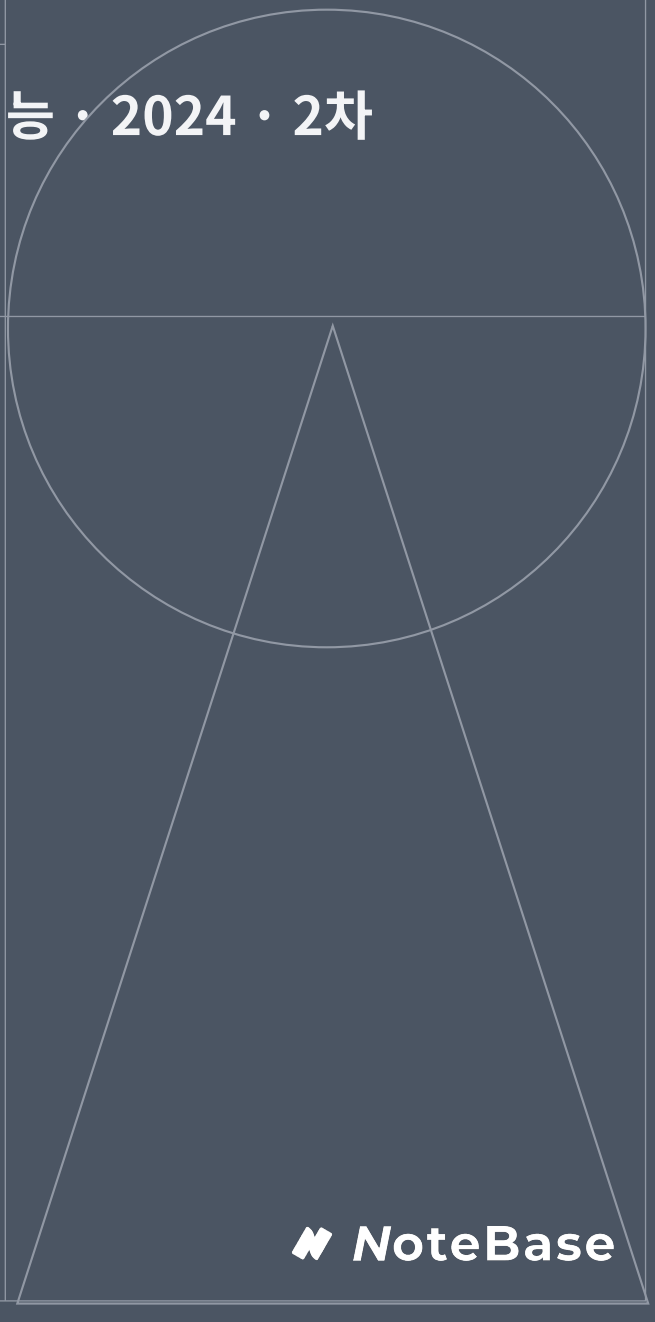
기출OX 해설집

공무원/국가직/7급 · 인공지능 · 2024 · 2차



NoteBase

기출OX 해설집

공무원/국가직/7급 · 인공지능 · 2024 · 2차

공무원/국가직/7급 · 인공지능 · 2024 · 2차

문 1. 다음 설명에 해당하는 기술은?

특정 영상(이미지)에 다른 인물의 얼굴, 음성 등을 합성하여 실제와 유사하게 행동하고 말하는 것처럼 보이는 영상을 생성하는 인공지능 기술

① 딥페이크(deepfake)
② 사물인터넷(IoT)
③ 블록체인(blockchain)
④ 가상 현실(virtual reality)

정답 1번

출제 포인트

이 문제는 생성형 인공지능의 합성 기술과 사물 연결, 분산 저장, 가상 체험 기술을 구별할 수 있는지를 묻는다.

핵심 개념

딥페이크는 특정 인물의 얼굴이나 음성 같은 특징을 인공지능으로 합성하여 실제처럼 보이는 영상이나 음성을 만드는 기술이다.
사물인터넷은 센서나 통신 기능이 있는 사물들이 네트워크로 연결되어 데이터를 주고받는 기술이다.
블록체인은 거래 기록을 여러 참여자가 분산 저장하고 검증하는 기술이다.
가상 현실은 사용자가 컴퓨터가 만든 가상 환경을 실제처럼 체험하게 하는 기술이다.

NoteBase

선지별 해설

1번: O. 설명의 핵심은 다른 인물의 얼굴과 음성을 합성해 실제처럼 말하고 행동하는 영상으로 보이게 만드는 기술이라는 점이다. 이는 딥페이크의 정의와 일치한다.
2번: X. 틀린 부분은 사물인터넷을 얼굴·음성 합성 영상 생성 기술처럼 본 점이다. 사물인터넷은 실제로는 가전, 센서, 차량 같은 사물을 연결해 데이터를 수집·전송·제어하는 기술이다.
3번: X. 틀린 부분은 블록체인을 인물 합성 영상 생성 기술처럼 본 점이다. 블록체인은 실제로는 거래나 정보를 분산 원장에 기록하고 위변조를 어렵게 만드는 기술이다.
4번: X. 틀린 부분은 가상 현실을 다른 인물의 얼굴·음성을 합성하는 기술처럼 본 점이다. 가상 현실은 실제로는 사용자가 가상 공간에 들어간 것처럼 체험하게 하는 기술이다.

오답 포인트

영상이라는 단어 때문에 4번 가상 현실과 헷갈리기 쉽지만, 가상 현실은 체험 환경의 구현이 핵심이고 딥페이크는 특정 인물의 얼굴·음성 합성이 핵심이다.

다시 나오면 이렇게 판단

문장에 특정 인물의 얼굴, 음성, 말하는 모습, 합성, 실제처럼 보임이 함께 나오면 딥페이크로 판단한다. 사물 연결은 사물인터넷, 분산 기록은 블록체인, 가상 체험은 가상 현실로 구분한다.

암기 포인트

딥페이크는 인물 합성, 사물인터넷은 사물 연결, 블록체인은 분산 기록, 가상 현실은 가상 체험이다.

NoteBase

문 2. 인공지능 활용 분야 중 사용되는 대표 학습 모델이 다른 것은?

① 유명한 화가가 그린 그림의 화풍을 분석하는 것
② 현금 인출기에서 수표에 쓰인 필기체 숫자를 인식하는 것
③ 스마트폰에서 연관성이 있는 사진들을 모아 정리해 주는 것
④ 사람이 하는 말을 텍스트로 변환해 주는 서비스를 이용하는 것

정답 4번

출제 포인트

이 문제는 응용 분야별 대표 학습 모델을 데이터 유형으로 구분하는 문제이다.

핵심 개념

합성곱신경망(CNN)은 이미지의 공간적 패턴을 추출해 분류·인식하는 대표 모델이다.
순환신경망(RNN)·LSTM·Transformer는 시간 순서가 있는 음성·문장 데이터를 처리하는 대표 모델이다.

선지별 해설

1번 X: 틀린 부분은 이 사례를 '다른 것'으로 볼 수 있다는 점이다. 화풍 분석은 그림 이미지의 색채·질감·형태 패턴을 읽는 비전 과제이므로 대표적으로 CNN 계열을 사용한다. 올바르게는 '2번, 3번과 같은 이미지 기반 대표 모델 사례'이다.
2번 X: 틀린 부분은 이 사례를 '다른 것'으로 볼 수 있다는 점이다. 필기체 숫자 인식은 대표적인 이미지 분류 문제이므로 CNN 계열이 자주 쓰인다. 올바르게는 '1번, 3번과 같은 계열'이다.
3번 X: 틀린 부분은 이 사례를 '다른 것'으로 볼 수 있다는 점이다. 스마트폰 사진 정리는 이미지 특징을 추출해 유사한 사진을 묶는 비전 과제이므로 대표적으로 CNN 기반 특징 추출이 활용된다. 올바르게는 '1번, 2번과 같은 이미지 처리 계열'이다.
4번 O: 사람의 말을 텍스트로 바꾸는 작업은 음성 신호의 시간적 순서를 처리하는 음성 인식 과제이다. 따라서 대표적으로 RNN·LSTM·Transformer 같은 시퀀스 모델을 사용하므로 1번부터 3번까지와 대표 학습 모델이 다르다.

오답 포인트

보기의 겉모습만 보면 모두 인공지능 활용 사례여서 비슷하게 보이지만, 출제 의도는 '무슨 데이터를 처리하느냐'를 묻는 점에 있다. 3번은 사진 정리라는 서비스 표현 때문에 추천 시스템처럼 느껴질 수 있으나, 핵심은 이미지 특징 추출이라는 점이다.

NoteBase

다시 나오면 이렇게 판단

먼저 입력 데이터가 이미지인지, 음성·문장 같은 순차 데이터인지 구분한다. 이미지 중심이면 CNN 계열, 시간 순서가 중요한 음성·문장 중심이면 시퀀스 모델 계열로 판단하면 된다.

암기 포인트

이미지는 CNN, 음성·문장은 시퀀스 모델이라는 축으로 정리하면 된다.

NoteBase

문 3. 생성형 인공지능에 대한 설명으로 옳지 않은 것은?

① 프롬프트(prompt)에 대응하여 텍스트, 이미지 등을 생성한다.

② 주요 생성형 인공지능 모델로는 ChatGPT, Bard, LLaMa 등이 있다.

③ 학습 데이터의 패턴과 구조를 학습하여 유사한 특징이 있는 새로운 데이터를 생성한다.

④ 텍스트를 이미지로 변환하는 생성형 모델로는 Stable Diffusion, Neocognitron, DALL-E 등이 대표적이다.

정답 4번

출제 포인트

이 문항은 생성형 인공지능의 개념과 대표 모델의 성격을 구분할 수 있는지를 묻는 문제이다.

핵심 개념

생성형 인공지능은 학습한 데이터의 분포와 패턴을 바탕으로 새로운 텍스트, 이미지, 음성 등을 만들어 내는 모델이다.
인식형 모델은 입력 데이터를 분류하거나 특징을 추출하는 데 초점이 있으며, 새로운 콘텐츠 생성이 주된 목적이 아니다.
텍스트-이미지 생성 모델은 텍스트 설명을 바탕으로 새로운 이미지를 합성하는 생성 모델이다.

선지별 해설

① O: 프롬프트는 생성형 인공지능에 입력하는 지시문이며, 이에 따라 텍스트나 이미지 같은 결과를 생성한다는 설명이므로 옳다.
② O: ChatGPT, Bard, LLaMA는 생성형 인공지능을 대표하는 대화형 서비스 또는 대규모 언어모델 계열의 예시로 볼 수 있으므로 옳다.
③ O: 생성형 인공지능은 학습 데이터의 패턴과 구조를 학습하여 유사한 특성을 가진 새로운 데이터를 생성하므로 옳다.
④ X: 틀린 표현은 "Neocognitron"이다. Neocognitron은 텍스트를 이미지로 바꾸는 생성형 모델이 아니라 초기 시각 패턴 인식 모델이다. 올바르게는 "텍스트를 이미지로 변환하는 대표적 생성형 모델로는 Stable Diffusion, DALL-E 등이 있다"라고 정리한다.

오답 포인트

출제자는 유명한 인공지능 이름을 한 선지에 섞어 두고 모두 생성형 모델처럼 보이게 만든다. ④는 Stable Diffusion과 DALL-E가 실제 생성형 모델이라는 점 때문에 전체를 맞는 설명처럼 오인하기 쉽지만, Neocognitron이 인식 모델이라는 점을 잡아내야 한다.

NoteBase

다시 나오면 이렇게 판단

모델 이름이 나오면 먼저 그 모델의 핵심 기능이 새로운 데이터를 만들어 내는지, 아니면 입력을 분류·인식하는지로 나눈다. 생성이 목적이면 생성형이고, 인식·분류가 목적이면 생성형 대표 모델 목록에 넣을 수 없다고 판단한다.

암기 포인트

생성형은 새 결과를 만든다. Neocognitron은 생성이 아니라 인식 계열이다.

NoteBase

문 4. 인공지능을 구현하기 위해 필요한 요소 기술에 대한 설명으로 옳지 않은 것은?

① 추론은 현재 상태에서 목표 상태에 도달하기 위해 수행해야 할 일련의 행동 순서를 찾는 것을 의미한다.

② 지식표현은 문제를 해결하거나 심층적인 추론을 하는 데 사용할 수 있도록 지식을 효과적으로 표현하는 방법이다.

③ 학습은 경험을 통해 나중에 동일한 문제나 유사한 문제를 더 잘 해결할 수 있도록 시스템의 구조나 파라미터를 바꾸는 것을 의미한다.

④ 탐색은 문제의 답이 될 수 있는 것들의 집합을 공간으로 간주하고 문제에 대한 최적의 해를 찾기 위해 공간을 체계적으로 검색하는 것을 의미한다.

정답 1번

출제 포인트

이 문제는 추론, 지식표현, 학습, 탐색의 정의를 구별할 수 있는지를 묻는다.

핵심 개념

추론은 주어진 사실과 규칙에서 새로운 결론을 도출하는 과정이다. 키워드는 결론 도출이다.
지식표현은 문제 해결에 사용할 지식을 기계가 처리할 수 있는 형식으로 구조화하는 방법이다. 키워드는 표현 방식이다.
학습은 경험이나 데이터에 따라 시스템의 구조나 매개변수를 조정하여 이후 성능을 높이는 과정이다. 키워드는 성능 개선이다.
탐색은 가능한 해의 집합을 상태 공간으로 보고 목표 해를 찾기 위해 공간을 체계적으로 조사하는 과정이다. 키워드는 상태 공간 탐색이다.

선지별 해설

1번: X. '현재 상태에서 목표 상태에 도달하기 위해 수행해야 할 일련의 행동 순서를 찾는 것'은 추론이 아니라 탐색 또는 계획의 설명이다. 틀린 표현은 '추론'이다. 올바르게는 탐색은 현재 상태에서 목표 상태까지의 경로를 상태 공간에서 찾는 과정이고, 추론은 주어진 지식으로부터 결론을 도출하는 과정이다.
2번: O. 지식표현은 지식을 규칙, 논리, 프레임, 의미망 등의 형식으로 표현하여 문제 해결과 추론에 활용할 수 있게 하는 기술이므로 설명이 옳다.
3번: O. 학습은 경험을 통해 이후 유사 문제를 더 잘 해결하도록 시스템의 구조나 매개변수를 바꾸는 과정이므로 설명이 맞다.
4번: O. 탐색은 답이 될 수 있는 상태들의 집합을 공간으로 보고 그 안에서 목표 해를 찾는 과정이므로 상태 공간을 체계적으로 검색한다는 설명이 옳다.

NoteBase

오답 포인트

1번의 '행동 순서'와 '목표 상태 도달'이라는 표현 때문에 추론과 탐색을 섞기 쉽다. 행동 경로나 상태 이동을 찾으면 탐색이고, 이미 가진 지식에서 결론을 뽑아내면 추론이다.

다시 나오면 이렇게 판단

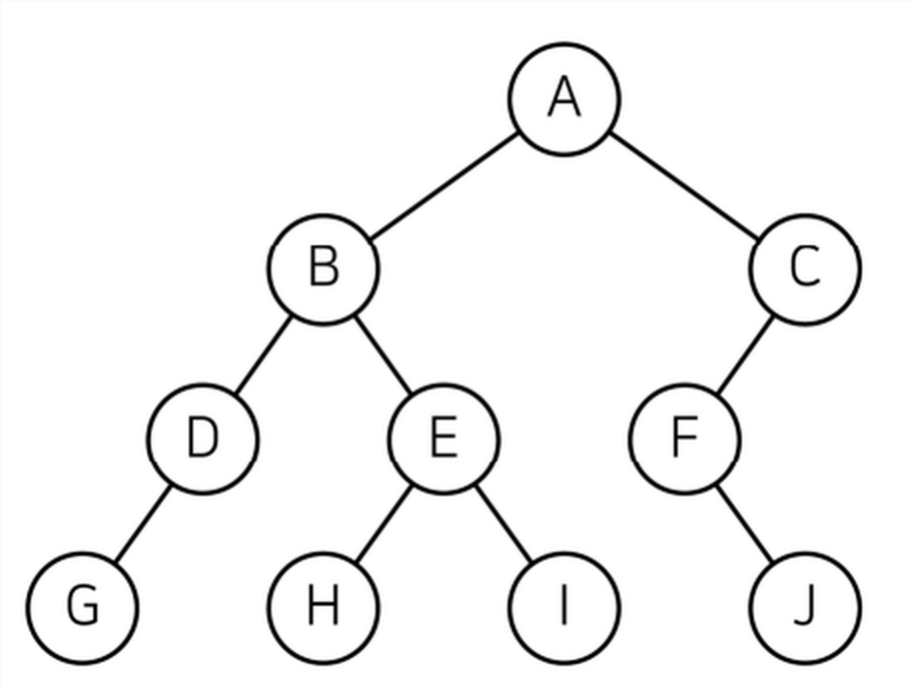
문장에 결론 도출이 나오면 추론, 지식의 형식화가 나오면 지식표현, 경험에 따른 성능 향상이 나오면 학습, 상태 공간이나 경로 탐색이 나오면 탐색으로 판단한다.

암기 포인트

추론은 결론, 탐색은 경로, 지식표현은 형식, 학습은 개선이다.

NoteBase

문 5. 그림과 같은 탐색 트리에서 시작 노드 A부터 깊이 우선 탐색(DFS)과 너비 우선 탐색(BFS)을 수행할 경우 노드 F를 몇 번째로 방문하게 되는지를 각각 M과 N이라고 할 때, M + N의 값은? (단, 노드 A의 방문 순서는 1이고, 왼쪽 자식을 먼저 방문한다)



① 13

② 14

③ 15

④ 16

정답 3번

출제 포인트

이 문제는 DFS와 BFS의 방문 규칙을 구분한 뒤 특정 노드 F의 방문 순서를 각각 세어 합을 구할 수 있는지를 묻는 문제이다.

올바른 순서

DFS에서 왼쪽 자식을 먼저 방문하면 순서는 A(1) -> B(2) -> D(3) -> G(4) -> E(5) -> H(6) -> I(7) -> C(8) -> F(9) -> J(10)이다.
BFS에서는 레벨 순서대로 A(1) -> B(2) -> C(3) -> D(4) -> E(5) -> F(6) -> G(7) -> H(8) -> I(9) -> J(10)이다.
따라서 F의 방문 순서는 DFS에서 9, BFS에서 6이므로 $M + N = 15$이다.

NoteBase

선지별 해설

① X: 틀린 값은 13이다. 이 값은 DFS에서 F를 너무 이르게 세었을 때 나온다. DFS는 B의 하위 트리인 D, G, E, H, I를 모두 방문한 뒤에야 C와 F로 이동하므로 F는 9번째이다. 올바르게는 13이 아니라 15이다.
② X: 틀린 값은 14이다. 이 값은 DFS나 BFS의 방문 차례를 한 칸씩 잘못 세었을 때 나오기 쉽다. BFS에서는 F가 A, B, C, D, E 다음에 오므로 6번째이고, DFS에서는 C에 도달한 뒤 바로 F를 방문하므로 9번째이다. 올바르게는 14가 아니라 15이다.
③ O: DFS는 한 분기를 끝까지 내려간 뒤 되돌아오고, BFS는 같은 깊이의 노드를 먼저 방문한다. 따라서 F는 DFS에서 9번째, BFS에서 6번째이므로 합은 15이다.
④ X: 틀린 값은 16이다. 이 값은 F를 J보다 늦게 방문한다고 잘못 생각할 때 나온다. 그러나 C의 자식은 F뿐이고 J는 F의 자식이므로 DFS와 BFS 모두에서 F가 J보다 먼저 방문된다. 올바르게는 16이 아니라 15이다.

오답 포인트

가장 흔한 실수는 DFS를 단순히 왼쪽부터 차례로 훑는 방식으로 오해하거나, BFS에서 같은 깊이의 노드를 모두 방문하기 전에 아래 단계로 내려가는 것이다. 또한 A의 방문 순서를 1로 두라는 조건을 놓치면 전체 번호가 한 칸씩 밀린다.

다시 나오면 이렇게 판단

트리 탐색 문제는 먼저 시작 노드의 번호를 고정한 뒤 DFS는 한 갈래를 끝까지 내려갔다가 되돌아오는 방식으로, BFS는 같은 깊이의 노드를 왼쪽부터 모두 방문한 뒤 다음 깊이로 내려가는 방식으로 각각 번호를 매기면 된다.

암기 포인트

DFS는 깊게 내려간 뒤 되돌아오고, BFS는 층별로 방문하므로 같은 노드라도 방문 차례가 크게 달라진다.

NoteBase

문 6. 다음 중 비지도 학습으로 분류되는 것은?

① 선형 회귀(LR, Linear Regression)

② K-평균 알고리즘(K-means algorithm)

③ k-최근접 이웃(kNN, k-Nearest Neighbor)

④ 서포트 벡터 머신(SVM, Support Vector Machine)

정답 2번

출제 포인트

이 문제는 지도 학습과 비지도 학습의 구분 기준을 묻는 문제이다.

핵심 개념

지도 학습은 정답 레이블이 있는 데이터를 학습해 입력과 출력의 관계를 예측하는 방법이다.
비지도 학습은 정답 레이블 없이 데이터의 구조나 군집 같은 숨은 패턴을 찾는 방법이다.
K-평균은 데이터들을 유사도 기준으로 여러 군집으로 묶는 대표적 비지도 학습 알고리즘이다.

선지별 해설

① X: 선형 회귀는 입력과 연속형 정답값 사이의 관계를 학습하는 지도 학습이다.
틀린 부분은 "비지도 학습으로 분류되는 것"에 해당한다고 본 점이다.
올바르게는 "선형 회귀는 대표적인 지도 학습 알고리즘이다."가 된다.

② O: K-평균 알고리즘은 정답 레이블 없이 데이터들을 K개의 군집으로 나누는 비지도 학습이다.
군집 구조를 찾는 것이 목적이므로 발문에 맞는 정답이다.

③ X: k-최근접 이웃은 주변의 레이블이 알려진 이웃들을 바탕으로 새 데이터의 클래스를 분류하거나 값을 예측하는 지도 학습이다.
틀린 부분은 "비지도 학습"으로 본 점이다.
올바르게는 "kNN은 대표적인 지도 학습 알고리즘이다."가 된다.

④ X: 서포트 벡터 머신은 주어진 레이블을 바탕으로 분류 경계 또는 회귀 함수를 학습하는 지도 학습이다.
틀린 부분은 "비지도 학습으로 분류된다"는 판단이다.
올바르게는 "SVM은 대표적인 지도 학습 알고리즘이다."가 된다.

NoteBase

오답 포인트

지도 학습과 비지도 학습은 알고리즘 이름보다 정답 레이블의 존재 여부로 구분한다. 회귀, kNN, SVM은 모두 예측 대상 레이블을 학습한다는 점에서 지도 학습인데, kNN이 거리 기반이라는 이유만으로 군집화와 혼동하면 오답이 된다.

다시 나오면 이렇게 판단

문제에서 학습 방식의 분류를 묻으면 먼저 정답 레이블이 있는지를 본다. 레이블이 있으면 지도 학습이고, 레이블 없이 군집화나 차원 축소처럼 데이터 구조를 찾으면 비지도 학습이다.

암기 포인트

K-평균은 군집화라서 비지도 학습이고, 회귀·kNN·SVM은 레이블을 학습하므로 지도 학습이다.

NoteBase

문 7. 스팸 메일 분류 시스템에서 분류기를 훈련시킨 후 검증 세트(1,000개의 데이터)에 대해 예측한 결과가 다음의 혼동 행렬(confusion matrix)과 같을 때, F1 점수(score)의 근삿값은?

실젯값: 스팸(양성), 스팸 아님(음성)
예측값 스팸(양성): 실젯값 스팸(양성) 90, 실젯값 스팸 아님(음성) 30
예측값 스팸 아님(음성): 실젯값 스팸(양성) 10, 실젯값 스팸 아님(음성) 870

① 0.75
② 0.82
③ 0.90
④ 0.96

정답 2번

출제 포인트

이 문제는 혼동 행렬에서 정밀도와 재현율을 구한 뒤 $F1$ 점수를 계산하는 문제이다.

조건 정리

주어진 값:
- 실제 스팸을 스팸으로 예측한 값 $TP = 90$이다.
- 실제 스팸 아님을 스팸으로 예측한 값 $FP = 30$이다.
- 실제 스팸을 스팸 아님으로 예측한 값 $FN = 10$이다.
- 실제 스팸 아님을 스팸 아님으로 예측한 값 $TN = 870$이다.

구해야 할 값: $F1$ 점수이다.
주의할 조건: $F1$은 정확도 *accuracy*가 아니라 정밀도와 재현율의 조화평균이다.

사용할 공식

정밀도는 $Precision = \frac{TP}{TP+FP} = \frac{90}{90+30} = 0.75$이다.
재현율은 $Recall = \frac{TP}{TP+FN} = \frac{90}{90+10} = 0.90$이다.
$F1$ 점수는 $F1 = \frac{2PR}{P+R}$ 또는 $F1 = \frac{2TP}{2TP+FP+FN}$이다.
이 공식을 쓰는 이유는 $F1$이 양성 예측의 정확성인 정밀도와 실제 양성 탐지율인 재현율을 함께 반영하는 지표이기 때문이다.

NoteBase

계산 과정

1. 정밀도는 0.75, 재현율은 0.90으로 계산된다.
2. $F1 = \frac{2 \times 0.75 \times 0.90}{0.75 + 0.90} = \frac{1.35}{1.65} \approx 0.81818$이다.
3. 따라서 $F1$ 점수의 근삿값은 약 0.82이다.

선지별 해설

① X: 0.75는 $F1$이 아니라 정밀도 값이다. 정밀도만 보고 답을 고른 경우의 오답이다. 틀린 값 0.75 → 올바르게는 약 0.82이다.
② O: $F1 \approx 0.81818$이므로 근삿값은 0.82이다.
③ X: 0.90은 $F1$이 아니라 재현율 값이다. 재현율만 보고 답을 고른 경우의 오답이다. 틀린 값 0.90 → 올바르게는 약 0.82이다.
④ X: 0.96은 $\frac{TP + TN}{1000} = \frac{90 + 870}{1000}$으로 계산한 정확도 값이다. $F1$과 정확도를 혼동한 경우의 오답이다. 틀린 값 0.96 → 올바르게는 약 0.82이다.

오답 포인트

혼동 행렬 문제에서는 정밀도, 재현율, 정확도를 서로 바꿔 계산하는 실수가 가장 흔하다. 이 문항은 보기 ①에 정밀도 0.75, 보기 ③에 재현율 0.90, 보기 ④에 정확도 0.96를 배치해 지표 개념 혼동을 유도한다.

다시 나오면 이렇게 판단

혼동 행렬 문제는 먼저 TP, FP, FN, TN을 표에서 정확히 읽고, 무엇을 묻는지에 따라 정밀도, 재현율, 정확도, $F1$ 중 해당 공식을 구분해 적용하면 된다. $F1$을 물으면 정밀도와 재현율을 함께 사용하거나 $\frac{2TP}{2TP + FP + FN}$ 공식을 바로 적용하면 된다.

암기 포인트

$F1$은 정밀도와 재현율의 조화평균이며, 정확도가 아니다.

NoteBase

문 8. 서포트 벡터 머신에 대한 설명으로 옳지 않은 것은?

① 주어진 데이터를 두 개의 영역으로 분류하는 이진 분류기이다.

② Vapnik 등이 개발한 통계 학습 이론의 결과를 기반으로 하는 기계학습 방법이다.

③ 데이터 분류를 위한 경계면은 경계면과 서포트 벡터들 간의 거리가 최대가 되도록 결정한다.

④ 경계면 결정 시 일부 데이터가 마진(margin) 내에 들어오도록 허용하는 것을 하드(hard) 마진이라 한다.

정답 4번

출제 포인트

이 문제는 서포트 벡터 머신의 기본 개념과 하드 마진, 소프트 마진의 차이를 묻는 문제이다.

핵심 개념

서포트 벡터 머신은 두 클래스 사이의 분류 경계를 가장 넓은 마진으로 정하는 지도학습 분류기이다.
하드 마진은 모든 학습 데이터가 마진 바깥에서 완전히 분리되어야 하는 방식이다.
소프트 마진은 일부 데이터의 마진 침범이나 오분류를 허용하되 그만큼 패널티를 주는 방식이다.

선지별 해설

① O: 기본적인 서포트 벡터 머신은 두 클래스를 구분하는 초평면을 찾는 이진 분류기이므로 맞는 설명이다.
② O: 서포트 벡터 머신은 Vapnik의 통계학습이론과 구조적 위험 최소화 원리에 기반한 기계학습 방법이므로 맞는 설명이다.
③ O: 서포트 벡터 머신은 결정경계와 가장 가까운 데이터인 서포트 벡터 사이의 거리가 최대가 되도록 초평면을 정하므로 맞는 설명이다.
④ X: 틀린 표현은 "일부 데이터가 마진 내에 들어오도록 허용하는 것을 하드 마진"이라는 부분이다. 실제로는 마진 침범이나 일부 오분류를 허용하는 것이 소프트 마진이고, 하드 마진은 그런 예외를 허용하지 않는다.

오답 포인트

④는 하드 마진과 소프트 마진의 용어를 서로 바꾸어 놓은 선지이다. 시험에서는 "허용한다"라는 표현이 나오면 소프트 마진을 먼저 떠올려야 한다.

다시 나오면 이렇게 판단

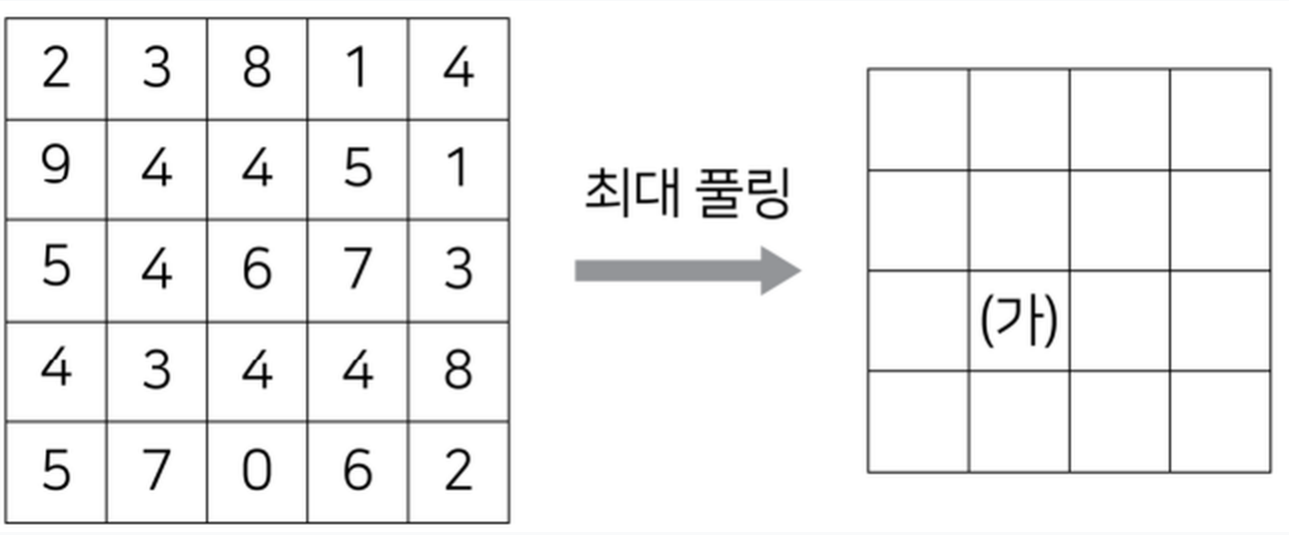
서포트 벡터 머신 문제에서는 먼저 최대 마진 분류기인지 확인하고, 이어서 예외를 허용하는지 여부로 하드 마진과 소프트 마진을 구분하면 된다.

암기 포인트

SVM은 최대 마진, 하드 마진은 예외 불허, 소프트 마진은 일부 허용이다.

NoteBase

문 9. 합성곱 신경망(CNN, Convolutional Neural Network)에서 그림과 같이 특징 맵이 설정된 경우, 최대 풀링(max pooling) 연산의 결과로 얻어지는 출력에서 (가)의 값은? (단, 필터(filter)의 크기는 2×2, 보폭(stride)은 1, 패딩(padding)은 사용하지 않는다)



① 4

② 5

③ 6

④ 7

정답 3번

출제 포인트

이 문제는 최대 풀링에서 출력 칸이 입력의 어느 2 × 2 영역을 보는지 찾고 그 영역의 최댓값을 구할 수 있는지를 묻는다.

조건 정리

입력 특징 맵은 5x5이다.
필터 크기는 2 × 2, stride는 1, padding은 없다.
따라서 출력 크기는 (5 − 2)/1 + 1 = 4이므로 4x4이다.
(가)는 출력 맵의 3행 2열 칸이다.

사용할 공식

최대 풀링은 각 2 × 2 영역의 최댓값을 출력한다. stride가 1이므로 출력의 한 칸이 이동할 때 입력 창도 한 칸씩 이동한다. 따라서 (가)에 해당하는 입력의 2 × 2 영역만 정확히 찾으면 된다.

NoteBase

계산 과정

1. 출력 3행 2열은 입력에서 3행 2열을 시작점으로 하는 2 × 2 영역에 대응한다.
2. 해당 영역의 값은 [4, 6; 3, 4]이다.
3. 이 네 값의 최댓값은 6이므로 (가)=6이다.

선지별 해설

1번: X. 4는 해당 2 × 2 영역 안의 일부 값일 뿐 최댓값이 아니다. (가)의 영역은 4, 6, 3, 4이므로 올바르게는 '(가)=6'이다.
2번: X. 5는 다른 위치의 풀링 결과에서는 나올 수 있지만 (가)가 가리키는 3행 2열 출력값은 아니다. (가)에 대응하는 영역의 최댓값은 6이므로 올바르게는 '(가)=6'이다.
3번: O. (가)는 입력의 [4, 6; 3, 4]에 대응하고, 최대 풀링 결과는 그중 최댓값인 6이다.
4번: X. 7은 인접한 다른 2 × 2 영역에서는 나올 수 있지만 (가)의 영역에는 7이 없다. 올바르게는 '(가)=6'이다.

오답 포인트

(가)가 출력 맵의 몇 행 몇 열인지 놓치거나, 대응되는 입력 창을 한 칸 잘못 잡으면 5나 7 같은 인접 칸 값으로 오답이 나온다. 최대 풀링은 영역 안의 모든 값을 본 뒤 최댓값 하나만 남긴다는 점을 빼먹어도 4 같은 오답이 나온다.

다시 나오면 이렇게 판단

풀링 문제는 먼저 출력 칸의 위치를 확인하고, 그 위치가 가리키는 입력의 창 시작 좌표를 찾은 뒤, 해당 창의 모든 값을 써 놓고 최댓값을 고하면 된다.

암기 포인트

최대 풀링은 출력 한 칸마다 대응되는 입력 창 하나를 잡고 그 창의 최댓값만 남긴다.

NoteBase

문 10. 활성화 함수 수식으로 옳지 않은 것은?

① $softmax(x) = \frac{2}{1+e^{-2x}} - 1$

② $softplus(x) = \ln(1+e^{x})$

③ $sigmoid(x) = \frac{1}{1+e^{-x}}$ (단극성)

④ $LeakyReLU(x) = \max(ax, x)$ (a는 양의 상수)

정답 1번

출제 포인트

이 문제는 대표적인 활성화 함수의 정의역과 출력 형태, 그리고 각 함수의 표준 수식을 구분하는지를 묻는 문제이다.

핵심 개념

softmax는 여러 클래스 점수를 확률분포로 바꾸는 함수로, 각 성분을 $\frac{e^{z_i}}{\sum_j e^{z_j}}$ 형태로 정규화한다.
softplus는 ReLU를 부드럽게 근사하는 함수로 $\ln(1+e^{x})$이다.
sigmoid는 입력을 0과 1 사이로 보내는 단극성 활성화 함수로 $\frac{1}{1+e^{-x}}$이다.
Leaky ReLU는 음수 구간에도 작은 기울기를 남기는 함수로, 보통 $x<0$이면 ax, $x \geq 0$이면 x이다.

선지별 해설

① X
제시식 $\frac{2}{1+e^{-2x}} - 1$은 softmax가 아니라 tanh와 동치인 식이다.
틀린 부분은 함수 이름을 softmax라고 둔 표현이다.
올바르게는 softmax는 단일 스칼라 식으로 저렇게 쓰지 않고, 벡터 입력에 대해 각 성분을 $\frac{e^{z_i}}{\sum_j e^{z_j}}$로 계산한다.

② O
softplus의 표준식은 $\ln(1+e^{x})$가 맞다.
이 함수는 ReLU처럼 증가하지만 미분이 모든 구간에서 부드럽게 정의된다는 점이 핵심이다.

③ O
sigmoid 함수의 대표식은 $\frac{1}{1+e^{-x}}$가 맞다.
출력이 0과 1 사이이므로 단극성 활성화 함수라는 설명도 맞다.

④ O
Leaky ReLU는 양수 구간에서는 x, 음수 구간에서는 ax를 쓰므로 $\max(ax, x)$로 표현할 수 있다.
a를 양의 상수로 둔 설명도 맞으며, 보통은 0보다 크고 1보다 작은 작은 값으로 둔다.

NoteBase

오답 포인트

①은 지수함수가 들어가 있어 sigmoid 계열처럼 보이므로 softmax와 혼동하기 쉽다. 그러나 softmax는 한 값의 모양보다 여러 출력의 합이 1이 되는 정규화 구조가 핵심이므로, 입력이 벡터인지와 분모에 전체 합이 있는지를 먼저 봐야 한다.

다시 나오면 이렇게 판단

활성화 함수 문제는 먼저 출력 범위와 입력 형태를 본다. 단일 스칼라를 0과 1 또는 -1과 1로 보내면 sigmoid나 tanh 계열이고, 여러 클래스 점수를 전체 합 1의 확률로 바꾸면 softmax이다.

암기 포인트

sigmoid는 0~1, tanh는 -1~1, softmax는 합이 1인 확률벡터이다.

NoteBase

문 11. 기계학습에서 발생할 수 있는 과적합(overfitting)을 완화하기 위한 방법으로 옳지 않은 것은?

① 드롭아웃(dropout)은 학습 과정에서 노드를 미리 정해진 비율만큼 랜덤으로 비활성화하여 과적합을 완화한다.

② 배치 정규화(batch normalization)는 은닉층의 가중치를 정규화하고 노드값의 표준편차를 증대시켜 과적합을 완화한다.

③ 데이터 증강(data augmentation)은 기존 학습 데이터에 약간의 변형을 가한 새로운 학습 데이터를 추가하여 과적합을 완화한다.

④ 규제화(regularization)는 오차 함수를 오차 항과 모델 복잡도 항의 합으로 정의하여 가중치의 절댓값을 제한함으로써 과적합을 완화한다.

정답 2번

출제 포인트

이 문제는 과적합을 완화하는 대표 기법들의 작동 대상과 원리를 구별하는지를 묻는 문제이다.

핵심 개념

드롭아웃은 학습 과정에서 일부 노드를 무작위로 비활성화하여 특정 노드나 경로에 대한 과도한 의존을 줄이는 기법이다.
배치 정규화는 각 층의 활성값 분포를 배치 단위로 정규화하여 학습을 안정화하는 기법이지 가중치 자체를 정규화하는 기법은 아니다.
데이터 증강은 기존 학습 데이터를 변형한 새 표본을 추가하여 일반화 성능을 높이는 기법이다.
규제화는 손실 함수에 가중치 패널티를 더해 모델 복잡도를 억제하는 기법이다.

선지별 해설

① O: 드롭아웃은 학습 중 미리 정한 비율만큼 노드를 무작위로 비활성화하여 과적합을 줄이는 대표 기법이므로 옳다.
② X: 틀린 부분은 "은닉층의 가중치를 정규화"와 "노드값의 표준편차를 증대"라는 표현이다. 배치 정규화는 가중치가 아니라 각 층의 활성값을 평균과 분산 기준으로 정규화하여 분포 변화를 줄이고 학습을 안정화한다. 표준편차를 일부러 키워 과적합을 완화하는 기법도 아니다.
③ O: 데이터 증강은 회전, 이동, 잡음 추가 같은 변형으로 학습 데이터를 늘려 모델이 더 다양한 입력을 보게 하므로 과적합 완화에 도움이 된다.
④ O: 규제화는 손실 함수에 가중치 크기에 대한 패널티를 더해 큰 가중치와 과도한 복잡도를 억제하므로 과적합 완화 방법으로 옳다.

NoteBase

오답 포인트

배치 정규화와 규제화를 모두 "정규화"라는 말로 묶어 기억하면 ②처럼 가중치 패널티와 활성값 정규화를 혼동하기 쉽다. ②의 핵심 함정은 정규화 대상이 가중치인지 활성값인지 바꿔 놓은 점이다.

다시 나오면 이렇게 판단

과적합 완화 기법 문제에서는 무엇을 무작위로 끄는지, 무엇을 더 많이 보여 주는지, 손실 함수에 무엇을 더하는지, 무엇의 분포를 정규화하는지를 기준으로 구분하면 된다.

암기 포인트

드롭아웃은 노드 끄기, 데이터 증강은 데이터 늘리기, 규제화는 가중치 벌점, 배치 정규화는 활성값 정규화이다.

NoteBase

문 12. 0부터 9까지의 손글씨 숫자를 판정하는 모델에서 숫자의 오름차순 기준으로 판정된 결과 벡터 y_1, y_2, y_3를 원-핫 인코딩(one-hot encoding)으로 표현할 때, 각 벡터를 나타내는 대표값을 바르게 연결한 것은? (단, 출력층의 활성화 함수로 softmax를 사용한다)

y_1 = [0, 0, 0.05, 0, 0, 0, 0.9, 0, 0.05, 0]
y_2 = [0, 0.1, 0, 0.7, 0, 0.15, 0, 0, 0, 0.05]
y_3 = [0.05, 0, 0, 0.4, 0, 0.2, 0.15, 0.05, 0.15, 0]

① y_1: 2, y_2: 2, y_3: 2
② y_1: 3, y_2: 7, y_3: 7
③ y_1: 6, y_2: 3, y_3: 3
④ y_1: 7, y_2: 4, y_3: 4

정답 3번

출제 포인트

softmax 출력 벡터에서 최댓값이 있는 위치를 찾고, 첫 번째 원소가 숫자 0에 대응한다는 점까지 반영해 대표 숫자를 정하는 문제이다.

자료 읽는 순서

1. 각 벡터의 원소가 숫자 0부터 9까지 순서대로 대응한다고 본다.
2. 각 벡터에서 가장 큰 값을 찾는다.
3. 최댓값이 놓인 위치를 숫자로 바꾸어 보기와 연결한다.

선지별 해설

① X: y1의 최댓값은 0.9이고 7번째 원소에 있으므로 대표값은 6이다. y2의 최댓값은 0.7이고 4번째 원소에 있으므로 대표값은 3이다. y3의 최댓값은 0.4이고 4번째 원소에 있으므로 대표값은 3이다. 틀린 표현은 y1=2, y2=2, y3=2이고, 올바르게는 y1=6, y2=3, y3=3이다.
② X: y1을 3으로 본 부분, y2를 7로 본 부분, y3를 7로 본 부분이 모두 틀리다. y1은 0.9가 있는 자리라 6이고, y2와 y3는 모두 0.7과 0.4가 놓인 4번째 원소가 최댓값이므로 3이다. 올바르게는 y1=6, y2=3, y3=3이다.
③ O: y1은 0.9가 가장 큰 값이므로 7번째 원소에 해당하는 숫자 6이 대표값이다. y2는 0.7이 가장 큰 값이므로 4번째 원소에 해당하는 숫자 3이 대표값이다. y3도 0.4가 가장 큰 값이므로 4번째 원소에 해당하는 숫자 3이 대표값이다.
④ X: y1을 7로 본 것은 원소 순서를 1부터 센 착오이다. 이 벡터는 첫 칸이 숫자 0이므로 7번째 원소는 숫자 6이다. y2와 y3도 각각 4번째 원소가 최댓값이므로 대표값은 4가 아니라 3이다. 올바르게는 y1=6, y2=3, y3=3이다.

NoteBase

오답 포인트

출력 벡터의 자리 번호를 1부터 세면 y1을 7로, y2와 y3를 4로 잘못 읽기 쉽다. 이 문항은 숫자 0부터 9까지의 분류이므로 첫 번째 원소가 0, 네 번째 원소가 3, 일곱 번째 원소가 6이라는 대응을 놓치면 바로 오답이 된다.

다시 나오면 이렇게 판단

softmax 분류 문제는 각 벡터에서 최댓값 하나만 먼저 찾고, 그 자리가 어떤 클래스 라벨에 대응하는지 확인하면 된다. 클래스가 0부터 시작하는지 1부터 시작하는지를 먼저 정리하면 위치 착오를 막을 수 있다.

암기 포인트

softmax 대표값은 최댓값의 자리이고, 0부터 시작하는 분류에서는 자리 번호보다 클래스 라벨을 먼저 본다.

NoteBase

문 13. 생성적 적대 신경망(GAN, Generative Adversarial Network)에 대한 설명으로 옳지 않은 것은?

① 판별자 출력층의 노드는 하나이다.

② 생성자와 판별자의 두 신경망을 사용한다.

③ 생성자의 학습 과정에서는 판별자를 사용하지 않는다.

④ 생성자의 목적은 판별자를 속일 수 있을 정도로 품질이 높은 위조 데이터를 생성하는 것이다.

정답 3번

출제 포인트

이 문제는 GAN에서 생성자와 판별자의 역할, 그리고 생성자 학습이 판별자의 출력에 의존한다는 점을 묻는 문제이다.

핵심 개념

생성자는 실제와 비슷한 가짜 데이터를 만들어 내는 신경망이다. 판별자는 입력 데이터가 진짜인지 생성자가 만든 가짜인지 구분하는 신경망이다. GAN의 핵심은 두 신경망이 경쟁하면서 학습하고, 생성자는 판별자의 판단 결과를 이용해 더 그럴듯한 데이터를 만들도록 갱신된다는 점이다.

선지별 해설

① O

판별자는 입력이 진짜일 확률 또는 가짜일 확률을 하나의 값으로 출력하는 이진 분류기 형태가 기본이다. 따라서 표준 GAN에서는 출력층 노드를 하나로 두는 설명이 맞다.

② O

GAN은 생성자와 판별자라는 두 신경망이 서로 경쟁하는 구조이다. 생성자는 가짜 데이터를 만들고, 판별자는 이를 진짜 데이터와 구별한다.

③ X

틀린 부분은 "생성자의 학습 과정에서는 판별자를 사용하지 않는다"는 표현이다. 실제로는 생성자를 학습할 때도 판별자의 출력과 오차가 필요하다. 다만 생성자 단계에서는 판별자의 판단을 이용해 생성자만 갱신할 뿐, 판별자를 전혀 쓰지 않는 것은 아니다.

④ O

생성자의 목적은 판별자가 진짜로 오인할 정도로 품질이 높은 가짜 데이터를 만드는 것이다. 이 설명은 GAN의 학습 목표를 올바르게 서술한다.

NoteBase

오답 포인트

③은 생성자 학습 시 판별자의 가중치를 함께 업데이트하지 않는다는 사실을, 판별자를 사용하지 않는다는 말로 바꿔 놓은 함정이다. "판별자를 고정한다"와 "판별자를 쓰지 않는다"는 전혀 다른 의미이다.

다시 나오면 이렇게 판단

GAN 관련 선지는 먼저 역할을 나눠서 본다. 생성자는 가짜 데이터를 만들고, 판별자는 진짜와 가짜를 구분한다. 그다음 생성자 학습이 무엇을 기준으로 이루어지는지 확인하면, 판별자의 출력이 생성자 업데이트의 기준이 되므로 판별자를 사용하지 않는다는 진술은 바로 틀린 선지로 판단할 수 있다.

암기 포인트

GAN은 생성자가 만들고 판별자가 가려내며, 생성자는 판별자의 반응을 보고 더 정교해진다.

NoteBase

문 14. 컴퓨터 비전 관련 딥러닝 모델에 대한 설명으로 옳지 않은 것은?

① YOLO는 정확도보다 처리 속도에 강점을 갖는 객체 탐지 및 분류 모델이다.

② R-CNN 모델에서는 객체 탐지와 분류를 동시에 수행하므로 효율성이 높다.

③ Fast R-CNN 모델에서는 입력 영상에서 객체를 탐지하기 위해 선택적 탐색 알고리즘을 사용한다.

④ SSD(Single Shot Detector)는 YOLO에 비해 객체 탐지 및 분류의 정확도와 처리 속도가 개선된 모델이다.

정답 2번

출제 포인트

이 문제는 YOLO, R-CNN, Fast R-CNN, SSD의 구조 차이와 장단점을 구분하는 문제이다.

핵심 개념

R-CNN은 후보 영역을 먼저 만든 뒤 각 영역을 분류하는 2단계 객체 탐지 모델이다.
Fast R-CNN은 합성곱 연산을 공유해 R-CNN보다 빨라졌지만 후보 영역 생성에는 여전히 선택적 탐색을 사용한다.
YOLO와 SSD는 후보 영역 생성과 분류를 하나의 네트워크에서 처리하는 1단계 객체 탐지 모델로, 처리 속도에 강점이 있다.

선지별 해설

① O: YOLO는 객체 위치와 클래스를 한 번에 예측하는 1-stage 방식이므로 정확도보다 실시간 처리 속도 측면의 강점으로 대표된다.
② X: 틀린 부분은 '개체 탐지와 분류를 동시에 수행하므로 효율성이 높다'는 표현이다. R-CNN은 선택적 탐색으로 후보 영역을 만든 뒤 각 후보를 CNN으로 분류하는 분리된 2단계 구조이므로 속도와 효율성이 높지 않다. 올바르게는 'R-CNN은 후보 영역 생성과 분류가 분리되어 있어 정확도 개선의 출발점이 되었지만 처리 효율은 낮다'이다.
③ O: Fast R-CNN은 입력 영상을 한 번만 합성곱 처리한 뒤 후보 영역별로 특징을 추출하므로 R-CNN보다 효율적이지만, 후보 영역 자체는 선택적 탐색 알고리즘으로 얻는다.
④ O: SSD는 YOLO와 같은 1-stage 계열이지만 여러 크기의 특징 맵에서 탐지하여 정확도를 높인 모델로 설명된다. 시험 문맥에서는 YOLO에 비해 정확도와 속도의 균형이 개선된 모델로 본다.

오답 포인트

R-CNN, Fast R-CNN, Faster R-CNN을 한 묶음으로 외우면 ②와 ③을 함께 틀리기 쉽다. 특히 '동시에 수행한다'는 표현은 YOLO·SSD 같은 1-stage 모델의 특징인데, 이를 R-CNN에 붙여 놓은 점이 함정이다.

NoteBase

다시 나오면 이렇게 판단

먼저 후보 영역을 외부 알고리즘으로 따로 만들면 R-CNN 계열 2-stage, 한 번의 네트워크 통과로 위치와 클래스를 함께 예측하면 YOLO·SSD 계열 1-stage로 판단하면 된다. Fast R-CNN은 빨라졌어도 후보 영역 생성은 여전히 선택적 탐색이라는 점을 같이 확인하면 된다.

암기 포인트

R-CNN은 후보 영역 먼저, YOLO·SSD는 한 번에 탐지이다. Fast R-CNN은 공유 합성곱, Faster R-CNN은 RPN 추가이다.

NoteBase

문 15. 검사 대상 65명 중 고혈압 환자(A) 및 정상인, 음주자(B) 및 비음주자에 대한 현황이 표와 같을 때, $P(A \mid \neg B)$와 $P(B \mid \neg A)$의 근삿값을 바르게 연결한 것은?

	비음주자	음주자	합계(명)
정상인	37	15	52
고혈압 환자	6	7	13
합계(명)	43	22	65

① $P(A \mid \neg B)$: 0.14, $P(B \mid \neg A)$: 0.29

② $P(A \mid \neg B)$: 0.14, $P(B \mid \neg A)$: 0.32

③ $P(A \mid \neg B)$: 0.19, $P(B \mid \neg A)$: 0.29

④ $P(A \mid \neg B)$: 0.19, $P(B \mid \neg A)$: 0.32

정답 1번

출제 포인트

이 문제는 이원분할표에서 조건부확률의 분모와 분자를 정확히 잡아 $P(A \mid \neg B)$와 $P(B \mid \neg A)$를 계산할 수 있는지를 묻는다.

조건 정리

주어진 값: 비음주자는 43명, 음주자는 22명, 정상인은 52명, 고혈압 환자는 13명이다.
교차값: 비음주자이면서 고혈압 환자는 6명, 정상인이면서 음주자는 15명이다.
구해야 할 값: $P(A \mid \neg B)$와 $P(B \mid \neg A)$의 근삿값이다.
주의할 조건: 조건부확률은 조건이 되는 집단이 분모가 된다.

사용할 공식

조건부확률은 $P(X \mid Y) = \frac{P(X \cap Y)}{P(Y)}$이다.
이 공식을 쓰는 이유: $P(A \mid \neg B)$는 비음주자 집단 안에서 고혈압 환자의 비율을 묻고, $P(B \mid \neg A)$는 정상인 집단 안에서 음주자의 비율을 묻기 때문이다.

NoteBase

계산 과정

1. $P(A \mid \neg B)$의 분모는 비음주자 43명이고 분자는 비음주자 중 고혈압 환자 6명이다.
2. 따라서 $P(A \mid \neg B) = \frac{6}{43} \approx 0.1395$이므로 근삿값은 0.14이다.
3. $P(B \mid \neg A)$의 분모는 정상인 52명이고 분자는 정상인 중 음주자 15명이다.
4. 따라서 $P(B \mid \neg A) = \frac{15}{52} \approx 0.2885$이므로 근삿값은 0.29이다.

선지별 해설

1번: O. $P(A \mid \neg B) = \frac{6}{43} \approx 0.14$, $P(B \mid \neg A) = \frac{15}{52} \approx 0.29$로 계산되므로 두 값을 바르게 연결한 선지이다.
2번: X. 틀린 표현은 $P(B \mid \neg A) = 0.32$이다. 올바르게는 정상인 52명을 분모로 하여 $\frac{15}{52} \approx 0.29$가 된다. 0.32는 분모를 정상인 수가 아닌 다른 수로 잘못 잡거나 반올림을 잘못한 오답이다.
3번: X. 틀린 표현은 $P(A \mid \neg B) = 0.19$이다. 올바르게는 비음주자 43명을 분모로 하여 $\frac{6}{43} \approx 0.14$가 된다. 0.19는 조건이 비음주자인데도 분모를 잘못 잡은 오답이다.
4번: X. $P(A \mid \neg B) = 0.19$와 $P(B \mid \neg A) = 0.32$가 모두 틀리다. 올바르게는 각각 0.14와 0.29이다. 이 선지는 두 조건부확률 모두에서 분모를 잘못 잡은 경우에 해당한다.

오답 포인트

조건부확률은 세로합이나 전체합을 기계적으로 분모로 두면 틀린다. 이 문항에서는 $P(A \mid \neg B)$의 분모가 비음주자 43명이고, $P(B \mid \neg A)$의 분모가 정상인 52명이라는 점을 놓치면 0.19나 0.32 같은 오답으로 흐르기 쉽다.

다시 나오면 이렇게 판단

조건부확률 문제는 먼저 기호를 우리말로 풀어 읽고, 조건 뒤에 오는 집단을 분모로 적은 다음, 그 집단 안에서 사건을 만족하는 교차값을 분자로 잡아 계산하면 된다.

암기 포인트

조건부확률은 조건 집단이 분모이고 교차칸이 분자이다.

NoteBase

문 16. 강화 학습(reinforcement learning) 모델과 관련성이 가장 적은 것은?

① Gym
② AlphaGo
③ AlphaStar
④ Deep Dream

정답 4번

출제 포인트

이 문제는 강화학습을 실제로 사용하는 시스템이나 강화학습 실험 환경과, 다른 학습 패러다임에 속하는 모델을 구별할 수 있는지를 묻는다.

핵심 개념

강화학습은 에이전트가 환경과 상호작용하면서 보상을 최대화하도록 정책을 학습하는 방법이다.
Gym은 강화학습 알고리즘을 훈련·평가할 때 쓰는 대표적인 환경 모음이다.
AlphaGo와 AlphaStar는 게임 환경에서 강화학습을 핵심 요소로 사용한 사례이다.
Deep Dream은 합성곱신경망이 학습한 특징을 증폭해 시각 패턴을 생성·시각화하는 기법으로, 강화학습과의 직접 관련성은 가장 약하다.

선지별 해설

1번: X. Gym은 강화학습 에이전트가 환경과 상호작용하며 학습하도록 설계된 실험 플랫폼이므로 강화학습과 관련성이 크다. 틀린 판단은 '강화학습과 관련성이 가장 적다'는 해석이다. 올바르게는 강화학습 연구와 구현에 직접 쓰이는 대표 환경이다.
2번: X. AlphaGo는 바둑에서 정책망, 가치망, 자기 대국, 강화학습을 결합한 시스템이므로 강화학습과 밀접하다. 틀린 판단은 '관련성이 가장 적다'는 해석이다. 올바르게는 강화학습의 대표 응용 사례로 본다.
3번: X. AlphaStar는 스타크래프트 II 플레이를 위해 심층강화학습과 자기 대전을 활용한 시스템이므로 강화학습과의 연관성이 매우 높다. 틀린 판단은 '관련성이 가장 적다'는 해석이다. 올바르게는 복잡한 게임 환경에 강화학습을 적용한 사례이다.
4번: O. Deep Dream은 신경망 내부 특징을 시각적으로 증폭해 이미지 패턴을 드러내는 기법으로, 보상 기반 의사결정이나 환경 상호작용을 학습하는 강화학습 모델과는 성격이 다르다. 따라서 강화학습 모델과 관련성이 가장 적다.

오답 포인트

강화학습 자체와 강화학습을 위한 도구를 함께 묶어 보지 못하면 Gym을 낯선 이름이라는 이유로 고르기 쉽다. 이 문항은 '강화학습 알고리즘인가'만 묻는 것이 아니라 '강화학습과 관련이 큰가'까지 함께 묻는 함정이 있다.

NoteBase

다시 나오면 이렇게 판단

보기마다 보상, 에이전트, 환경 상호작용, 자기 대전 같은 강화학습 핵심 요소가 있는지를 먼저 본다. 이런 요소가 없고 단순 시각화, 특징 증폭, 일반 지도학습 기반 기법에 가까우면 강화학습과의 관련성이 낮다고 판단한다.

암기 포인트

Gym은 강화학습 환경, AlphaGo·AlphaStar는 강화학습 응용, Deep Dream은 시각화 기법이다.

NoteBase

문 17. 오차를 최소화하는 가중치를 찾기 위해 사용되는 경사 하강법(gradient descent)은 함수의 최솟값을 찾기 위해 경삿값을 사용하는 반복적인 최적화 알고리즘이다. $y = (x-3)^2 + 15$로 표현되는 함수가 손실 함수라고 할 때, $x = 7$인 경우의 경삿값은?

① 8

② 14

③ 23

④ 31

정답 1번

출제 포인트

이 문제는 손실함수 $y = (x-3)^2 + 15$를 미분해 특정 점에서의 경사값을 구하는 문제이다.

조건 정리

주어진 식은 $y = (x-3)^2 + 15$이다.
구해야 할 값은 $x = 7$에서의 경사값이다.
경사 하강법에서 경사값은 현재 점에서의 미분값이다.

사용할 공식

사용할 공식은 도함수 $y' = \frac{dy}{dx}$이다.
이 식은 특정 x에서 함수가 얼마나 증가하거나 감소하는지를 나타내므로 경사값을 구할 때 바로 사용된다.

계산 과정

1. $y = (x-3)^2 + 15$를 미분하면 $y' = 2(x-3)$이다.
2. 이를 정리하면 $y' = 2x - 6$이다.
3. $x = 7$을 대입하면 $y' = 2 \times 7 - 6 = 14 - 6 = 8$이다.

선지별 해설

① O: 계산 결과 경사값은 8이므로 맞는 선지이다.
② X: ②의 '14'는 $(x-3)^2$를 미분하지 않고 단순히 $2x$처럼 처리한 실수에 가깝다. 올바른 경사값은 14가 아니라 8이다.
③ X: ③의 '23'은 상수항 15를 경사값 계산에 잘못 더한 경우에 가깝다. 상수항은 미분하면 0이므로 올바른 값은 23이 아니라 8이다.
④ X: ④의 '31'은 제곱식 계산값이나 다른 항을 섞어 경사와 함수값을 혼동한 경우에 가깝다. 이 문항은 함수값이 아니라 미분값을 묻기 때문에 올바른 값은 31이 아니라 8이다.

NoteBase

오답 포인트

경사값과 함수값을 혼동하거나, $(x-3)^2$를 미분할 때 안쪽 항까지 반영하지 않으면 오답이 나온다. 특히 상수항 15는 함수값에는 영향을 주지만 경사값에는 영향을 주지 않는다는 점이 함정이다.

다시 나오면 이렇게 판단

경사값을 묻는 계산형 문항은 먼저 미분으로 경사함수를 만든 뒤, 그다음에 지정된 x값을 대입하는 순서로 판단한다. 상수항은 미분하면 0이 된다는 점을 함께 확인하면 실수를 줄일 수 있다.

암기 포인트

경사값은 함수값이 아니라 미분값이며, 상수항의 미분은 0이다.

NoteBase

문 18. 전이 학습(transfer learning)에 대한 설명으로 옳은 것은?

① 입력 데이터와 출력 데이터가 동일하도록 학습하는 과정을 갖는다.

② 강화 학습의 한 종류로 환경에서 상태의 전이와 보상값의 생성 메커니즘을 설명하는 일종의 함수이다.

③ 서열(sequence) 데이터에서 이전 값들을 고려하기 위해 은닉층 또는 출력층의 값을 활용한다.

④ 어떤 한 분야에서 특정 과업을 수행하도록 학습한 후 유사한 분야 또는 다른 분야의 과업을 수행할 때 이전 학습 경험을 적용한다.

정답 4번

출제 포인트

이 문제는 전이 학습의 정의를 다른 학습 방식과 구별할 수 있는지를 묻는다.

핵심 개념

전이 학습은 한 도메인이나 과업에서 학습한 지식, 가중치, 표현을 유사한 다른 도메인이나 과업에 옮겨 활용하는 방법이다.
오토인코더는 입력을 스스로 복원하도록 학습하는 표현 학습 방법이다.
강화 학습의 상태 전이와 보상 생성 메커니즘은 환경 모델 또는 강화 학습의 구성 요소에 관한 설명이다.
순환신경망은 시퀀스 데이터의 이전 정보를 은닉 상태 등으로 전달해 현재 출력을 계산하는 구조이다.

선지별 해설

1번: X. 틀린 부분은 "입력 데이터와 출력 데이터가 동일하도록 학습"이다. 이는 전이 학습이 아니라 오토인코더처럼 입력 복원을 목표로 하는 학습 방식의 설명이다. 전이 학습은 동일한 입출력을 맞추는 것이 아니라 이전 과업에서 얻은 지식을 새 과업에 이전하는 데 초점이 있다.
2번: X. 틀린 부분은 "강화 학습의 한 종류"와 "상태의 전이와 보상값의 생성 메커니즘"이다. 이는 전이 학습이 아니라 강화 학습에서 환경 모델을 설명할 때 나오는 표현에 가깝다. 전이 학습은 보상과 상태 전이를 다루는 학습 종류가 아니라 이미 학습된 표현을 다른 과업에 재사용하는 방법이다.
3번: X. 틀린 부분은 "시퀀스 데이터에서 이전 값들을 고려하기 위해 은닉층 또는 출력층의 값을 활용"이다. 이는 전이 학습이 아니라 순환신경망 계열의 시퀀스 처리 방식 설명이다. 전이 학습의 핵심은 시간적 이전값 활용이 아니라 사전 학습된 지식의 이전이다.
4번: O. 한 분야에서 학습한 경험을 유사한 분야나 다른 과업에 적용한다는 설명이 전이 학습의 정의와 정확히 맞는다. 사전 학습 모델을 다른 데이터셋이나 과업에 미세조정하는 방식이 대표적 사례이다.

오답 포인트

보기 1은 오토인코더, 보기 3은 순환신경망, 보기 2는 강화 학습의 환경 모델 설명을 전이 학습과 섞어 놓은 점이 함정이다. 전이 학습은 "이전 학습 결과를 다른 과업에 옮겨 쓰는가"를 기준으로 보면 빠르게 걸러진다.

NoteBase

다시 나오면 이렇게 판단

선지에 이전에 학습한 가중치, 표현, 지식을 다른 도메인이나 과업에 재사용한다는 뜻이 있으면 전이 학습이다. 반대로 입력 복원, 상태 전이와 보상, 시퀀스의 이전 시점 정보 활용이 중심이면 각각 오토인코더, 강화 학습, 순환신경망 쪽 개념이다.

암기 포인트

전이 학습은 이전 지식의 재사용이고, 오토인코더는 복원, 순환신경망은 시점 연결, 강화 학습은 보상 기반 학습이다.

NoteBase

문 19. 영상의 특성을 효과적으로 추출하거나 영상 분석 및 인식에 활용 가능한 딥러닝 모델만을 모두 고르면?

ㄱ. ResNet
ㄴ. Inception
ㄷ. VGG

① ㄱ
② ㄱ, ㄷ
③ ㄴ, ㄷ
④ ㄱ, ㄴ, ㄷ

정답 4번

출제 포인트

이 문제는 대표적인 컴퓨터 비전용 딥러닝 모델인 ResNet, Inception, VGG를 식별할 수 있는지를 묻는 문제이다.

핵심 개념

ResNet은 잔차 연결을 넣어 매우 깊은 신경망 학습을 안정화한 CNN 모델이다. 키워드는 잔차 연결이다.
Inception은 서로 다른 크기의 합성곱을 병렬로 두어 다중 스케일 특징을 함께 추출하는 CNN 계열 모델이다. 키워드는 병렬 분기와 다중 스케일이다.
VGG는 작은 3 × 3 합성곱을 반복해 깊이를 늘린 전형적인 이미지 인식 CNN 모델이다. 키워드는 단순한 깊은 구조이다.
세 모델 모두 영상 특징 추출과 영상 분석·인식에 활용되는 딥러닝 모델이라는 점이 공통점이다.

NoteBase

선지별 해설

① X
- ㄱ인 ResNet만 포함했다.
- ResNet은 맞는 모델이지만 Inception과 VGG도 모두 영상 분석 및 인식에 활용되는 딥러닝 모델이므로 일부만 고른 선택지이다.
- 틀린 표현은 "ㄱ"만 고른 부분이다. 올바르게는 "ㄱ, ㄴ, ㄷ"이다.

② X
- ㄱ, ㄷ인 ResNet과 VGG는 맞지만 Inception이 빠졌다.
- Inception도 대표적인 컴퓨터 비전 딥러닝 모델이므로 제외할 수 없다.
- 틀린 표현은 Inception을 누락한 부분이다. 올바르게는 "ㄱ, ㄴ, ㄷ"이다.

③ X
- ㄴ, ㄷ인 Inception과 VGG는 맞지만 ResNet이 빠졌다.
- ResNet 역시 영상 특징 추출과 인식에 널리 쓰이는 딥러닝 모델이다.
- 틀린 표현은 ResNet을 누락한 부분이다. 올바르게는 "ㄱ, ㄴ, ㄷ"이다.

④ O
- ResNet, Inception, VGG는 모두 대표적인 컴퓨터 비전용 딥러닝 모델이므로 세 항목을 모두 고른 ④가 맞다.

오답 포인트

세 모델의 내부 구조는 서로 다르지만 모두 영상 인식에 쓰이는 CNN 계열 모델이라는 공통점을 놓치면 일부만 고르게 된다. 특히 Inception은 이름이 독특해 일반적인 비전 모델 목록에서 빠뜨리기 쉽다.

다시 나오면 이렇게 판단

이런 문제는 각 모델의 세부 구조보다 먼저 "영상 분석 및 인식에 활용되는 딥러닝 모델인가"를 기준으로 묶어 판단한다. ResNet, Inception, VGG처럼 대표적인 CNN 계열 비전 모델이면 모두 포함된다.

암기 포인트

ResNet, Inception, VGG는 모두 컴퓨터 비전의 대표적인 CNN 계열 딥러닝 모델이다.

NoteBase

문 20. 집의 면적과 방의 개수에 관한 데이터가 다음과 같이 주어질 때, 면적이 $88m^2$이고 방의 개수가 5개인 집의 가격을 선형 회귀를 이용하여 예측한 값은? (단, 가격 단위는 만 원이다)

면적: $55m^2$, 방의 개수: 1, 가격: 1,475
면적: $70m^2$, 방의 개수: 2, 가격: 1,600
면적: $80m^2$, 방의 개수: 4, 가격: 1,750

① 1,820
② 1,840
③ 1,880
④ 1,940

정답 2번

출제 포인트

이 문제는 주어진 3개 관측치로 다중선형회귀식을 세워 새로운 입력값의 예측 가격을 계산하는 문제이다.

조건 정리

주어진 관측치는 3개이다.
독립변수는 면적과 방의 개수 2개이고, 종속변수는 가격이다.
구해야 할 값은 면적이 $88m^2$이고 방의 개수가 5개인 집의 예측 가격이다.

사용할 공식

다중선형회귀식을 $y = b_0 + b_1x_1 + b_2x_2$로 둔다.
이 문제는 면적과 방의 개수 두 변수가 가격에 선형으로 작용한다고 보고 회귀식을 세워 예측값을 구하는 형태이므로 이 식을 사용한다.

NoteBase

계산 과정

회귀식을 $y = b_0 + b_1x_1 + b_2x_2$로 두고 세 관측치를 대입하면
$1475 = b_0 + 55b_1 + b_2$
$1600 = b_0 + 70b_1 + 2b_2$
$1750 = b_0 + 80b_1 + 4b_2$
가 된다.
둘째 식에서 첫째 식을 빼면 $125 = 15b_1 + b_2$이다.
셋째 식에서 둘째 식을 빼면 $150 = 10b_1 + 2b_2$이다.
이를 풀면 $b_1 = 5$, $b_2 = 50$, $b_0 = 1150$이다.
따라서 예측식은 $y = 1150 + 5x_1 + 50x_2$이고, $x_1 = 88$, $x_2 = 5$를 대입하면
$y = 1150 + 5 \times 88 + 50 \times 5 = 1840$이다.

선지별 해설

1번 X: 회귀식에 $x_1 = 88$, $x_2 = 5$를 넣으면 1,820이 아니라 1,840이 나온다. 계수 계산이나 대입 계산을 잘못한 값이다. 올바르게는 예측 가격이 1,840이다.
2번 O: 예측식 $y = 1150 + 5x_1 + 50x_2$에 88과 5를 대입하면 1,840이므로 옳다.
3번 X: 1,880은 정답보다 40 큰 값으로, 면적 증가분을 잘못 더했을 때 나올 수 있는 값이다. 올바르게는 예측 가격이 1,840이다.
4번 X: 1,940는 정답보다 100 큰 값으로, 방 개수 효과를 과대반영하거나 상수항을 잘못 구했을 때 나올 수 있는 값이다. 올바르게는 예측 가격이 1,840이다.

오답 포인트

세 관측치와 계수 b_0, b_1, b_2가 각각 3개이므로 이 문항은 연립방정식처럼 계수를 정확히 구할 수 있다는 점이 핵심이다. 면적 증가 효과와 방 개수 증가 효과를 분리하지 않으면 보기 3번, 4번 같은 과대 계산으로 흐르기 쉽다.

다시 나오면 이렇게 판단

변수가 2개인 회귀 예측 문제는 먼저 $y = b_0 + b_1x_1 + b_2x_2$ 형태로 놓고, 주어진 관측치를 모두 대입해 계수를 구한 뒤 마지막에 목표 입력값을 넣어 계산한다.

암기 포인트

다중선형회귀 예측은 회귀식 설정, 계수 결정, 목표값 대입의 3단계로 정리된다.

NoteBase

문 21. 결정 트리(decision tree)에 대한 설명으로 옳지 않은 것은?

① 엔트로피(entropy) 값이 작은 집단일수록 동질적이다.

② 일반적으로 정보 이득(information gain)이 큰 분할 속성일수록 우수하다.

③ 정보 이득비(information gain ratio)는 속성의 엔트로피를 정보 이득으로 나눈 값이다.

④ 데이터를 가능한 한 동질적 집단이 되도록 분류하는 분할 속성(splitting attribute)을 선택하는 것이 효율적이다.

정답 3번

출제 포인트

이 문제는 결정 트리의 분할 기준인 엔트로피, 정보 이득, 정보 이득비의 의미와 관계를 구분하는 문제이다.

핵심 개념

엔트로피는 집단이 얼마나 불순한지를 나타내는 지표이므로 값이 작을수록 집단이 더 동질적이다.
정보 이득은 어떤 속성으로 분할했을 때 불순도가 얼마나 줄어드는지를 뜻하므로 값이 클수록 분할 효과가 크다.
정보 이득비는 정보 이득을 분할 정보량(split information, intrinsic information)으로 보정한 값이므로, 정보 이득을 분모로 두지 않는다.

선지별 해설

① O
엔트로피가 작다는 것은 클래스가 한쪽으로 더 치우쳐 있다는 뜻이므로 집단의 동질성이 높다.
② O
결정 트리는 일반적으로 정보 이득이 큰 속성을 더 좋은 분할 후보로 본다. 다만 값의 종류가 많은 속성에 치우치는 문제는 정보 이득비로 보정한다.
③ X
틀린 부분은 "속성의 엔트로피를 정보 이득으로 나눈 값"이라는 표현이다.
올바르게는 정보 이득비는 정보 이득을 분할 정보량으로 나눈 값이다. 즉 분자와 분모가 뒤바뀌었다.
④ O
결정 트리의 목표는 분할 뒤 각 노드가 가능한 한 순수하고 동질적인 집단이 되게 하는 것이므로 이런 속성을 고르는 것이 효율적이다.

오답 포인트

③은 정보 이득과 정보 이득비의 관계를 아는지만 확인하는 선지인데, 분자와 분모를 뒤집어 놓아 혼동을 유도한다. 정보 이득이 크면 좋은 속성이라는 설명과 정보 이득비의 정의를 같은 것으로 섞어 기억하면 틀리기 쉽다.

NoteBase

다시 나오면 이렇게 판단

결정 트리 선지는 먼저 엔트로피가 작을수록 순수하다는 점을 확인하고, 다음으로 정보 이득은 감소한 불순도, 정보 이득비는 정보 이득을 분할 정보량으로 보정한 값이라는 순서로 대조하면 된다.

암기 포인트

엔트로피는 작을수록 순수, 정보 이득은 클수록 우수, 정보 이득비는 정보 이득을 분할 정보량으로 나눈 값이다.

NoteBase

문 22. 퍼지 이론(fuzzy theory)에 대한 설명으로 옳지 않은 것은?

① 소속 정도(degree of membership(μ))는 $0 < \mu \leq 1$로 정의된다.

② 퍼지 규칙은 IF-THEN 형태의 문장으로 표현된다.

③ 소속 함수를 통해 정성적인 대상을 표현할 수 있다.

④ 비퍼지화(defuzzification)를 통해 퍼지 추론 결과를 하나의 실수 값으로 변환할 수 있다.

정답 1번

출제 포인트

이 문제는 퍼지 이론의 기본 구성요소인 소속 정도, 퍼지 규칙, 소속 함수, 비퍼지화의 의미를 정확히 구별할 수 있는지를 묻는다.

핵심 개념

퍼지 집합은 어떤 원소가 집합에 속하는 정도를 $0 \leq \mu \leq 1$의 값으로 표현한다.
소속 함수는 정성적 개념을 수치화하는 함수이고, 퍼지 규칙은 보통 IF-THEN 형태로 지식을 표현하며,
비퍼지화는 퍼지 추론 결과를 하나의 실수값으로 바꾸는 단계이다.

선지별 해설

1번: X. 소속 정도는 $0 \leq \mu \leq 1$로 정의된다. $\mu = 0$도 전혀 속하지 않음을 나타내는 정상적인 값이므로 "$0 < \mu \leq 1$"이라는 표현이 틀리다. 올바르게는 "소속 정도는 $0 \leq \mu \leq 1$로 정의된다."이다.
2번: O. 퍼지 규칙은 전건과 후건을 연결하는 IF-THEN 형태로 표현하는 것이 일반적이다.
3번: O. 소속 함수를 쓰면 "덥다", "크다"처럼 경계가 모호한 정성적 개념을 수치적으로 표현할 수 있다.
4번: O. 비퍼지화는 퍼지 추론 결과로 나온 퍼지 집합을 하나의 실수값으로 변환하는 과정이므로 설명이 옳다.

오답 포인트

소속 정도의 범위를 떠올릴 때 0을 빠뜨리면 1번에 속기 쉽다. 퍼지 집합에서 0은 "완전히 속하지 않음"을 뜻하는 필수 값이다.

다시 나오면 이렇게 판단

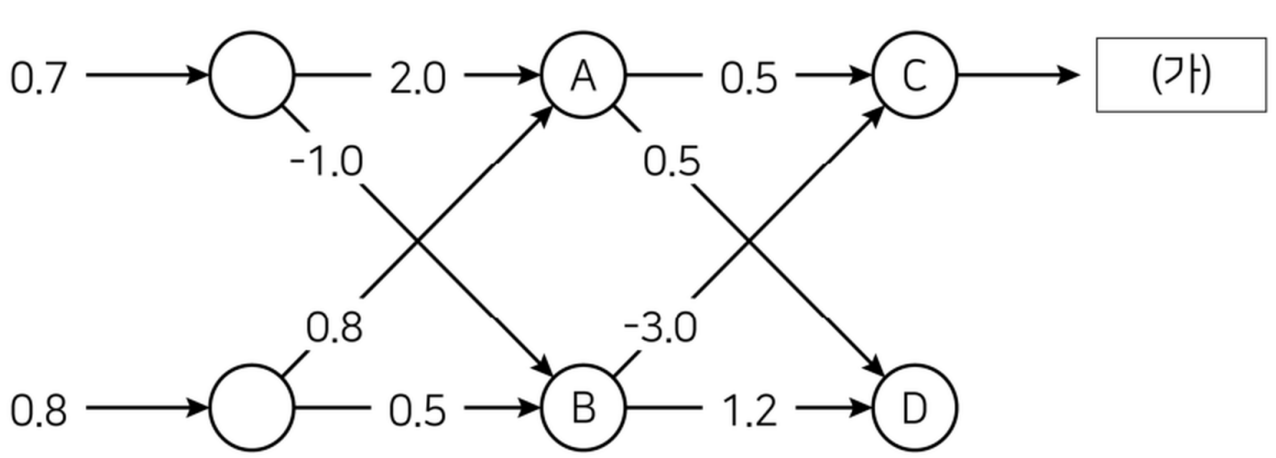
퍼지 이론 문제는 먼저 소속 정도의 범위가 $0 \leq \mu \leq 1$인지 확인하고, 그다음 규칙은 IF-THEN, 소속 함수는 수치화, 비퍼지화는 실수값 변환으로 대응시키면 판단이 정리된다.

암기 포인트

퍼지는 정도로 표현하고, 규칙은 IF-THEN이며, 마지막은 비퍼지화로 하나의 값이 된다.

NoteBase

문 23. 그림과 같은 신경망 모델에서 A, B, C, D의 활성화 함수로는 렐루(ReLU)를 사용하며, 각 연결선에는 가중치를 설정하고 0.7, 0.8을 입력할 때, 노드 C의 출력값 (가)는? (단, 편향(bias)은 0이다)



① 0.92

② 1.00

③ 1.02

④ 1.92

정답 3번

출제 포인트

ReLU 활성화 함수가 각 노드의 가중합에 어떻게 적용되는지 계산하고, 음수 출력이 0으로 잘리는 지점을 정확히 찾는 문제이다.

조건 정리

입력값 0.7과 0.8은 모두 양수이므로 왼쪽 두 노드의 출력은 ReLU를 거쳐도 그대로 0.7, 0.8이다. 따라서 A의 가중합은 $0.7 \times 2.0 + 0.8 \times 0.8 = 2.04$이고 ReLU를 거쳐도 2.04이다. B의 가중합은 $0.7 \times (-1.0) + 0.8 \times 0.5 = -0.3$이므로 ReLU 출력은 0이다. C의 가중합은 $2.04 \times 0.5 + 0 \times (-3.0) = 1.02$이므로 C의 출력도 1.02이다.

NoteBase

선지별 해설

1번 X: 0.92는 B의 출력이 0으로 잘린다는 점은 반영했지만, A를 계산할 때 $0.8 \times 0.8 = 0.64$를 빠뜨리거나 일부 가중치를 누락한 값이다. 틀린 표현은 A의 가중합을 불완전하게 잡은 점이고, 올바르게는 A의 출력이 2.04이므로 C는 1.02가 된다.
2번 X: 1.00은 계산 과정에서 반올림하거나 2.04를 2.0으로 단순화한 값에 가깝다. 틀린 표현은 정확한 가중합을 임의로 줄인 점이고, 올바르게는 C의 입력이 정확히 1.02이므로 출력도 1.02이다.
3번 O: A의 출력 2.04와 B의 출력 0을 사용하면 C의 입력은 $2.04 \times 0.5 + 0 \times (-3.0) = 1.02$이다. ReLU는 양수를 그대로 내보내므로 C의 출력은 1.02이다.
4번 X: 1.92는 B의 음수 가중합 -0.3에 ReLU를 적용하지 않고 그대로 사용했을 때 나오는 값이다. 틀린 표현은 B가 음수여도 그대로 다음 층으로 전달된다고 본 점이고, 올바르게는 ReLU 때문에 B의 출력은 0이어서 C는 1.02가 된다.

오답 포인트

가장 흔한 함정은 B의 가중합이 음수라는 사실을 계산하고도 ReLU를 한 번 더 적용하지 않는 점이다. 이 문항은 마지막 C만 보는 문제가 아니라 중간 노드 A, B 각각에서 활성화 함수를 적용해야 맞는다.

다시 나오면 이렇게 판단

신경망 계산 문제는 입력층부터 각 노드의 가중합을 구한 뒤 그 자리에서 바로 ReLU를 적용하고, 그 출력값만 다음 층으로 넘기는 순서로 판단하면 된다. 중간에 음수가 나오면 그 노드의 다음 출력은 0으로 바뀐다고 보면 된다.

암기 포인트

ReLU는 음수를 0으로 자르고 양수는 그대로 통과시키므로, 중간 노드에서 음수가 한 번 나오면 이후 경로 계산이 크게 달라진다.

NoteBase

문 24. 합성곱 신경망과 순환 신경망(RNN, Recurrent Neural Network)에 대한 설명으로 옳지 않은 것은?

① 순환 신경망은 기울기 소멸(vanishing gradient) 문제가 심각하게 발생하지 않는 장점이 있다.

② 순환 신경망에서는 일반적으로 하이퍼볼릭 탄젠트(hyperbolic tangent) 함수(tanh())를 활성화 함수로 사용한다.

③ 합성곱 신경망은 특징 추출을 담당하는 합성곱층과 분류를 담당하는 전결합층을 포함하는 다층 퍼셉트론 모델의 한 종류이다.

④ 합성곱 신경망은 필터로 특징을 추출하고 풀링을 이용하여 입력의 변화에 강건한(robust) 방식으로 사물을 분류한다.

정답 1번

출제 포인트

이 문제는 합성곱 신경망과 순환 신경망의 핵심 구조와 대표적 성질을 구별할 수 있는지를 묻는다.

핵심 개념

합성곱 신경망은 합성곱 필터와 풀링을 이용해 공간적 특징을 추출하는 신경망이다. 순환 신경망은 이전 시점의 상태를 다음 계산에 반영해 순차 데이터를 처리하는 신경망이다. CNN은 공간 구조 보존과 지역 특징 추출이 핵심이고, RNN은 시계열 의존성 반영이 핵심이다.

선지별 해설

1번: X. 순환 신경망은 긴 시퀀스를 학습할 때 기울기 소멸과 기울기 폭주 문제가 대표적으로 발생하는 구조이다. 틀린 표현은 "기울기 소멸 문제가 심각하게 발생하지 않는"이다. 올바르게는 "기울기 소멸 문제가 발생하기 쉬워 LSTM, GRU 같은 변형 구조가 사용된다"이다.
2번: O. 전통적인 순환 신경망에서는 은닉 상태를 갱신할 때 *tanh*를 활성화 함수로 쓰는 구성이 널리 사용된다. 최근 변형 구조에서는 다른 게이트 함수도 함께 쓰이지만, 일반적 설명으로는 맞다.
3번: O. 합성곱 신경망은 합성곱층으로 특징을 추출하고, 뒤쪽의 전결합층으로 분류를 수행하는 전형적 구조를 가진다. 완전연결만 사용하는 기본 다층 퍼셉트론과는 다르지만, 다층 신경망의 한 변형으로 이해하는 설명으로는 타당하다.
4번: O. 합성곱 신경망은 필터로 지역 특징을 추출하고 풀링으로 작은 위치 변화에 대한 민감도를 낮춰 입력 변화에 비교적 강건한 분류를 수행한다.

오답 포인트

1번은 RNN의 약점을 장점처럼 뒤집어 놓은 선지이다. 수험생이 CNN의 강건성이나 LSTM의 개선 효과를 RNN 전체의 기본 성질로 일반화하면 틀리기 쉽다.

NoteBase

다시 나오면 이렇게 판단

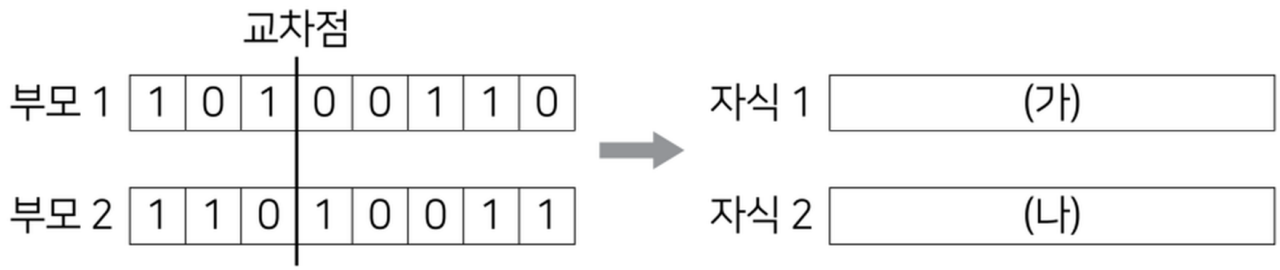
CNN은 공간적 특징 추출, RNN은 순차 의존성 처리라는 축으로 먼저 구분한다. 그다음 RNN에는 기울기 소멸 문제가 따라붙는지, CNN에는 필터와 풀링이 연결되는지를 확인하면 된다.

암기 포인트

CNN은 필터와 풀링, RNN은 순차 상태와 기울기 소멸 위험으로 구분된다.

NoteBase

문 25. 유전(genetic) 알고리즘에서 그림과 같은 단순 교차 연산으로 생성되는 2개의 자식 유전자 (가), (나)를 바르게 연결한 것은?



① (가): 10111001, (나): 11010100

② (가): 11000110, (나): 10110011

③ (가): 10110010, (나): 11000111

④ (가): 11010011, (나): 10100110

정답 2번

출제 포인트

이 문제는 단순 교차에서 교차점 기준으로 앞 블록과 뒤 블록을 그대로 나눈 뒤, 뒤 블록 전체를 서로 맞바꾼 결과를 읽는 문제이다.

NoteBase

선지별 해설

① X
(가)와 (나) 모두 교차점 뒤 5비트를 그대로 이어 붙이지 않고 비트를 임의로 바꾼 배열이다. 단순 교차 결과는 제시된 10111001, 11010100이 될 수 없고, 올바르게는 (가)=11000110, (나)=10110011이다.

② O
부모 1은 101|00110, 부모 2는 110|10011으로 나뉜다. 교차점 뒤 블록을 서로 바꾸면 두 자식은 11000110과 10110011이 되며, 문제의 (가), (나) 배치와 일치하는 것이 ②이다.

③ X
교차점 뒤 블록의 마지막 비트를 잘못 적은 선택지이다. 단순 교차라면 뒤 블록은 부모에서 잘린 그대로 붙어야 하므로 10110010, 11000111이 아니라 (가)=11000110, (나)=10110011이다.

④ X
앞 블록과 뒤 블록을 서로 교환하지 않고 한 부모의 일부를 그대로 유지한 배열이라서 단순 교차 결과가 아니다. 올바른 결과는 (가)=11000110, (나)=10110011이다.

오답 포인트

단순 교차는 교차점 뒤의 비트를 재정렬하는 연산이 아니라, 잘린 뒤쪽 블록 전체를 통째로 바꾸는 연산이다. ①, ③, ④는 이 점을 놓치고 일부 비트만 바꾸거나 부모의 뒷부분을 그대로 둔 경우를 노린 오답이다.

다시 나오면 이렇게 판단

교차점을 기준으로 먼저 부모를 왼쪽 블록과 오른쪽 블록으로 자른다. 그다음 가능한 두 자식 후보를 각각 한 번씩 만든 뒤, 문제에서 제시한 (가), (나) 위치와 맞는 배열을 고르면 된다.

암기 포인트

단순 교차는 교차점 뒤 꼬리 블록 전체를 서로 맞바꾸는 연산이다.

NoteBase