

1. 인공지능의 정의

- 튜링테스트: 사람처럼 행동하는가?
- AI 파라독스: 어제의 시로 간주되던 것이 오늘은 시가 아님

2. 탐색

1. 맹목적 탐색(전체 탐색): 깊이 우선 탐색, 너비 우선 탐색, 반복적 깊이 실행 탐색, 양방향 탐색

깊이 우선 탐색

- (단점) 최단 경로 해 탐색 보장 불가
- (장점) 메모리 공간 사용 효율적

너비 우선 탐색

- (장점) 최단 경로 해 탐색 보장
- (단점) 메모리 공간 사용 비효율

반복적 깊이 실행 탐색

- 최단 경로 해 보장
- 깊이 우선과 너비 우선의 장점을 모두 가짐
- 반복적인 깊이 우선 탐색에 따른 비효율성은 낮음
 - 노드별 10개의 자식노드를 가질 때, 너비 우선 탐색 대비 약 11%의 추가 노드 생성

양방향 탐색

- 너비 우선 탐색 점진적 모두 유지
- 상대적으로 복잡

2. 정보 이용 탐색(부분 탐색, 휴리스틱 탐색): 최상 우선 탐색, 빈 탐색, A* 알고리즘

• 언덕 오르기 탐색: 국소 최적점(local optima)에 빠질 위험 존재

3. 게임 탐색(상대적 탐색):

• mini-max 알고리즘: 지정된 깊이의 게임트리를 제작, 단말 노드부터 위로 올라가면서 연산을 반복해 판세 계산

• α-β 가지치기: 검토할 필요 없는 노드 탐색에서 제외

• 몬테칼로 트리 탐색

- 1) 반복적 깊이 실행 탐색 트리의 레벨을 증가하면서 루트 노드부터 해당 레벨까지의 부분 트리(서브트리)에 대해 너비 우선 탐색을 수행한다.
- 2) 탐색 공간 전체를 차례로 검사하는 방식이다.
- 3) 너비 우선 탐색 기본은 탐색공간 트리를 레벨별로 차례로 검사하므로 반드시 핵을 찾을 수 있다.
- 4) 깊이 우선 탐색 기본은 한 노드를 검사한 이후에는 그 노드에 연결되어 있는 노드를 등에서 아직 검사하지 못한 노드를 선택하여 검사한다.

정보 이용 탐색에 관한 설명 중에서 맞지 않는 것은?

- 1) 탐색 공간 전체를 차례로 검사하는 방식으로 과정의 각 상태에서 추출할 수 있는 정보를 활용하여 적절한 검사 대상 노드를 선택한다.
- 2) A* 알고리즘은 휴리스틱 값과 길경에 이미 투입된 비용과 남은 비용이 합계 고려된다.
- 3) 빈 탐색은 최상 우선 탐색을 기반으로 하되 각 레벨에 정해진 개수의 노드만 탐색한다.
- 4) 언덕 오르기 탐색은 전역 최적해(global optima)를 항상 찾을 수 있는 것은 아니다.

다음 중에서 게임 트리 탐색이 아닌 것은?

- 1) A* 알고리즘
- 2) mini-max 알고리즘
- 3) 몬테칼로 트리 탐색
- 4) α-β 가지치기

다음 중에서 게임 트리 탐색에 관한 설명 중에서 맞지 않는 것은?

- 1) 게임 트리 탐색에서 항상 '나' 또는 '상대방'은 자신이 승리하는 최종적인 최적의 상태까지 미리 수를 뒤서서 다음 역전(적점)을 취한다.
- 2) 게임 트리 탐색은 2명의 참여자가 서로 경쟁해서 승리를 경쟁하려는 게임에 대한 탐색 기법이다.
- 3) 게임 트리 탐색에서 '나'와 '상대방'이 고대로 상대 변형을 초래하는 역전을 취한다.
- 4) 게임 트리 탐색에서 '나'와 '상대방' 각자는 판세를 잘 못 읽어 잘못된 역전을 취하지는 않는다고 가정한다.

3. 지식 표현의 개요

- AI 초창기에는 탐색 중심의 GPS(General Problem Solver) 제작에 주안점을 둬. 지금은 실제적인 문제를 해결하기 위해 지식 + 추론 패러다임과 특화로 방향 전환
- 인공지능은 형식지에 주안점

종류	유형	비고
논리 기호	부정(negation)	$\neg P$ P가 아님
논리합(disjunction)	$P \vee Q$	P 또는 Q
논리곱(conjunction)	$P \wedge Q$	P 그리고 Q
함의(implication)	$P \rightarrow Q$	P이면 Q
동치(equivalence)	$P \leftrightarrow Q$	$(P \rightarrow Q) \wedge (Q \rightarrow P)$

진리표 (truth table)

P	Q	$\neg P$	$P \vee Q$	$P \wedge Q$	$P \rightarrow Q$	$P \leftrightarrow Q$
F	F	T	F	F	T	T
F	T	T	T	F	T	F
T	F	F	T	F	F	F
T	T	F	T	T	T	T

- 논리의 진리값 결정(interpretation)
 - $P = T, Q = F, R = T$ 일때,
 - $(P \vee \sim Q) : T$
 - $(Q \wedge \sim R) : F$
 - $(P \vee \sim Q) \wedge (Q \wedge \sim R) : F$
- 함의(implication) : $P \rightarrow Q$
 - P 이면 Q 이다.
 - $\neg(P \rightarrow Q) \rightarrow \neg P \vee Q$

- 정형식(wff)
- 리터럴: 한 명제 기호와 해당 명제 기호의 부정을 통칭
- 절: 리터럴들이 논리합이나 논리곱으로만 연결된 논리식
- 논리곱 정규형(conjunctive normal form, CNF): 논리합 절들의 논리곱 형태의 논리식
- 논리합 정규형(disjunctive normal form, DNF): 논리곱 절들의 논리합 형태의 논리식
- 모델: 논리식에 포함되어 있는 각 명제 기호의 진리값 상태(2^n 개의 모델 존재)
- 항진식(tautology): 모든 모델에서 참인 논리식
- 모순적 또는 충족불가능한 논리식(contradiction or unsatisfiable): 항위식(contradiction): 모든 모델에서 거짓인 논리식
- 충족가능한(satisfiable) 논리식: 적어도 하나의 모델에서 참인 논리식
- 연역적 추론: 참인 사실들로부터 새로운 참인 명제를 도출하는 것
 - 추론의 정당성(soundness): 추론 규칙을 통해 도출된 논리식은 항상 논리적 귀결이 된다 ($\nabla \vdash w \rightarrow \nabla \models w$)
 - 추론 규칙의 완전성(completeness): 주어진 논리식들의 논리적 귀결은 항상 추론 규칙을 통해 찾아낼 수 있다.
 - 정리 증명(theorem proving): ∇ 가 공리(추론을 할 때 참인 것으로 주어지는 논리식), ∇ 가 정리(공리들에 추론 규칙을 적용하여 얻어지는 논리식)

논리적 귀결(logical implication)

P	Q	Δ	ω
F	F	F	F
F	T	F	T
T	F	F	F
T	T	T	T

- Δ : 정형식(wff)의 집합
- ω : 정형식 (의 집합)
- $\Delta \models \omega$
 - Δ 가 참이면, ω 도 참이다
 - ω 는 Δ 의 논리적 귀결(logical implication or consequence)
- 추론
 - Δ 로부터, 알려지지 않은 ω 를 찾는 것

추론규칙(inference rule)

- 추론 과정에 적용하는 규칙
 - $P \rightarrow Q, P \vdash Q$ (modus ponens)
 - $P \rightarrow Q, \neg Q \vdash \neg P$ (modus tollens)
 - $P \rightarrow Q, Q \rightarrow R \vdash P \rightarrow R$ (syllogism)

장점:

- 대수학적 근거를 바탕으로 논리 개념을 자연스럽게 표현 가능
- 지식의 첨가와 삭제가 용이
- 정리증명 등 정형화된 지식 영역에 적합

단점:

- 절차적인 지식의 표현이 난해
- 실제계의 복잡한 구조의 표현이 난해

• 술어 논리(predicate logic): 명제 논리의 한계를 극복하기 위해 고안된 논리 체계. 술어명(인수) 형태로 표현

- 항(term): 상수, 변수, 함수로 구성된 표현식. 그 개수는 제한이 없음
 - * ex) John, x, father(John, legs(John))

전칭 한정사(universal quantifier)

- "모든 x"
- "모든 x가 만족한다, for every"
- "모든 x가 적어도 하나 존재한다."

• 일차 술어논리(first-order predicate logic): 변수에만 한정사를 쓸 수 있도록 한 술어논리

술어 논리를 이용한 지식 표현

likes(Tom, Math) likes(Tom, Physics) likes(Tom, Philosophy)	likes(Judy, Math) likes(Judy, Physics) ~likes(Judy, Philosophy)	~likes(John, Math) ~likes(John, Physics) likes(John, Philosophy)
---	---	--

- 모든 학생은 모든 과목을 좋아한다. (거짓)
 - 모든 과목을 좋아하는 학생이 있다. (참), Tom
 - 수학을 좋아하면 물리도 좋아한다. (참), Tom & Judy
 - 수학과 물리를 모두 좋아하는 학생도 있다. (참), Tom & Judy

• Horn 절: 절의 한 형태로, 긍정 리터럴이 최대 하나인 절 ex) $p \rightarrow Q$ (Horn 절이 아님), $\neg p \vee Q$ (Horn 절)

- 논리(logic) 기반 지식 표현 및 추론
 - 기호를 사용하여 문장들을 표현 & 기호의 조작을 통해 문장들의 참 또는 거짓을 판정하는 분야
 - 명제논리와 술어논리로 구분
 - * 명제논리는 문장을 기호로 표현하여 지식을 표현
 - * 술어논리는 문장의 내용을 술어(predicate)와 객체(주체 또는 대상)으로 나눠 지식을 표현
 - 긍정논법, 부정 논법, 삼단논법, 도출(resolution) 등의 대수적 기법을 사용한 추론 • 장단점
 - 선언적 지식 표현 및 지식의 추가 • 삭제가 용이
 - 실환경의 복잡한 지식의 표현에는 한계
 - * 술어논리 기반의 PROLOG 언어가 한 때 주목을 받았지만 실패
- 규칙 기반 추론:
 - 전문가시스템은 상대적으로 지식 표현이 수월하고, 불확실한 지식을 표현하는데 장점이 있어 규칙 기반으로 제작됨
 - 지식의 자동추출 및 축적(학습) 불가능

- 전가 시스템(expert)에 대한 설명으로 맞지 않는 것은?
 - 한 개의 우수한 전문가 시스템을 구축하면, 의료, 법률 등 대부분의 분야에 그대로 활용할 수 있다.
 - 전문가 시스템은 주로 논리보다는 보이는 규칙을 기반으로 제작되었다.
 - 전문가 시스템은 추론 과정에 시간이 걸리며, 지식 구축에 비용이 많이 든다는 단점이 있다.
 - 전문가 시스템은 지식 표현이 상대적으로 수월하고 불확실한 지식을 표현하는데 장점이 있어 1980년대 중반에 많은 상용시스템이 구축되었다.
- 논리 기반 지식 표현과 규칙 기반 지식 표현을 비교한 것으로 알맞은 것은?
- 일반적으로 논리 기반 지식 표현이 규칙 기반 지식 표현보다 어렵지만, 추론 방식은 동일하다.
 - 일반적으로 논리 기반 지식 표현이 규칙 기반 지식 표현보다 지식 표현의 유연성이 높다.
 - 대규모 지식의 구축에는 논리 기반 지식 표현이 규칙 기반 지식 표현보다 적합하다.
 - 논리 기반 지식 표현이 규칙 기반 지식 표현보다 실용적인 유용을 위한 상황화에 성공적이었다.


머신러닝의 개념

- 인공지능 > 머신러닝 > 딥러닝
- 프로그래밍은 해결할 수 없는 문제가 많았다: **특징점 자동 추출 학습, 새로운것 인식(필기체, 얼굴 인식 등)**
- 머신 러닝 태스크: 분류, 상관관계 파악(회귀), 군집화**
- 학습 방식:** 감독학습, 비지도학습 등
- 분류:** 분류 대상 카테고리(클래스)는 사전에 지정됨. 사물 인식, 손글씨 숫자 인식, 음성 인식 등
- 회귀(상관관계 분석):** 출력은 실수. 상관관계 모델링을 통한 예측 및 추세 분석
- 로지스틱 회귀:** 종속변수가 범주형. 이항형, 다항형, 사실은 확률적 성격을 가미한 분류 기법
- 군집화:** 클러스터의 개수는 사전에 정해져 있지 않음. 문서 분류, 영상의 색조에 따라 영상을 분류(위성 사진으로 국토 수확량, 화재 상황 분석 등)
- 감독 학습(지도 학습):** 데이터에 사람이 작업을 한 라벨을 다한 학습 데이터 구축. 분류, 회귀
 - 학습 샘플은 **샘플과 목표치 쌍**
- 비감독 학습(비지도 학습):** 라벨이 없는 데이터로 학습. 군집화 등
- 강화 학습:** 게임 수행(아타리 알파고) 등
- 딥 러닝:** 학습 데이터(MNIST, CIFAR-10 등)에서 특징점 자동 추출 학습. **다층구조, 계층적 추상화 학습, End-to-End 학습**



신경망

- 신경망의 학습: 가중치 변경**
- 생물학적 뉴런: 시냅스 연결 강도, 인공 뉴런 네트워크: 연결선의 가중치 크기
- 학습 데이터를 입력으로 사용하여 연결 강도에 반영
- $b = -\theta$




Rectified Linear Function

- Linear threshold function과도 함
- 가중치가 음수일 경우에는 출력은 무조건 0
- 가중치가 양수일 경우에는 선형값이 있음
- 딥러닝 학습에서 시그모이드 함수에서 나타나는 여러 기울기 초실이나 폭증의 문제점을 해소
- 축약영어로 **ReLU**를 사용
- 여러가지 변형 존재
 - Leaky ReLU


시그모이드 함수

- 계단 함수이며, 3종류 출력: $y = \text{sgn}(x)$
- 초기 뉴런인 McCulloch-Pitts (1943) 뉴런에서 사용
 - 하지만, 출력은 아래와 같이 2가지로 변경한 형태로 사용



로지스틱 시그모이드 함수

- [0,1] 범위의 출력 값을 갖는 부드러운(smooth) 함수
- 출력값이 확률인 경우에도 사용 가능
 - 이런 뉴런은 Stochastic binary neuron이라 부름
- 미분가능
 - 기울기 강하 기반 신경망 학습에 적합




- 퍼셉트론:** 입력층과 출력층만으로 구성. 엄밀하게는 뉴런은 아니다. 시그널 함수의 수정된 사용 ($1 \text{ v} >= 0$)

- 선형 분리 가능한 데이터에 대해서는 무조건 수렴
- 퍼셉트론의 한계: 선형분리성 (OR 연산은 가능하지만 XOR 연산은 불가능)

FNN


- No cyclck link, 한 개 이상의 히든 계층, 다양한 활성화 함수 사용**
- 완전연결층**



- affine 계층: 선형 뉴런으로 구성된 계층. $xW + b \rightarrow y$
- 단일 모드: 한번에 하나의 입력을 처리
- 배치 모드: 여러 개의 입력을 한 번에 처리. 병렬처리 가능, 학습 속도 향상, 일반적으로 더 나은 성능
- 배치 처리를 하는 이유: **병렬 처리로 학습 속도 향상, 정확도는 떨어지지만 일반화 좋다.**



- 평균제곱에러 ($\frac{1}{2N} \sum_{d=1}^N \sum_{i=1}^q (d_{di} - y_{di})^2$)
- 기울기 강하법: $x_{t+1} = x_t - \eta \nabla f(x_t)$



- 신경망의 학습이 문제로 대두 (* 델타규칙은 단층신경망에만 유용)
- 백프로퍼게이션 알고리즘은 다층 신경망의 학습을 가능하게 함
- 하지만, 기울기 소실 또는 폭증(error gradient vanishing or explosion) 현상으로 계층의 개수가 커지면 실용성이 떨어짐) 다층 신경망이 소규모 응용에만 사용이 제한됨
- 백프로퍼게이션 알고리즘의 여러 다른 이름: 오류 역전파 알고리즘, 역전파 알고리즘, 역전파 학습 알고리즘




Figure 1: 노드 에러 기울기(활성화 함수의 미분값 x 후방계층 노드들의 가중 노드 에러 기울기의 합)




Figure 2: 가중치 에러 기울기(앞노드의 출력 x 뒷노드의 에러 기울기)

- SGD(stochastic gradient descent): 샘플 단위로 가중치 갱신.(배턴 모드, Online 모드) 전체 샘플 학습 처리를 Epoch라고 함. 미니배치의 크기가 1개 샘플인 경우
- 미니 배치 모드: 배치 모드와 온라인 모드의 절충안. Local minima에 빠져도 나올 가능성이 있음.
- 확률적 순서: 샘플의 학습 순서를 무작위로 선정