



INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
UNIVERSIDADE DE SÃO PAULO



XLIX Programa de Verão (2020) - Introdução ao Aprendizado por Reforço

Redução de Variância e Funções Valor

Thiago Pereira Bueno
tbueno@ime.usp.br

IME - USP, 13/02/2019

LIAMF: Grupo PAR (Planejamento e Aprendizado por Reforço)



Aula 3

Agenda


1. Policy Gradients e REINFORCE: revisão
2. Propriedades do Score Function
3. Redução de Variância via *Reward-to-Go*
4. Funções Valor e *Baseline*: escala de referência para retornos

Objetivos


- Relacionar as propriedades do estimador REINFORCE com a performance do agente
- Entender e implementar técnicas estatísticas para redução de ruído / variância
- Aprender um aproximador paramétrico para estimar retornos esperados




Policy Gradients e REINFORCE: revisão (1/3)




Policy Gradients e REINFORCE: revisão (1/3)



Policy Gradients e REINFORCE: revisão (1/3)



Policy Gradients e REINFORCE: revisão (1/3)



Policy Gradient

$$\nabla_\theta J(\theta) = \mathbb{E}_{\tau \sim \pi_\theta} \left[\sum_{t=0}^{T-1} \nabla_\theta \log \pi_\theta(a_t | s_t) R(\tau) \right]$$


Policy Gradients e REINFORCE: revisão (2/3)

$$\nabla_{\theta} J(\theta) = \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(a_t | s_t) R(\tau) \right]$$

↑
↑
 Score Function Retorno

REINFORCE = Tentativa & Erro

$R(\tau) > 0$	$\uparrow \pi_{\theta}(\mathbf{a}_t \mathbf{s}_t)$	Reforço positivo 
$R(\tau) < 0$	$\downarrow \pi_{\theta}(\mathbf{a}_t \mathbf{s}_t)$	Reforço negativo 



Policy Gradients e REINFORCE: revisão (3/3)

Algoritmo 1 REINFORCE

Entrada: parâmetros da política, θ

- 1: **enquanto** não satisfeito **faça**
- 2: Colete trajetórias com a política atual, $\tau_1, \tau_2, \dots, \tau_N \sim \pi_\theta$
- 3: Calcule os retornos de cada trajetória, $R_k = \sum_{t=1}^T r_t^k$
- 4: Estime o *Policy Gradient*

$$\nabla_\theta J(\theta) \approx \frac{1}{N} \sum_{k=1}^N \sum_{t=0}^{T-1} \nabla_\theta \log \pi_\theta(a_t^k | s_t^k) R_k \quad \leftarrow \text{Monte-Carlo Sampling}$$



- 5: Atualize os parâmetros da política, $\theta \leftarrow \theta + \alpha \nabla_\theta J(\theta)$
 - 6: **fim enquanto**
 - 7: **devolve** π_θ
-

Na aula de hoje vamos nos concentrar em **estudar as propriedades** do estimador **REINFORCE**



Como acelerar o treinamento de políticas?

CartPole-v1 (média e desvio padrão para 10 *trials*)



- Quais as propriedades do **Policy Gradient** que impactam no treinamento?
 - Qual a relação da **variância do estimador** com o ruído nos experimentos?
 - Como uma estimativa enviesada do gradiente pode interferir na performance final ?



Propriedades do *Score Function*

$$\mathbb{E}_{x \sim p_\theta} [\nabla_\theta \log p_\theta(x)] = \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx$$

↑
Score Function



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Propriedades do *Score Function*

$$\mathbb{E}_{x \sim p_\theta} [\underbrace{\nabla_\theta \log p_\theta(x)}_{\substack{\uparrow \\ \text{Score Function}}}] = \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx$$
$$= \int p_\theta(x) \frac{\nabla_\theta p_\theta(x)}{p_\theta(x)} dx$$



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Propriedades do *Score Function*

$$\begin{aligned}\mathbb{E}_{x \sim p_\theta} [\underbrace{\nabla_\theta \log p_\theta(x)}_{\substack{\uparrow \\ \text{Score Function}}}]] &= \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx \\ &= \int p_\theta(x) \frac{\nabla_\theta p_\theta(x)}{p_\theta(x)} dx \\ &= \int \nabla_\theta p_\theta(x) dx\end{aligned}$$



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Propriedades do *Score Function*

$$\begin{aligned}\mathbb{E}_{x \sim p_\theta} [\underbrace{\nabla_\theta \log p_\theta(x)}_{\substack{\uparrow \\ \text{Score Function}}}]] &= \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx \\ &= \int p_\theta(x) \frac{\nabla_\theta p_\theta(x)}{p_\theta(x)} dx \\ &= \int \nabla_\theta p_\theta(x) dx \\ &= \nabla_\theta \int p_\theta(x) dx\end{aligned}$$



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Propriedades do *Score Function*

$$\begin{aligned}\mathbb{E}_{x \sim p_\theta} [\underbrace{\nabla_\theta \log p_\theta(x)}_{\substack{\uparrow \\ \text{Score Function}}}]] &= \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx \\ &= \int p_\theta(x) \frac{\nabla_\theta p_\theta(x)}{p_\theta(x)} dx \\ &= \int \nabla_\theta p_\theta(x) dx \\ &= \nabla_\theta \int p_\theta(x) dx \\ &= \nabla_\theta 1\end{aligned}$$



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Propriedades do *Score Function*

$$\begin{aligned}\mathbb{E}_{x \sim p_\theta} [\underbrace{\nabla_\theta \log p_\theta(x)}_{\substack{\uparrow \\ \text{Score Function}}}]] &= \int p_\theta(x) \nabla_\theta \log p_\theta(x) dx \\ &= \int p_\theta(x) \frac{\nabla_\theta p_\theta(x)}{p_\theta(x)} dx \\ &= \int \nabla_\theta p_\theta(x) dx \\ &= \nabla_\theta \int p_\theta(x) dx \\ &= \nabla_\theta 1 \\ &= 0\end{aligned}$$



Teorema: o valor esperado do *score function* de uma distribuição paramétrica é zero.

Redução de Variância via *Reward-to-Go* (1/3)

$$\nabla_{\theta} J(\pi_{\theta}) = \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right]$$



Redução de Variância via *Reward-to-Go* (1/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} [\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau)]\end{aligned}$$



Redução de Variância via *Reward-to-Go* (1/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} [\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau)] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\sum_{t'=0}^{T-1} r_{t'} \right) \right]\end{aligned}$$



Redução de Variância via *Reward-to-Go* (1/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\sum_{t'=0}^{T-1} r_{t'} \right) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\sum_{t'=0}^{t-1} r_{t'} + \sum_{t'=t}^{T-1} r_{t'} \right) \right]\end{aligned}$$



Redução de Variância via *Reward-to-Go* (1/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\sum_{t'=0}^{T-1} r_{t'} \right) \right] \\ &= \sum_{t=0}^{T-1} \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\underbrace{\sum_{t'=0}^{t-1} r_{t'}}_{\text{passado}} + \underbrace{\sum_{t'=t}^{T-1} r_{t'}}_{\text{futuro}} \right) \right]\end{aligned}$$





Redução de Variância via *Reward-to-Go* (2/3)

$$\mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] =$$


passado

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (2/3)

$$\mathbb{E}_{\tau \sim \pi_{\theta}} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] = \mathbb{E}_{\tau_{0:t} \sim \pi_{\theta}} \left[\mathbb{E}_{\mathbf{a}_t \sim \pi_{\theta}(\cdot | \mathbf{s}_t)} \left[\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \mid \tau_{0:t} \right] \right]$$

~~passado~~
↑
passado

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (2/3)

$$\begin{aligned}
 \mathbb{E}_{\tau \sim \pi_\theta} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} [\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) | \tau_{0:t}] \right]
 \end{aligned}$$

~~passado~~
 ↑
 passado

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (2/3)

$$\begin{aligned}
 \mathbb{E}_{\tau \sim \pi_\theta} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \mid \tau_{0:t} \right] \right]
 \end{aligned}$$

↑ **passado**
↑ *Esperança do Score Function*

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (2/3)

$$\begin{aligned}
 \mathbb{E}_{\tau \sim \pi_\theta} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \cdot 0 \right]
 \end{aligned}$$

↑
↑
 passado Esperança do Score Function

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (2/3)

$$\begin{aligned}
 \mathbb{E}_{\tau \sim \pi_\theta} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \right] &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=0}^{t-1} r_{t'} \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \mathbb{E}_{\mathbf{a}_t \sim \pi_\theta(\cdot | \mathbf{s}_t)} \left[\nabla_\theta \log \pi_\theta(\mathbf{a}_t | \mathbf{s}_t) \mid \tau_{0:t} \right] \right] \\
 &= \mathbb{E}_{\tau_{0:t} \sim \pi_\theta} \left[\left(\sum_{t'=0}^{t-1} r_{t'} \right) \cdot 0 \right] \\
 &= 0
 \end{aligned}$$

↑ **passado**
↑ *Esperança do Score Function*

- Lembre-se que o **valor esperado do Score Function** de uma distribuição é **zero**.



Redução de Variância via *Reward-to-Go* (3/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \underbrace{\sum_{t'=t}^{T-1} r_{t'}}_{\text{Reward-to-Go}} \right) \right]\end{aligned}$$



Redução de Variância via *Reward-to-Go* (3/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \underbrace{\sum_{t'=t}^{T-1} r_{t'}}_{\text{Reward-to-Go}} \right) \right]\end{aligned}$$

1. O principal desafio do *Policy Gradient* é o número de trajetórias para se obter uma boa estimativa



Redução de Variância via *Reward-to-Go* (3/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \underbrace{\sum_{t'=t}^{T-1} r_{t'}}_{\text{Reward-to-Go}} \right) \right]\end{aligned}$$

1. O principal desafio do *Policy Gradient* é o número de trajetórias para se obter uma boa estimativa
2. A fórmula inicial continha termos que “reforçavam” ações de acordo com recompensas passadas



Redução de Variância via *Reward-to-Go* (3/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right]\end{aligned}$$



1. O principal desafio do *Policy Gradient* é o número de trajetórias para se obter uma boa estimativa
2. A fórmula inicial continha termos que “reforçavam” ações de acordo com recompensas passadas
3. Todos esses termos tem média zero, embora contribuam para a variância do estimador (i.e., ruído)



Redução de Variância via *Reward-to-Go* (3/3)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) R(\tau) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right]\end{aligned}$$



1. O principal desafio do *Policy Gradient* é o número de trajetórias para se obter uma boa estimativa
2. A fórmula inicial continha termos que “reforçavam” ações de acordo com recompensas passadas
3. Todos esses termos tem média zero, embora contribuam para a variância do estimador (i.e., ruído)
4. Ao remover esses termos do estimador, podemos reduzir o número de episódios necessários!



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:

- A função *baseline* serve como um valor referência para o reforço dado pelo *reward-to-go*



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:

- A função *baseline* serve como um valor referência para o reforço dado pelo *reward-to-go*

Note que sem essa referência ...



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:

- A função *baseline* serve como um valor referência para o reforço dado pelo *reward-to-go*

Note que sem essa referência ...

- A probabilidade de uma boa ação pode ser diminuída se o retorno do episódio for negativo



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:

- A função *baseline* serve como um valor referência para o reforço dado pelo *reward-to-go*

Note que sem essa referência ...

- A probabilidade de uma boa ação pode ser diminuída se o retorno do episódio for negativo
- Ao longo do treinamento, piores ações serão mais desencorajadas; isso irá encorajar **indiretamente** as boas ações;



Funções *Baseline*: referência para retornos (1/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Intuição:

- A função *baseline* serve como um valor referência para o reforço dado pelo *reward-to-go*

Note que sem essa referência ...

- A probabilidade de uma boa ação pode ser diminuída se o retorno do episódio for negativo
- Ao longo do treinamento, piores ações serão mais desencorajadas; isso irá encorajar **indiretamente** as boas ações;
- No entanto, isso irá **retardar** consideravelmente o treinamento!



Funções *Baseline*: referência para retornos (2/2)

$$\begin{aligned}\nabla_{\theta} J(\pi_{\theta}) &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \sum_{t'=t}^{T-1} r_{t'} \right) \right] \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} \left(\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) \left(\left(\sum_{t'=t}^{T-1} r_{t'} \right) - \underline{b(\mathbf{s}_t)} \right) \right) \right]\end{aligned}$$

↑
baseline

Prova (sketch): use o teorema do valor esperado do score function para provar o lema:

$$\mathbb{E}_{\mathbf{a}_t \sim \pi_{\theta}(\cdot | \mathbf{s}_t)} [\nabla_{\theta} \log \pi_{\theta}(\mathbf{a}_t | \mathbf{s}_t) b(\mathbf{s}_t)] = 0$$



Funções Valor como Baseline (1/2)

Uma boa referência para o *retorno de um episódio* é dada pela **Função Valor**

$$\begin{aligned} b(\mathbf{s}) &= V^{\pi_{\theta}}(\mathbf{s}) \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} r_t \mid \mathbf{s}_0 = \mathbf{s} \right] \end{aligned}$$



Funções Valor como Baseline (1/2)

Uma boa referência para o *retorno de um episódio* é dada pela **Função Valor**

$$\begin{aligned} b(\mathbf{s}) &= V^{\pi_{\theta}}(\mathbf{s}) \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=0}^{T-1} r_t \mid \mathbf{s}_0 = \mathbf{s} \right] \end{aligned}$$

Note que naturalmente uma trajetória $\tau = (\mathbf{s}_0, \mathbf{a}_0, r_1, \dots, \mathbf{s}_{T-1}, \mathbf{a}_{T-1}, r_T)$:



Funções Valor como Baseline (1/2)

Uma boa referência para o *retorno de um episódio* é dada pela **Função Valor**

$$\begin{aligned} b(\mathbf{s}) &= V^{\pi_\theta}(\mathbf{s}) \\ &= \mathbb{E}_{\tau \sim \pi_\theta} \left[\sum_{t=0}^{T-1} r_t \mid \mathbf{s}_0 = \mathbf{s} \right] \end{aligned}$$

Note que naturalmente uma trajetória $\tau = (\mathbf{s}_0, \mathbf{a}_0, r_1, \dots, \mathbf{s}_{T-1}, \mathbf{a}_{T-1}, r_T)$:

- pode ser considerada "**boa**" se $R(\tau' \mid \mathbf{s}_0 = \mathbf{s}) > \mathbb{E}_{\tau \sim \pi_\theta}[R(\tau) \mid \mathbf{s}_0 = \mathbf{s}]$ 

Funções Valor como Baseline (1/2)

Uma boa referência para o *retorno de um episódio* é dada pela **Função Valor**

$$\begin{aligned} b(\mathbf{s}) &= V^{\pi_\theta}(\mathbf{s}) \\ &= \mathbb{E}_{\tau \sim \pi_\theta} \left[\sum_{t=0}^{T-1} r_t \mid \mathbf{s}_0 = \mathbf{s} \right] \end{aligned}$$

Note que naturalmente uma trajetória $\tau = (\mathbf{s}_0, \mathbf{a}_0, r_1, \dots, \mathbf{s}_{T-1}, \mathbf{a}_{T-1}, r_T)$:

- pode ser considerada "**boa**" se $R(\tau' \mid \mathbf{s}_0 = \mathbf{s}) > \mathbb{E}_{\tau \sim \pi_\theta}[R(\tau) \mid \mathbf{s}_0 = \mathbf{s}]$ 
- pode ser considerada "**ruim**" se $R(\tau' \mid \mathbf{s}_0 = \mathbf{s}) < \mathbb{E}_{\tau \sim \pi_\theta}[R(\tau) \mid \mathbf{s}_0 = \mathbf{s}]$ 

Funções Valor como Baseline (2/2)


Problema: não temos acesso direto à função Valor de um estado!

Solução:

1. **Simular trajetórias** e estimar retornos de episódios via **Monte-Carlo**
2. Aproximar a função Valor via **regressão** (e.g., à la *Supervised Learning*)

$$\phi_k = \arg \min_{\phi} \mathbb{E} \left[\left(V_{\phi}(\mathbf{s}_t) - \sum_{t'=t}^{T-1} r_{t'} \right)^2 \right]$$

↑
Mean Squared Error



Referências

(1) OpenAI Spinning Up

- https://spinningup.openai.com/en/latest/spinningup/extra_pg_proof1.html
- https://spinningup.openai.com/en/latest/spinningup/rl_intro3.html#baselines-in-policy-gradients

(2) Deep RL Bootcamp Lecture 4A: Policy Gradients

- https://www.youtube.com/watch?v=S_gwYj1Q-44

(3) Reinforcement Learning: An Introduction (Sutton & Barto 2018, 2nd Edition)

- Seções 13.3 e 13.4

