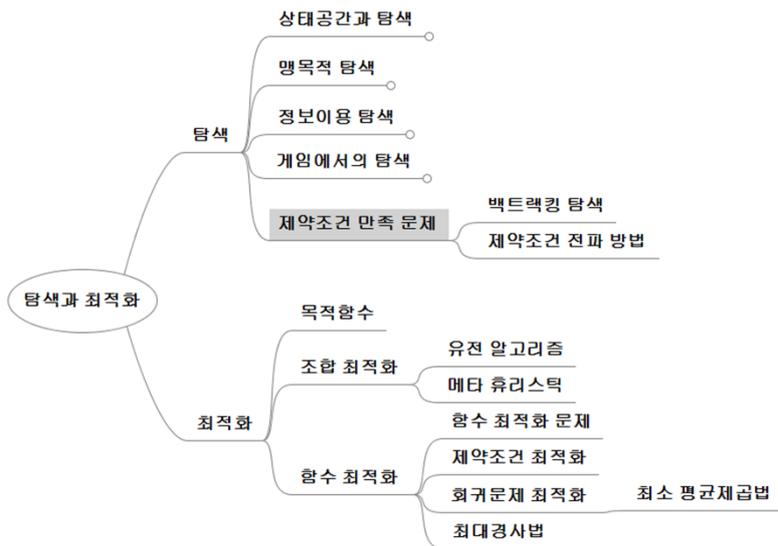


탐색과 최적화 - II

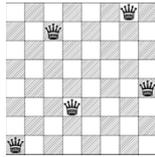
충북대학교 소프트웨어학과
이건명



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

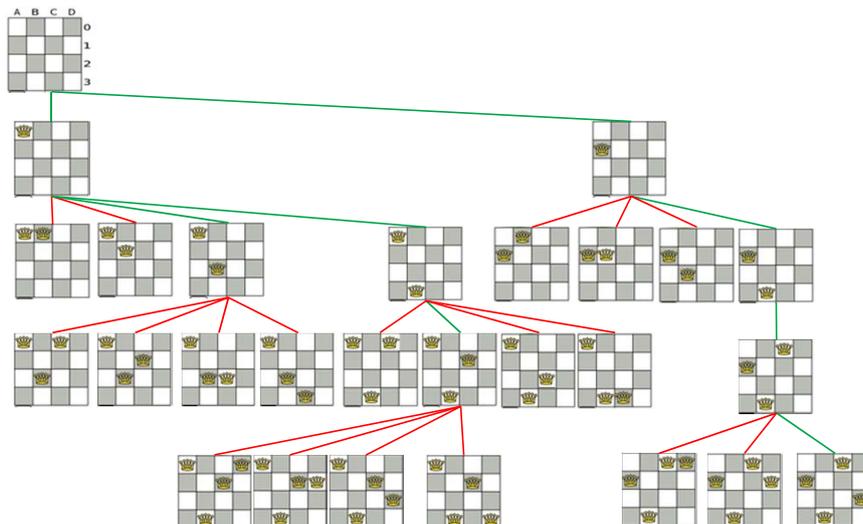
- 백트래킹 탐색
- 제약조건 전파

▪ 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

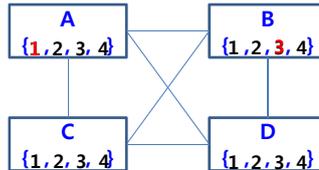


제약조건 만족 문제

❖ 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

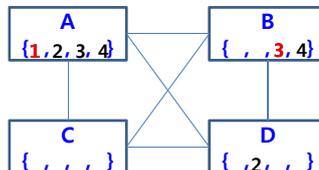


제약조건 만족 문제

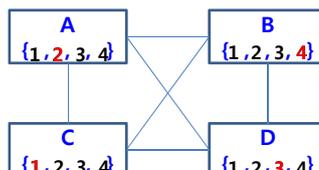
❖ 제약조건 전파(constraint propagation)

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

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



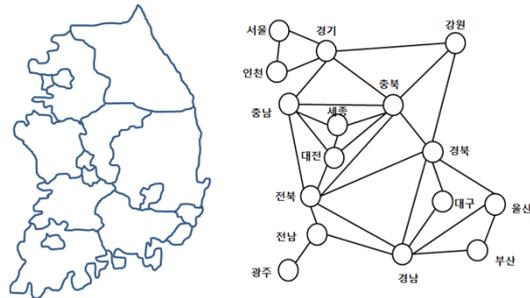
	A	B	C	D
1		X	♔	X
2	♔	X	X	X
3		X	X	♔
4		♔	X	X



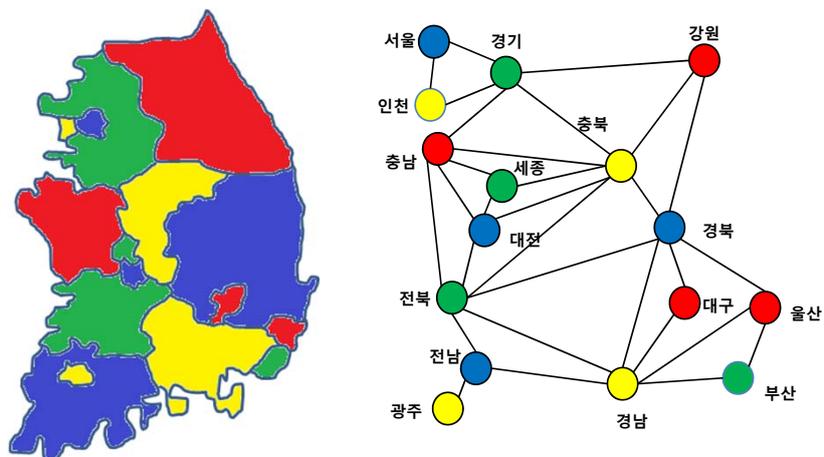
제약조건 만족 문제

❖ 4색 문제(four color problem)

- 도상에서 인접한 영역 간에는 동일한 색상으로 칠하면 안 되고, 4개 이내의 색상을 사용하여 각 영역을 색칠



제약조건 만족 문제



6. 최적화

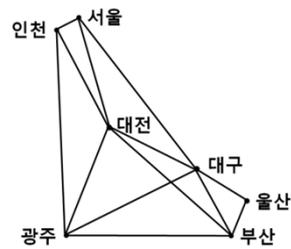
❖ 최적화(optimization)

- 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)

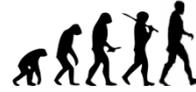
- 순회 판매자 문제(TSP)와 같이 주어진 항목들의 조합으로 해가 표현되는 최적화 문제
- 순회 판매자 문제의 목적함수 : 경로의 길이



(서울, 인천, 광주, 부산, 울산, 대전, 서울)

(서울, 인천, 대전, 광주, 부산, 울산, 서울)

유전 알고리즘

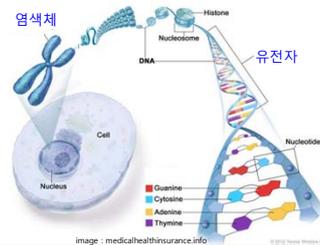


❖ 유전 알고리즘 (genetic algorithm, GA)

- 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

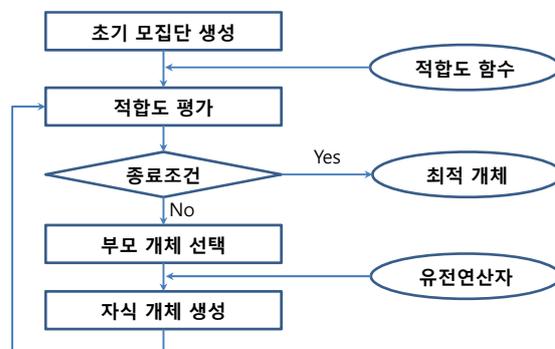
- 염색체(chromosome)의 유전자(gene)들이 개체 정보 코딩
- 적자생존(fittest survival)/자연선택(natural selection)
 - 환경에 적합도가 높은 개체의 높은 생존 및 후손 번성 가능성
 - 우수 개체들의 높은 자손 증식 기회
 - 열등 개체들도 작지만 증식 기회
- 집단(population)의 진화
 - 세대(generation) 집단의 변화
- 형질 유전과 변이
 - 부모 유전자들의 교차(crossover) 상속
 - 돌연변이(mutation)에 의한 변이



유전 알고리즘

❖ 유전 알고리즘 - cont.

- 생물 진화와 문제 해결
 - 개체 ⇔ 후보 해(candidate solution)
 - 환경 ⇔ 문제(problem)
 - 적합도 ⇔ 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

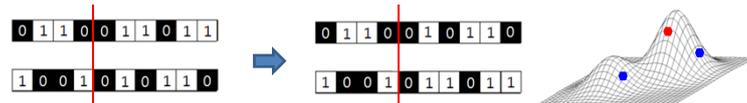
❖ 유전 알고리즘 – cont.

- 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

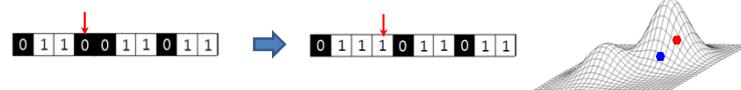


- 유전 연산자(genetic operator) : 새로운 개체 생성

- 교차(crossover) 연산자



- 돌연변이(mutation) 연산자



유전 알고리즘

❖ 유전 알고리즘 – cont.

▪ 세대(Generation) 교체

• 엘리트주의(Elitism)

– 우수한 개체를 다음 세대에 유지

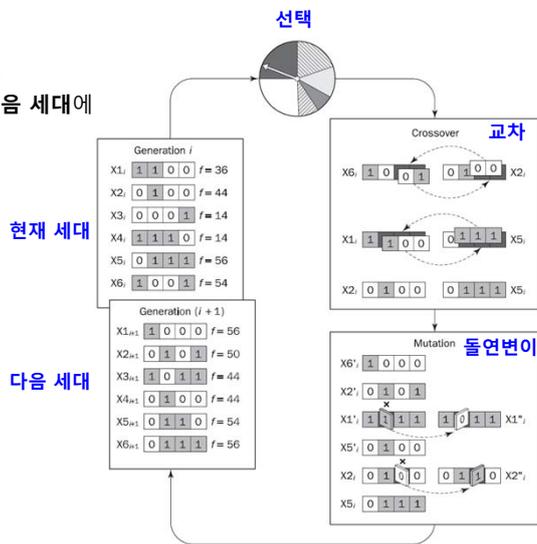


Image : MICHAEL NEGNEVITSKY, Artificial Intelligence

메타 휴리스틱

❖ 메타 휴리스틱(meta heuristics)

▪ 최적해(optimal solution)을 보장하지는 않지만 준최적해(suboptimal solution)을 빠르게 찾는 알고리즘

- 유전 알고리즘
- 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)



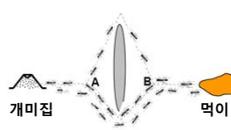
유전 알고리즘



모방 알고리즘



입자 군집 최적화



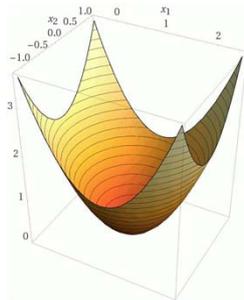
개미집단 알고리즘

image source: Tarek Hegazy

함수 최적화

❖ 함수 최적화(function optimization)

- 어떤 목적 함수(objective function)가 있을 때, 이 함수를 최대 하거나 최소로 하는 변수 값을 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

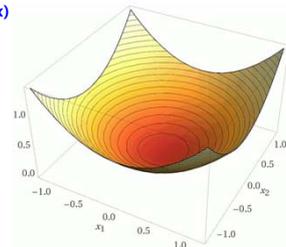
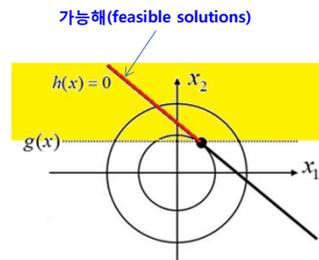
Find x_1, x_2

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
(constraintx)



- 기계학습 방법인 SVM의 학습에서 사용

함수 최적화

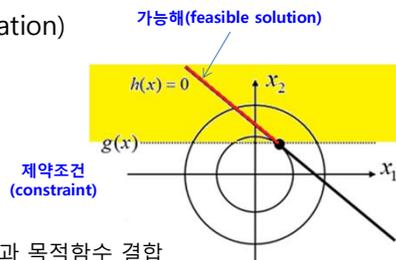
❖ 제약조건 최적화(constrained optimization)

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

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

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

- 최적화 방법

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

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

$$\geq \max_{\lambda, \alpha} L_d(\lambda, \alpha) \quad \text{쌍대함수(dual function)}$$

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

함수 최적화

❖ 제약조건 최적화(constrained optimization) – cont.

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

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

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

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

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

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

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

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

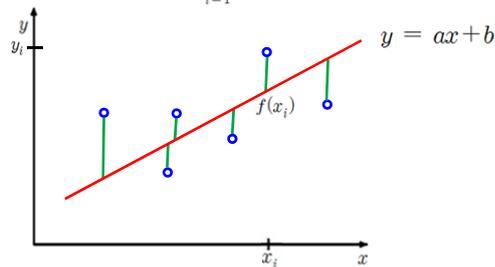
$$\therefore x_1 = \frac{1}{4} \quad x_2 = \frac{3}{4}$$

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

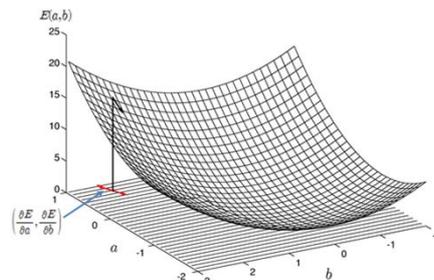
함수 최적화

❖ 최대 경사법(maximum gradient descent method, 경사 하강법)

- 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
 η : 학습률 ($0 < \eta < 1$)



함수 최적화

❖ 최대 경사법(gradient descent method)

- 회귀모델, 신경망 등의 기본 학습 방법
- 국소해(local minima)에 빠질 위험
- 개선된 형태의 방법 존재
 - conjugate gradient method 등

