

예를 들어 두 개의 행렬 $A = \begin{bmatrix} 19 & 22 \\ 43 & 50 \end{bmatrix}$ 과 $B = \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix}$ 이면

$$(AB) = \begin{bmatrix} 19 & 22 \\ 43 & 50 \end{bmatrix} \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 95 & 132 \\ 301 & 400 \end{bmatrix} \text{ 이고, } (AB)^T = \begin{bmatrix} 95 & 301 \\ 132 & 400 \end{bmatrix}$$

이제 $A^T = \begin{bmatrix} 19 & 43 \\ 22 & 50 \end{bmatrix}$ 과 $B^T = \begin{bmatrix} 5 & 7 \\ 6 & 8 \end{bmatrix}$ 을 곱해보면 다음과 같다.

$$B^T A^T = \begin{bmatrix} 5 & 7 \\ 6 & 8 \end{bmatrix} \begin{bmatrix} 19 & 43 \\ 22 & 50 \end{bmatrix} = \begin{bmatrix} 95 & 301 \\ 132 & 400 \end{bmatrix}$$

따라서 $(AB)^T = B^T A^T$ 가 성립한다.

>>

예를 들어 두 개의 행렬 $A = \begin{bmatrix} 19 & 22 \\ 43 & 50 \end{bmatrix}$ 과 $B = \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix}$ 이면

$$(AB) = \begin{bmatrix} 19 & 22 \\ 43 & 50 \end{bmatrix} \begin{bmatrix} 5 & 6 \\ 7 & 8 \end{bmatrix} = \begin{bmatrix} 249 & 290 \\ 565 & 658 \end{bmatrix} \text{ 이고, } (AB)^T = \begin{bmatrix} 249 & 565 \\ 290 & 658 \end{bmatrix}$$

이제 $A^T = \begin{bmatrix} 19 & 43 \\ 22 & 50 \end{bmatrix}$ 과 $B^T = \begin{bmatrix} 5 & 7 \\ 6 & 8 \end{bmatrix}$ 을 곱해보면 다음과 같다.

$$B^T A^T = \begin{bmatrix} 5 & 7 \\ 6 & 8 \end{bmatrix} \begin{bmatrix} 19 & 43 \\ 22 & 50 \end{bmatrix} = \begin{bmatrix} 249 & 565 \\ 290 & 658 \end{bmatrix}$$

따라서 $(AB)^T = B^T A^T$ 가 성립한다.

A 는 n 개의 열 벡터인 $c^{(i)} \in \mathbb{R}^{m \times 1} \forall i \in \{1, 2, 3, \dots, n\}$ 으로 구성되며, 다음과 같이 나타낼 수 있다.

$$A = [c^{(1)} c^{(2)} c^{(3)} \dots c^{(n)}]$$

$$b = Ax = [c^{(1)} c^{(2)} c^{(3)} \dots c^{(n)}] \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} = x_1 c^{(1)} + x_2 c^{(2)} + \dots + x_n c^{(n)}$$

위의 행렬과 벡터의 곱은 행렬 A 의 열 벡터와 선형 계수^{linear coefficient}인 x 벡터의 선형 조합이다. 벡터 x 의 구성 요소는 선형 계수다.

곱셈을 통해 형성된 새로운 벡터 b 는 A 의 열 벡터와 동일한 차원을 가지며 동일한 열 공간에 남는다. 열 벡터를 결합하는 방법에 관계없이 열 벡터가 차지하는 공간을 벗어나지 않는다. 즉 열 벡터 공간과 동일하다.

>>

A 는 n 개의 열^{column}을 가진 벡터인 $c^{(i)} \in \mathbb{R}^{m \times 1} \forall i \in \{1, 2, 3, \dots, n\}$ 으로 구성되며, 다음과 같이 나타낼 수 있다.

$$A = [c^{(1)} c^{(2)} c^{(3)} \dots c^{(n)}]$$

$$b = Ax = [c^{(1)} c^{(2)} c^{(3)} \dots c^{(n)}] \begin{bmatrix} x_1 \\ x_2 \\ \cdot \\ \cdot \\ x_n \end{bmatrix} = x_1 c^{(1)} + x_2 c^{(2)} + \dots + x_n c^{(n)}$$

위의 행렬과 벡터의 곱은 행렬 A 의 열 벡터와 선형 계수^{linear coefficient}인 x 벡터의 선형 조합이다. 벡터 x 의 구성 요소는 선형 계수다.

곱셈을 통해 형성된 새로운 벡터 b 는 A 와 동일한 차원의 행을 가지며 동일한 개수의 행을 가진다. 행렬 A 를 결합하는 방법에 관계없이 행렬 A 가 차지하는 공간을 벗어나지 않는다. 즉 A 의 행 공간과 동일하다.

[p.35: 2행]

보다시피 A 와 $b \in \mathbb{R}^{2 \times 1}$ 은 동일한 열 벡터 차원을 갖는다.

→

보다시피 A 와 $b \in \mathbb{R}^{2 \times 1}$ 은 동일한 **행 공간**을 갖는다.

[p.35: 3행]

벡터가 다른 벡터의 선형 조합으로 표현될 수 있다면 벡터는 다른 벡터에 일차독립이라고 한다.

→

벡터가 다른 벡터의 일차 결합으로 표현될 수 있다면 벡터는 다른 벡터에 **일차 종속**이라고 한다.

[p.35: 5행]

$v_1 = 5v_2 + 7v_3$ 인 경우에 다른 벡터들의 합으로 표현될 수 있기 때문에 v_1, v_2, v_3 은 일차독립이다.

→

$v_1 = 5v_2 + 7v_3$ 인 경우에 다른 벡터들의 합으로 표현될 수 있기 때문에 v_1, v_2, v_3 은 **일차 종속**이다.

[p.35: 아래에서 2행]

즉, n 개의 벡터를 선형 조합해 n 차원 공간에서 모든 가능한 벡터를 생성할 수 있다.

→

즉, n 개의 벡터를 **일차 결합**해 n 차원 공간에서 모든 가능한 벡터를 생성할 수 있다.

[p.36: 아래에서 2행]

원하는 3차원 벡터를 가져와서 앞서 언급된 세 벡터의 선형 조합으로 표현할 수 있다.

→

원하는 3차원 벡터를 가져와서 앞서 언급된 세 벡터의 **일차 결합**으로 표현할 수 있다.

[p.37: 3행]

벡터 v_1, v_2 의 선형 조합인 벡터 v_3 을 취했다면, 3차원 공간 전체에 생성할 수 없기 때문에 v_1 과 v_2 에 생성된 2차원 부분 공간에 국한해야 한다.

→

벡터 v_1, v_2 의 **일차 결합**인 벡터 v_3 을 취했다면, 3차원 공간 전체에 생성할 수 없기 때문에 v_1 과 v_2 에 생성된 2차원 부분 공간에 국한해야 한다.

[p.38: 마지막행]

n행 벡터 또는 열 벡터가 일차독립이 아닌 경우,

→

n개의 벡터 또는 열 벡터가 일차독립이 아닌 경우,

[p.57: 아래에서 3행]

단변수 함수의 미분값이 0이거나 다변수 함수의 기울기 벡터가 영벡터인 점을 고정점^{stationary point}이라 한다.

→

단변수 함수의 미분값이 0이거나 다변수 함수의 기울기 벡터가 영벡터인 점을 정류점^{stationary point}이라 한다.

[p.57: 마지막행]

그림 1-12는 고정점의 종류를 보여준다.

→

그림 1-12는 정류점의 종류를 보여준다.

[p.71: 아래에서 2행]

확률 밀도 함수^{PDF, probability density function}는 도메인의 각 값에서 연속 확률 변수의 확률 밀도를 제공한다.

→

확률 밀도 함수^{PDF, probability density function}는 정의역의 각 값에서 연속 확률 변수의 확률 밀도를 제공한다.

[p.72: 아래에서 4행]

즉, X 는 pmf $P(X = x_i) = p_i$ 를 갖는 이산 확률 변수다.

→

즉, X 는 확률 질량 함수 $P(X = x_i) = p_i$ 를 갖는 이산 확률 변수다.

[p.73: 5행]

X 가 $P(X = x_i) = p_i$ pmf를 가진 n개의 불연속 값을 취하는 이산 확률 변수인 경우, X 의 분산은 다음과 같이 나타낼 수 있다.

→

X 가 $P(X = x_i) = p_i$ 확률 질량 함수를 가진 n개의 불연속 값을 취하는 이산 확률 변수인 경우, X 의 분산은 다음과 같이 나타낼 수 있다.

[p.74: 1행]

왜도의 양수 값은 그림 1-20에 설명된 것처럼 데이터의 대량이 왼쪽을 향하는 것을 의미하며, 비대칭의 음의 값은 그림 1-21에 표시된 것처럼 데이터의 대량이 오른쪽을 향한 것을 의미한다.

→

왜도의 양수 값은 그림 1-20에 설명된 것처럼 데이터의 **많은 부분이** 왼쪽을 향하는 것을 의미하며, 비대칭의 음의 값은 그림 1-21에 표시된 것처럼 데이터의 **많은 부분이** 오른쪽을 향한 것을 의미한다.

[p.83: 1행]

또한 다변수 정규분포는 가우스 ^{Gaussian} 모델의 혼합에서 널리 사용되며,

→

또한 다변수 정규분포는 가우스 ^{Gaussian} **혼합 모델**에서 널리 사용되며,

[p.83: 3행]

가우스 혼합은 클러스터링, 이상 탐지, 은닉 마르코프 모델 등과 같은 여러 분야에서 사용된다.

→

가우스 **혼합 모델**은 클러스터링, 이상 탐지, 은닉 마르코프 모델 등과 같은 여러 분야에서 사용된다.

[p.87: 2행]

좀 더 명확하게 하기 위해 L 이 $p^7(1-p)^3$ 이 될 가능성을 알아보자.

→

좀 더 명확하게 하기 위해 **우도** L 이 $p^7(1-p)^3$ 이 될 가능성을 알아보자.

[p.92: 아래에서 7행]

따라서 주택 가격 (y/x')은 입력 벡터 x' 에 편향 항 b 와 무작위 요소 ϵ 의 선형 조합이며 0의 평균과 σ^2 의 유한 분산을 갖는 정규분포를 따른다.

→

따라서 주택 가격 (y/x')은 입력 벡터 x' 에 편향 항 b 와 무작위 요소 ϵ 의 **선형결합**이며 0의 평균과 σ^2 의 유한 분산을 갖는 정규분포를 따른다.

[p.93: 1행]

m 샘플 $(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})$ 이 있다고 가정해보자.

→

m 개의 샘플 $(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(m)}, y^{(m)})$ 이 있다고 가정해보자.

[p.105~106]

기울기가 음의 방향이 되면, 최소치 쪽으로 움직일 수 있다.

→

기울기가 음의 방향이 되면, **최솟값** 쪽으로 움직일 수 있다.

[p.107: 수식 1행]

$$C(\theta + \Delta\theta) = C(\theta) + \Delta\theta^T \nabla C(\theta) + \frac{1}{2} \Delta\theta^T H(\theta) \Delta\theta + \text{higher order terms}$$

→

$$C(\theta + \Delta\theta) = C(\theta) + \Delta\theta^T \nabla C(\theta) + \frac{1}{2} \Delta\theta^T H(\theta) \Delta\theta + \text{고차원항}$$

[p.118: 10행]

λ 는 라그랑주 승수법 Lagrange multiplier 이라 불린다.

→

λ 는 라그랑주 **승수** Lagrange multiplier 라 불린다.

[p.130: 1행]

작은 값의 λ 를 취하면 b 의 값이 증가하고, u 의 노름도 증가하지만 λ 값이 클수록 b 가 작아지므로 θ 는 더 작아진다.

→

작은 값의 λ 를 취하면 b 의 값이 증가하고, u 의 노름도 증가하지만 λ 값이 클수록 b 가 작아지므로 θ 의 노름은 더 작아진다.

[p.220: 1행]

$N \times M$ 차원의 그레이스케일 영상은 공간 좌표의 스칼라 2D 신호로 표현할 수 있다.

→

$N \times M$ 차원의 그레이스케일 **이미지**는 공간 좌표의 스칼라 2D 신호로 표현할 수 있다.

[p.225: 6행]

좌표 방향곱의 합계 및 임펄스 응답 값을 출력으로 나타낸다.

→

좌표 **방향끼리의 곱과 임펄스 응답을 합해** 출력으로 나타낸다.

[p.233]

예제 3-2에서는 모나리자의 이미지를 읽고 이미지에 가우스 백색 잡음을 도입했다.

→

예제 3-2에서는 모나리자의 이미지를 읽고 이미지에 가우스 백색 잡음을 **추가**했다.

[p.243: 아래에서 7행]

세 번째 계층에서는 이전 계층에서 생성된 기능을 기반으로 훨씬 더 복잡한 기능을 배운다.

→

세 번째 계층에서는 이전 계층에서 생성된 기능을 기반으로 훨씬 더 복잡한 **특성**을 배운다.

[p.246: 4행]

2D 컨볼루션은 공간 차원에서 수행되지만, 이미지 볼륨의 깊이 채널에는 컨볼루션하지 않는다.

→

2D 컨볼루션은 공간 차원에서 수행되지만, 이미지 볼륨의 **깊이 차원**^{depth dimension}에서는 컨볼루션하지 않는다.

[p.286: 아래에서 2행]

ResNet은 깊이라는 개념을 가지고 있으며, 잔여 블록이라는 고유한 아이디어를

→

ResNet은 깊이라는 개념을 가지고 있으며, **잔차 블록**이라는 고유한 아이디어를

[p.287: 3행]

그러나 ResNet의 잔차 블록 개념을 사용해 입력에서 출력으로의 직접 매핑이 아닌 잔여 매핑을 학습하려고 한다.

→

그러나 ResNet의 잔차 블록 개념을 사용해 입력에서 출력으로의 직접 매핑이 아닌 **잔차** 매핑을 학습하려고 한다.

[p.288: 12행]

초기 계층은 곡선과 가장자리 같은 매우 일반적인 기능을 감지하는 법을 학습한다.

→

초기 계층은 곡선과 가장자리 같은 매우 일반적인 **특성**을 감지하는 법을 학습한다.

[p.303: 마지막행]

구문 분석은 단어가 그룹화돼 문장으로 연결되는 방법을 나타낸다.

→

구문 분석은 단어를 **그룹화하고 문장으로 연결하는** 방법을 나타낸다.

[p.304: 6행]

두 벡터 사이의 코사인을 계산하면, 벡터 구성 간의 유사성을 기반으로 유사성을 측정할 수 있다.

→

두 벡터 사이의 코사인을 계산하면, **벡터 간의 유사도를** 측정할 수 있다.

[p.307: 아래에서 2행]

정규화 스킴^{normalizing scheme}은 역문서 빈도를 비선형으로 만들기 위해 용어 빈도 n 에 적용할 수 있다.

→

정규화 스킴^{normalizing scheme}은 역문서 빈도를 비선형으로 만들기 위해 용어 빈도 **n** 을 적용할 수 있다.

[p.308: 1행]

이는 문서 빈도 기여도가 n 의 작은 값에 대해 선형이며, n 이 증가함에 따라 기여도가 포화된다.

→

문서 빈도 기여도는 **n 이 작은 경우** 선형이며, n 이 증가함에 따라 기여도가 포화된다.

[p.335: 아래에서 4행]

이는 벡터 간의 차이점을 나타내는 데 가장 좋은 방법인 선형 벡터 공간에서와 같은 방식이다.

→

이는 **선형 벡터 공간에서도 벡터 간의 차이점을 나타낼 수 있는 가장 좋은 방식**이다.

[p.336: 아래에서 4행]

f 와 g 를 지수 함수^{exponential function}로 선택하면, 확률의 비율이 단어 벡터의 차이를 부호화^{encode}할 수 있고 동시에 동시 발생 확률이 내적에 의존하게 유지할 수 있다.

→

f 와 g 를 지수함수^{exponential function}로 선택하면, 확률의 비율이 단어 벡터의 차이를 **인코딩할 수 있고**, 그와 함께 동시 발생 확률이 내적에 의존하게 유지할 수 있다.

[p.336: 마지막행]

벡터의 유사성 및 차별의 개념을 유지한다.

→

벡터의 유사성 및 **식별력**의 개념을 유지한다.

[p.374: 아래에서 6행]

z_t 에서 업데이트 게이트 출력 단위가 0에 가까워지면

→

z_t 에서 업데이트 게이트 출력 **유닛이** 0에 가까워지면

[p.381: 첫행]

여기서 Z 는 다음에 의해 주어진 분할 함수 partition function 다.

→

여기서 Z 는 다음에 의해 주어진 **분배 함수** partition function 다.

[p.381: 위에서 5행]

이러한 경우 분할 함수는 다음과 같이 표현될 수 있다.

→

이러한 경우 **분배 함수**는 다음과 같이 표현될 수 있다.

[p.401: 아래에서 5행]

분할 함수 Z 는 계산하기가 어렵고, $P(v, h)$ 의 계산을 어렵게 만든다. 작은 사건 집합의 경우 분할 함수를 계산할 수 있다.

→

분배 함수 Z 는 계산하기가 어렵고, $P(v, h)$ 의 계산을 어렵게 만든다. 작은 사건 집합의 경우 **분배 함수**를 계산할 수 있다.

[p.407: 첫행]

분할 함수 Z 는 (5.3.20)의 첫 번째 식과 달리

→

분배 함수 Z 는 (5.3.20)의 첫 번째 식과 달리
