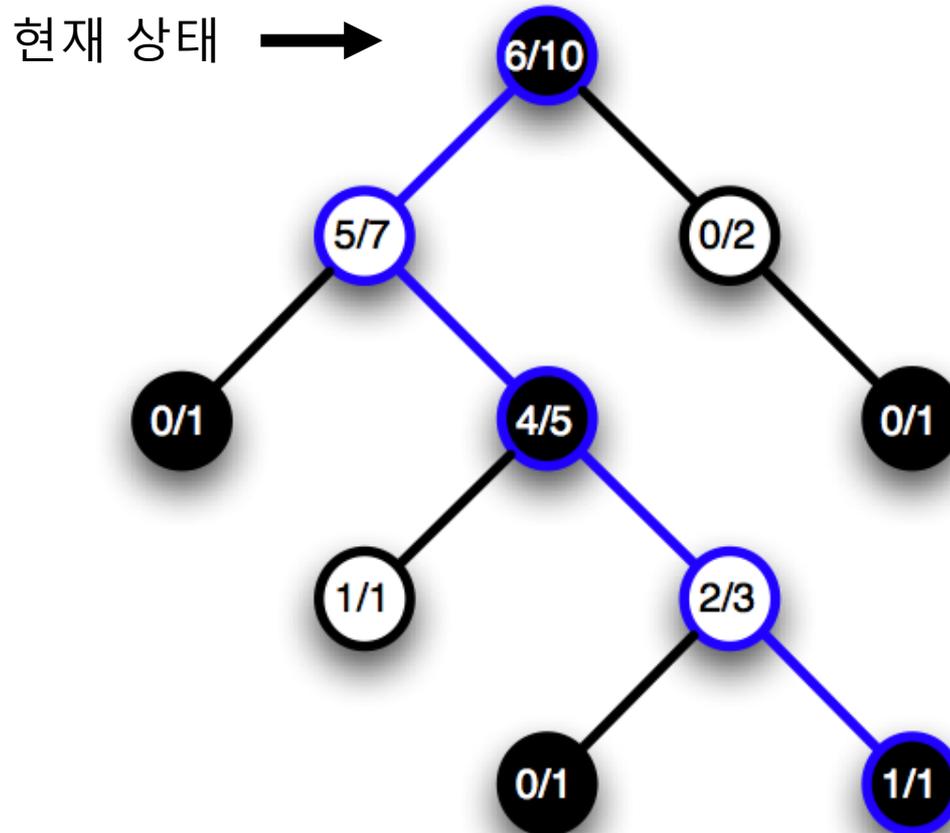
# 몬테카를로 트리 탐색



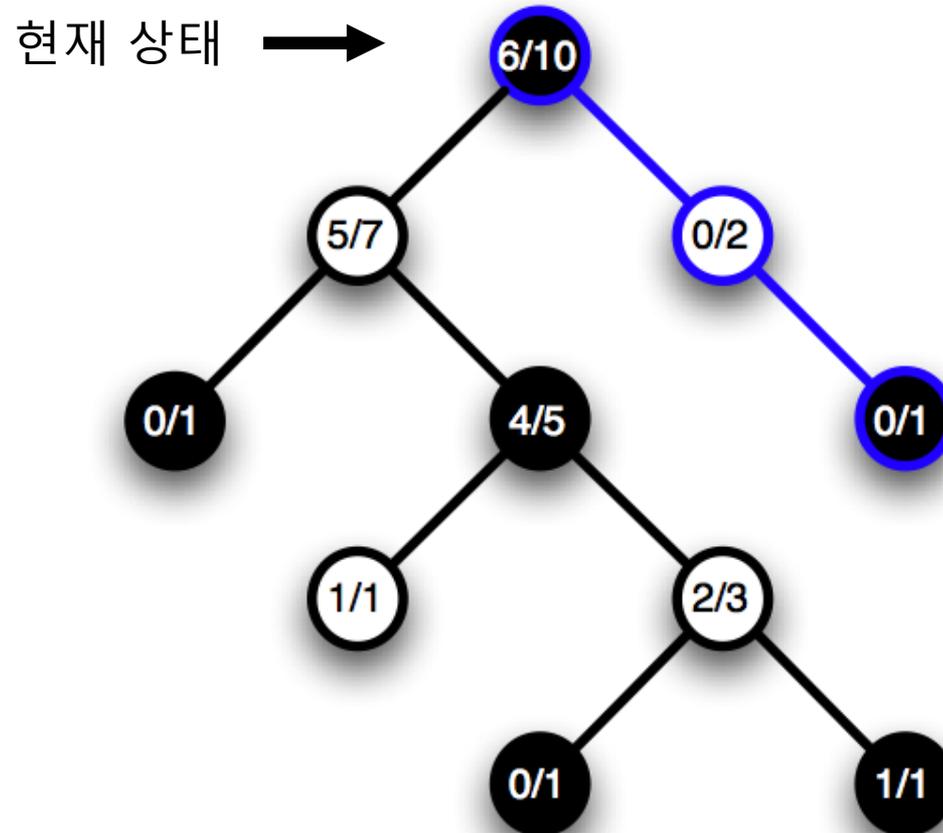
# 몬테카를로 트리 탐색



# 몬테카를로 트리 탐색



# 몬테카를로 트리 탐색



# 게임에서의 탐색

## ❖ 몬테카를로 트리 탐색(Monte Carlo Tree Search, MCTS)

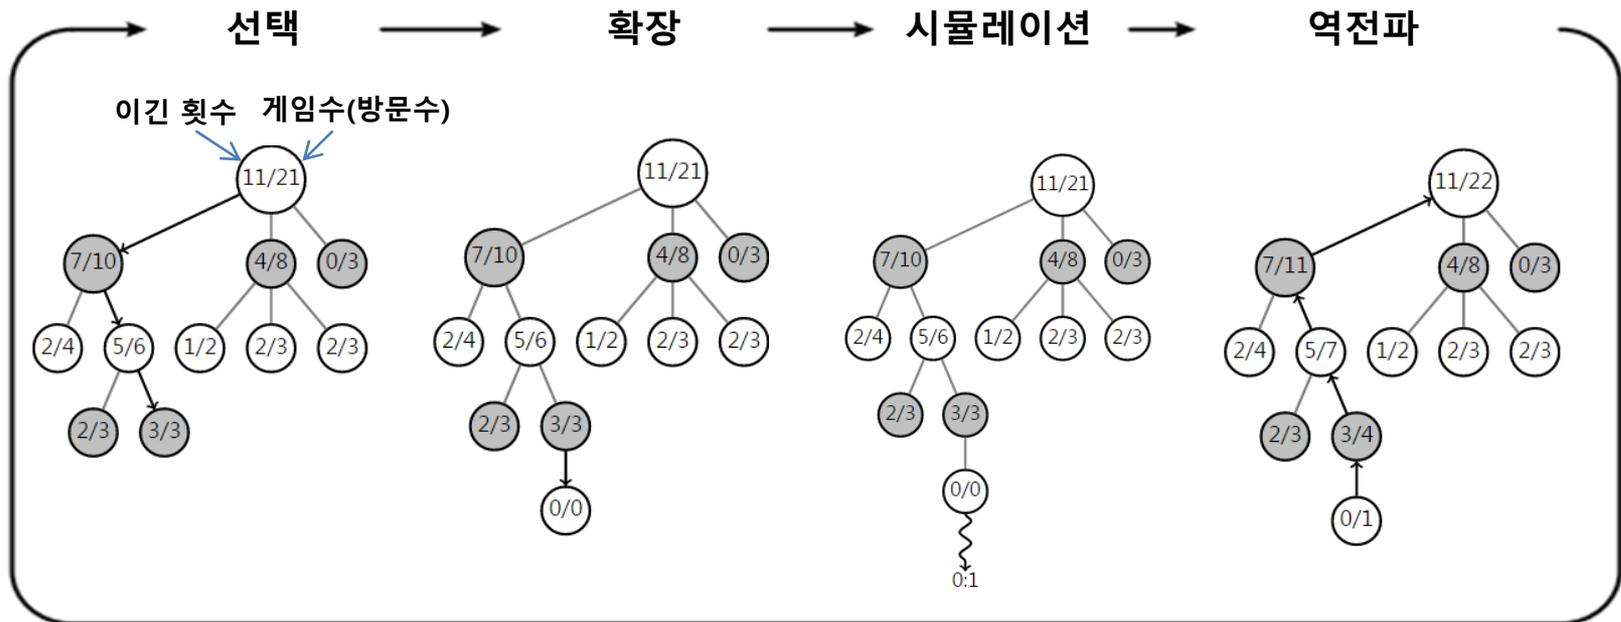
- 탐색 공간(search space)을 무작위 표본추출(random sampling)을 하면서, 탐색트리를 확장하여 가장 좋아 보이는 것을 선택하는 휴리스틱 탐색 방법
- 4개 단계를 반복하여 시간이 허용하는 동안 트리 확장 및 시뮬레이션

**선택(selection)**

→ **확장(expansion)**

→ **시뮬레이션(simulation)** : 몬테카를로 시뮬레이션

→ **역전파(back propagation)**



# 게임에서의 탐색

## ❖ 몬테카를로 트리 탐색 - cont.

- **선택(selection)** : 트리 정책(tree policy) 적용
  - 루트노드에서 시작
  - 정책에 따라 자식 노드를 선택하여 단말노드까지 내려 감
    - 승률과 노드 방문횟수 고려하여 선택
    - **UCB(Upper Confidence Bound) 정책** : UCB가 큰 것 선택

$$\frac{Q(v')}{N(v')} + c\sqrt{\frac{2\ln N(v)}{N(v')}}$$

$v$  : 부모노드,  $v'$  : 자식노드  
 $N(v')$  : 방문 횟수  
 $Q(v')$  : 점수 (이긴 횟수)

활용(exploitation)    탐험(exploration)  
 확장                      시뮬레이션

선택

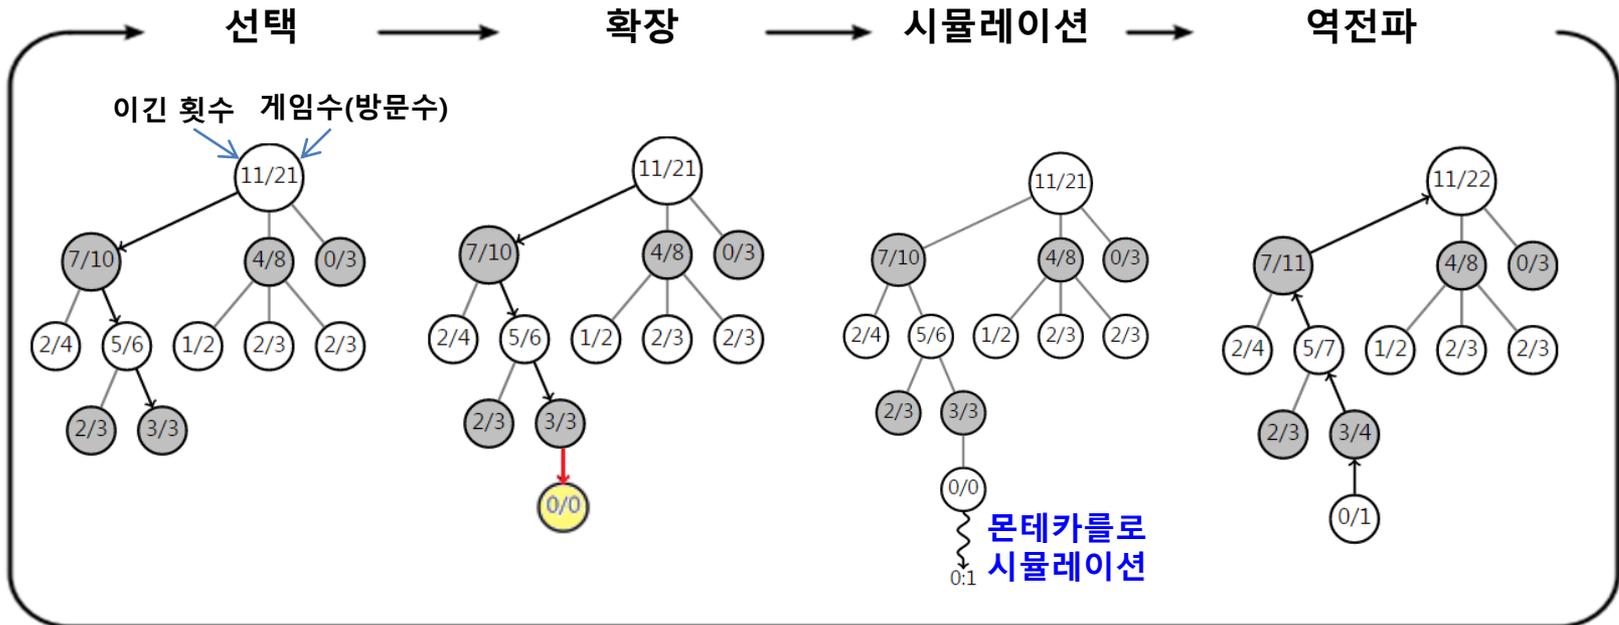
역전파



# 게임에서의 탐색

## ❖ 몬테카를로 트리 탐색 - cont.

- **확장(expansion)**
  - 단말노드에서 트리 정책에 따라 노드 추가
    - 예. 일정 횟수이상 시도된 수(move)가 있으면 해당 수에 대한 노드 추가
- **시뮬레이션(simulation)**
  - 기본 정책(default policy)에 의한 몬테카를로 시뮬레이션 적용
  - 무작위 선택(random moves) 또는 약간 똑똑한 방법으로 게임 끝날 때까지 진행
- **역전파(backpropagation)**
  - 단말 노드에서 루트 노드까지 올라가면서 승점 반영



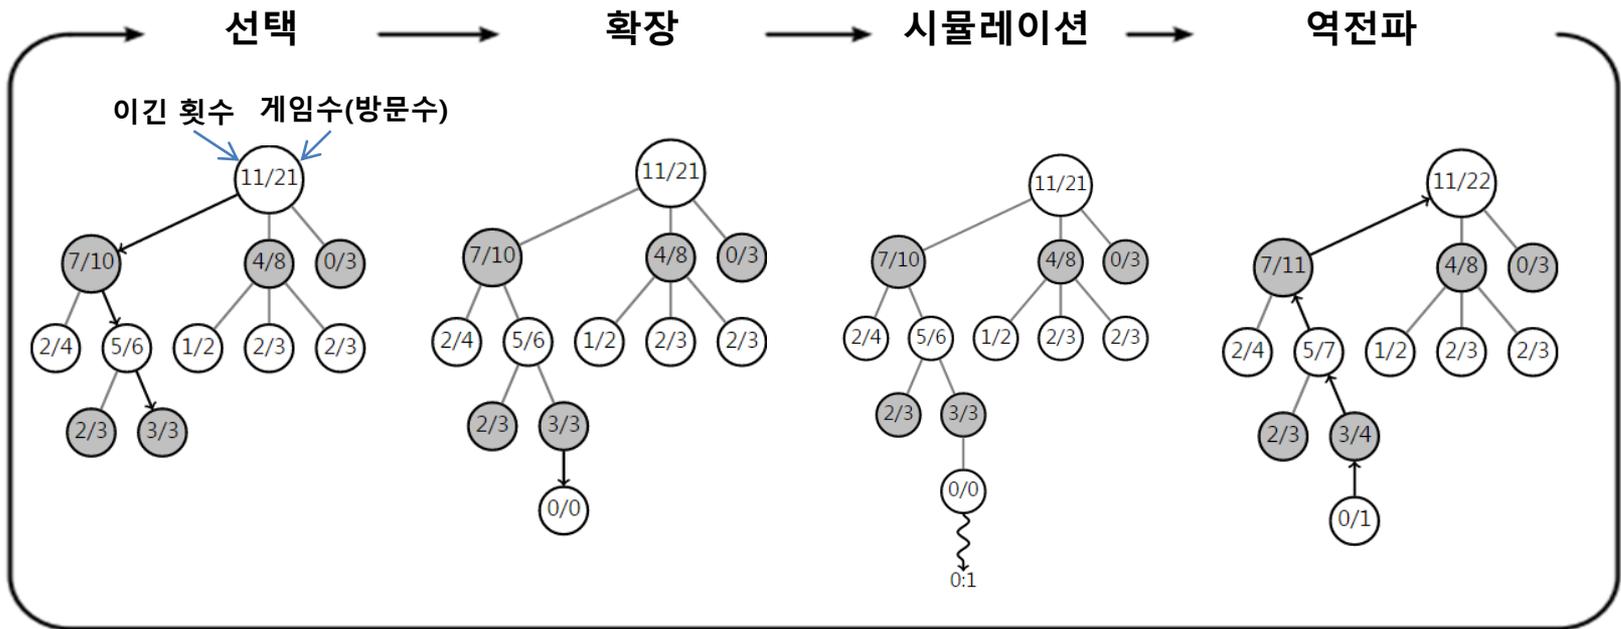
# 몬테카를로 트리 탐색

## ❖ 몬테카를로 트리 탐색 - cont.

### ▪ 동작 선택 방법

- 가장 승률이 높은, 루트의 자식 노드 선택
- 가장 빈번하게 방문한, 루트의 자식 노드 선택
- 승률과 빈도가 가장 큰, 루트의 자식 노드 선택  
없으면, 조건을 만족하는 것이 나올 때까지 탐색 반복
- 자식 노드의 **confidence bound**값의 **최소값이 가장 큰**, 루트의 자식 노드 선택

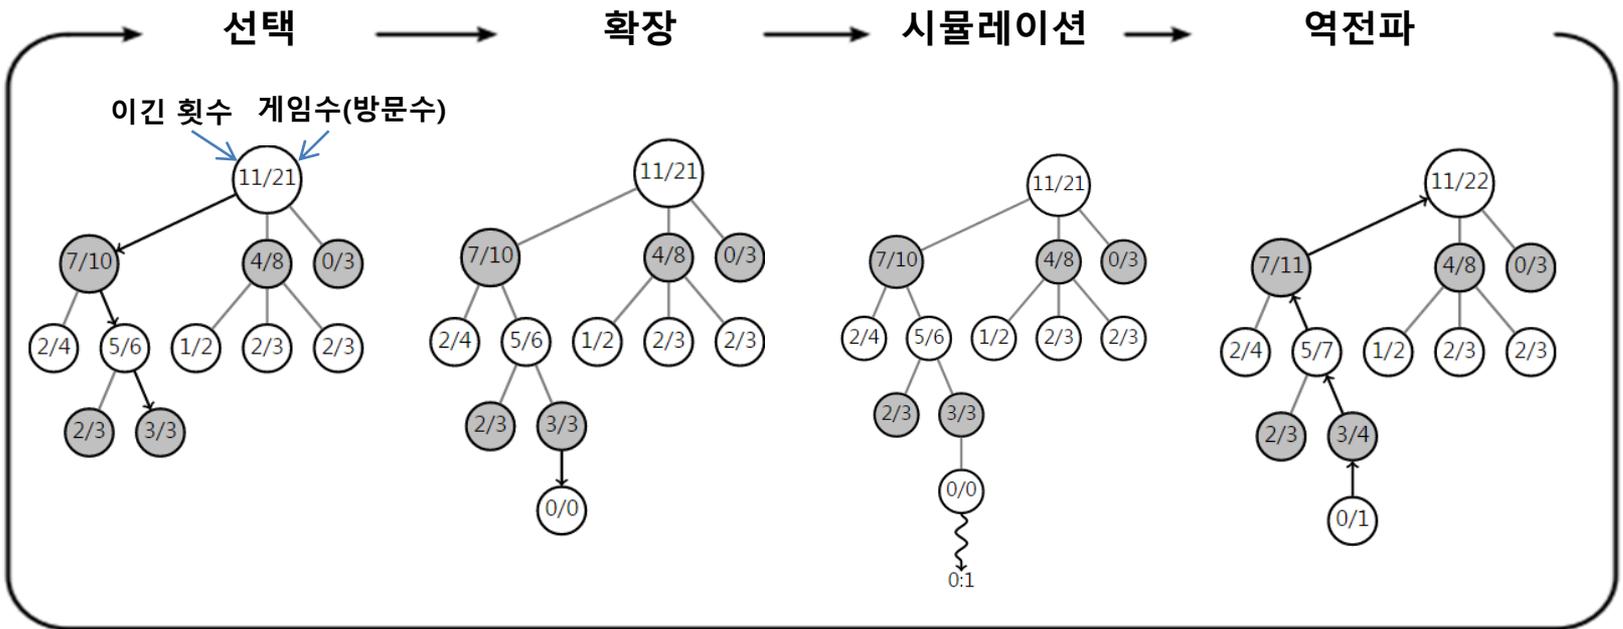
$$\frac{Q(v')}{N(v')} + c\sqrt{\frac{2 \ln N(v)}{N(v')}}$$



# 몬테카를로 트리 탐색

## ❖ 몬테카를로 트리 검색 - cont.

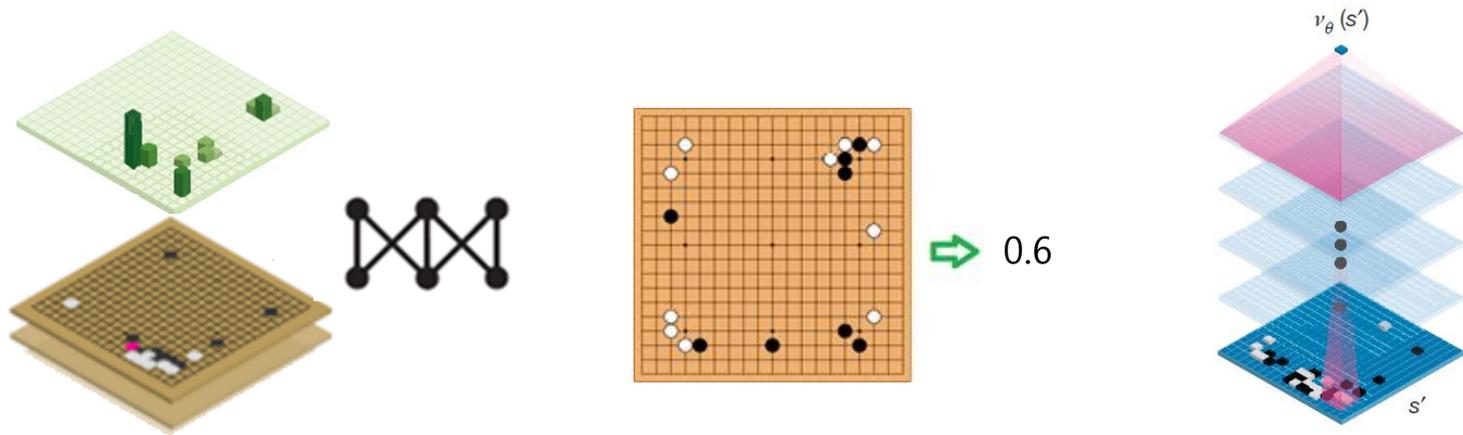
- 판의 형세판단을 위해 휴리스틱을 사용하는 대신, 가능한 많은 수의 몬테카를로 시뮬레이션 수행
- 일정 조건을 만족하는 부분은 트리로 구성하고, 나머지 부분은 몬테카를로 시뮬레이션
  - 가능성이 높은 수(move)들에 대해서 노드를 생성하여 트리의 탐색 폭을 줄이고, 트리 깊이를 늘리지 않기 위해 몬테카를로 시뮬레이션을 적용
  - 탐색 공간 축소



# 알파고의 탐색

## ❖ 알파고의 몬테카를로 트리 검색

- 바둑판 형세 판단을 위한 한가지 방법으로 몬테카를로 트리 검색 사용
- 무작위로 바둑을 두는 것이 아니라, 프로 바둑기사들을 기보를 학습한 확장 정책망(rollout policy network)이라는 간단한 계산모델을 사용



**정책망** : 가능한 착수(着手)들에 대한 선호 확률분포

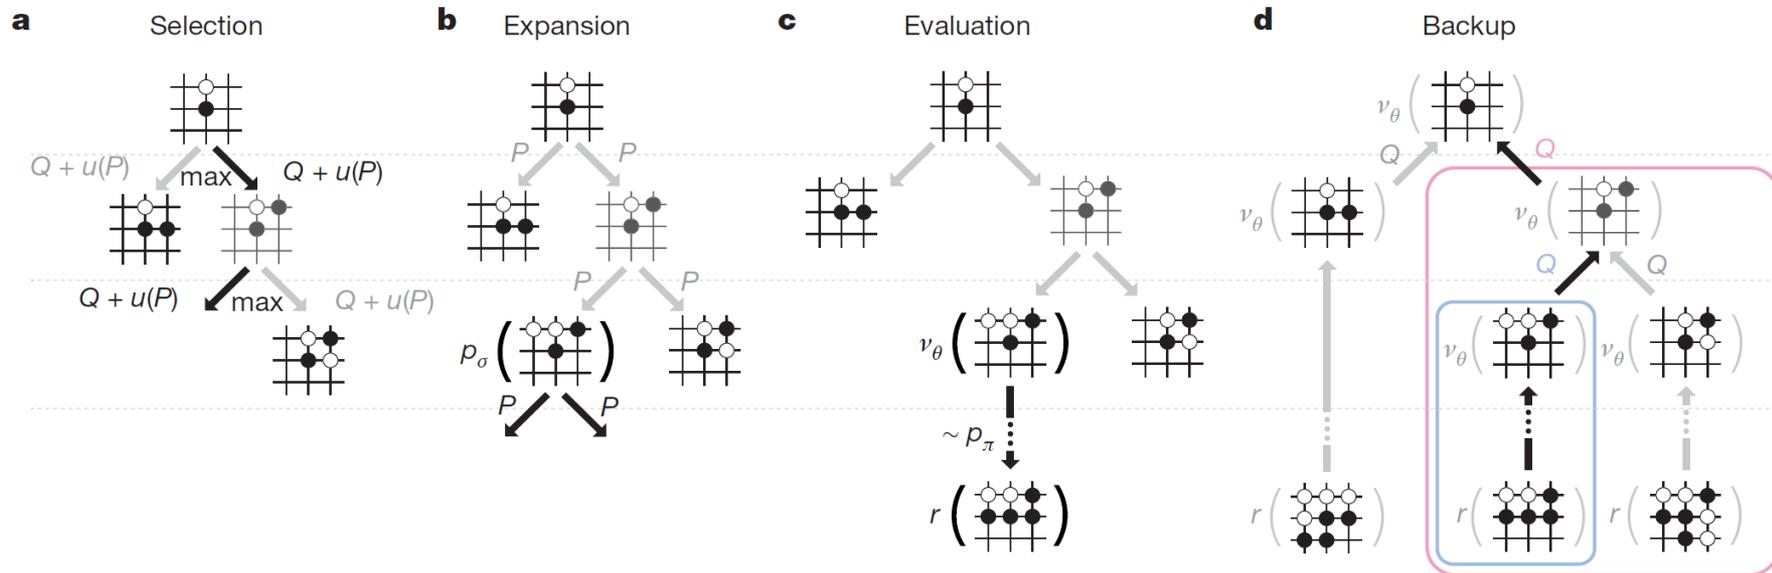
**가치망** : 바둑판의 형세 값을 계산하는 계산모델

- 확률에 따라 착수를 하여 몬테카를로 시뮬레이션을 반복하여 해당 바둑판에 대한 형세판단값 계산
- 별도로 학습된 딥러닝 신경망인 가치망(value network)을 사용하여 형세판단값을 계산하여 함께 사용

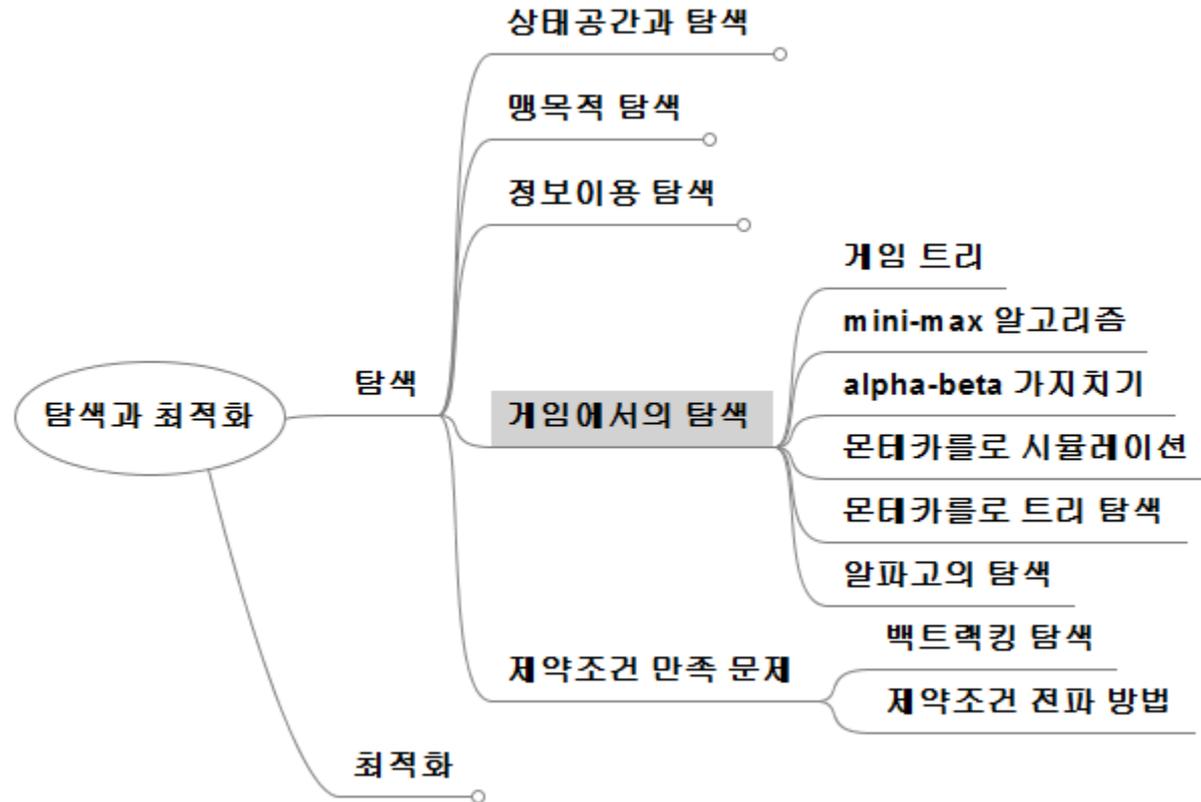
# 알파고의 탐색

## ❖ 알파고의 몬테카를로 트리 검색

- 많은 수의 몬테카를로 시뮬레이션과 딥러닝 모델의 신속한 계산을 위해 다수의 CPU와 GPU를 이용한 분산처리



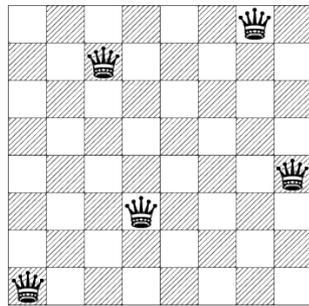
# 게임에서의 탐색



# 5. 제약조건 만족 문제

## ❖ 제약조건 만족 문제(constraint satisfaction problem)

- 주어진 제약조건을 만족하는 **조합 해**(combinatorial solution)를 찾는 문제
- 예. 8-퀸(queen) 문제



### ▪ 탐색 기반의 해결방법

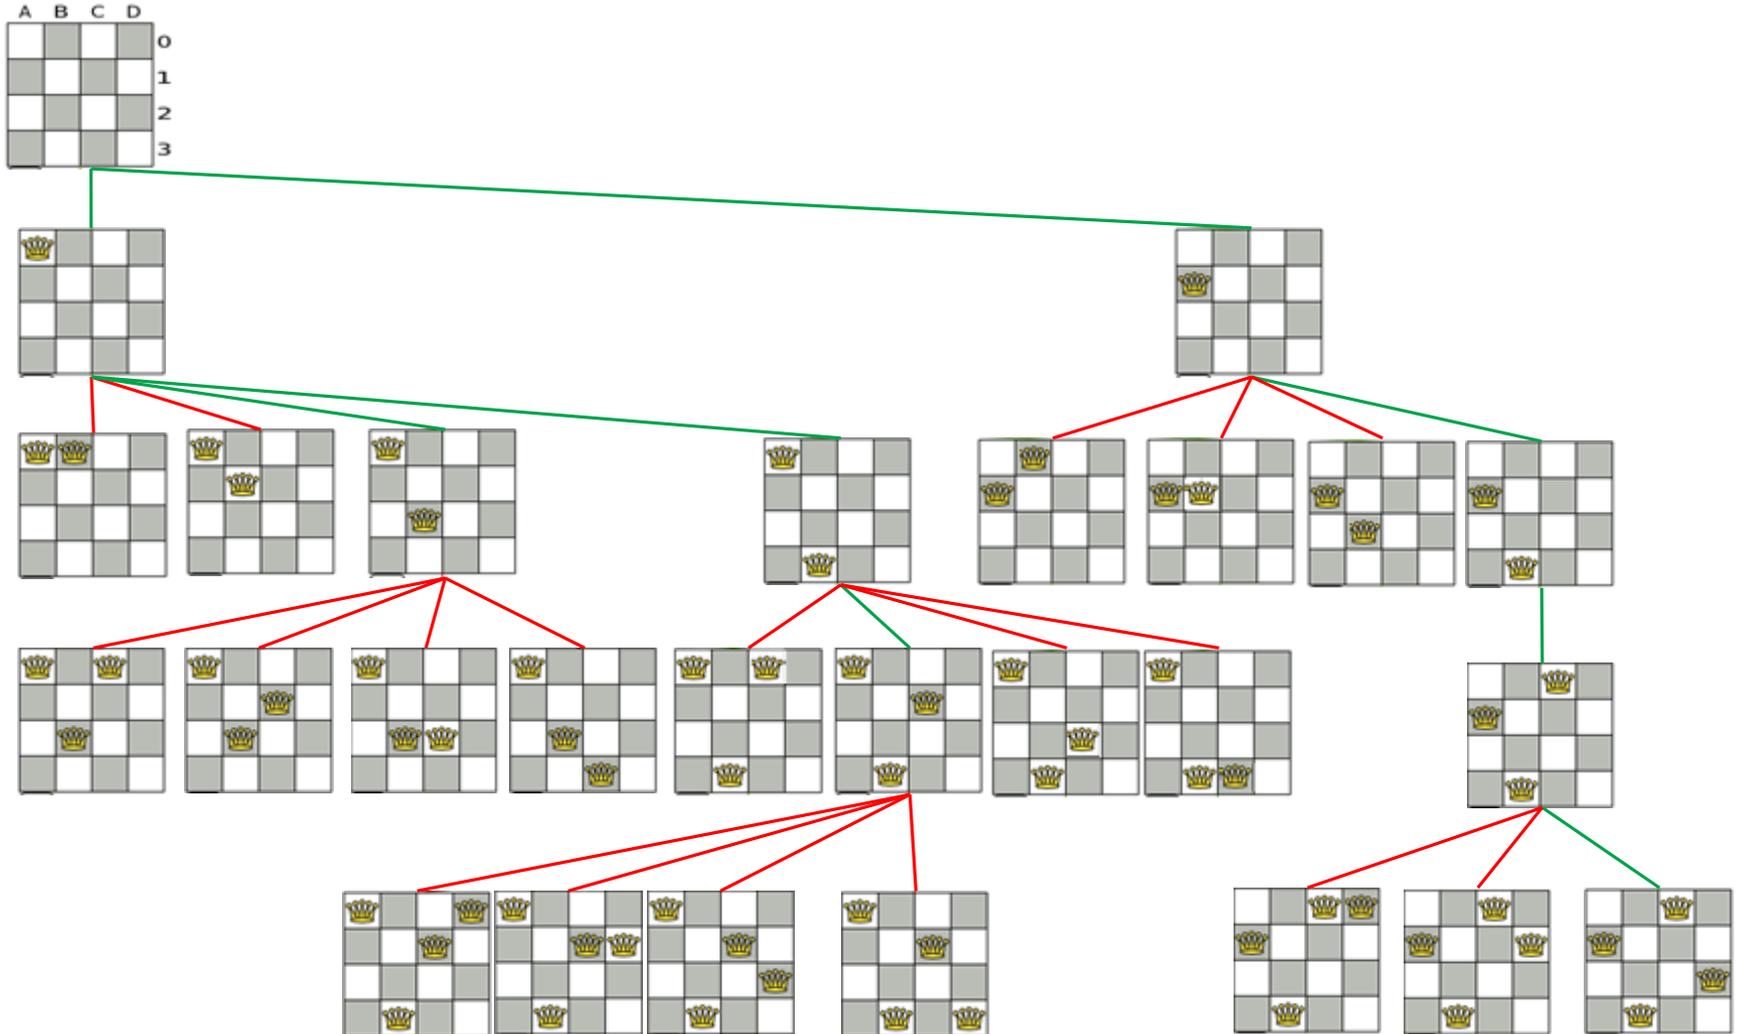
- 백트래킹 탐색
- 제약조건 전파

### ▪ 백트래킹 탐색(backtracking search)

- 깊이 우선 탐색을 하는 것처럼 변수에 허용되는 값을 하나씩 대입
- 모든 가능한 값을 대입해서 만족하는 것이 없으면 이전 단계로 돌아가서 이전 단계의 변수에 다른 값을 대입

# 제약조건 만족 문제

❖ 예. 백트래킹 탐색을 이용한 4-퀸(queen) 문제

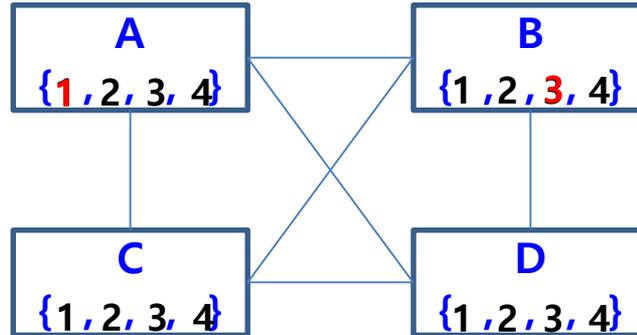


# 제약조건 만족 문제

## ❖ 제약조건 전파(constraint propagation)

- 인접 변수 간의 제약 조건에 따라 각 변수에 허용될 수 없는 값들을 제거하는 방식

	A	B	C	D
1		X	X	X
2		X	X	
3			X	X
4			X	X

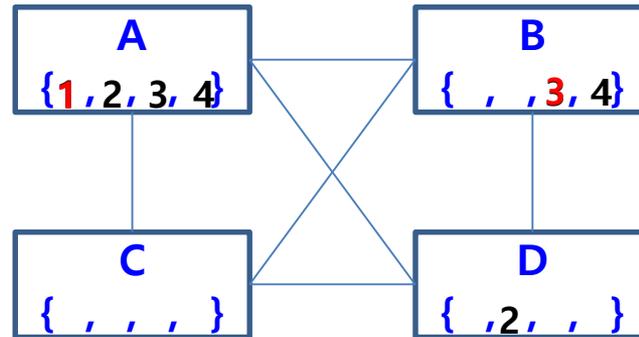


# 제약조건 만족 문제

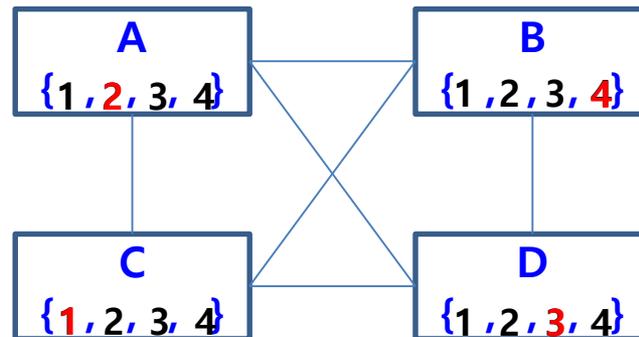
## ❖ 제약조건 전파(constraint propagation)

- 인접 변수 간의 제약 조건에 따라 각 변수에 허용될 수 없는 값들을 제거하는 방식

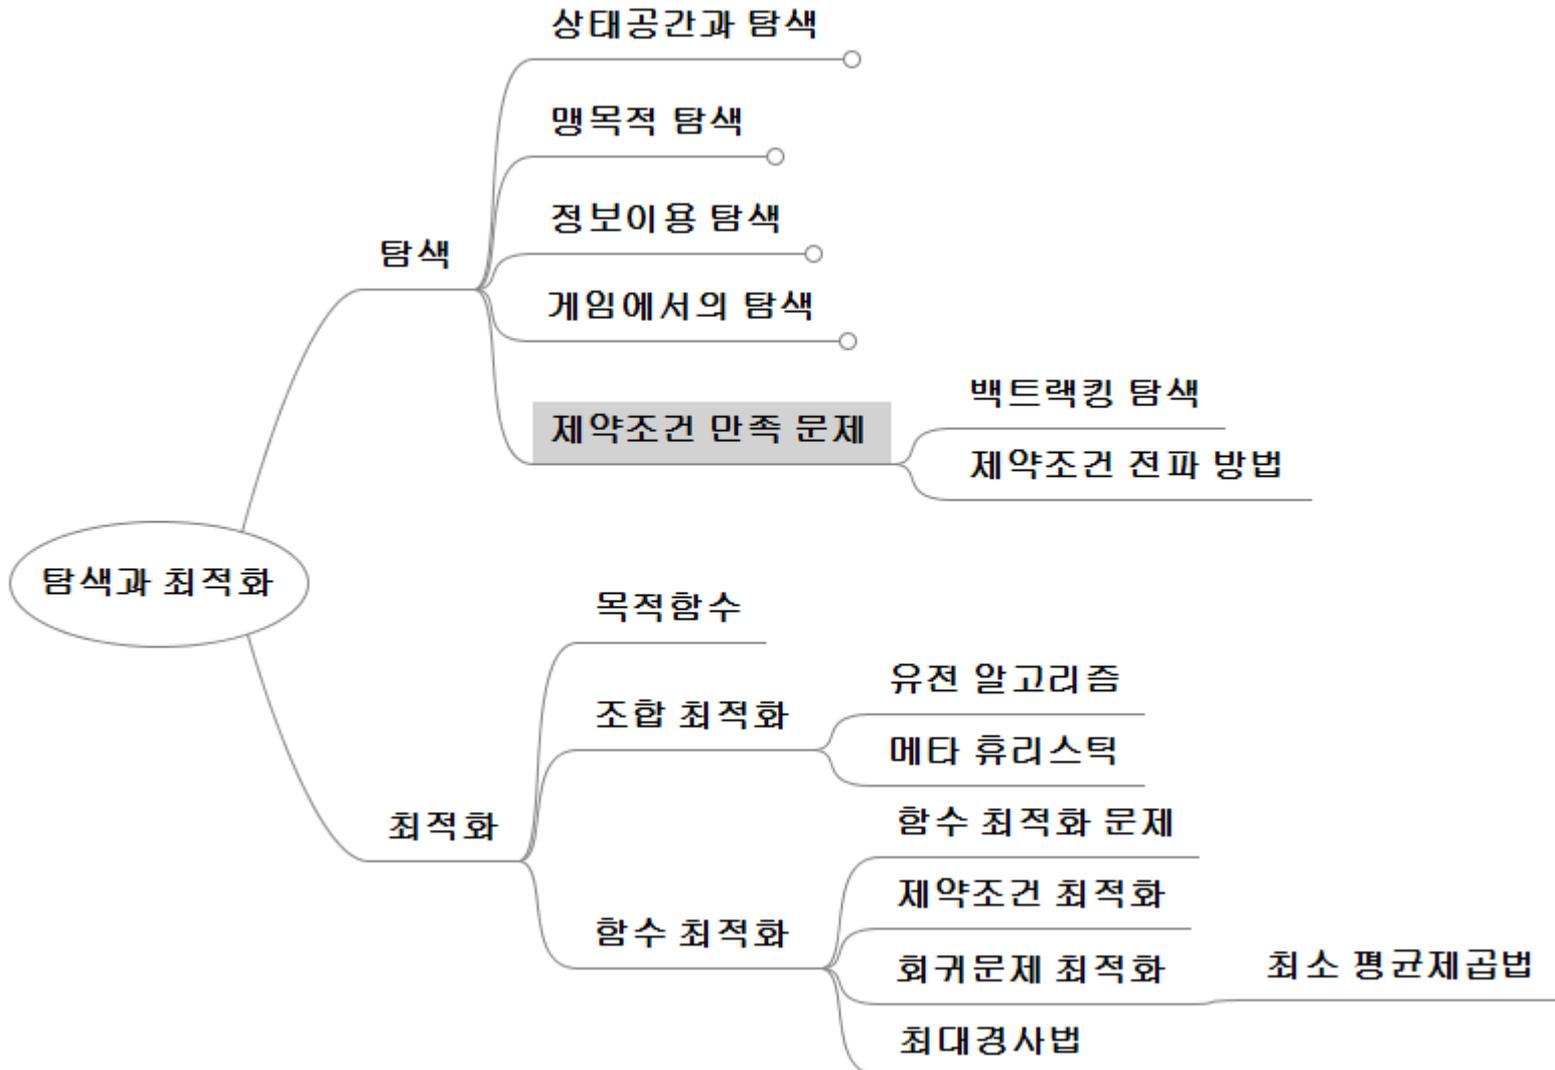
	A	B	C	D
1	♔	×	×	×
2	♚	×	×	
3		♔	×	×
4	♚		×	×



	A	B	C	D
1		×	♔	×
2	♔	×	×	×
3		×	×	♔
4	♚	♔	×	×



# 제약조건 만족 문제



# 6. 최적화

## ❖ 최적화(optimization)

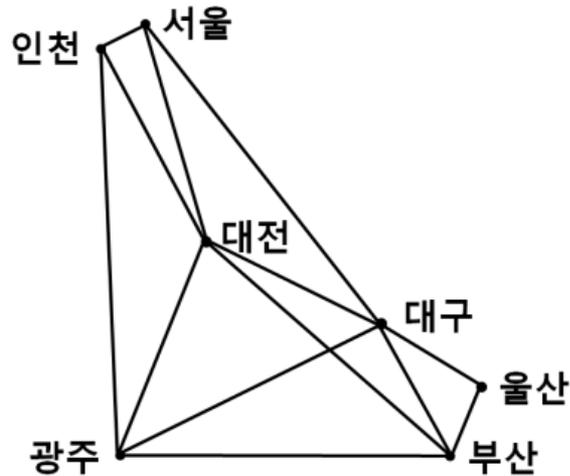
- 여러 가지 허용되는 값들 중에서 주어진 기준을 가장 잘 만족하는 것을 선택하는 것
- **목적함수**(objective function)
  - 최소 또는 최대가 되도록 만들려는 함수
- **조합 최적화**
  - 유전 알고리즘
- **함수 최적화**
  - 최대 경사법
  - 제약 함수 최적화

# 조합 최적화

## ❖ 조합 최적화(combinatorial optimization)

- 순회 판매자 문제(TSP)와 같이 주어진 항목들의 조합으로 해가 표현되는 최적화 문제

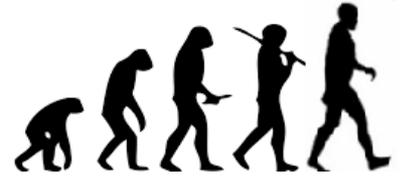
- 순회 판매자 문제의 목적함수 : 경로의 길이



(서울, 인천, 광주, 부산, 울산, 대전, 서울)

(서울, 인천, 대전, 광주, 부산, 울산, 서울)

# 유전 알고리즘

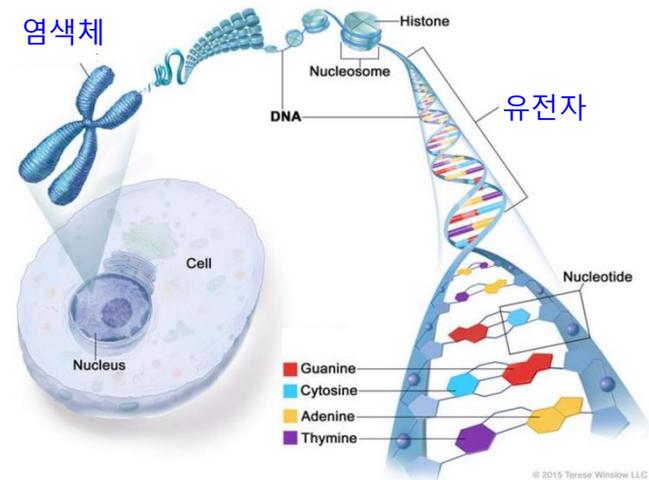


## ❖ 유전 알고리즘 (genetic algorithm, GA)

- 생물의 진화를 모방한 집단 기반의 확률적 탐색 기법(John Holland, 1975)
- 대표적인 진화 연산(evolutionary computation)의 하나
  - 유전 알고리즘, 유전자 프로그래밍(genetic programming), 진화 전략(evolutionary strategy)

## ▪ 생물의 진화

- 염색체(chromosome)의 유전자(gene)들이 개체 정보 코딩
- 적자생존(fittest survival)/자연선택(natural selection)
  - 환경에 적합도가 높은 개체의 높은 생존 및 후손 번성 가능성
  - 우수 개체들의 높은 자손 증식 기회
  - 열등 개체들도 작지만 증식 기회
- 집단(population)의 진화
  - 세대(generation) 집단의 변화
- 형질 유전과 변이
  - 부모 유전자들의 교차(crossover) 상속
  - 돌연변이(mutation)에 의한 변이

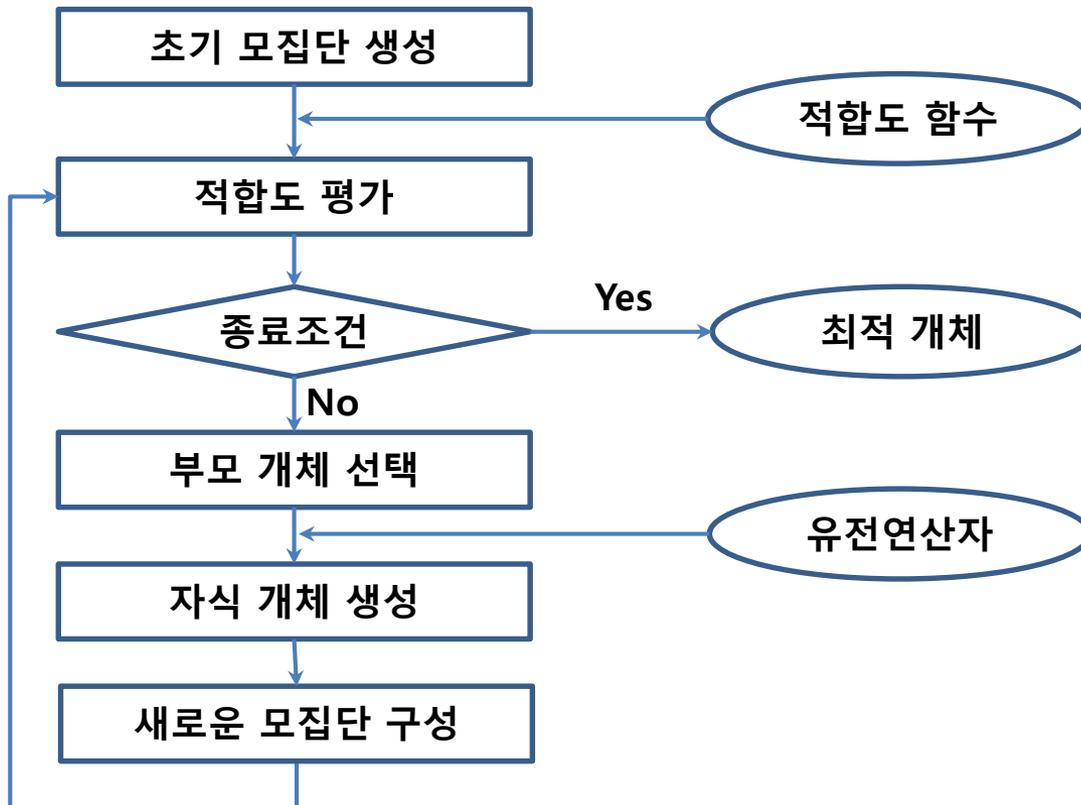


# 유전 알고리즘

## ❖ 유전 알고리즘 – cont.

### ▪ 생물 진화와 문제 해결

- 개체  $\Leftrightarrow$  후보 해(candidate solution)
- 환경  $\Leftrightarrow$  문제(problem)
- 적합도  $\Leftrightarrow$  해의 품질(quality)



# 유전 알고리즘

## ❖ 유전 알고리즘 – cont.

- 후보해(candidate solution) 표현
  - 염색체(chromosome) 표현

1	0	1	1	0	1	0	0	0	0	1	0	1	0	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

(0.6 0.8 ... 1.2 0.9)

(E2 E5 E3 ... E11 E7)

- 모집단(population)
  - 동시에 존재하는 염색체들의 집합
- 적합도 함수(fitness function)
  - 후보해가 문제의 해(solution)로서 적합한 정도를 평가하는 함수

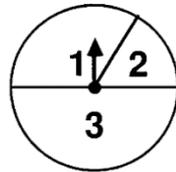
# 유전 알고리즘

## ❖ 유전 알고리즘 – cont.

### ▪ 부모 개체 선택(selection)

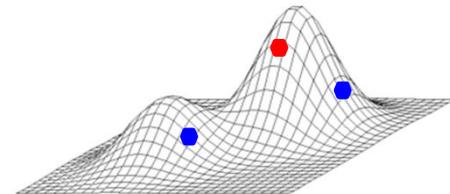
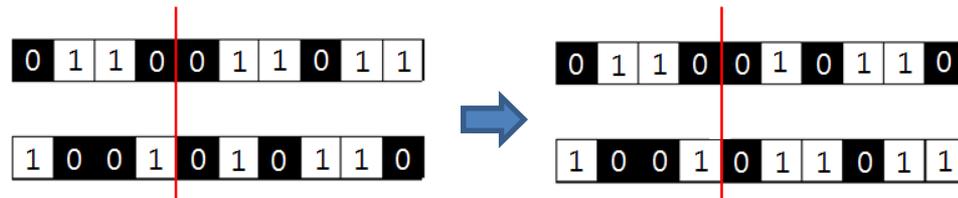
- 높은 적합도의 개체가 새로운 개체를 생성할 확률이 높도록 함
- 적합도에 비례하는 **선택확률**

– 예. 개체 1의 적합도: 10, 개체 2의 적합도: 5, 개체 3의 적합도: 15

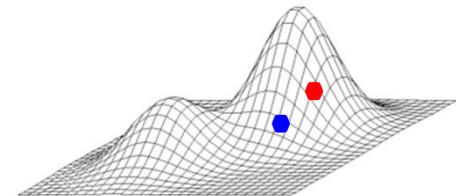


### ▪ 유전 연산자(genetic operator) : 새로운 개체 생성

#### • 교차(crossover) 연산자



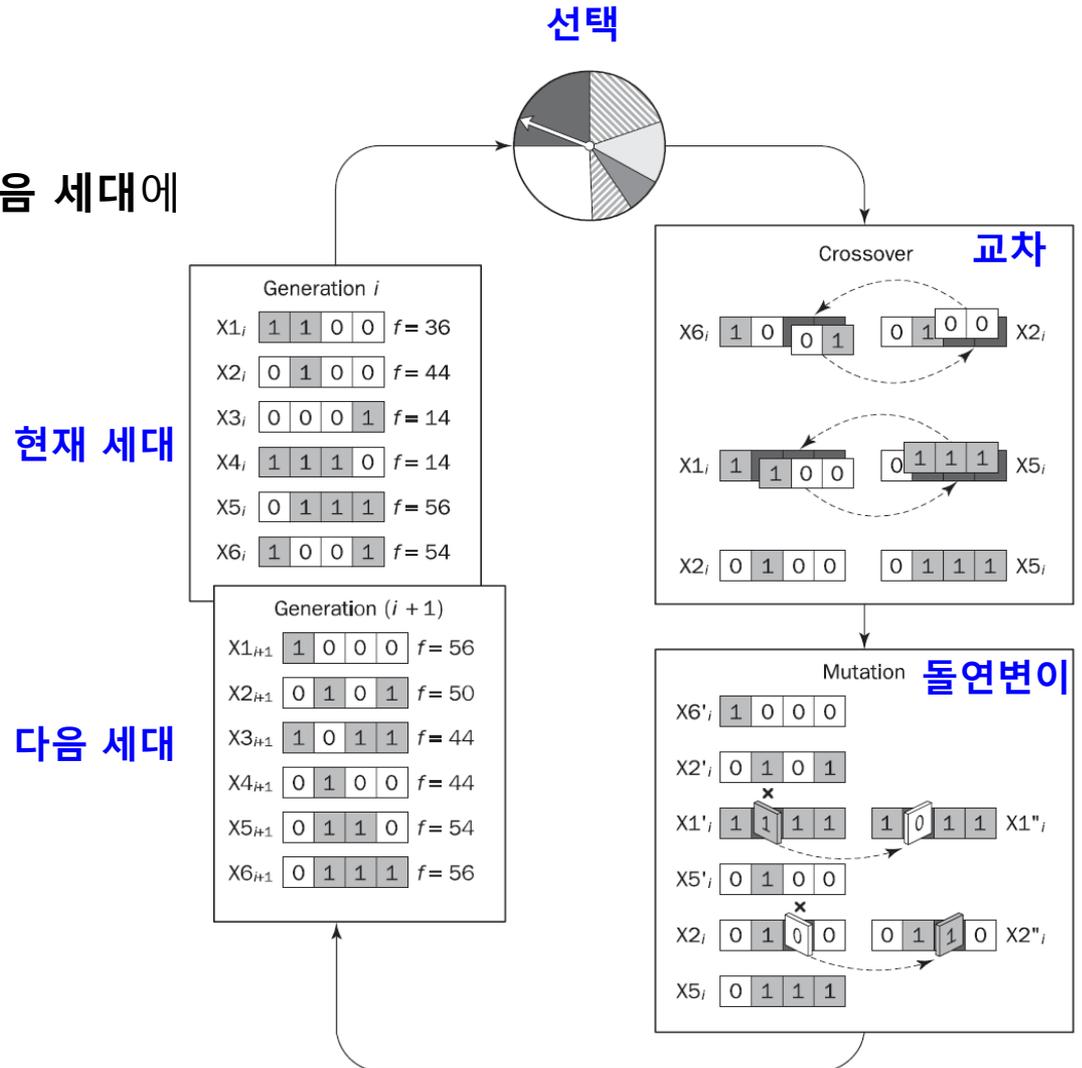
#### • 돌연변이(mutation) 연산자



# 유전 알고리즘

## ❖ 유전 알고리즘 – cont.

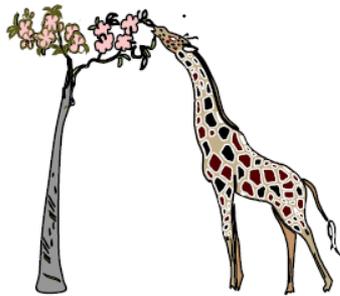
- 세대(generation) 교체
  - 엘리트주의(elitism)
    - 우수한 개체를 다음 세대에 유지



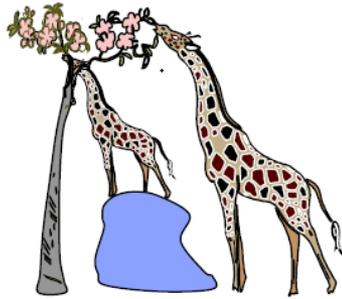
# 메타 휴리스틱

## ❖ 메타 휴리스틱(meta heuristics)

- 최적해는 아니지만 우수한 해를 빠르게 찾기 위한 휴리스틱적인 문제해결 전략
- 유전 알고리즘 (genetic algorithm)
- 모방 알고리즘(memetic algorithm)
- 입자 군집 최적화(particle swarm optimization, PSO)
- 개미 집단(ant colony) 알고리즘
- 타부 탐색(Tabu search)
- 담금질 기법(simulated annealing)
- 하모니 탐색(Harmonic search)
- 유전 프로그래밍(genetic programming)



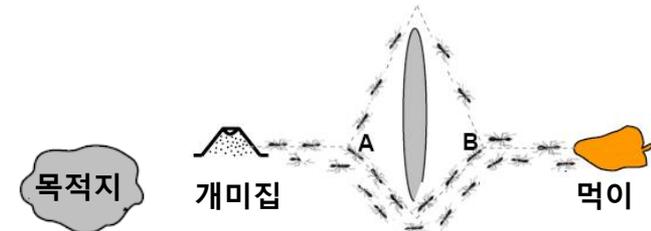
유전 알고리즘



모방 알고리즘

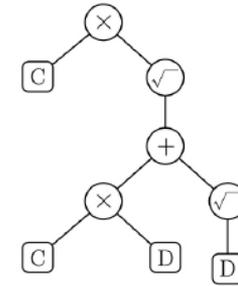


입자 군집 최적화



개미집단 알고리즘

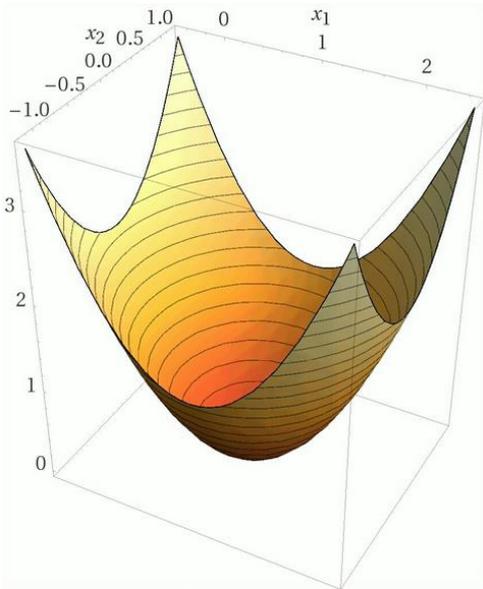
image source: Tarek Hegazy



# 함수 최적화

## ❖ 함수 최적화(function optimization)

- 어떤 목적 함수(objective function)가 있을 때, 이 함수를 **최대로** 하거나 **최소**로 하는 **변수 값**를 찾는 최적화 문제



Find  $x_1, x_2$

which minimizes  $f(x_1, x_2) = (x_1 - 1)^2 + x_2^2$

목적함수 (objective function)

$$\frac{\partial f(x_1, x_2)}{\partial x_1} = 2x_1 - 2 = 0 \quad x_1 = 1$$

$$\frac{\partial f(x_1, x_2)}{\partial x_2} = 2x_2 = 0 \quad x_2 = 0$$

$$(x_1^*, x_2^*) = (1, 0)$$

# 함수 최적화

## ❖ 제약조건 최적화(constrained optimization)

- 제약조건(constraints)을 만족시키면서 목적함수를 최적화시키는 변수값들을 찾는 문제

Find  $x_1, x_2$

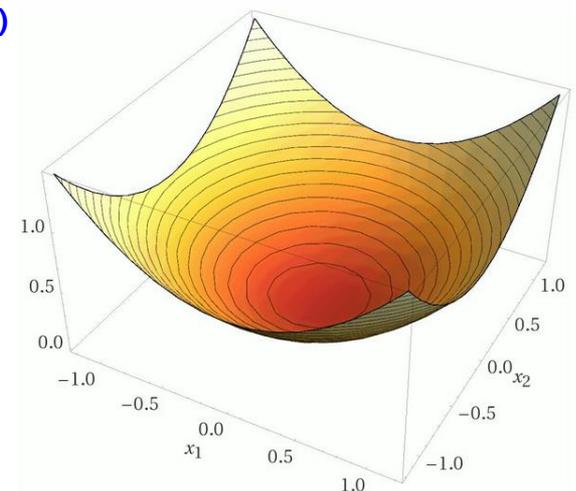
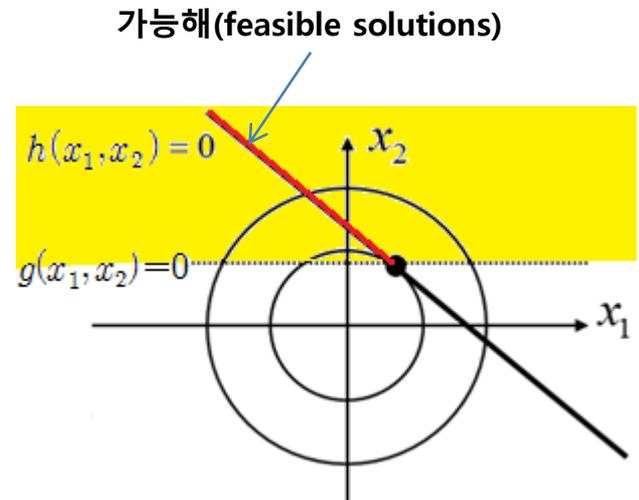
which minimizes  $f(x_1, x_2) = \frac{1}{2}(x_1^2 + x_2^2)$

subject to  $h(x_1, x_2) = 1 - x_1 - x_2 = 0$

$$g(x_1, x_2) = \frac{3}{4} - x_2 \leq 0$$

제약조건  
(constraints)

- 기계학습 방법인 SVM의 학습에서 사용



# 함수 최적화

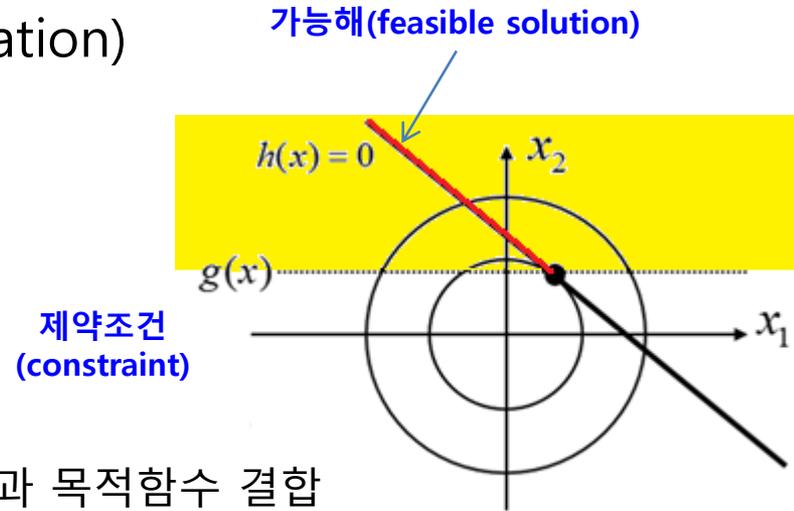
## ❖ 제약조건 최적화(constrained optimization)

Find  $x_1, x_2$

which minimizes  $f(x_1, x_2) = \frac{1}{2}(x_1^2 + x_2^2)$

subject to  $h(x_1, x_2) = 1 - x_1 - x_2 = 0$

$$g(x_1, x_2) = \frac{3}{4} - x_2 \leq 0$$



### ■ 라그랑주(Lagrange) 함수 : 제약조건들과 목적함수 결합

$L(x_1, x_2, \lambda, \alpha) = f(x_1, x_2) + \lambda h(x_1, x_2) + \alpha g(x_1, x_2)$        $\lambda, \alpha$  : 라그랑주 승수(Lagrange multiplier)

$$= \frac{1}{2}(x_1^2 + x_2^2) + \lambda(1 - x_1 - x_2) + \alpha\left(\frac{3}{4} - x_2\right) \quad (\alpha \geq 0)$$

### ■ 최적화 방법

$\min_{x_1, x_2 \in FS} f(x_1, x_2) = \min_{x_1, x_2} \max_{\lambda, \alpha} L(x_1, x_2, \lambda, \alpha)$        $FS$  : 가능해(feasible solution)의 집합

$\min_{x_1, x_2} \max_{\lambda, \alpha} L(x_1, x_2, \lambda, \alpha) \geq \max_{\lambda, \alpha} \min_{x_1, x_2} L(x_1, x_2, \lambda, \alpha)$        $L_d(\lambda, \alpha) = \min_{x_1, x_2} L(x_1, x_2, \lambda, \alpha)$   
 $\geq \max_{\lambda, \alpha} L_d(\lambda, \alpha)$       **쌍대함수(dual function)**

- 쌍대함수를 최대화하면서 상보적 여유성을 만족하는  $x_1, x_2$ 를 구함       $\alpha g(x_1, x_2) = 0$   
**상보적 여유성(complementary slackness)**

# 함수 최적화

❖ 제약조건 최적화(constrained optimization) – cont.

$$L(x_1, x_2, \lambda, \alpha) = \frac{1}{2}(x_1^2 + x_2^2) + \lambda(1 - x_1 - x_2) + \alpha\left(\frac{3}{4} - x_2\right)$$

$$L_d(\lambda, \alpha) = \min_{x_1, x_2} L(x_1, x_2, \lambda, \alpha)$$

$$\frac{\partial L(x_1, x_2, \lambda, \alpha)}{\partial x_1} = x_1 - \lambda = 0 \quad x_1 = \lambda$$

$$\frac{\partial L(x_1, x_2, \lambda, \alpha)}{\partial x_2} = x_2 - \lambda - \alpha = 0 \quad x_2 = \lambda + \alpha$$

$$L_d(\lambda, \alpha) = -\lambda^2 - \frac{1}{2}\alpha^2 - \lambda\alpha + \lambda + \frac{3}{4}\alpha$$

$$\max_{\lambda, \alpha} L_d(\lambda, \alpha)$$

$$\frac{\partial L_d(\lambda, \alpha)}{\partial \lambda} = -2\lambda - \alpha + 1 = 0 \quad \frac{\partial L_d(\lambda, \alpha)}{\partial \alpha} = -\alpha - \lambda + \frac{3}{4} = 0$$

$$\lambda = \frac{1}{4} \quad \alpha = \frac{1}{2} \quad \alpha\left(\frac{3}{4} - x_2\right) = 0 \quad x_2 = \frac{3}{4} \quad 1 - x_1 - x_2 = 0 \quad x_1 = \frac{1}{4}$$

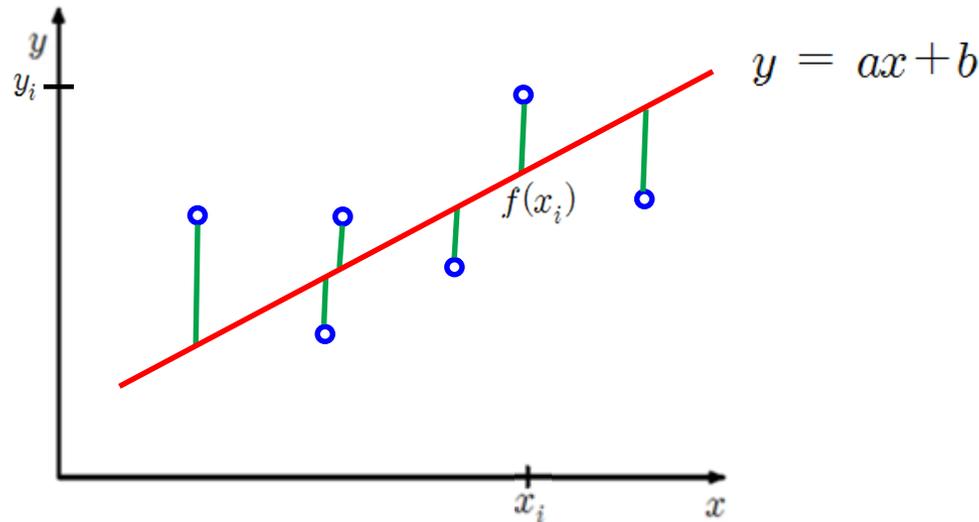
$$\therefore x_1 = \frac{1}{4} \quad x_2 = \frac{3}{4}$$

# 함수 최적화

## ❖ 회귀(regression) 문제의 최적 함수

- 주어진 데이터를 가장 잘 근사(近似, approximation)하는 함수
- **최소 평균제곱법**(least mean square method)
  - 오차 함수(error function) 또는 **에너지 함수**(energy function)를 최소화 하는 함수를 찾는 방법

$$E = \frac{1}{2N} \sum_{i=1}^N (y_i - f(x_i))^2$$



## • 최적화 문제

Find  $a, b$  which minimizes  $\min_{a,b} \frac{1}{2N} \sum_{i=1}^N (y_i - ax_i - b)^2$

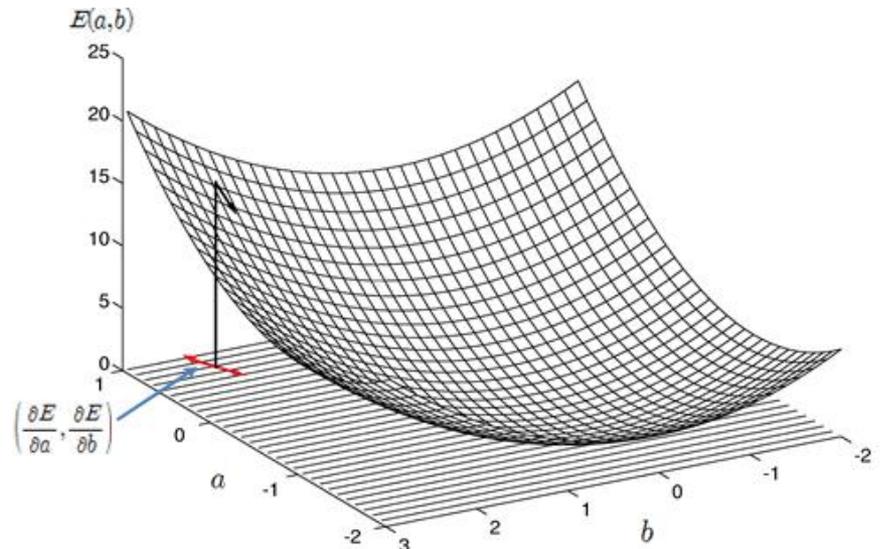
# 함수 최적화

## ❖ 경사 하강법 (gradient descent method)

- 함수의 **최소값 위치**를 찾는 문제에서 오차 함수의 **그레디언트** (gradient) 반대 방향으로 조금씩 움직여 가며 최적의 파라미터를 찾으려는 방법
- **그레디언트**
  - 각 파라미터에 대해 편미분한 벡터  $\left(\frac{\partial E}{\partial a}, \frac{\partial E}{\partial b}\right)$
- 데이터의 입력과 출력을 이용하여 각 파라미터에 대한 그레디언트를 계산하여 **파라미터를 반복적으로 조금씩 조정**

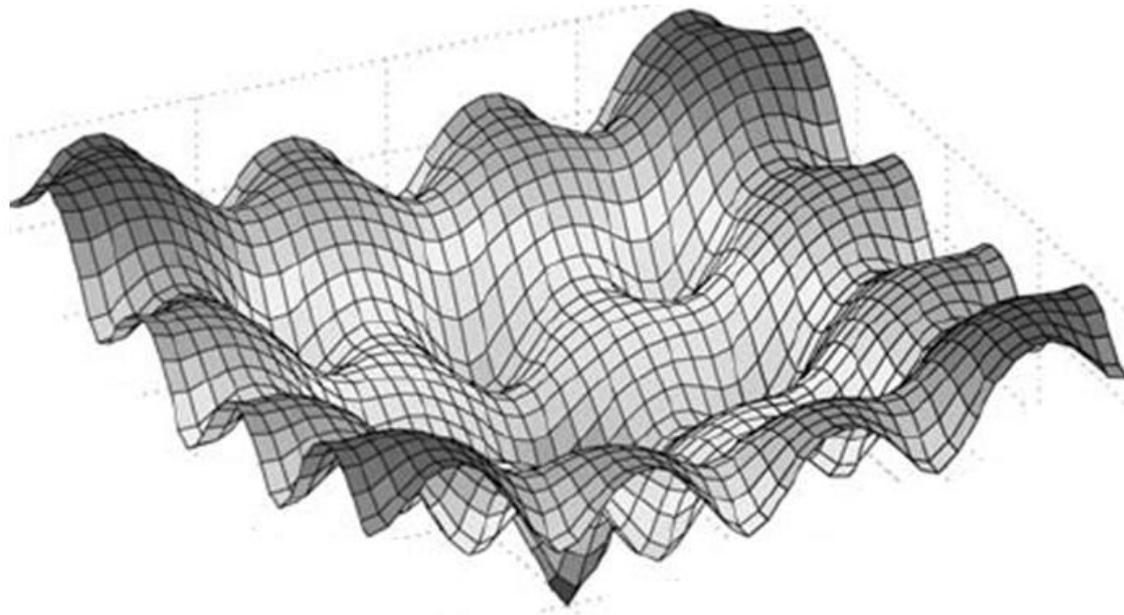
$$a^{(t+1)} = a^{(t)} - \eta \frac{\partial E}{\partial a}$$

$a^{(t)}$ : 현 시점에서 파라미터  $a$ 의 값  
 $\eta$ : 학습율 ( $0 < \eta < 1$ )



# 함수 최적화

- ❖ **최대 경사법**(gradient descent method)
  - 회귀 모델, 신경망 등의 기본 학습 방법
  - 국소해(local minima)에 빠질 위험
  - 개선된 형태의 여러 방법 존재



# 요약

## ❖ 탐색

- 상태공간과 탐색
  - 상태 공간, 상태 공간 그래프
- 맹목적 탐색
  - 깊이 우선 탐색, 너비 우선 탐색, 반복적 깊이 심화 탐색, 양방향 탐색
- 정보이용 탐색
  - 휴리스틱, 언덕 오르기 방법, 최상우선 탐색, 빔탐색, A\* 알고리즘
- 게임에서의 탐색
  - 게임트리, mini-max 알고리즘,  $\alpha$ - $\beta$  가지치기, 몬테카를로 트리 탐색
- 제약조건 만족 문제
  - 백트래킹 탐색, 제약조건 전파 방법

## ❖ 최적화

- 조합 최적화
  - 유전 알고리즘, 메타 휴리스틱
- 함수 최적화
  - 함수 최적화 문제, 제약조건 최적화, 경사하강법