11월 3일 수업 강의 정리

1. 중간고사 이전 강의내용 Review

1) MC, TD 사용 이유

-. Value function 추정

-. Optimal action 찾기(by policy iteration): greedy 또는 ε-greedy 사용

2) MDP: S(State), T(Transition Probability), A(Action), R(Reward) 정보 알 수 있음

3) Model을 알 수 있는 경우와 알 수 없는 경우(Model-free) 비교

① Model given

-. MDP로 모델링 후 Bellman equation으로 Value function 구함

-. Bellman equation은 Bellman expectation equation과 Bellman optimality equation 두 종류

-. Prediction: Value function evaluation ($V^{\pi}(s)$, $Q^{\pi}(s,a)$), Control: 최적 정책 찾기 by greedy policy

② Model free

-. $P_{ss'}^{a}$ unknown → 시뮬레이터로 대체 → return의 평균을 Value function으로 사용

-. MC(Monte Carlo), TD(Temporal Difference) 사용

.MC: t 시점의 return값(t시점 이후 모든 reward들의 discounted 합)을 target으로 사용

.TD: 다음 step의 state의 Value function($V(s_{t+1})$: biased, 초기값 좋지 않음)을 TD Target에 사용

-. MC 수렴 조건: Greedy in the Limit with Infinite Exploration(GLIE)

Definition

Greedy in the Limit with Infinite Exploration (GLIE)

- All state-action pairs are explored infinitely many times,

(s, a)

$$\lim_{k\to\infty} N_k(s,a) = \infty$$

모든 state, action을 충분히 많이 방문해야 함

- The policy converges on a greedy policy,

policy가 마지막에는 greedy policy여야 함

$$\lim_{k\to\infty} \pi_k(a|s) = \mathbf{1}(a = \underset{a'\in\mathcal{A}}{\operatorname{argmax}}\ Q_k(s,a'))$$

- For example, ϵ-greedy is GLIE if ϵ reduces to zero at $\epsilon_k = \frac{1}{k}$

-. Sarsa(TD계열) 수렴 조건

Theorem

Sarsa converges to the optimal action-value function,
$Q(s,a) \rightarrow q_*(s,a)$, under the following conditions:

- *GLIE sequence of policies $\pi_t(a|s)$*
- *Robbins-Monro sequence of step-sizes α_t*

: 충분히 많이 탐색해야 함 $$\sum_{t=1}^{\infty} \alpha_t = \infty$$ α=0.1

: 너무 많이 돌아다니면 안된다. $$\sum_{t=1}^{\infty} \alpha_t^2 < \infty$$ $\alpha^2 = 0.01$

상수 term 경우 → ∞

$\alpha = \frac{1}{k}$ $\sum \frac{1}{k} = \infty$

$\sum \frac{1}{k^2} < \infty$

⇒ step size는 처음에 커도 나중에 계속 작아져야 함

-. Prediction: MC, TD 사용, Control: ε-greedy 사용

4) SARSA: TD + ε-greedy 사용

-. S, A, R, S′, A′, R′, S″, A″, R″,...

-. MC의 경우 Target으로 Return Gt = R + R′ + R″ ... 사용(γ = 1)

-. SARSA는 다음과 같이 Sampling: (S, A, R, S′, A′), (S′, A′, R′, S″, A″)

-. on-policy: behavior policy와 target policy가 동일하고 모두 ε-greedy 사용

5) Q-Learning

-. off-policy: behavior policy와 target policy가 다름

-. behavior policy는 ε-greedy 사용, target policy는 greedy 사용

6) TD(λ): n-step TD의 가중평균

7) Value Function Approximation: state 또는 action space의 size가 커서 계산 로드와 저장공간 부족 문제를 해결하고자 approximation

-. 단점: convergence 문제 발생

2. Value Function Approximation

1) Large Scale Reinforcement Learning

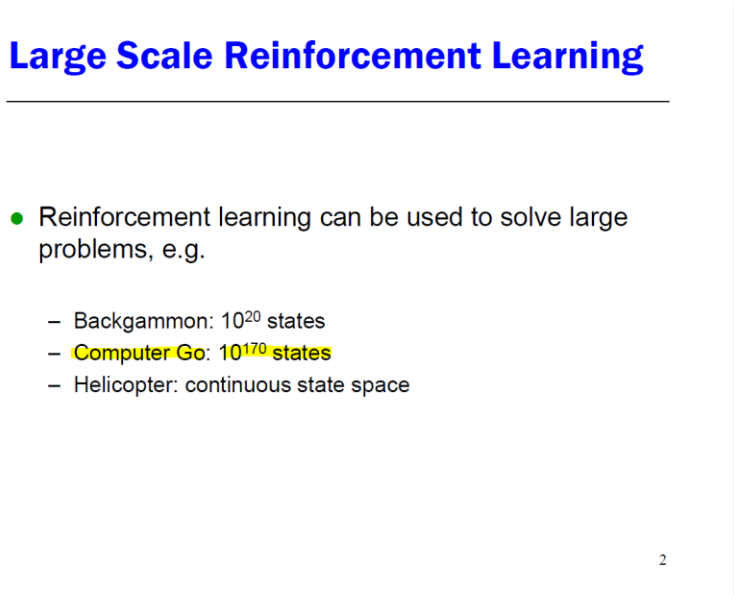

-. Computer Go의 경우 10^{170} states가 있음

. state 당 1byte 가정하면, 10^{170}byte가 필요함

. 10^{170}byte를 저장하는 것은 현실적으로 불가능

: RAM 32GB ≒ 32 × 10^{9}, Hard Disk 1TB ≒ 1 × 10^{12} 가정

: 10^{170-12} ≒ 10^{150}개의 1TB Hard Disk 필요

➔ 10^{170}개의 Q value 값을 table 형태로 저장하는 것은 불가능

-. Value Function Approximation을 하면 학습모델의 Weight만 저장

.선형회귀 모델의 경우 모든 예측값은 필요 없고 절편과 기울기만 있으면 예측값 계산 가능

.장점: 저장공간이 크게 줄어듦

.단점: 정확도가 떨어지고, 수렴 잘 안됨 → 그래도 못하는 것보다 나음

2) Value Function Approximation

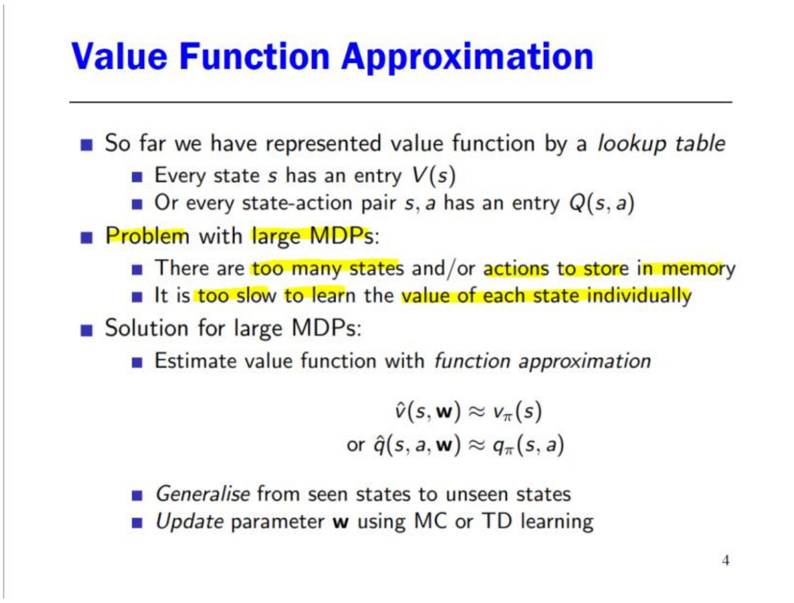

-. State와 Acton space의 size가 큰 Large MDP의 문제점과 Approximation 통한 해결방안

① 모든 state과 action을 메모리와 Hard disk에 저장하는 것은 불가능

→ 해결 방안: 모든 state과 action의 table을 갖지 않고, approximation 모델의 parameter를 저장

② 모든 state과 action pair를 방문하는 것은 불가능

→ 해결 방안: approximation 통해 모든 state과 action에 대한 정확한 value function을 계산하지 않고 근사값을 찾아서 computational load를 줄임

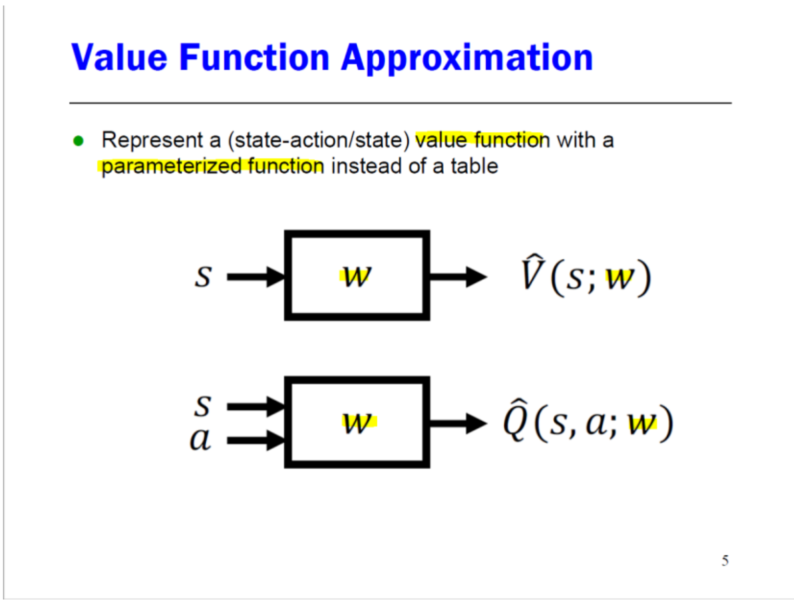

-. parameter w가 바뀌면 다른 Function approximation model이 됨

-. gradient descent 알고리즘에 의해 Loss = E[(V(s) - $\hat{V}(S,W)$)^2]를 최소화하는 w값을 구함

3) How to approximate?

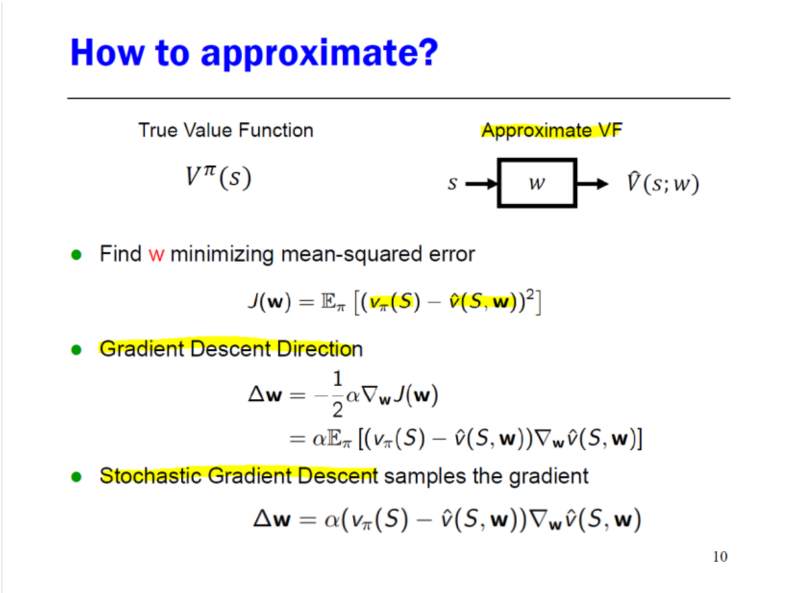

-. { (x_i, y_i), i = 1, 2, 3, …, n} 데이터가 주어졌을 때, 예측모델 f(·) 활용한 예측값은 $\hat{y}_i = f(x_i)$로 표현하며, 다양한 종류의 예측모델 f를 사용할 수 있음

→ 예측모델의 최적 parameter ***w***는 $\min\sum(y_i - f(x_i))^2$ → $\min\sum(\hat{V}(w) - V^{\pi}(w))^2$를 최소화하는 parameter로써 예측값 $\hat{V}$가 V^{π}에 가까워지게 해야함

-. Value Function Approximation에서는 (x_i, y_i)로 state와 그 state에서의 주어진 policy π에 대한 value function으로 사용: (x_i, y_i) → (s_i, $V^{\pi}(s_i)$) 또는 (s_i, $Q^{\pi}(s_i, a_i)$)

-. 그러나, 주어진 데이터는 sample일 뿐이기 때문에, 실제로는 $V^{\pi}(s_i)$과 $Q^{\pi}(s_i, a_i)$를 알 수 없음

: s, a, r, s', a', r'

-. MC에서는 G_t를 V_{π}로 놓고, TD에서는 TD Target을 V_{π}로 놓고 문제를 풀어감

-. Gradient Descent Direction: gradient descent direction으로 가면 J(w)가 감소되는게 보장되기 때문에 사용하지만, 반드시 최적값을 도출하지는 않을 수 있음

-. Stochastic Gradient Descent: 모든 state에 대해서 gradient descent 알고리즘을 적용하면 computational load가 매우 크지만, 한 개의 state에 대해 업데이트하면 computational load가 작아지게 되지만, state 마다의 variability가 커지는 단점이 있음

-. Value Function Approximation에서는 stochastic gradient descent에 의해 approximation 모델의 parameter w를 계속 업데이트함. $V^{\pi}(s_i)$과 $Q^{\pi}(s_i, a_i)$를 업데이트 하지 않음

4) Feature Vectors

Feature Vectors

- Represent state by a *feature vector*

$$\mathbf{x}(S) = \begin{pmatrix} \mathbf{x}_1(S) \\ \vdots \\ \mathbf{x}_n(S) \end{pmatrix}$$

- For example:
  - Distance of robot from landmarks
  - Trends in the stock market
  - Piece and pawn configurations in chess

11

-. State를 잘 설명할 수 있는 Feature 추출 필요하며 State와 Feature는 같지 않음

5) Linear VFA

Linear VFA

- Represent value function by a linear combination of features

$$\hat{v}(S, \mathbf{w}) = \mathbf{x}(S)^\top \mathbf{w} = \sum_{j=1}^{n} \mathbf{x}_j(S)\mathbf{w}_j$$

12

-. State에서 추출한 Feature들의 선형 조합은 Linear VFA는 제일 간단한 형태

6) Linear VFA Example: Tetris

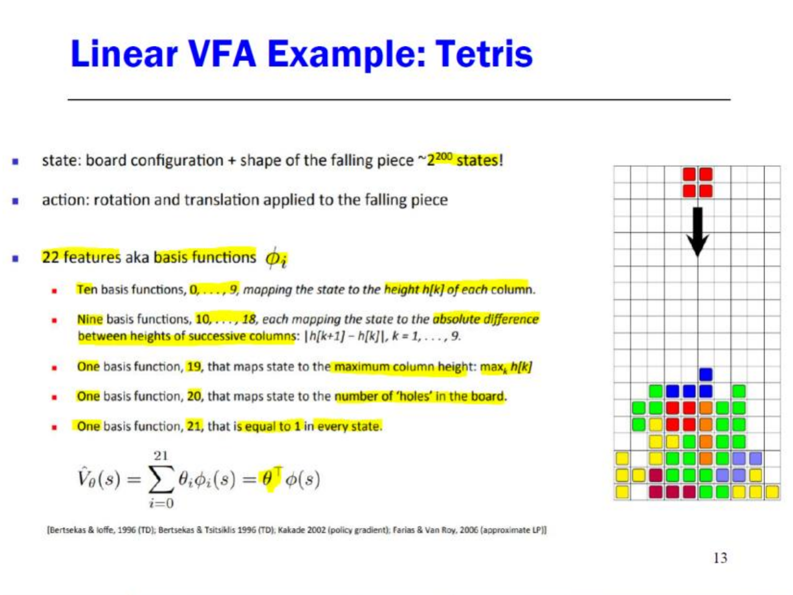

-. 2^{200} states ≒10^{60} Bytes → 10^{60}-12 = 10^{48}개의 Hard Disk 필요 → 저장 불가

-. 2^{200}개의 states에서 22개의 Feature를 뽑고, 선형 결합하면 계수 22개의 값만 저장하면 됨: 약 88bytes

7) Incremental Prediction Algorithm

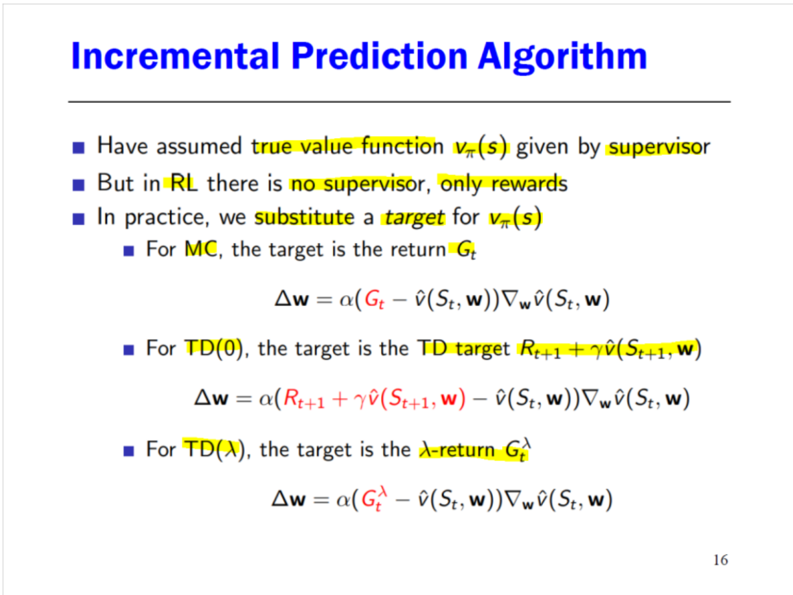

-. 강화학습에서는 true value function $v_\pi(s)$가 주어지지 않고 오직 reward만 주어지기 때문에, $v_\pi(s)$를 target으로 대체함

.MC: G_t

.TD(0): R_{t+1} + $\gamma\hat{v}(S_{t+1}, w)$

.TD(λ): G_t^λ

8) Monte-Carlo with VFA

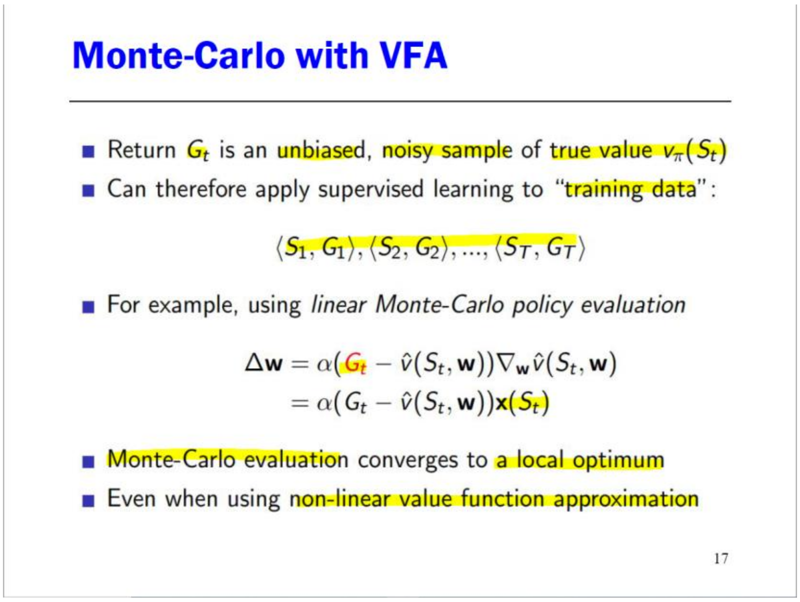

-. Return G_t가 high variance지만 unbiased하기 때문에 $v_\pi(s)$ 대신 사용하며, 다음과 같이 학습 데이터 구성: $(S_1, G_1), (S_2, G_2), \ldots, (S_T, G_T)$

-. MC Evaluation은 non-linear VFA를 사용해도 local optimum에 빠짐

9) TD Learning with VFA

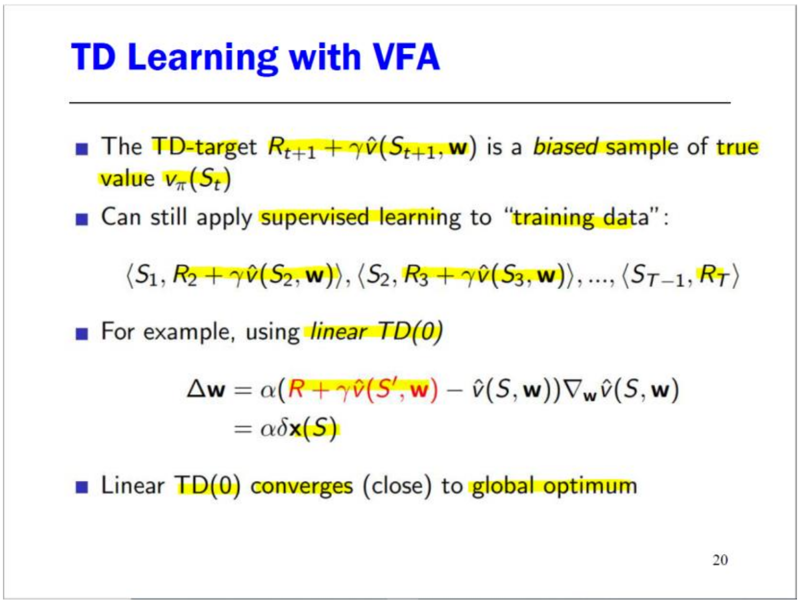

-. TD target은 biased 하지만, training data의 response 값으로 true value function을 대체하여 사용

-. TD(0)는 global optimum에 수렴

10) Linear SARSA with Coarse Coding in Mountain Car

Linear SARSA with Coarse Coding in Mountain Car

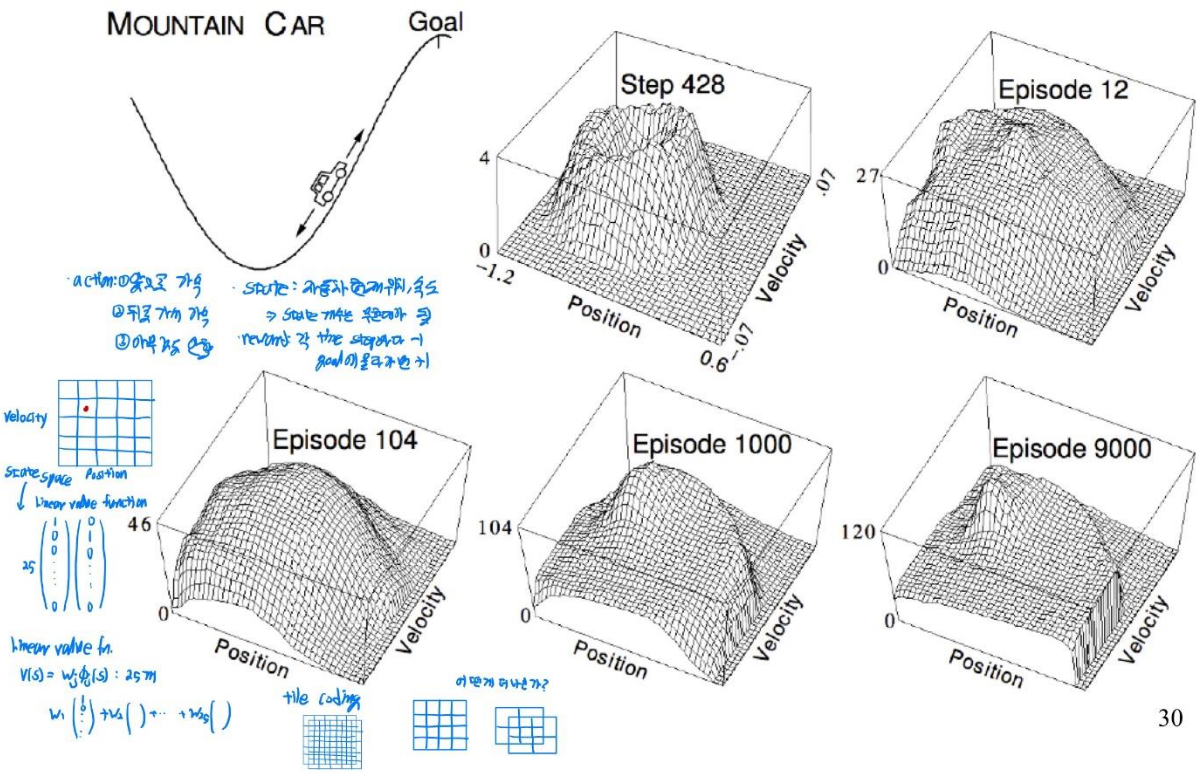

-. action: 앞으로 가속, 뒤로 이동 후 앞으로 가속, 아무것도 안함

-. state: 자동차 현재 위치, 속도 → 위치와 속도는 연속치라서 state space는 무한대가 됨

-. state space를 5 x 5 grid로 discretize 하면, 25 x 1 크기의 one-hot vector로 나타낼 수 있음

-. Linear Value Function Approximation은 $\hat{v}(s) = \sum w_j \Phi_j(s)$로 표현