

N / A / N / O / D / E / G / R / E / E


# 지도학습 알고리즘

04. 선형 회귀 III

# Polynomial regression

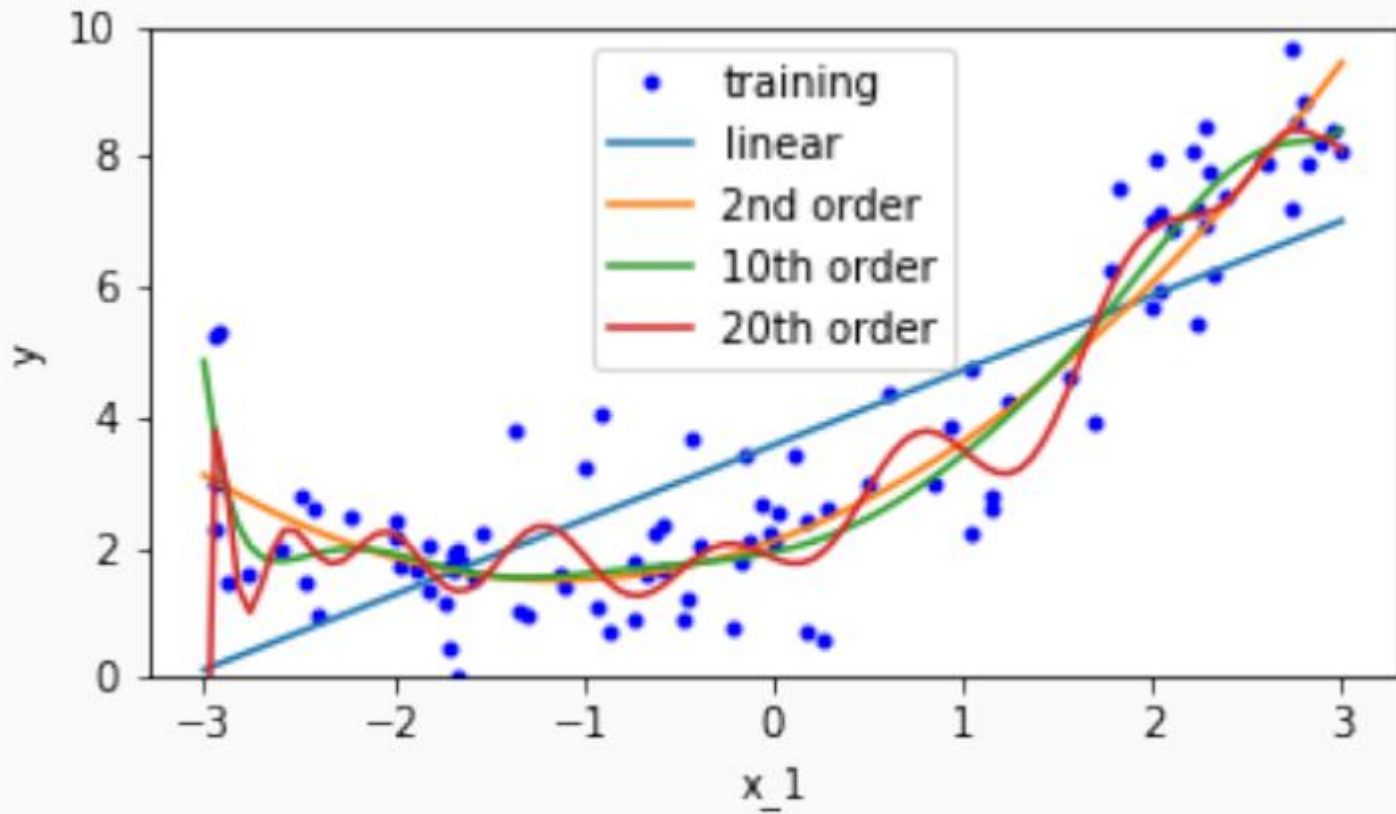
- ✓ 데이터들이 비선형 관계를 이루고 있을 때
- ✓ Polynomial의 각 항을 별개의 feature로 간주
- ✓ 동일하게 normal equation이나 gradient descent의 적용 가능

$$\hat{y} = \theta_0 + \theta_1 x_1 + \theta_2 x_1^2$$



# Polynomial regression

- ☑ 모델의 차수는 어떻게 결정해야 하는가?





# Overfitting and underfitting

## ❑ 과적합 overfitting

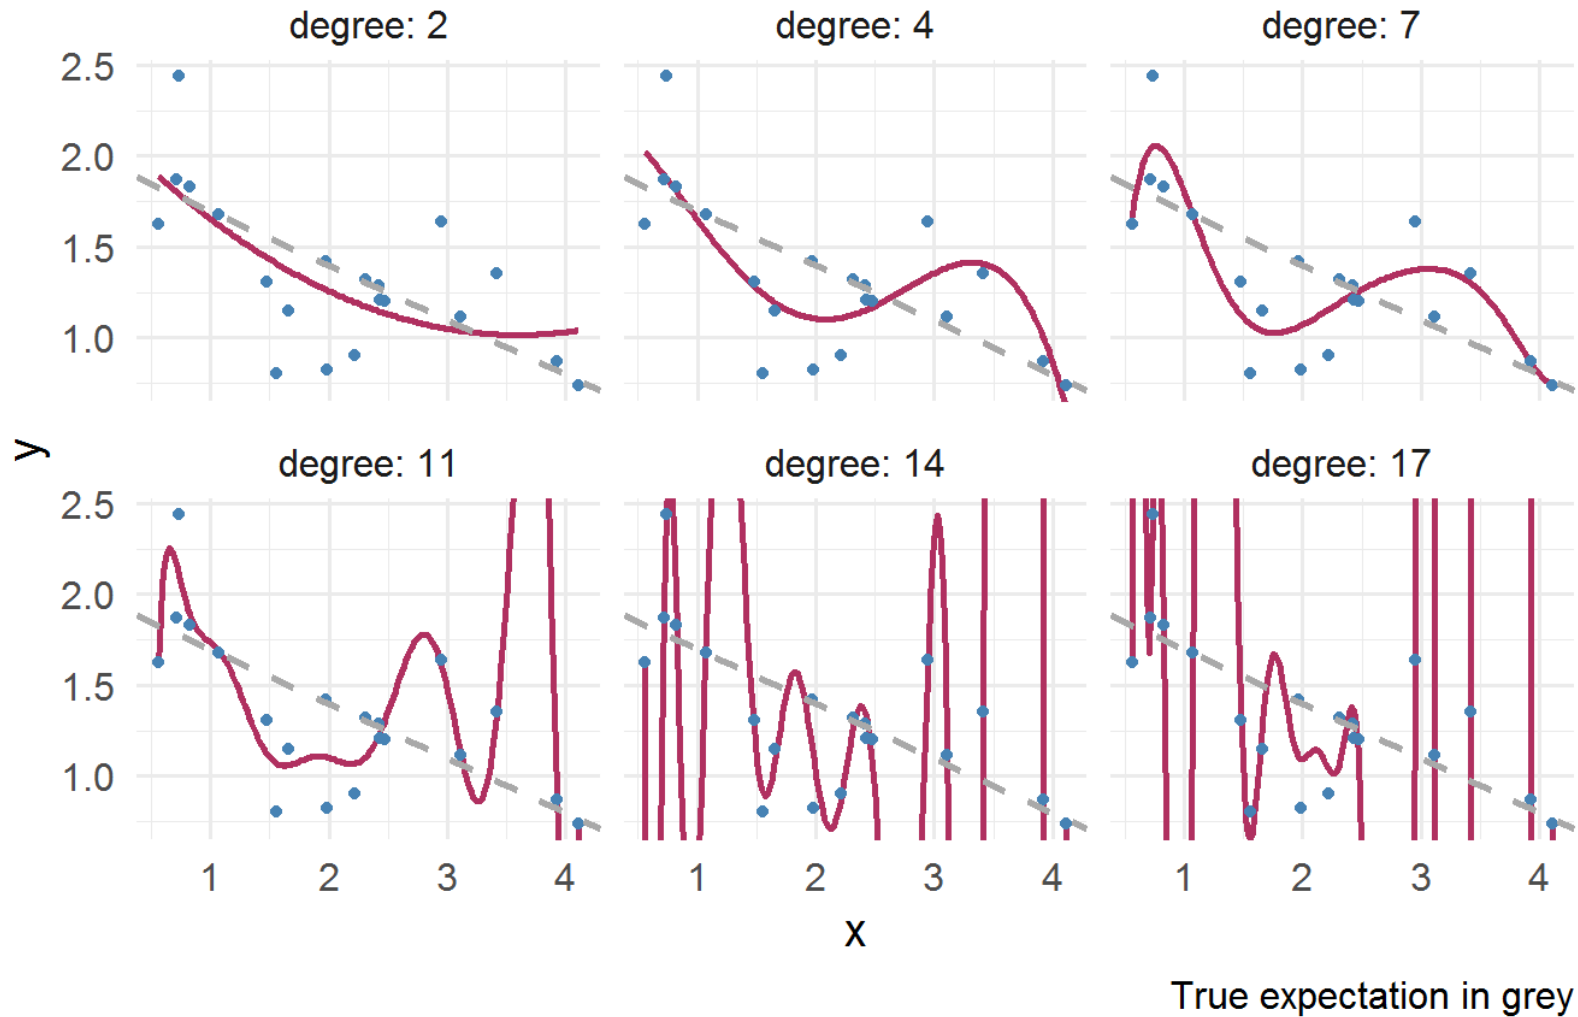
- 학습 데이터에 대해서는 좋은 성능을 보이지만, 처음 보는 데이터에 대해서는 일반화하지 못함
- 학습 데이터의 양이나 노이즈의 정도에 비해 모델이 너무 복잡할 때
- 모델이 학습 데이터를 일반화하는 범위를 넘어서 과도하게 의존함
- 모델이 학습 데이터를 기억하기 시작함

## ❑ 미적합 underfitting

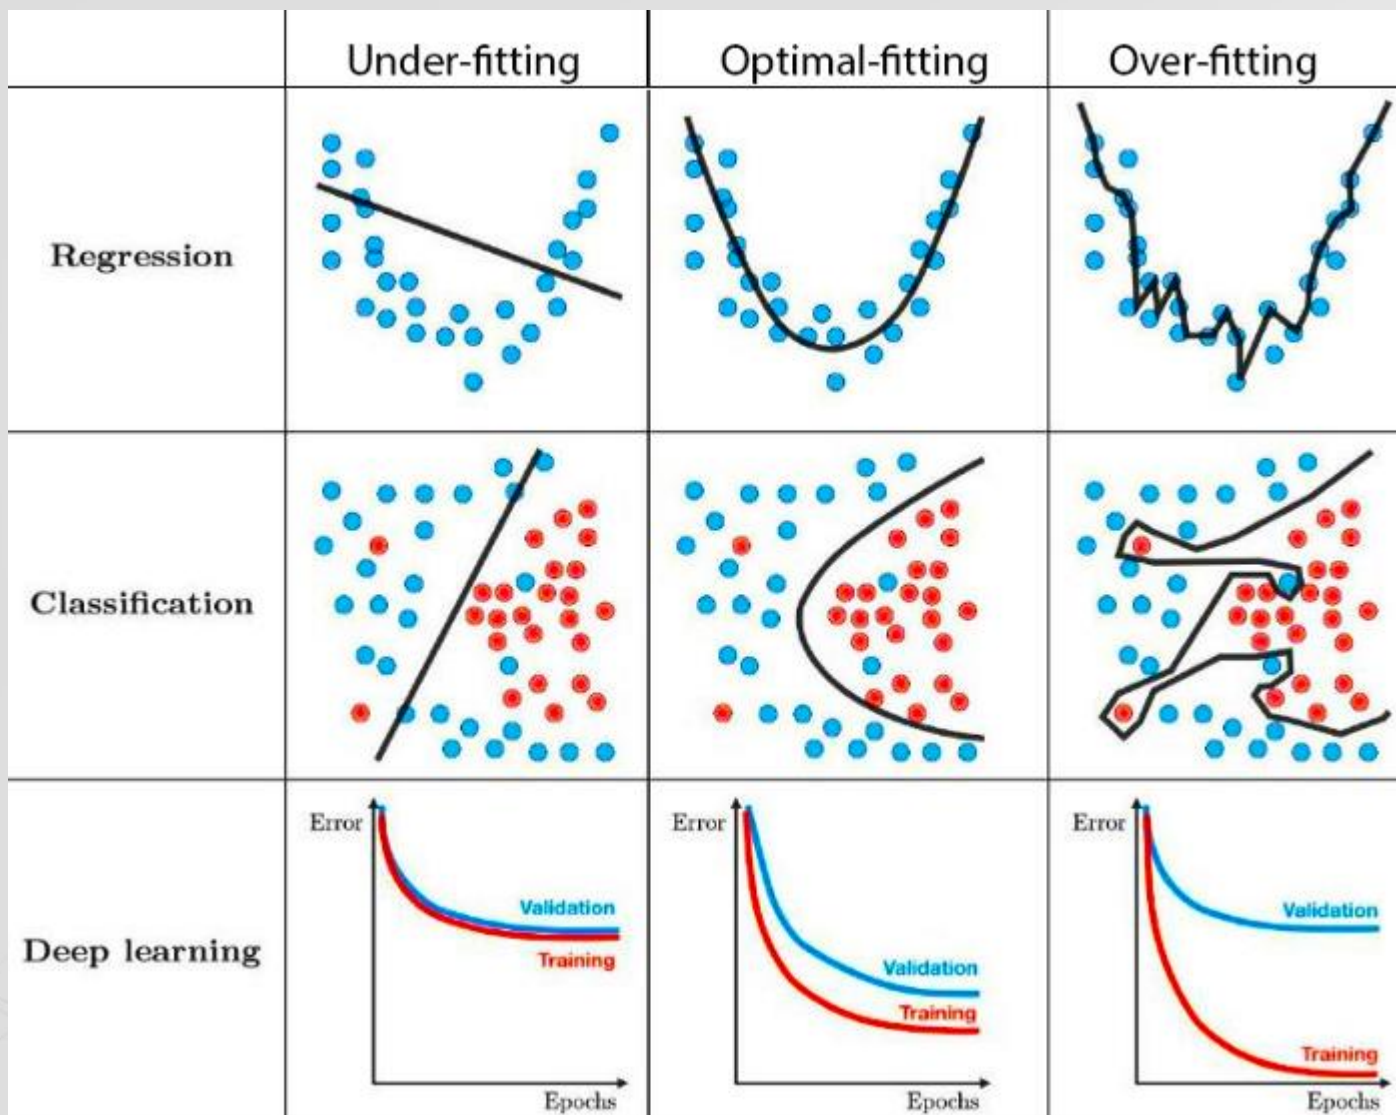
- 모델이 너무 단순하여 학습 데이터에 대해서도 부정확

# Overfitting and underfitting

## High degree polynomial models fit data better



# Overfitting and underfitting



# Ridge regression

- ✓ 비용 함수에 model parameter에 대한 penalty를 추가
- ✓ 과적합을 방지하면서 동시에 model parameter도 가능한 작게 만들도록

$$J(\boldsymbol{\theta}) = \text{SSE}(\boldsymbol{\theta}) + \frac{\alpha}{2} \|\boldsymbol{\theta}\|^2$$

- ✓ Hyperparameter  $\alpha$ 를 통해 상대적인 비중을 조정
- ✓ Closed form solution

$$\hat{\boldsymbol{\theta}} = (\mathbf{X}^T \mathbf{X} + \alpha \mathbf{I}_n)^{-1} \mathbf{X}^T \mathbf{y}$$



# Ridge regression




Figure 4-17. Ridge Regression



# Lasso regression

- ✓ Least absolute shrinkage and selection operator regression (LASSO)
- ✓ 중요하지 않은 feature에 대해서는 parameter가 0으로 나오는 경향
- ✓ Feature selection에 이용이 가능함

$$J(\boldsymbol{\theta}) = \text{SSE}(\boldsymbol{\theta}) + \alpha \sum_i |\theta_i|$$

# Lasso regression




Figure 4-18. Lasso Regression