


그림으로 쉽게 설명하는 파이썬 알고리즘

## CHAPTER 11

# 휴리스틱 알고리즘

Heuristic Algorithms

완벽한 지도가 없다면, 나침반과 직관을 믿고 나아가라



# 이번 장에서 배울 내용



11.1

## 왜 다시 직관인가

근사의 한계와 휴리스틱



11.2

## 언덕 오르기

반복적 개선의 기본



11.3

## TSP 언덕 오르기

swap으로 경로 다듬기



11.4

## A\* 알고리즘

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



11.5

## 메타 휴리스틱

탐색과 활용의 균형



11.6

## 모의 담금질

온도로 무작위성을 조절한다



11.7

## TSP 모의 담금질

2-opt 구간 뒤집기



11.8

## 유전 알고리즘

적자생존 · 교배 · 돌연변이



11.9

## TSP 유전 알고리즘

순서 교배(OX)가 핵심



11.10

## 자연 영감 알고리즘

PSO와 ACO



11.11

## 정리 및 비교

선택 가이드



10장에서 내려놓은  
수학적 보장 대신,  
경험과 직관으로  
실전을 돌파한다.



11.1

# 왜 다시 직관인가?

이론이 멈추는 곳에서 산업 현장은 계속 돌아간다.  
증명을 기다릴 시간이 없을 때 무엇을 쓸 것인가.

11.1

## 근사 알고리즘의 한계 — 이론이 멈추는 곳



### 증명 자체가 불가능하다

현실의 복잡한 공학적 최적화 문제는 수학적으로 모델링하기조차 벅차다. 근사 비율 증명은 최고의 수학자들에게도 난제다.



### 보장된 비율이 너무 나쁘다

"최악의 경우 정답의 100배 이내를 보장한다"는 수준이라면, 비용 절감이 절실한 기업에게는 사실상 아무 의미가 없다.



### 산업 현장에는 수년간 증명에 매달릴 시간이 없다

당장 돌아가는 솔루션이 필요하다. 10장에서 붙였던 수학적 보증서를 떼어 내는 대신, 실행 가능성과 속도를 얻는 선택이 남아 있다.



### 그래서 다시 직관으로 돌아온다

보장이 없다는 것은 약점이지만, 어떤 문제에도 붙일 수 있다는 것은 강점이다.

## 휴리스틱의 정의 — 경험과 직관의 힘



Heuristics — 그리스어 heuriskein(발견하다)에서 왔다. 최적해를 보장하지는 않지만, 현실적인 시간 안에 "꽤 괜찮은" 해를 찾아내는 경험적이고 직관적인 방법이다.



### 근사 알고리즘

"반드시 이 오차 범위 안에 든다"는  
계약서를 쓰는 것



### 휴리스틱

"써 보니까 대체로 잘 맞더라"는  
입소문을 믿는 것

VS



계약서가 없다고 해서 쓸모없는 것은 아니다 — 계약서를 쓸 수 없는 문제가 훨씬 많다.

## 휴리스틱의 예 — 열쇠 찾기



### 완전 탐색 (brute-force)

집 안의 모든 바닥을 1cm<sup>2</sup> 단위로 돌보기를 대고 확인한다. 시간은 엄청 걸리지만 반드시 찾아낸다.

100% 보장 · 지수 시간



### 휴리스틱 (heuristic)

현관 신발장, 거실 탁자, 침실 옷걸이처럼 유력한 곳만 빠르게 훑는다. 몇 분이면 끝난다.

보장 없음 · 매우 빠름



### "공짜 점심은 없다" (No Free Lunch) 정리

모든 종류의 문제에 대해 평균적으로 가장 좋은 성능을 내는 만능 알고리즘은 존재하지 않는다. 어떤 문제에서 뛰어난 방법은 다른 문제에서 반드시 그만큼 뒤쳐진다.



### 그래서 "문제의 특성에 맞는 휴리스틱을 고르는 일" 자체가 실력이 된다

이 장에서 배우는 것은 만능 해법이 아니라, 고를 수 있는 도구의 목록과 각각의 성격이다.



11.2

## 지역 탐색과 언덕 오르기

이미 만들어진 해를 조금씩 고쳐 나간다.  
단, 더 올라갈 곳이 없어 보일 때가 함정이다.

# 11.2

## 욕심쟁이의 직관 (greedy heuristic)



대표 예시 — TSP의 "가장 가까운 이웃(nearest neighbor)". 5장에서 이미 만난 방법이다.



방식

현재 위치에서 가장 가까운, 아직 방문하지 않은 도시로 이동하기를 반복한다.



속도

$O(N^2)$ 로 매우 빠르게 경로를 완성한다.

$O(N^2)$



쓰임새

구현이 간단하고, "그럭저럭 쓸 만한" 첫 번째 해를 얻는 데 유용하다.



근시안적 결정의 위험성

당장 가까운 도시로만 이동하다 보면, 마지막에 남은 도시들이 서로 멀리 떨어져 있어 최종 경로가 엄청나게 길어질 수 있다.



그래서 "만들고 끝"이 아니라 "만든 뒤에 고치는" 전략이 필요해진다.

## 언덕 오르기 (hill climbing)



이미 만들어진 해를 조금씩 수정하여 더 좋은 해로 나아가는 "반복적 개선" 기법이다.



### 안개 낀 산맥의 비유

"일단 내 발밑 주변을 더듬어 보고, 지금 위치보다 조금이라도 경사가 높은 쪽으로 한 발자국 내딛는다. 더 이상 올라갈 곳이 없을 때까지 반복한다."

1

### 초기 해 생성

무작위 또는 그리디로 시작한다.

2

### 이웃 해 탐색

현재 해를 조금 수정해 후보를 만든다.

3

### 개선 여부 판단

더 좋으면 채택하고, 아니면 그대로 둔다.



④ 종료 조건 — 더 이상 개선이 없으면 멈춘다.

# 언덕 오르기 유사 코드

hill\_climbing.pseudo

```
Algorithm DISCRETE_HILL_CLIMBING(start)

  current <- start

  while true:
    bestNeighbor <- NIL
    bestValue <- -무한대

    for each neighbor in NEIGHBORS(current):
      value <- EVAL(neighbor)
      if value > bestValue:
        bestValue <- value
        bestNeighbor <- neighbor

    if bestValue <= EVAL(current):
      return current // 개선이 없으면 종료

    current <- bestNeighbor
```



## NEIGHBORS(current)

현재 해를 조금 바꿔 만든 후보들. 이 정의가 알고리즘의 성격을 결정한다.



## EVAL(x)

해의 좋음을 점수로 매기는 함수. TSP라면 경로 길이의 부호를 뒤집은 값이다.



## 최선의 이웃만 채택

이웃 전부를 보고 가장 좋은 하나로 이동한다. 이것을 steepest-ascent라 한다.



## 종료 조건

어떤 이웃도 현재보다 낫지 않으면 멈춘다 — 바로 이 지점이 국소 최적해다.



"더 좋은 이웃이 없다"는 것과 "여기가 전역 최적이다"는 전혀 다른 말이다.

## 치명적 약점 — 국소 최적해의 함정

열심히 언덕을 올라 정상에 도착했다. 사방이 내리막길이다. "여기가 가장 높은 곳이구나!" 하지만 안개가 걷히고 보니 그저 동네 뒷산이었다. 진짜 정상은 골짜기를 지나야 한다.



### 국소 최적해

주변보다는 높지만 전체로 보면 낮은 봉우리에 갇힌다.



### 평원 (plateau)

주위가 모두 평평해 어느 쪽으로 가야 할지 방향을 잡을 수 없다.




### 능선 (ridge)

좁고 가파른 길에서는 한 발만 헛디뎈다고 급격히 낮은 곳으로 떨어진다.

# 언덕 오르기와 딥러닝의 그라디언트 디센트

| 구분    | 언덕 오르기         | 그라디언트 디센트            |
|-------|----------------|----------------------|
| 상태 공간 | 이산적 (discrete) | 연속적 수학 공간            |
| 이동 방법 | 이웃 상태를 하나씩 비교  | 기울기(gradient)로 방향 계산 |
| 문제 유형 | 최대화 — 높은 곳 탐색  | 최소화 — 손실 함수 최소화      |
| 갈히는 곳 | 국소 최적해         | 국소 최솟값 · 안장점         |



**공통 철학 — 현재 위치에서 얻을 수 있는 정보만으로 점진적으로 더 나은 상태로 이동한다**

이름과 분야는 달라도 구조가 같다. 딥러닝의 학습률 조절이나 모멘텀도, 결국 국소 최적을 벗어나기 위한 장치라는 점에서 이 장의 메타 휴리스틱과 문제의식을 공유한다.



**그래서 딥러닝을 배운 사람에게 이 장은 낯설지 않다**

언덕 오르기는 이산 공간판 경사 하강법이라고 생각하면 된다.



11.3

# TSP 언덕 오르기

무작위 경로에서 출발해  
두 도시를 바꿔 가며 조금씩 줄인다.

# 11.3

# TSP 언덕 오르기 — 알고리즘 흐름



## ① 초기 해

무작위 순서로 도시를 배열해 초기 경로를 만든다.



## ② 이웃 생성

임의의 두 도시 위치를 swap해 새 경로를 만든다.



## ③ 평가

새 경로의 총 거리가 현재보다 짧은지 비교한다.



## ④ 선택

더 좋으면 채택하고, 아니면 원상복구한다 (swap-back).

### RESULT

```
Initial   : 522.03
Iter      4 : 489.93
Iter     25 : 428.15
Iter     32 : 376.57
Iter     47 : 326.91
Iter    277 : 313.56
```



### 3000회 동안 개선 없음 → 종료

522에서 시작해 313까지 내려왔다. 그 뒤로는 어떤 swap도 더 나은 결과를 주지 못한다 — 국소 최적해에 도달한 것이다.



초반에는 빠르게 좋아지다가 점점 개선 폭이 줄어드는 것이 전형적인 패턴이다.

# 가장 가까운 이웃 vs 언덕 오르기

| 구분     | 가장 가까운 이웃 (greedy) | 언덕 오르기 (hill climbing) |
|--------|--------------------|------------------------|
| 전략     | 구성 (construction)  | 개선 (improvement)       |
| 시작점    | 빈 경로에서 시작          | 완성된 경로에서 시작            |
| 방식     | 가장 가까운 미방문 도시를 연결  | 도시 순서를 swap하며 개선       |
| 수정 가능성 | 한 번 결정하면 변경 불가     | 계속 수정 가능               |
| 속도     | 매우 빠름              | 상대적으로 느림 (반복)          |
| 품질     | 보통                 | 초기 해보다 확실히 나음          |



**둘은 경쟁 관계가 아니라 이어 붙이는 관계다**

가장 가까운 이웃으로 빠르게 초기 해를 만들고, 그 해를 언덕 오르기로 다듬는 조합이 실무에서 가장 흔하다.



다만 언덕 오르기만으로는 국소 최적해를 벗어날 수 없다 — 다음 절의 주제다.



11.4

# A\* 알고리즘

지금까지 쓴 비용과 앞으로 들 비용을 더한다.  
나침반 하나가 탐색량을 통째로 줄인다.

# 11.4

## A\* 알고리즘 — 핵심 아이디어

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



**$f(n)$  — 총 예상 비용**

시작점에서 목표점까지의 총 예상 비용.  
이 값이 작은 정점부터 꺼낸다.



**$g(n)$  — 실제 비용**

시작점에서 현재 정점  $n$ 까지 실제로 소요  
된 비용. 이미 확정된 값이다.



**$h(n)$  — 휴리스틱 비용**

현재 정점  $n$ 에서 목표까지의 예상 비용.  
추정치이며 정확할 필요는 없다.




**A\*는  $f(n)$ 이 가장 작은 정점을 우선 탐색한다**

5장 다익스트라가  $g(n)$ 만 보고 골랐다면, A\*는 여기에 "앞으로 얼마나 남았을까"라는 추정을 더한다. 그만큼 목적지 방향으로 탐색이 쏠린다.

## 다익스트라 vs A\* — 탐색 방식 비교


다익스트라 — 맹목적 탐색



시작점을 중심으로 동그랗게 모든 방향으로 퍼져 나간다

비효율적

A\* — 휴리스틱 탐색



시작점에서 목적지 방향으로 타원형으로 길게 뻗어 나간다

효율적



$h(n)$ 이 나침반 역할을 한다 — 불필요한 탐색을 줄이고 목표를 향해 직진한다.

## 나침반의 역할 — 휴리스틱 함수 $h(n)$



### 유클리드 거리

대각선 이동이 가능한 경우 — 직선거리를 추정치로 쓴다.



### 맨해튼 거리

직각으로만 이동하는 경우 —  $|x_1 - x_2| + |y_1 - y_2|$  를 쓴다.

$$h(n) \leq \text{실제 남은 거리}$$

허용성(admissibility) 조건 — 언제나 낙관적으로 추정해야 한다



### 조건 만족


이 조건을 만족하면 A\*는 반드시 최단 경로를 찾아낸다는 것이 보장된다.



### 조건 위반

$h(n)$ 이 실제보다 크면, 좋은 경로를 탐색 대상에서 빼 버릴 위험이 생긴다.

## 예제 — 미로 찾기 (grid pathfinding)



S 출발 · E 도착 · ■ 벽 · 연보라 = A\*가 찾은 경로



### 최단 경로 발견

벽을 피해 돌아가면서도 길이 8칸의 최단 경로를 찾아낸다.



### $h(n)$ 이 방향을 안내

맨해튼 거리가 나침반 역할을 해 목적지 쪽 칸부터 먼저 열어 본다.



### 다익스트라보다 효율적

같은 답을 찾되, 열어 보는 칸의 수가 훨씬 적다.



### A\*는 두 알고리즘의 일반화다

$h(n) = 0$  이면 다익스트라와 같고,  $g(n) = 0$  이면 순수 그리디 탐색과 같아진다.

# A\* 알고리즘의 위상과 활용



## 내비게이션

실시간 길 찾기 시스템의 핵심 두뇌다.  
도로망 규모에서도 실용적으로 동작한다.



## 게임 AI

실시간 전략 게임 유닛의 경로 계획에  
표준처럼 쓰인다.



## 로봇 경로

자율 주행 로봇의 이동 경로 최적화에  
사용된다.

**A\* = 다익스트라의 정확성 + 그리디의 신속성**



**현대 컴퓨터 과학에서 가장 널리 쓰이는 길 찾기 도구**

휴리스틱을 쓰면서도 조건만 지키면 최적성을 잃지 않는다는 점에서, 이 장의 다른 기법들과는 성격이 조금 다르다.



11.5

# 메타 휴리스틱

가끔은 나쁜 쪽으로도 움직여야  
더 높은 봉우리에 닿을 수 있다.

# 11.5

# 메타 휴리스틱이란?



다양한 문제에 범용적으로 적용할 수 있는 상위 레벨의 탐색 전략 프레임워크



## 하위 레벨 — 휴리스틱

실제로 해를 수정하고 이동하는 구체적 행동

예: "두 도시의 순서를 바꿔 본다"



## 상위 레벨 — 메타 휴리스틱

전체적인 탐색 방향과 규칙을 지휘

예: "국소 최적해 탈출을 위해 나쁜 해로의 이동을 허락한다"



## 등반가와 베이스캠프 대장의 관계

등반가(하위)가 발밑을 보며 한 발씩 옮길 때, 무전기로 전체 작전을 지시하는 베이스캠프 대장이 메타 휴리스틱이다. 대장은 지형을 직접 밟지 않지만 어디로 갈지를 정한다.



메타 휴리스틱은 문제에 독립적이다 — TSP든 스케줄링이든 같은 틀을 얻을 수 있다.

## 핵심 메커니즘 — 탐색과 활용의 균형



### 탐색 (exploration)

- 미지의 새로운 영역을 넓게 훑어본다
- 나쁜 해로의 이동을 허용한다
- 국소 최적해를 탈출할 기회를 준다

과도하면 → 무작위 탐색과 다를 바 없다



### 활용 (exploitation)

- 현재 좋은 해의 주변을 집중적으로 판다
- 더 좋은 이웃 해로만 이동한다
- 빠르게 국소 최적해로 수렴한다

과도하면 → 조기 수렴 문제가 생긴다

초반 : 넓은 탐색 → 후반 : 깊은 활용

# 자연에서 배우다 — 물리와 생물의 지혜

수십억 년 동안 최적화 과정을 거쳐 온 자연의 섭리야말로 가장 잘 검증된 메타 휴리스틱이다.



물리 현상

## 모의 담금질 (SA)

금속의 담금질 과정을 모방한다. 높은 온도에서는 탐색, 낮은 온도에서는 활용.



생물학적 진화

## 유전 알고리즘 (GA)

자연선택과 교배, 돌연변이로 해의 집단을 진화시킨다.



곤충 행동

## 개미 집단 (ACO)

페로몬을 기반으로 경로를 최적화한다. 짧은 경로에 페로몬이 더 쌓인다.



새 떼 비행

## 입자 군집 (PSO)

개인의 경험과 집단의 정보를 합쳐 최적 위치를 향해 이동한다.



## 왜 자연을 흉내 내는가

자연의 최적화 과정은 모두 "가끔 손해를 감수하면서 다양성을 유지한다"는 공통점을 가진다. 그것이 곧 국소 최적해를 벗어나는 방법이다.



11.6

# 모의 담금질

금속을 천천히 식히면 가장 안정된 결정이 된다.  
알고리즘도 천천히 식히면 더 좋은 해에 닿는다.

# 11.6

## 핵심 아이디어 — 담금질 과정

1

### 가열

금속을 높은 온도로 가열한다. 원자들이 무질서하게 움직인다.

2

### 급랭 (나쁜 예)

찬물에 확 식히면 불안정한 상태 그대로 굳어 버린다.

3

### 서냉 (좋은 예)

천천히 온도를 낮추면 가장 안정적인 결정 구조로 배열된다.

| 물리적 개념 | 알고리즘 대응             |
|--------|---------------------|
| 금속의 상태 | 문제의 해 (solution)    |
| 내부 에너지 | 비용 함수의 값 — 최소화 대상   |
| 온도 (T) | 탐색의 무작위성을 제어하는 파라미터 |



온도 하나로 "탐색 ↔ 활용"의 비중을 연속적으로 조절한다는 것이 이 기법의 핵심이다.

## 확률적 수용 규칙 — 볼츠만 분포

$$P(\text{accept}) = e^{(-\Delta E / T)}$$



이웃이 더 좋으면 ( $\Delta E < 0$ )

무조건 이동한다 ( $P = 1$ ). 좋은 쪽으로 가는 것을 망설일 이유가 없다.



이웃이 더 나쁘면 ( $\Delta E > 0$ )

확률  $P$ 로 이동을 허용한다. 이 한 줄이 국소 최적해를 탈출하는 유일한 통로다.



**T가 높으면**

초반 — 나쁜 해도 높은 확률로 수용한다. 곧 탐색(exploration)이다.



**T가 낮으면**

후반 — 나쁜 해는 거의 거부한다. 곧 활용(exploitation)이다.

## "초반엔 과감하게, 후반엔 신중하게"

T (온도)



반복 횟수 →

### 초반 — 고온 상태 (탐색)

해가 좋아졌다 나빠졌다를 반복한다.  
탐색 공간을 활발히 돌아다닌다.  
깊은 국소 최적해도 탈출할 수 있다.

### 중반 — 서냉 중 (균형)

좋은 쪽으로 움직이려 하지만,  
국소 최적해에 빠지더라도  
탈출할 가능성이 아직 남아 있다.

### 후반 — 저온 상태 (수렴)

나쁜 해로는 거의 이동하지 않는다.  
가장 좋은 지역에서  
미세 조정하며 수렴한다.

“

"처음에는 술 취한 사람처럼 비틀거리며 헤매다가, 술이 깰수록 목적지를 향해 똑바로 걸어가는 전략"

# 모의 담금질 유사 코드

simulated\_annealing.pseudo

Algorithm SIMULATED\_ANNEALING( $s_0$ ,  $k_{\max}$ ,  $T_0$ ):

$s \leftarrow s_0$

for  $k \leftarrow 0$  to  $k_{\max} - 1$  do

$T \leftarrow T_0 * (1 - (k+1) / k_{\max})$  // 온도 감소

$s_{\text{new}} \leftarrow \text{RANDOM\_CHOICE}(\text{NEIGHBORS}(s))$  // 이웃 하나 선택

if  $E(s_{\text{new}}) \leq E(s)$  then

$s \leftarrow s_{\text{new}}$  // 더 좋으면 무조건 수용

else

$P \leftarrow \exp(-(E(s_{\text{new}}) - E(s)) / T)$  // 수용 확률 계산

if  $\text{RANDOM}(0,1) < P$  then

$s \leftarrow s_{\text{new}}$  // 확률적 수용!

return  $s$



## 온도 스케줄

$T$ 를 어떻게 낮추느냐가 성능을 좌우한다. 선형·지수 감소가 흔히 쓰인다.



## 이웃 하나만 뽑는다

언덕 오르기와 달리 모든 이웃을 비교하지 않는다. 무작위로 하나만 본다.



## $\exp(-\Delta E / T)$

$\Delta E$ 가 클수록,  $T$ 가 작을수록 수용 확률이 급격히 떨어진다.



## 고정 횟수 종료

$k_{\max}$ 번 반복하면 끝난다. 개선 여부와 무관하게 예산이 정해진다.



최종 해가 아니라 "지금까지 본 최선"을 따로 기억해 두는 것이 실무의 요령이다  
온도가 남아 있는 동안에는 마지막  $s$ 가 최선이 아닐 수 있기 때문이다.

## 모의 담금질 적용 분야



### 반도체 회로 배치

VLSI layout — 수백만 개의 트랜지스터를 배치하며 배선 길이를 최소화한다.



### 공정 스케줄링

job-shop 문제 — 공장의 작업 순서를 정해 전체 완료 시간을 줄인다.



### TSP

꼬인 경로를 천천히 풀어내며 깔끔한 순회 경로로 수렴시킨다.



### 냉각 속도(cooling rate) 조절이 성패를 가른다

너무 빠르면(예: 0.9) 꼬인 선을 다 풀지 못한 채 멈추고, 너무 느리면(예: 0.9999) 시간이 감당할 수 없이 늘어난다.



### 파라미터 하나에 결과가 크게 흔들린다는 점이 메타 휴리스틱의 공통된 약점이다

이 때문에 실무에서는 여러 설정으로 여러 번 돌려 보고 가장 좋은 것을 고르는 방식을 쓴다.



11.7

# TSP와 모의 담금질

엮킨 실타래 같은 경로가  
서서히 풀려 깔끔한 다각형이 된다.

# 11.7

# TSP + 모의 담금질 — 핵심 기법



## 구간 뒤집기 (2-opt)

임의의 두 지점  $i, j$ 를 잡아  $path[i:j+1]$ 을 통째로 뒤집는다. 꼬인 선을 한번에 풀어 주므로 단순 swap보다 훨씬 효과적이다.



## 확률적 점프

초반에는  $T$ 가 높아  $P \approx 1$ 로 거의 무조건 수용하고, 후반에는  $T$ 가 낮아  $P \approx 0$ 이 되어 좋은 것만 남는다.

tsp\_sa.py

```
# 2-opt: 구간을 통째로 뒤집는다
i, j = sorted(random.sample(range(n), 2))
new_path = path[:i] + path[i:j+1][::-1] + path[j+1:]

# 확률적 수용
diff = length(new_path) - length(path)
if diff < 0 or random.random() < math.exp(-diff / temp):
    path = new_path
```



## 왜 뒤집기인가

두 도시를 바꾸면 네 개의 간선이 흔들리지만, 구간을 뒤집으면 딱 두 개만 바뀐다.



## 수렴하는 모습

뒤죽박죽 엉킨 실타래 같던 경로가 서서히 풀려, 외곽을 도는 깔끔한 다각형이 된다.



이웃(neighbor)을 어떻게 정의하느냐가 메타 휴리스틱 성능의 절반을 결정한다.



11.8

# 유전 알고리즘

하나의 해를 고치는 대신,  
해의 집단을 세대에 걸쳐 진화시킨다.

# 11.8

## 다윈의 진화론과 적자생존



### 적자생존

더 우월한 개체가 다음 세대의 부모가 될 확률이 높다.



### 교배

우수한 부모의 유전자를 섞으면 더 뛰어난 자식이 나올 수 있다.



### 돌연변이

유전자에 무작위 변화를 준다. 다양성을 유지하고 새로운 가능성을 연다.

**교배 = 활용(exploitation) · 돌연변이 = 탐색(exploration)**



앞 절의 "탐색과 활용의 균형"이 여기서는 두 연산으로 분리되어 나타난다

모의 담금질이 온도 하나로 균형을 잡았다면, 유전 알고리즘은 교배율과 돌연변이율이라는 두 손잡이로 조절한다.

## 주요 구성 요소 — 유전자와 적합도



### 유전자 & 염색체

하나의 해(solution)가 곧 염색체이고,  
그 안의 각 비트나 값이 유전자다.

[ 1, 0, 1, 1, 0 ]

배낭 문제의 한 해 — 1번·3번·4번 물건을 담는다



### 적합도 함수 (fitness)

해가 "얼마나 좋은지"를 점수로 평가한다.  
배낭 문제라면 담은 물건 가치의 총합이다.

점수 ↑ → 생존 확률 ↑

TSP라면 경로 길이의 역수를 쓴다 — 짧을수록 적합하다



### 해를 어떤 모양으로 표현할 것인가가 첫 번째 설계 결정이다

표현이 정해져야 교배와 돌연변이를 어떻게 할지가 따라 나온다. TSP처럼 순열이 해가 되는 경우에는 표현 방식 자체가 문제가 되는데, 그것이 §11.9의 주제다.

# 진화의 과정 — 알고리즘 사이클



## ① 초기 집단 생성

무작위 해를 수 십에서 수백 개 만든다.



## ② 적합도 평가 & 선택

점수를 매기고 룰렛 휠 등으로 부모를 고른다.



## ③ 교배 (crossover)

부모의 유전자를 조합해 자식을 만든다.



## ④ 돌연변이 (mutation)

극히 일부 유전자를 무작위로 바꾼다.



## ⑤ 세대교체

자식들이 새로운 부모가 되어 ②부터 반복한다.



한 세대가 아니라 수백 세대를 돌린다 — 집단 전체가 조금씩 좋아진다.

crossover.txt

```
# 교배 예시 (단일 지점)
부모1: [1,1,1 | 0,0]
부모2: [0,0,0 | 1,1]
-----
자식 : [1,1,1 | 1,1]  <- 슈퍼 개체!
```

mutation.txt

```
# 돌연변이 예시
[1,1,1,1,1] -> [1,1,0,1,1]

3번째 비트가 무작위로 변경됨
```



## 왜 돌연변이가 필요한가

집단이 비슷해지면 교배만으로는 새로운 해가 나오지 않는다. 무작위 변화가 정체를 깬다.

# 유전 알고리즘 유사 코드

genetic\_algorithm.pseudo

Algorithm GENETIC\_ALGORITHM():

```
P <- INITIALIZE_POPULATION(pop_size)
best <- BEST_IN(P)
```

```
for gen <- 1 to max_generations do
  FITNESS_EVALUATE(P)           // 적합도 평가
  P_new <- TOP_K(P, elite_count) // 엘리트 보존
```

```
while SIZE(P_new) < pop_size do
  p1, p2 <- SELECT(P)           // 부모 선택
  child <- CROSSOVER(p1, p2)     // 교배
  child <- MUTATE(child, rate)   // 돌연변이
  P_new <- P_new + {child}
```

```
P <- P_new                      // 세대 교체
```

```
return best
```



## pop\_size

집단의 크기. 크면 다양성이 늘지만 세대당 계산량도 늘어난다.



## elite\_count

무조건 살아남는 상위 개체 수. 퇴보를 막는 안전장치다.



## SELECT

적합도에 비례해 확률적으로 부모를 뽑는다 (룰렛 휠).



## rate

돌연변이 확률. 너무 크면 무작위 탐색이 되고, 너무 작으면 정체된다.



네 개의 파라미터가 서로 얽혀 있다 — 튜닝이 곧 실력이 되는 이유다.

## 유전 알고리즘 실전 응용



### 게임 AI 행동 진화

다양한 AI를 서로 싸우게 하고 승리한 AI의 행동을 진화시켜, 사람이 생각하지 못한 전략을 얻는다.



### NASA 안테나 설계

GA로 설계를 진화시킨 결과물은 기괴하게 생겼지만 성능이 가장 좋았고, 실제 우주선에 탑재되었다.



### 복잡한 함수 최적화

자동차 공기역학 설계나 금융 모델 파라미터 튜닝처럼 변수가 수없이 많은 문제에 쓰인다.



### GA는 인간의 고정관념을 뛰어넘는 창의적인 해를 찾아낼 수 있다

사람은 "이렇게 생겨야 안테나답다"는 선입견에서 벗어나기 어렵지만, 알고리즘에는 그런 편견이 없다. 평가 함수만 정확하면 형태는 아무래도 좋다.



### 뒤집어 말하면, 평가 함수가 잘못되면 엉뚱한 방향으로 진화한다

무엇을 좋다고 정의했는지가 결과의 전부를 결정한다.



11.9

# TSP와 유전 알고리즘

순열을 유전자로 쓰면 교배가 까다로워진다.  
도시가 중복되거나 빠지기 때문이다.

# 11.9

# TSP 유전 알고리즘 — 순서 교배 (OX)



일반적인 단일 지점 교배를 쓰면 도시가 중복되거나 누락된다 — 순서 교배(ordered crossover)가 필요하다.

ordered\_crossover.txt

- ① 부모1에서 구간 (start=2, end=5) 을 고른다  
 Parent1: [0, 1, 2, 3, 4, 5, 6, 7, 8]  
 Parent2: [8, 4, 2, 6, 3, 1, 5, 0, 7]
- ② 부모1의 그 구간을 자식에 그대로 복사한다  
 Child : [-1, -1, 2, 3, 4, 5, -1, -1, -1]
- ③ 부모2의 순서대로 남은 칸을 채운다 (중복은 건너뛰다)  
 8 -> 빈칸0    4 -> 이미 있음    2 -> 이미 있음  
 6 -> 빈칸1    1 -> 빈칸6        0 -> 빈칸7 ...  
 Child : [ 8, 6, 2, 3, 4, 5, 1, 0, 7]



## 중복도 누락도 없다

모든 도시가 정확히 한 번씩만 등장한다.



## 순서 정보 보존

부모1의 구간 순서와 부모2의 상대 순서를 함께 물려받는다.



## 순열 문제의 표준

스케줄링처럼 순서가 해가 되는 문제 전반에 그대로 쓰인다.



해의 표현이 순열이면 교배 연산자부터 새로 설계해야 한다.

## TSP GA — 엘리트 보존과 돌연변이



### 엘리트 보존 (elitism)

- 상위 20% 개체는 교배 없이 다음 세대로 넘긴다
- 우연히 찾은 좋은 경로가 파괴되는 것을 막는다
- 세대가 지날수록 최선이 나빠지지 않도록 하는 안전장치



### 돌연변이 (mutation)

- 도시 순서를 강제로 swap한다
- 비슷한 경로끼리만 교배하는 정체 상태를 깬다
- 엉뚱한 곳에서 획기적인 지름길이 발견되기도 한다



**"끼리끼리만 결혼하면 유전병이 생기듯, 알고리즘도 비슷한 경로끼리만 교배하면 발전이 멈춘다"**

엘리트 보존은 활용(exploitation)을, 돌연변이는 탐색(exploration)을 담당한다. 둘 중 하나만 세게 밀면 반드시 실패한다.



엘리트 비율과 돌연변이율은 서로 반대 방향으로 작용한다 — 함께 조절해야 한다.



11.10

# 자연 영감 알고리즘들

지휘자 없는 무리가 최적을 찾아낸다.  
PSO와 ACO.

11.10

# 입자 군집 최적화 (PSO)



영감 — 새 떼나 물고기 떼의 움직임. 지휘자가 없는데도 무리 전체가 하나처럼 움직인다.



## pBest — 개인 경험

"내가 지금까지 날아다닌 곳 중 가장 좋았던 위치" 쪽으로 끌린다. 인지적 요소라고 부른다.



## gBest — 집단 정보

"무리 전체가 발견한 곳 중 가장 좋은 위치" 쪽으로 끌린다. 사회적 요소라고 부른다.



## 특징

교배나 돌연변이 없이 간단한 속도 벡터 연산만으로 구현된다. 계산 효율이 매우 높다.



## 주요 응용

연속적인 파라미터 최적화, 신경망 학습 등에 널리 쓰인다.

## 개미 집단 알고리즘 (ACO)



영감 — 개미들의 최단 경로 탐색. 페로몬(pheromone)을 통한 간접적인 정보 공유가 핵심이다.



① 초기 탐색 아무 정보가 없으므로 개미들이 무작위로 경로를 돌아다닌다.



② 페로몬 축적 짧은 경로일수록 왕복이 빨라 같은 시간에 페로몬이 더 많이 쌓인다.



③ 경로 강화 페로몬이 진한 길을 고를 확률이 올라간다. 양성 피드백이 일어난다.



④ 페로몬 증발 오래된 정보는 서서히 사라져, 새로운 경로를 탐색할 여지를 남긴다.



강점 — TSP, 네트워크 라우팅, 물류 배차처럼 그래프 기반 경로 최적화에서 뛰어나다



11.11

# 11장을 마치며

세 가지 접근을 나란히 놓고,  
언제 무엇을 쓸지 정리한다.

11.11

## 근사 알고리즘 vs 휴리스틱 vs 메타휴리스틱

| 구분     | 근사 알고리즘         | 휴리스틱           | 메타휴리스틱           |
|--------|-----------------|----------------|------------------|
| 핵심 목적  | 이론적 보장 + 빠른 해   | 빠른 시간에 괜찮은 해   | 범용 탐색 프레임워크      |
| 최적해 보장 | 근사 비율만 보장       | 보장 없음          | 보장 없음            |
| 수학적 분석 | 가능 (증명)         | 거의 불가능         | 거의 불가능           |
| 문제 의존성 | 비교적 낮음          | 매우 높음          | 낮음 (범용)          |
| 결과 안정성 | 안정적             | 실행마다 다름        | 실행마다 다름          |
| 대표 기법  | 2-근사, Greedy SC | 최근접 이웃, 언덕 오르기 | SA, GA, ACO, PSO |
| 장점     | "얼마나 나쁜지"를 안다   | 빠르고 구현이 단순     | 복잡한 문제에도 적용 가능   |
| 단점     | 품질이 제한적일 수 있음   | 국소 최적해 위험      | 파라미터 튜닝이 필요      |



세 접근은 대체재가 아니라, 문제의 성격에 따라 고르는 선택지다.

# 언제 무엇을 써야 하는가?



## 근사 알고리즘 — Safety First

- 최악의 상황에 대한 보장이 필수인 경우
- 금융 리스크, 구조물 안전, 의료 분야
- 문제 구조가 수학적으로 명확할 때



## 메타 휴리스틱 — Performance First

- 최악보다 평균적 성능이 중요할 때
- 문제가 너무 복잡하거나 제약 조건이 많을 때
- 내부 구조를 모르는 블랙박스 최적화



## 파라미터 튜닝 = 과학 + 예술

온도 스케줄, 돌연변이율, 집단 크기에는 정답 공식이 없다. 훌륭한 엔지니어는 파라미터들이 서로 얽혀 춤추는 리듬을 이해하고 지휘할 수 있는 사람이다.



무엇을 고르든, 결과를 실측으로 검증하는 절차만큼은 빼놓을 수 없다.

# 11장 정리



## 휴리스틱

최적해 보장 없이 빠르게 괜찮은 해를 찾는 경험적 방법. 보장을 내려놓는 대신 적용 범위를 얻는다.



## A\* 알고리즘

$f(n) = g(n) + h(n)$  — 과거 비용과 미래 예측을 결합한다.  $h$ 가 낙관적이면 최적성도 지킨다.



## 모의 담금질

온도 기반 확률적 수용. 초반에는 과감하게, 후반에는 신중하게 움직인다.



## PSO / ACO

무리 지능 기반. 개체가 정보를 공유하며 함께 최적해를 찾아 나간다.



## 언덕 오르기

이웃 해 중 더 좋은 것으로만 이동한다. 빠르지만 국소 최적해에 갇힐 위험이 있다.



## 메타 휴리스틱

탐색(exploration)과 활용(exploitation)의 균형을 지휘하는 상위 전략이다.



## 유전 알고리즘

적자생존 · 교배 · 돌연변이로 해의 집단을 세대에 걸쳐 진화시킨다.



## NFL 정리

만능 알고리즘은 없다. 문제 특성에 맞는 선택이 결국 실력이 된다.

## CHAPTER 11

# Q & A

정답이 아니어도 괜찮습니다.

지금보다 조금 더 나은 쪽으로 한 걸음이면 충분합니다.

