



تمرین سری چهارم: فرآیندهای تصمیم‌گیری مارکوف

لطفاً به نکات زیر توجه کنید:

- مهلت ارسال این تمرین برای هر دو گروه ۴ آذر ماه است.
 - در صورتی که به اطلاعات بیشتری نیاز دارید می‌توانید به صفحه‌ی تمرین در وب‌سایت درس مراجعه کنید.
 - ما همواره هم‌فکری و هم‌کاری را برای حل تمرین‌ها به دانشجویان توصیه می‌کنیم. اما هر فرد باید تمامی سوالات را به تنها بی‌یاری تمام کند و پاسخ ارسالی حتماً باید توسط خود دانشجو نوشته شده باشد. لطفاً اگر با کسی هم‌فکری کردید نام او را ذکر کنید.
 - لطفاً برای ارسال پاسخ‌های خود از راهنمای موجود در صفحه‌ی تمرین استفاده کنید.
 - هر سؤالی درباره‌ی این تمرین را می‌توانید در گروه درس مطرح کنید و یا از دستیاران حل تمرین پرسید.
- آدرس صفحه‌ی تمرین: https://iust-courses.github.io/ai97/assignments/04_mdp
- آدرس گروه درس: <https://groups.google.com/forum/#!forum/ai97>

موفق باشید

سؤال‌ها

سؤال یک (۲۵ نمره)

هدف یک عامل شیوه‌ساز فوتبال ۲ بعدی در زمین، کمک کردن به تیم برای رسیدن به پیروزی در بازی است. بیشترین سود برای تیم رسیدن توب به خط حمله هست اما در این مکان احتمال از دست دادن توب وجود دارد و برای برگرداندن توب به خط حمله نیاز به صرف انرژی می‌باشد (در هر مرحله از دست دادن توب، توب به یک منطقه عقب‌تر در صورت وجود برمی‌گردد).

این عامل می‌تواند در یکی از ۳ حالت ۱ - خط دفاع - ۲ - خط هافبک - ۳ - خط حمله باشد. در هر یکی از این حالت‌ها ۲ اکشن ۱ - حرکت کردن نکردن را می‌توانند انجام بدهد. حرکت کردن معادل یک واحد صرف انرژی است و یک امتیاز منفی برای عامل در پی دارد. وقتی عامل در خط حمله قرار می‌گیرد ۳ امتیاز مثبت دریافت می‌کند و در حالت‌های دیگر ۱ امتیاز . برای مثال اگر عامل در خط حمله باشد و در حال حرکت (برای حفظ توب) پاداش $= 2 - 3 = 1$ را دریافت می‌کند.

احتمال موقعیت بعدی عامل بعد هر عمل در هر منطقه از زمین معادل جدول زیر است:

حرکت نکردن	حرکت کردن	
۱ دفاع	۰.۴ هافبک / ۰.۶ دفاع	دفاع
۱ دفاع	۰.۶ حمله / ۰.۱ هافبک / ۰.۳ دفاع	هافبک
۰.۷ حمله / ۰.۳ هافبک	۰.۹ حمله / ۰.۱ هافبک	حمله

الف) MDP این مسئله را رسم کنید.

ب) با استفاده از ضریب تخفیف^۱ ۰.۸ و روش «تکرار ارزش^۲»، این MDP را حل کنید. با مجموعه مقادیر صفر باید این کار را آغاز کنید، و راهبرد^۳ و مقدار بهینه را نشان دهید.

پ) با استفاده از ضریب تخفیف ۰.۸ و روش «تکرار راهبرد^۴» این MDP را حل کنید. حل را با راهبرد اولیه و غیر بهینه‌ی «حرکت نکردن» آغاز کنید. راهبرد و مقدار بهینه را نشان دهید.

¹ Discount Factor

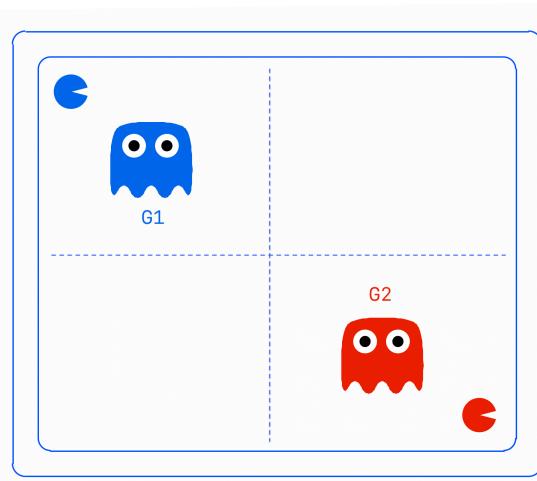
² Value Iteration

³ Policy

⁴ Policy Iteration

سوال دو (۲۵ نمره)

در این سوال می‌خواهیم از MDP در شکلی از بازی پکمن که یک بازی دو نفره‌ی نوبتی با مجموع صفر است استفاده کنیم. فرض کنید در یک صفحه‌ی ۲ در ۲، دوروح G1 و G2 به شکل زیر قرار دارند. وظیفه‌ی دوروح خوردن پکمن طرف مقابل است. مکان پکمن‌ها در نقشه مشخص شده‌اند و با رسیدن هر روح به پکمن مورد نظرش آن را می‌خورد و بازی تمام می‌شود. هم‌چنین دوروح هم نمی‌توانند هم‌زمان در یک خانه از جدول باشند. هر روح فقط می‌تواند در جهت عمودی و یا افقی حرکت کند. (s, R) تابعی است که پاداش بودن در هر حالت را از دید روح اول (G1) مشخص می‌کند به این صورت که اگر روح اول زودتر پکمن طرف مقابل را بخورد مقدار $+1$ و اگر روح دوم زودتر پکمن طرح مقابل را بخورد مقدار -1 و در غیر این صورت صفر برگردانده می‌شود. شروع بازی با روح اول است.



الف) در حالت کلی اگر (s, V_{G1}) ارزش حالت s وقتی نوبت حرکت G1 باشد و هم‌چنین (s, V_{G2}) ارزش حالت s وقتی نوبت حرکت G2 باشد، معادلات بی‌من^۵ را برای V_{G1} و V_{G2} بنویسید (دقت کنید که تمامی محاسبات امتیاز و ارزش‌ها بر اساس دید روح اول از بازیست).

ب) توضیح دهید چگونه با استفاده از این دو معادله‌ای که به دست آورده‌ید می‌توان الگوریتم «تکرار ارزش» را به صورت دو نفره انجام داد. ضمناً شرط پایان مناسب را هم تعیین کنید.

پ) نقشه‌ی حالات MDP را برای این بازی رسم کنید و هم‌چنین امتیاز هر حالت را برای آن بنویسید.

ت) (امتیازی / ۱۰ نمره) حال الگوریتم «تکرار ارزش»ی که در قسمت (ب) به دست آورده‌ید را برای این بازی اعمال کنید و راهبرد بهینه را به دست آورید.

^۵ Bellman Equations

سوال سه (۳۰ نمره)

تا به اینجا از الگوریتم «تکرار ارزش» برای حل MDP‌ها استفاده کردیم و می‌دانیم با استفاده از آن حتماً به جواب بهینه می‌رسیم. اما در این سوال می‌خواهیم دلیل هم‌گرایی این الگوریتم را بیابیم. در ریاضی مفهومی وجود دارد به نام نگاشت انقباضی^۶. اگر بخواهیم حدودی آن را تعریف کنیم، این نگاشت یک تابع با یک ورودیست که اگر آن را به طور مجزا روی دو عدد اعمال کنیم، این تابع خروج‌هایی برای این دو تولید می‌کند که به هم نزدیکترند. به طور مثال « تقسیم بر دو » یک نگاشت انقباضیست. توجه کنید که این نوع عملگر یک نقطه‌ی ثابت هم دارد که در اثر اعمال تابع، بدون تغییر می‌ماند (مثلاً عدد صفر در نگاشت « تقسیم بر دو » یک نقطه‌ی ثابت است).

این نگاشت دو خاصیت مهم دارد: ۱- تنها یک نقطه‌ی ثابت دارد و ۲- اگر به صورت حدی آن را بر روی یک ورودی مرتب‌آیی اعمال کنیم به به نقطه‌ی ثابت آن می‌رسیم (چرا؟) بنابراین اگر ثابت کنیم رویه‌ی آپدیت بِل من^۷ از این نوع است هم‌گرایی و رسیدن به جواب یکتا برای آن اثبات می‌شود.

اگر V_i یک بردار باشد که هر خانه‌ی آن بیان‌گر یک ارزش در مرحله‌ی i ام الگوریتم تکرار ارزش باشد، و هم‌چنین اگر رویه‌ی بِل من را به صورت یک عملگر بیینیم که به صورت هم‌مان روی تمام خانه‌ی این بردار اعمال می‌شود، رابطه‌ی آپدیت بِل من را می‌توان به صورت زیر نوشت:

$$V_{i+1} \leftarrow B[V_i]$$

به علاوه برای اثبات، به روشی برای اندازه‌گیری «فاسله» بین دو بردار ارزش نیاز داریم، برای این منظور از MaxNorm استفاده می‌کنیم. اگر این عملگر روی یک بردار اعمال شود بزرگ‌ترین قدر مطلق از مقادیر آن را برمی‌گرداند:

$$\|V\| = \max_s |V_s|$$

با این تعریف، بیشترین تفاوت بین هر دو المان دو بردار برابر با $\|V - V'\|$ خواهد شد، در ادامه اگر با فرض اینکه V_i' دو بردار ارزش باشد برای رسیدن به انقباضی بودن رابطه‌ی بِل من شما باید رابطه زیر را اثبات کنید:

$$\|B[V_i] - B[V_i']\| \leq \gamma \|V_i - V_i'\|$$

راهنمایی: ابتدا اثبات کنید به ازای هر دو تابع g و f رابطه‌ی زیر برقرار است، سپس رابطه بِل من را در نامساوی بالا قرار دهید.

$$|\max_a f(a) - \max_a g(a)| \leq \max_a |f(a) - g(a)|$$

⁶ Contraction Mapping

⁷ Bellman Update

سوال چهار (۲۰ نمره)

در یک فرآیند تصمیم‌گیری مارکوف با تابع پاداش $R(s,a)$ می‌توان راهبرد بهینه $(s)^*\pi$ را یافت. برای چه مقداری را از c ، اعمال تغییر در تابع پاداش، همان راهبرد بهینه قبلی را به ما می‌دهد؟ هر قسمت را اثبات و یا با یک مثال نقض رد کنید.

$$R'(s,a) = R(s,a) \times c \quad \text{الف}$$

$$R'(s,a) = R(s,a) + c \quad \text{ب}$$