



تکلیف شماره‌ی ۳

فصل شانزدهم و هفدهم

تصمیم‌گیری: اتخاذ تصمیم‌های ساده، اتخاذ تصمیم‌های پیچیده

DECISION MAKING: MAKING SIMPLE DECISIONS / MAKING COMPLEX DECISIONS

(۱) در ۱۸۳۷ م، نیکولاوس برنولی، معماهی را با نام پارادوکس سنت پترزبورگ بیان کرد که به صورت زیر بیان می‌شود: «سکه‌ی سالمی انداخته می‌شود و شما تا زمانی که شیر باید فرصت دارید بازی کنید. اگر اولین شیر آمدن در n -امین پرتاب اتفاق بیفت، ۲ⁿ دلار جایزه می‌گیرید.»

(الف) نشان دهید که امید ارزش پولی (EMV) این بازی، بی‌نهایت است.

(ب) شما چه قدر حاضرید برای ورود به این بازی پرداخت کنید؟

(ج) برنولی این پارادوکس را با این پیشنهاد حل کرد که سودمندی پول با مقیاس لگاریتمی اندازه‌گیری شود، یعنی $= U(S_n)$ که در آن $S_n = a \log_2 n + b$ حالت داشتن n دلار است. متوسط سودمندی این بازی تحت این فرض چه قدر است؟

(د) با فرض سرمایه‌ی اولیه‌ی k دلار، حداقل مبلغ پرداختی برای ورود به این بازی که رسیونال باشد، چه قدر است؟

(۲) فرض کنید سودمندی یک دنباله از حالت‌ها، ماکزیمم پاداش به دست آمده در میان تمام حالت‌های آن دنباله تعريف شود. نشان دهید که این تابع سودمندی موجب ترجیحات ایستان (stationary preferences) میان دنباله‌های حالت‌ها نمی‌شود. آیا با این وجود ممکن است که یک تابع سودمندی بر روی حالت‌ها تعريف کنیم که اتخاذ تصمیم MEU موجب رفتار بهینه شود؟

(۳) آیا هر مسئله‌ی جستجوی متناهی را می‌توان دقیقاً به یک مسئله‌ی تصمیم‌گیری مارکوف تبدیل کرد به‌طوری که یک راه حل بهینه‌ی آن، یک راه حل بهینه‌ی مسئله‌ی اول باشد؟ اگر چنین است، با دقت چگونگی تبدیل مسئله و بازگرداندن راه حل مسئله‌ی تبدیل شده را توضیح دهید. در غیر این صورت، با دقت توضیح دهید که چرا نه (مثلاً یک مثال نقض بزنید).

(۴) فرض کنید یک MDP بدون تخفیف (undiscounted) دارای ۳ حالت (۱, ۲, ۳) به ترتیب با پاداش‌های $(1, -2, 0)$ باشد. حالت ۳ یک حالت پایانی است. در حالت‌های ۱ و ۲ دو کنش ممکن وجود دارد: $\{a, b\}$. مدل گذار به صورت زیر است:

- در حالت ۱ کنش a به احتمال $8/10$ عامل را به حالت ۲ منتقل می‌کند و با احتمال $2/10$ عامل را همان‌جا باقی می‌گذارد.
- در حالت ۲ کنش a به احتمال $8/10$ عامل را به حالت ۱ منتقل می‌کند و با احتمال $2/10$ عامل را همان‌جا باقی می‌گذارد.
- در حالت‌های ۱ و ۲ کنش b به احتمال $1/10$ عامل را به حالت ۳ منتقل می‌کند و با احتمال $9/10$ عامل را همان‌جا باقی می‌گذارد.

حال به پرسش‌های زیر پاسخ بدھید:

(الف) به صورت کیفی، چه چیزی در مورد سیاست بهینه در حالت‌های ۱ و ۲ می‌تواند تعیین شود؟

(ب) از الگوریتم تکرار سیاست استفاده کنید و سیاست بهینه را به صورت کمی ارزیابی کنید تا ارزش‌های حالت‌های ۱ و ۲ مشخص شود. فرض کنید سیاست آغازین در هر دو حالت کنش b را در نظر گرفته است.

(ج) اگر سیاست آغازین در هر دو حالت کنش a را در نظر گرفته باشد، با تکرار سیاست چه اتفاقی خواهد افتاد؟ آیا تخفیف (discounting) کمکی می‌کند؟ آیا سیاست بهینه به فاکتور تخفیف بستگی دارد؟


(۵) گاهی اوقات، MDP‌ها با یک تابع پاداش $R(s, a)$ فرمول‌بندی می‌شوند که به کنش انجام شده a در حالت s وابسته است یا با یک تابع پاداش $R(s, a, s')$ که به حالت برآمد s' هم وابسته است.

(الف) معادلات بلمن را برای این فرمول‌بندی‌ها بنویسید.

(ب) نشان دهید که یک MDP با تابع پاداش $R(s, a, s')$ می‌تواند به یک MDP دیگر با تابع پاداش $R(s, a)$ تبدیل شود، به‌گونه‌ای که سیاست‌های بهینه در MDP جدید دقیقاً متضاد با سیاست‌های بهینه در MDP اصلی باشد.

(ج) کار مشابهی را برای تبدیل MDP‌های با $R(s, a)$ به MDP‌های با $R(s)$ انجام بدهید.

(۶) نمودار زیر یک مدل MDP از یک دعوای خیابانی (!) را ترسیم کرده است.



در این دعوا می‌توان بین محل‌های L_1 و L_2 جابه‌جا شد. یکی از این مکان‌ها به حریف نزدیک‌تر است. اگر عامل از نزدیک‌ترین حالت حمله کند، شанс بیشتری برای موفقیت دارد (0.9) (در مقابل 0.7 برای مکان دورتر از حریف). به‌مرحال، ممکن است عامل توسط حریف دیده شود و مضروب شود (با شанс 0.8) (در مقابل شанс 0.5 برای مکان دورتر). اگر عامل در یک مکان بماند (stay) ممکن است توسط حریف دیده شود. عامل نیازمند یک سیاست بهینه برای کنش در این محیط نامطمئن است. در گراف فوق، پیکان‌ها کنش‌های ممکن را نشان می‌دهد (M کنش قطعی حرکت move, A , move کنش تصادفی حمله attack, S attack stay). بر روی یال‌ها (a, p) نوشته شده است (کنش و احتمال گذار حالت). همه‌ی پاداش‌ها در همه‌ی مراحل صفر هستند، به جز حالت‌های پایانی که موفقیت عامل در آن با پاداش $+50$ و موفقیت حریف با پاداش -50 برای عامل ما نشان داده شده است. به استفاده از فاکتور تخفیف $\gamma = 0.9$ سیاست بهینه را محاسبه کنید.

(۷) در این تمرین، MDP‌های دو بازیکن را بررسی می‌کنیم. فرض می‌کنیم بازیکنان A و B باشند. $R(s)$ پاداش برای بازیکن A در s است و پاداش B همیشه قرینه پاداش بازیکن A است (بازی مجموع صفر).

(الف) فرض می‌کنیم $U_A(s)$ سودمندی حالت s زمانی که نوبت A برای حرکت در حالت s است و $U_B(s)$ سودمندی حالت s زمانی که نوبت B برای حرکت در حالت s است. تمام پاداش‌ها و سودمندی‌ها از دیدگاه A محاسبه می‌شوند (درست مانند درخت بازی MINIMAX). معادلات بلمن را با تعریف $U_A(s)$ و $U_B(s)$ بنویسید.

(ب) چگونگی انجام تکرار ارزش دو بازیکن را با این معادلات توضیح دهید و یک معیار مناسب برای توقف بازی ارائه دهید.

(ج) یک بازی دونفره را در نظر بگیرید که بر روی یک صفحه با چهار موقوعیت که از ۱ تا ۴ شماره‌گذاری شده و در طول یک خط قرار گرفته‌اند انجام می‌شود. هر بازیکن یک نشانه دارد. بازیکن A با نشانه‌ی خود از موقوعیت ۱ و بازیکن B با نشانه‌ی خود از موقوعیت ۴ آغاز می‌کند. ابتدا بازیکن A حرکت می‌کند.



این دو بازیکن به نوبت حرکت می‌کنند. هر بازیکن باید نشانه‌ی خود را از یک خانه به فضای خالی موجود در یکی از دو جهت انتقال دهد. اگر رقیب یکی از خانه‌های مجاور را اشغال کرده باشد، بازیکن می‌تواند از روی رقیب پرش کند و در صورت وجود خانه‌ی خالی در محل بعدی قرار گیرد (برای مثال اگر A در ۳ باشد و B در ۲ باشد، آنگاه A می‌تواند به ۱ برسد). بازی وقتی تمام می‌شود که یکی از بازیکن‌ها به موقوعیت مقابل خود بر روی صفحه برسد. اگر بازیکن A ابتدا به فضای ۴ برسد، در این صورت ارزش بازی $1 + \text{اگر بازیکن B ابتدا به فضای ۱ برسد، در این صورت ارزش بازی } 1 - \text{ خواهد بود.}$ فضای حالتی (به جای درخت بازی) را ترسیم کنید که حرکت‌های A را با خطوط ممتد و حرکت‌های B را با خطوط مقطع نشان دهد. هر حالت را با $R(s)$ علامت‌گذاری کنید. مرتب کردن حالت‌های (s_A, s_B) در یک شبکه‌ی دو بعدی با استفاده از مختصات (s_A, s_B) مفید خواهد بود.

(د) الگوریتم تکرار ارزش دو بازیکن را برای حل این بازی به کار بگیرید و سیاست بهینه را استخراج کنید.