نقش یادگیری تفاوت زمانی تخلیص شده با تقریب زننده‌های تابع برای کاهش زمان و هزینه‌های محاسباتی یادگیری تقویتی

جواد عبدی[۱] اعظم فامیل خلیلی[۲] کارولوکس[۱و۳] علی خاکی صدیق[۴]

[۱]گروه مهندسی برق وکامپیوتر دانشکده فنی دانشگاه تهران- تهران - ایران
[۲]گروه مهندسی کامپیوتر دانشکده فنی دانشگاه آزاد اسلامی واحد کرج- کرج - ایران
[۳]مرکز تحقیقات فیزیک نظری ایران -تهران - ایران
[۴] دانشکده مهندسی برق دانشگاه خواجه نصیرالدین‌طوسی- تهران - ایران

چکیده - ترکیب الگوریتم یادگیری تقویتی[۱] با تقریب زننده‌های تابعی[۲] برای تعمیم فضای حالت اخیراً از توجه ویژه‌ای برخوردار شده و به صورت گسترده‌ای این اعتقاد وجود دارد که یکی از موارد تعیین کننده برای سنجش میزان یادگیری تقویتی به قلمروهای جالب عملی، است. این مقاله ترکیب دستورالعمل TTD، یک پیاده‌سازی تقریبی مؤثر محاسباتی از روش‌های $TD(\lambda)$ با $CMAC$، یک تقریب‌گر تابع به ویژه مناسب برای یادگیری تقویتی درخور کارآیی محاسباتی آن و توانایی یادگیری پیوسته را مورد بررسی قرار می‌دهد. اکثر مطالعات قبلی ترکیب $CMAC$ با الگوریتم‌های براساس $TD(0)$ که معمولاً برای $\lambda > 0$ یادگیری بسیار آهسته‌تر صورت می‌گیرد، یا با پیاده‌سازی مرسوم $TD(\lambda)$ که بر اساس آثار صلاحیت است به همراه هزینه‌های محاسباتی بالا مورد بررسی قرار داده‌اند. مطالعه فعلی، سعی دارد علاوه بر معرفی کامل روش TTD برای کاهش هزینه‌های محاسباتی، با ترکیب $CMAC$ و TTD یادگیری سریع با کارآیی محاسباتی و توانمندی‌های تعمیمی را بیان کند. نتایج تجربی ارائه شده، عملکرد موفقیت‌آمیز الگوریتم یادگیری Q را که با استفاده از دستورالعمل TTD و $CMAC$ در دو کار با فضاهای حالت پیوسته پیاده‌سازی شده‌اند، را نشان می‌دهد.

کلید واژه: یادگیری تقویتی، یادگیری تفاوت زمانی[۳]، تفاوت زمانی تخلیص شده[۴]، پاداش، تقریب، عامل‌های یادگیر، بروزآوری

۱- مقدمه

الگوریتم‌های یادگیری تقویتی [7][13][8] بر مبنای روش‌های تفاوت زمانی [14] در مورد تعامل اصلی این موضوع بین عامل یاد گیرنده و محیط پیرامونی او بکار

[1] Reinforcement Learning (RL)
[2] Function Approximators
[3] Temporal Difference (TD)
[4] Truncated Temporal Difference (TTD)

می‌رود. در هر گام زمانی t، عامل حالت فعلی محیط، x_t، را مشاهده می‌کند و عمل a_t را انجام می‌دهد. سپس یک ارزش یا پاداش تقویتی r_t دریافت می‌دارد، و حالت محیط به x_{t+1} تغییر می‌یابد. منظور از یادگیری شناخت بدون هیچ دانش قبلی از محیط است، یک سیاست تصمیم‌گیری (به عنوان مثال، یک ترسیم از حالات به عمل‌ها) که منجر به افزایش مقدار تنزیل داده شدهٔ تقویت، که عامل در طول دورهٔ زندگی‌اش دریافت می‌نماید، می‌گردد.

$$E\left[\sum_{t=0}^{\infty}\gamma^t r_t\right] \qquad (۱)$$

که در آن $\gamma \in [0,1]$ یک عامل تنزیل است که اهمیت نسبی پاداش‌های بلند مدت را نسبت به پاداش‌های کوتاه مدت تنظیم می‌کند.

۲- الگوریتم‌های بر مبنای الگوریتم یادگیری TD

گسترده‌ترین مطالعات الگوریتم‌های یادگیری تقویتی بر اساس روش تفاوت زمانی ساتن[1] [14]، $TD(\lambda)$ است. این الگوریتم‌ها الزاماً به یادگیری توابع مقدار معین از حالت‌ها یا زوجی از حالت-عمل متکی هستند که کاربرد آنها را نسبت به پاداش‌های تنزیلی آینده برآورد می‌نماید. سیاست عامل یا مطلقاً از این ارزیابی‌ها استخراج می‌شود و یا قطعاً و صراحتاً از طریق یک تابع خط مشی ارائه می‌گردد. قاعده عمومی یادگیری تقویتی بر مبنای TD ممکن بصورت زیر نوشته شود:

$$update^{\beta}\left(U, x_t, r_t + \gamma U_t(x_{t+1}) - U_t(x_t)\right) \qquad (۲)$$

که U تابع کاربرد حالت است که به هر حالت، x یک برآورد از مقدار تنزیل داده شدهٔ تقویت دریافت شده که از حالت x شروع و سیاست جاری را دنبال می‌نماید. به ویژه آنکه، $U(x_t)$ برای پیش‌بینی مجموع تنزیلی پاداش‌های آتی مورد نظر می‌باشد.

$$z_t = \sum_{k=0}^{\infty}\gamma^k r_{t+k} \qquad (۳)$$

که برگشت TD برای زمان t نامیده می‌شود. علائم بروزرسانی که در معادله (۲) بکار رفته است، به این معنی است که مقدار تابع U برای بحث x_t می‌بایست با استفاده از مقدار خطا که در فرمول (۴) نشان داده شده است، تنظیم گردد. یعنی، به طرف $U_t(x_t)+\Delta$، به یک درجه‌ای که توسط یک نرخ یادگیری β کنترل می‌شود، کشیده شود.

$$\Delta = r_t + \gamma U_t(x_{t+1}) - U_t(x_t) \qquad (۴)$$

$$update^{\beta}\left(Q, x_t, a_t, r_t + \gamma \max_a Q_t(x_{t+1}, a) - Q_t(x_t, a_t)\right) \qquad (۵)$$

که در آن مقدار Q نسبت داده شده به هر زوج حالت-عمل (x,a)، به منظور پیش‌بینی مقدار تنزیل داده شدهٔ تقویت دریافت شده بعد از اجرای عمل a در حالت x و سپس تعقیب یک سیاست حریصانه برای رسیدن به مقادیر Q فعلی. وقتی که مقادیر Q بهینه یاد گرفته شود، یک سیاست حریصانه در ارتباط با آنها، یک سیاست بهینه است.

در واقع، قانون عمومی ارائه شده در معادله (۲) با ساده‌ترین شکل روش‌های تفاوت زمانی $TD(0)$ مطابقت دارد. برای مقادیر کلی از ضریب λ جدید قانون به روز آوری $TD(\lambda)$، برای هر حالت x در گام زمانی t توسط فرمول زیر اعمال می‌شود:

$$update^{\beta}\left(U, x, \left(r_t, \gamma U_t(x_{t+1}) - U_t(x_t)\right)e_x(t)\right) \qquad (۶)$$

که در آن:

$$e_x(t) = \sum_{k=0}^{t}(\gamma\lambda)^{t-k}\chi_x(k) \qquad (۷)$$

مقدار اثر شایستگی[2] [3][11] برای هر حالت x در زمان t و $\chi_x(t)$ مساوی ۱ است اگر $x = x_t$ و در غیر اینصورت صفر باشد. آثار شایستگی برای تمام حالات در هر

[1] Sutton

[2] Eligibility Traces

گام زمانی بر طبق قاعده به روزآوری زیر، بروز[1] می‌گردند:

$$e_x(t) = \gamma\lambda e_x(t-1) + \chi_x(t) \xrightarrow{e_x(0)=\chi_x(0)} update^{\beta}(U, x, (r_t + \gamma U_t(x_{t+1}) - U_t(x_t))e_x(t)) \quad (۸)$$

که در آن به صورت قراردادی $e_x(0) = \chi_x(t)$ می‌باشد.

توجه داشته باشید که برای $\lambda = 0$ فقط یک حالت x_t در گام زمانی t مقدار غیر صفر دارد و معادله شماره (۶) به معادله (۲) خلاصه می‌شود. برای λ مثبت، فرد می‌بایست در هر گام زمانی پیش‌بینی‌ها و آثار شایستگی را برای تمام حالات بروز در آورد. به همین دلیل است که این پیاده‌سازی با استفاده از $\lambda > 0$ از نظر محاسباتی بسیار گرانتر از وقتی که $\lambda = 0$ مورد استفاده قرار می‌گیرد می‌باشد، به ویژه برای کارهایی با فضای حالت بزرگتر. در هر صورت، استفاده از λ مثبت اغلب به یادگیری منجر می‌گردد که به صورت قابل ملاحظه‌ای سریعتر است. [15][14][8] تکنیک ساده‌تری بنام رویه TTD وجود دارد [6] که استفاده از λ عمومی با هزینه‌های محاسباتی پایین را میسر می‌نماید. این تکنیک به اختصار در بخش ۳ توضیح داده خواهد شد.

۳- استفاده از تقریب زننده‌های تابع

برای پیاده‌سازی هر الگوریتم یادگیری تقویتی بر مبنای تفاوت زمانی، فرد می‌بایست تعدادی روش ارائه تابع را انتخاب نموده و تابع بروزآوری را بطور مناسب تعریف نماید. ساده‌ترین انتخاب یک ارائه فهرست‌وار است که مقادیر تابع در یک جدول جستجو[2] ذخیره می‌شود و برای هر مقدار یک مدخل مجزا وجود دارد. به روز رسانی مقدار Q برای حالت x و عمل a با مقدار خطای Δ و میزان یادگیری β به سادگی به صورت زیر پیاده‌سازی می‌شود.

$$Q(x,a) := Q(x,a) + \beta\Delta \quad (۹)$$

اکثر نتایج نظری مربوط به همگرایی الگوریتم‌های یادگیری تقویتی یک ارائه فهرست‌وار را فرض می‌کنند، ولی این شیوه برخی وقفه‌های عملی مهم را نیز دارد. شیوه ارائه جدولی به سختی باری کارهایی با فضاهای حالت بزرگ کاربرد دارد، نه تنها به خاطراحتیاجات حافظه‌ای فزاینده بلکه اول از همه، برای زمان بسیار طولانی برای همگرایی. برای کارهایی با فضاهای حالت پیوسته، این ارائه به هیچ وجه به طور مستقیم کاربرد ندارد.

باور عمومی بر آنست که استفاده از روش‌های تقریب تابع به منظور نمایش تابع‌های مقدار در الگوریتم‌های RL نه تنها ممکن است حافظه را ذخیره کند بلکه تعمیم بر فضای حالت را نیز میسر می‌نماید و بنابراین کاربرد موفق این الگوریتم‌ها در کارهای بزرگ را ممکن می‌سازد. نتایج نظری اخیری وجود دارد که درک ما از مزایای بالقوه و محدودیت‌های استفاده از تقریب تابع برای یادگیری تقویتی را بهبود می‌بخشد. [16][12][7][2] همچنین تعدادی مطالعات تجربی با ترکیب‌های یادگیری تقویتی و چندین تقریب زننده تابع، شامل شبکه پرسپترون چند لایه [8]تقریب زننده‌های بر مبنای حافظه، [11] یا $CMAC$ [17][15]، که هم موفقیت آمیز و هم ناامید کننده بوده‌اند، وجود داشته است. از تعداد زیادی تقریب زنندهٔ آزمایش شده با Rl تا این زمان، $CMAC$ به علت سرعت یادگیری بالای آن، کارآئی محاسباتی و توانائی یادگیری پیوسته، بطور ویژه‌ای مورد توجه قرار گرفته است. این مسئله در بخش ۴ به اختصار توضیح داده می‌شود و در ترکیب با دستورالعمل TTD در آزمایش‌های ارائه شده در بخش ۵ مورد استفاده قرار می‌گیرد.

۴- تفاوت‌های زمانی تخلیص شده

این قسمت به تفصیل توضیح می‌دهد که چگونه رویه TTD می‌تواند از یک فرمولاسیون متفاوت $TD(\lambda)$ مشتق شود و چگونه می‌تواند برای پیاده‌سازی الگوریتم‌های یادگیری

[1] Update
[2] Lookup Table

تقویت شده بر مبنای TD بکار برده شود. همچنین تحلیل ساده‌ای از مزایای کارآیی محاسباتی آن در مقایسه با اثرهای شایستگی مطرح می‌شود. [18][6]

۴-۱-خطاهای TD و بازگشت‌های TD

اگر یک رشته از حالت‌ها را به صورت $x_0, x_1, ..., x_k, ...$ و همچنین مقادیر سیگنال تقویت نسبت داده شده به آنها را به ترتیب به صورت $r_0, r_1, ..., r_k, ...$ در نظر بگیریم، و با توجه به فرمول تعمیم یافته (٤)، برای حالت x_t می‌توان نوشت:

$$\begin{aligned}\Delta_x &= \sum_{t=0}^{\infty}\Delta_x(t)\\ &= \sum_{t=0}^{\infty}\left\{\left(r_t+\gamma U_t(x_{t+1})-U_t(x_t)\right)\sum_{t=0}^{\infty}(\gamma\lambda)^{t-k}\chi_x(k)\right\}\end{aligned} \quad (۱۰)$$

و

$$\begin{aligned}\Delta_{xt} &= r_t+\gamma U_t(x_{t+1})-U_t(x_t)+\\ &= \gamma\lambda\left[r_{t+1}+\gamma U_{t+1}(x_{t+2})-U_{t+1}(x_{t+1})\right]\\ &= (\gamma\lambda)^2\left[r_{t+2}+\gamma U_{t+2}(x_{t+3})-U_{t+2}(x_{t+2})\right]+...\\ &= \sum_{k=0}^{\infty}(\gamma\lambda)^{t-k}\left(r_{t+k}+\gamma U_{t+k}(x_{t+k+1})-U_{t+k}(x_{t+k})\right)\end{aligned} \quad (۱۱)$$

اگر یک حالت چندین مرتبه در دنباله اتفاق بیافتد، هر حالت تکراری به یک صورت مشابه بروز می‌شود. این مشاهدهٔ ساده راهی به سوی فرمولاسیون تناوبی $TD(\lambda)$ می‌گشاید که امکانات پیاده‌سازی جدیدی را میسر می‌سازد.

با فرض:

$$\Delta_t^0 = r_t+\gamma U_t(x_{t+1})-U_t(x_t) \quad (۱۲)$$

در فرمول (۱۲) خطای $TD(0)$ در گام زمانی t نشان داده شده است.

خطای $TD(\lambda)$ در زمان t با استفاده از خطاهای $TD(0)$ به صورت زیر تعریف می‌شود:

$$\begin{aligned}\Delta_t^\lambda &= \sum_{k=0}^{\infty}(\gamma\lambda)^k\left[r_{t+k}+\gamma U_{t+k}(x_{t+k+1})-U_{t+k}(x_{t+k})\right] \quad (۱۳)\\ &= \sum_{k=0}^{\infty}(\gamma\lambda)^k\Delta_{t+k}^0\end{aligned}$$

همان طوری که در [5][18] نشان داده شده، مجموع خطای $TD(\lambda)$ برای حالت x بر حسب خطاهای Δ_t^λ به صورت زیر بیان می‌شود:

$$\sum_{t=0}^{\infty}\Delta_x(t) = \sum_{t=0}^{\infty}\Delta_t^\lambda\chi_x(t) \quad (۱۴)$$

بنابراین $\Delta_t(t)$ در هر گام زمانی t برای هر x محاسبه، و برای بروزرسانی $U(x)$ به ازای هر x بکار برده می‌شود، و Δ^λ در هر گام زمانی t فقط برای x_t محاسبه می‌شود و فقط برای تعیین $U(x_t)$ بکار برده می‌شود، تاثیرات کلی استفاده از این دو فرم از خطاهای TD یکسان هستند.

بازگشت $TD(\lambda)$ برای زمان t به صورت زیر تعریف می‌شود: [17]

$$\begin{aligned}z_t^\lambda &= (1-\lambda)\sum_{k=0}^{\infty}\lambda^k z_t^{(k+1)} \quad (۱۵)\\ &= \sum_{k=0}^{\infty}(\gamma\lambda)^k\left[r_{t+k}+\gamma(1-\lambda)U_{t+k}(x_{t+k+1})\right]\end{aligned}$$

مجموع پاداش فوری[1] و فایده پیش‌بینی شدهٔ تنزیل حالت جانشین برای $\lambda=0$ ساده است. برای $\lambda=1$ بازگشت TD معمول، مجموع تنزیل کلی تقویت، برقرار است. استفاده از λ در بازهٔ $0<\lambda<1$ اجازه می‌دهد که به آسانی بین این دو حد تعریف شود. باید به خاطر داشت که تعریف بالا ممکن است به طور بازگشتی به صورت زیر نیز بیان شود:

$$z_t^\lambda = r_t+\gamma\left(\lambda z_{t+1}^\lambda+(1-\lambda)U_t(x_{t+1})\right) \quad (۱۶)$$

واضح است که اگر اندیس‌های زمان حذف شود، خواهیم داشت:

$$\Delta_t^\lambda = z_t^\lambda - U(x_t) \quad (۱۷)$$

[1] Immediate Reward

این معادله نشان می‌دهد که چگونه در یادگیری بازگشت‌های $TD(\lambda)$ می‌توانند به جای خطاهای $TD(\lambda)$ به کار روند. این تنها برای حالت یادگیری دسته[1] درست می‌شود، اما در واقع هدف اصلی یادگیری تقویتی مبتنی بر TD، انعکاس پیش بینی درست بازگشت‌های TD می‌باشد.

۴-۲- بازگشت‌های $TD(\lambda)$ تلخیص شده

متاسفانه در عمل تا زمانی که بازگشت‌های $TD(\lambda)$ موجود نیستند، مشاهدهٔ شرح داده شده در فرمول (۱۷) نمی‌تواند مستقیماً بکار برده شود. در [5] پیشنهاد شده است که آنها را با بازگشت‌های $TD(\lambda)$ تلخیص شده به صورت زیر تقریب بزنند:

$$\begin{aligned} z_t^{\lambda,m} &= \sum_{k=0}^{m-2}(\gamma\lambda)^k\left[r_{t+k}+\gamma(1-\lambda)U_{t+k}(x_{t+k+1})\right] \\ &\quad +(\gamma\lambda)^{m-1}\left[r_{t+m-1}+\gamma U_{t+m-1}(x_{t+m})\right] \\ &= \sum_{k=0}^{m-1}(\gamma\lambda)^k\left[r_{t+k}+\gamma(1-\lambda)U_{t+k}(x_{t+k+1})\right] \\ &\quad +(\gamma\lambda)^m U_{t+m-1}(x_{t+m}) \end{aligned} \qquad (۱۸)$$

که، $z_t^{\lambda,m}$، بازگشت $TD(\lambda)$ مختصر شدهٔ m مرحله‌ای یا بازگشت $TTD(\lambda,m)$ در زمان t نامیده می‌شود. باید به خاطر داشت که $z_t^{\lambda,m}$ تعریف شده توسط فرمول (۱۸) تصحیح شده است، بعنوان مثال $z_t^{\lambda,m}$ را نمی‌توان به آسانی از فرمول مختصر شدهٔ (۱۵) بدست آورد. اصطلاح تصحیح شدهٔ $(\gamma\lambda)^m U_{t+m-1}(x_{t+m})$ منجر به ضرب شدن آخرین پیش‌بینی $U_{t+m-1}(x_{t+m})$ در γ، به جای ضرب شدن در $\gamma(1-\lambda)$، می‌شود که بطور مجازی معادل استفاده از $\lambda=0$ برای آن مرحله است، و به همین ترتیب $U_{t+m-1}(x_{t+m})$ برای گام‌های زمانی $(t+m,t+m+1,\ldots)$ محاسبه می‌شود. بدون این تصحیح برای $\gamma(1-\lambda)$های بزرگ، این اطلاعات تقریباً دست نیافتنی بودند.

۴-۳- رویه TTD

همانطور که توضیح داده شد، خطاهای $TD(\lambda)$ تلخیص شدهٔ m مرحله‌ای، بوسیله پیگیری آخرین m حالت ملاقات شده و بروزرسانی فایده پیش‌بینی شدهٔ آخرین حالت یک بافر تجربهٔ m-عنصری حاصل شده با رکوردهای $\langle x_{t-k}, a_{t-k}, r_{t-k}, U_{t-k}(x_t-k+1)\rangle$ است که برای همگی آنها $k=0,1,\ldots,m-1$ و t گام زمانی جاری است.

در هر گام t با نوشتن $r_{[k]}, a_{[k]}, x_{[k]}$ به عناصر مورد نظر بافری که x_{t-k}، a_{t-k}، r_{t-k} و $U_{t-k}(x_t-k+1)$ را ذخیره کرده، رجوع می‌شود. ارجاع‌های U با گام‌های زمانی اندیس گذاری نشده‌اند، چون همگی آنها مقادیر موجود در هر گام زمانی جاری را نشان می‌دهند. با این توضیحات، عملکرد رویهٔ $TTD(\lambda,m)$ در نمودار (۱) نشان داده شده است.

نمودار ۱: رویه دستورالعمل $TTD(\lambda,m)$

در هر گام زمانی t

۱) حالت فعلی x_t مشاهده می‌شود؛ $x_{[0]} := x_t$

۲) یک عمل a_t برای حالت x_t انتخاب می‌شود.

$a_{[0]} := a_t$

۳) عمل a_t انجام می‌شود، حالت جدید x_{t+1} پاداش فوری r_t را حاصل می‌کند.

۴) $r_{[0]} := r_t; u_{[0]} := U(x_{t+1})$

۵) $z := ttd\_return(0)$

۶) $update^{\beta}\left(U, x_{[m-1]}, a_{[m-1]}, z-U(x_{[m-1]})\right)$ بروزآوری.

۷) اندیس‌های بافر تجربه جابجا می‌شود.

[1] Batch Learning Mode

در ابتدای یادگیری، قبل از اینکه اولین m گام‌ها بوجود آید، هیچ یادگیری نمی‌تواند اتفاق بیافتد. در جریان گام‌های اولیه عملکرد رویهٔ TTD برای بروز کردن محتویات بافر تجربه به نحوی شایسته، کاهش می‌یابد.

در نمودار (۱) برای سادگی کار از این جزئیات تکنیکی چشم‌پوشی شده است و در ادامه نیز از آنها صرف نظر شده است.

۴-۳-۱- محاسبات بازگشت TTD

عملکرد مرحله ۵ الگوریتم، یعنی $ttd\_return(k_0)$، بازگشت TTD را در زمان $t-m+1$، بر مبنای محتویات ذخیره شده در بافر تجربه با اندیس‌های از k_0 تا $m-1$، محاسبه می‌کند. نمودار (۱)، مقدار $k_0=0$ را بکار می‌برد. اما همانطور که بعداً دیده می‌شود در بعضی موارد $k_0>0$ نیز نیاز است.

در [5] دو روش برای اجرای این محاسبه پیشنهاد شده است، یکی روش تناوبی ساده و دیگری روش فزاینده‌ای، که از نظر محاسباتی کار آمدتر است. روش تناوبی بر مبنای کاربردهای تکراری فرمول (۱۶) است:

For $k=k_0,k_0+1,...,m-1$ do
if $k=k_0$ then $z:=r_{[k]}+\gamma u_{[k]}$
else $z:=r_{[k]}+\gamma\left(\lambda z+(1-\lambda)u_{[k]}\right)$

هزینهٔ محاسباتی چنین تکثیری، در صورت بازگشت بموقع، برای مقادیر منطقی m قابل قبول است. برای بعضی از روش‌های ارائه تابع، مثل شبکه‌های عصبی، رویهمرفته پیچیدگی زمانی در مقابل هزینه‌های بازیابی و بروزرسانی مقدار یک تابع که در مرحلهٔ ٤ و ٦ انجام می‌شود، و همچنین هزینهٔ محاسباتی z قابل صرف‌نظر کردن است.

برای نشان دادن چگونگی انجام این محاسبه به طور فزاینده، تعریف بازگشت TTD (فرمول (۱۸)) به دو قسمت تقسیم می‌شود:

$$z_t^{\lambda,m}=S_t^{\lambda,m}+T_t^{\lambda,m}+W_t^{\lambda,m} \qquad (۱۹)$$

که

$$\begin{aligned} S_t^{\lambda,m}&=\sum_{k=0}^{m-1}(\gamma\lambda)^k r_{t+k}\\ T_t^{\lambda,m}&=\sum_{k=0}^{m-2}(\gamma\lambda)^k\gamma(1-\lambda)U_{t+k}(x_{t+k+1}) \qquad (۲۰)\\ W_t^{\lambda,m}&=(\gamma\lambda)^{m-1}\gamma U_{t+m-1}(x_{t+m}) \end{aligned}$$

که $W_t^{\lambda,m}$ می‌تواند مستقیماً برای هر mای در زمان ثابت محاسبه شود. لذا کاملاً مفروض است که:

$$\begin{cases} S_{t+1}^{\lambda,m}=\dfrac{1}{\gamma\lambda}\left[S_t^{\lambda,m}-r_t+(\gamma\lambda)^m r_{t+m}\right]\\ T_{t+1}^{\lambda,m}=\dfrac{1}{\gamma\lambda}\left[T_t^{\lambda,m}-\gamma(1-\lambda)\left(U_t(x_{t+1})-W_{t+1}^{\lambda,m}\right)\right] \end{cases} \qquad (۲۱)$$

فرمول فوق الگوریتم محاسبهٔ فزایندهٔ $S_t^{\lambda,m}$ و در نتیجه محاسبهٔ $z_t^{\lambda,m}$ در زمان ثابت (کوچک) برای هر m دلخواه را توضیح می‌دهد. این الگوریتم از نظر ریاضی کاملاً معادل روش تناوبی نشان داده شده در بالا، است.[1]

TTD فزاینده امکان استفاده $TD(\lambda>0)$ را با هزینه‌ای کاملاً برابر هزینهٔ محاسباتی $TD(0)$، ممکن می‌سازد.

۴-۳-۲- انتخاب m

انتخاب منطقی m، به وضوح به λ بستگی دارد. برای $\lambda=0$ بهترین امکان $m=1$ است و برای $\lambda=1$ و $\gamma=1$ هیچ مقدار محدودی از m وجود ندارد که برای تقریب زدن دقیق $TD(\lambda)$ به اندازه کافی بزرگ باشد. خوشبختانه، نتایج عملی موجود گذشته در مورد $TD(\lambda)$ نشان می‌دهد که معمولاً $\lambda=1$ مقدار بهینه‌ای برای استفاده نیست. [8][14][17][19]

[1] ضرورتاً از حیث عددی معادل نیستند، زیرا ممکن است در بعضی پیاده سازی‌های عملی ایجاد مشکل کند.

برای $\lambda<1$ یا $\gamma<1$ ترجیحاً مقداری از m مورد نظر است که تنزیل $(\gamma\lambda)^m$، عدد کوچکی شود. یک تعریف ممکن از کوچک این است که مثلاً کمتر از $\gamma\lambda$ باشد. جدول (۱) تاثیرات تجربی این ابتکار را نشان می‌دهد. این معیار غیر رسمی کاملی است اما مطالعات عملی [20][18][5] نشان داد که حتی mهای نسبتاً کوچک نیز خوب عمل می‌کنند. از طرفی دیگر، mهای خیلی بزرگ ممکن است برای تعریف وقفه‌های طولانی بین تجربه و یادگیری بکار برده شوند که اثرات زیان باری در پی خواهد داشت اگر چه این پدیدهٔ خارق العاده تا حالا مشاهده نشده است.

در قسمت مطالعات تجربی مقادیر مختلف m برای λ در بازه صفر تا یک مورد ارزیابی قرار گرفته است.

جدول ۱: *انتخاب m : یک ارائه*

$\gamma\lambda$	0.99	0.975	0.95	0.9	0.8	0.6
$\min\left\{m \mid (\gamma\lambda)^m < \frac{1}{10}\gamma\lambda\right\}$	231	92	46	23	12	6

۴-۳-۳- عملیات راه اندازی مجدد

در فعالیت‌های پراکنده[۱] [13] و بسیاری فعالیت‌های دنیای واقعی، بعضی زمان‌های یادگیری باید متوقف شود و این امر ضرورت طراحی یک مکانیزم ویژه برای رویه TTD را اجباری می‌کند، که عملیات راه اندازی مجدد نامیده می‌شود. عملیات راه اندازی مجدد در پایان هر رویداد از رویدادهای نامنظم، یا بعد از اتمام یادگیری فراخوانده می‌شود.

تنها مساله‌ای که باید مورد بحث قرار گیرد این است که بافر تجربه شامل ذخیره‌ای از m مرحلهٔ آخر است که هنوز یادگیری برای آنها انجام نشده و نیز هیچ مرحلهٔ دیگری هم وجود نخواهد داشت که یادگیری را برای مراحل باقیمانده ممکن سازد. راه حل واضح این است که m مرحلهٔ خیالی اضافی را به طریقی که یادگیری را برای تمام مراحل واقعی باقی مانده در بافر و بازگشت‌های TTDای که تحت تاثیر مراحل خیالی شبیه‌سازی شده قرار نگرفته‌اند، ممکن است، شبیه‌سازی نمود.

الگوریتم مورد نظر، که در نمودار (۲) نشان داده شده است به عنوان جانشینی برای الگوریتم اصلی نمودار (۱) برای گام زمانی پایانی، فرموله شده است.

نمودار ۲: راه‌اندازی مجدد برای رویه دستورالعمل $TTD(\lambda, m)$

در گام زمانی پایانی t:

۱) حالت فعلی x_t مشاهده می‌شود؛ $x_{[0]} := x_t$

۲) یک عمل a_t برای حالت x_t انتخاب می‌شود. $a_{[0]} := a_t$

۳) عمل a_t انجام می‌شود، حالت جدید x_{t+1} پاداش فوری r_t را حاصل می‌کند.

٤) $r_{[0]} := r_t ; u_{[0]} := U(x_{t+1})$

٥) برای $k = 0,1,..., m-1$ انجام می‌دهد:

الف) برای $k = k_0, k_0+1,..., m-1$ انجام می‌دهد:

اگر $k = k_0$ پس $z := r_{[k]} + \gamma u_{[k]}$

دیگر $z := r_{[k]} + \gamma\left(\lambda z + (1-\lambda)u_{[k]}\right)$

ب) $update^{\beta}\left(U, x_{[m-1]}, a_{[m-1]}, z - U(x_{[m-1]})\right)$

ج) اندیس‌های بافر تجربه جابجا می‌شود.

[۱] episodic

۴-۳-۴- اقتصاد محاسباتی

این بخش تحلیل ساده‌ای از پس اندازهای محاسباتی با استفاده از رویه TTD، در مقایسه با اثر شایستگی ارائه می‌کند. هزینه عملیات یک مرحله‌ای پیاده‌سازی اثرات شایستگی $TD(\lambda)$ که در فرمول (۸) تعریف شد و همچنین الگوریتم TTD پایه‌ای در نمودار (۱) نشان داده شده است. تحلیل ارائه شده به طور مناسب می‌تواند برای هر الگوریتم یادگیری تقویتی بر مبنای TD پیاده‌سازی شود. معمولاً فرض می‌شود که از یک ارائه تابعی جدولی[۱] استفاده می‌شود، هر چند که ممکن است بعضی نتایج برای دیگر ارائه‌ها نیز بخوبی معتبر باشند.

نمادهای زیرین برای تعیین هزینه‌های عملیات‌های اصلی بکار برده می‌شوند.

c_+ هزینه عملیات‌های افزودنی

c_* هزینهٔ عملیات‌های صفر

c_r هزینهٔ ذخیره‌سازی مقدار یک تابع

c_u هزینهٔ بروزرسانی مقدار یک تابع

و نماد N نشان دهندهٔ سایز مؤثر فضای حالت است، مثلاً تعداد کل حالت‌های متمایز که برای فواید پیش‌بینی شده یاد گرفته شده‌اند[۲].

فرض، که از یک λ با مقدار ثابت استفاده می‌شود، این امر باعث ایجاد زیر عبارت‌هایی مثل $\gamma\lambda$ یا $\gamma(1-\lambda)$ می‌شود که می‌توانند از قبل محاسبه شوند و سپس به عنوان مقادیر ثابت بکار برده شوند. برای سادگی کار، از هزینه‌های عملیات‌های اختصاص دادن‌ها و مقایسه‌ها صرف نظر می‌شود.

پیاده‌سازی اثرات شایستگی مستلزم این است که عملیات‌های زیر در هر مرحله انجام شوند:

۱) بروزرسانی اثرات شایستگی در هر حالت،

۲) ذخیره‌سازی بازیابی فواید پیش‌بینی شده حالت جاری و جانشین‌های آن،

۳) محاسبه مقدار خطای $TD(0)$ جاری،

٤) بروزرسانی فواید پیش بینی شده تمام حالت‌های با اثرات شایستگی غیر صفر، یعنی در بدترین حالت، تمام n حالت را بروز نماید[۱]. هزینه‌های این عملیات‌ها به ترتیب عبارتند از: $(N-1)c_* + c_* + c_+$ ، $2c_r$ ، $2c_+ + c_*$ ، و $N(c_+ + c_u)$ ، که روی هم رفته هزینه بدبینی پیاده‌سازی اثرات شایستگی در هر مرحله برابر خواهد شد با:

$$\begin{aligned} C(\mathrm{ET}) &= [(N-1)c_* + c_* + c_+] + 2c_r \\ &\quad + [2c_+ + c_*] + N(c_* + c_u) \\ &= 3c_+ + (2N+1)c_* + 2c_r + Nc_u \end{aligned} \qquad (۲۲)$$

رویه TTD در هر مرحله فایده پیش‌بینی شدهٔ حالت فعلی را ذخیره‌سازی می‌کند، بازگشت‌های $TD(\lambda)$ مختصر شده را محاسبه می‌کند. فایده پیش‌بینی شدهٔ آخرین حالت در بافر تجربه را ذخیره‌سازی می‌کند. خطای TTD آن حالت را بصورت اختلاف بازگشت TTD و فایده آن حالت محاسبه می‌کند، و در نهایت فایده پیش بینی شدهٔ آن حالت را بروز می‌کند.

طبق الگوریتم تناوبی ساده، هزینهٔ محاسبه بازگشت TTD برابر است با $c_+ + c_* + (m-1)(2c_+ + 2c_*)$ و هزینه‌های باقی عملیات‌ها به ترتیب عبارتند از: c_r، c_+ و c_u.

بنابراین هزینه کلی در رویه تناوبی TTD در هر گام زمانی برابر است با:

$$\begin{aligned} C(\mathrm{TTD}_{\mathrm{iter}}) &= [c_+ + c_* + (m-1)(2c_+ + 2c_*)] \\ &\quad + c_r + c_r + c_+ + c_u \\ &= 2mc_+ + (2m-1)c_* + 2c_r + c_u \end{aligned} \qquad (۲۳)$$

---

[۱] Tabular Function

[۲] در واقع سایز فضای حالت است اما برای فضاهای حالت پیوسته، N ممکن است نشان دهندهٔ تمامی نواحی باشد که فضای حالت از طریق کوانتیزاسیون به آنها تقسیم شده است. در صورتیکه پیش‌بینی‌های در یک شبکه عصبی ذخیره شده باشند، N، تعداد وزنهای شبکه است.

استفاده از روش افزایشی برای محاسبه بازگشت TTD می‌تواند هزینه محاسباتی رویه TTD را کاهش دهد. در این روش هزینهٔ محاسبهٔ بازگشت TTD در هر مرحله برابر است با مجموع $3c_* + 4c_+$ (که عبارت $S_t^{\lambda,m}$ را بروز می‌کند)، c_* (که عبارت $T_t^{\lambda,m}$ را بروز می‌کند)، و c_+ (جمع دو عبارت). پس هزینهٔ کلی TTD به صورت زیر خواهد شد:

$$\begin{aligned} C(\mathrm{TTD}_{\mathrm{iter}}) &= c_r + [3c_* + 4c_+ + c_* + c_+] \\ &\quad + c_r + c_+ + c_u \\ &= 6c_+ + 4c_* + 2c_r + c_u \end{aligned} \qquad (۲۴)$$

که دیگر به m بستگی ندارد.

با کلی ساده سازی بیشتر و جایگزینی تمام هزینه‌های مقدماتی با مقدار ثابت c_*، خواهیم داشت:

$$C(\mathrm{ET}) = (3N+6)c \qquad (۲۵)$$

$$C(\mathrm{TTD}_{\mathrm{iter}}) = (4m+2)c \qquad (۲۶)$$

$$C(\mathrm{TTD}_{\mathrm{iner}}) = 13c \qquad (۲۷)$$

پس، روش تناوبی رویهٔ TTD از نظر محاسباتی ارزانتر از پیاده‌سازی اثرات شایستگی است، اگر و تنها اگر:

$$4m+2 < 3N+6 \equiv m < \frac{3}{4}N + 1 \qquad (۲۸)$$

در TTD افزایشی شرط متناظر به صورت زیر خواهد بود:

$$13 < 3N+6 \equiv N > \frac{7}{3} \qquad (۲۹)$$

برای رسیدن به تخمین واقع بینانه‌تر، فرض می‌شود که: $c_* = 5c$، $c_+ = c$، $c_r = c_+ = c$ و $c_u = c_* + c_+ = 6c$ بدین ترتیب:

$$C(\mathrm{ET}) = (16N+10)c \qquad (۳۰)$$

$$C(\mathrm{TTD}_{\mathrm{iter}}) = (12m+3)c \qquad (۳۱)$$

$$C(\mathrm{TTD}_{\mathrm{iner}}) = 34c \qquad (۳۲)$$

و هزینه‌های TTD کمتر از هزینه‌های TTD کمتر از هزینه‌های اثرات شایستگی است اگر و تنها اگر، در روش تناوبی،

$$12m+3 < 16N+10 \equiv m < \frac{4}{3}N + \frac{7}{12} \qquad (۳۳)$$

و در روش افزایشی،

$$34 < 16N+10 \equiv N > \frac{3}{2} \qquad (۳۴)$$

در فعالیت‌های واقعی‌تر می‌توان انتظار داشت که $m << N$. یعنی شرایط داده شده در فرمول (۲۹) یا (۳۱) باید همراه برقرار باشند، یعنی حتی ساده‌ترین رویهٔ TTD تناوبی باید کار آمدتر از اثرات شایستگی باشد. هر چند در حالت‌های قطعی، این شرایط ممکن است معتبر نباشند. آنها از این فرض ساده‌سازی مشتق شده‌اند که تمام N حالت در هر مرحله مقادیر اثرات شایستگی غیر صفر دارند و این بطور آشکارا خیالی است، البته مواقعی وجود دارد که تنها n حالت با اثرات شایستگی غیر صفر وجود دارد که $n << N$. اگر $n \approx m$ باشد، مزیت کارآیی TTD تناوبی بدیهی نخواهد بود.

باید بخاطر داشت که هزینهٔ تابعی که عملیات را بروز می‌کند، c_u، در عمل ممکن است خیلی بزرگتر از هزینه‌های عملیات‌های اضافی و ضربی، c_+ و c_*، باشد و بنابراین انتظار می‌رود که TTD سودمند و با صرفه است. حتی برای روش‌های نمایش تابع تخمین پارامتری، مثل شبکه‌های عصبی، که پیاده‌سازی اثرات شایستگی آنها بطور خاصی مناسب هستند، نیز ضروری است که تمام وزن‌ها و اثرات شایستگی‌شان را در هر مرحله بروز نماید و این در حالی است که TTDای که از نمایش تابع یکسانی استفاده می‌کند در هر مرحله بازگشت TTD را محاسبه می‌کند و اگر تعداد وزن‌ها در مقایسه با m بیشتر باشد تنها وزن‌ها را بروز می‌کند که ممکن است به طور منطقی و از نظر محاسباتی ارزانتر باشند.

[۱] اگر تعداد زیادی حالت با اثرات شایستگی برابر صفر وجود داشته باشد، هزینه این پیاده سازی ممکن است به اندازه قابل توجهی کاهش یابد.

پس بنابراین واضح است که نسخهٔ تناوبی رویهٔ TTD کار آمدتر از اثرات شایستگی است. البته، با توجه به فرمول‌های (۲۹) و (۳۴)، اگر بازگشت TTD به طور فزاینده محاسبه شود، هزینهٔ TTD برای N یا nهای واقعی دلخواه همواره کمتر خواهد بود.

۴-۴- یادگیری Q مبتنی بر TTD

برای پیاده‌سازی الگوریتم‌های یادگیری تقویت شده مبتنی بر TD خاص که بر اساس رویهٔ TTD باشند، فقط باید برای U مقادیر تابع مقتضی را جایگزین کرد، و عملیات بروزرسانی مرحلهٔ ٦ در نمودار ۱ و مرحلهٔ ۵-ب در نمودار ۲ را تعریف نمود. بخصوص برای الگوریتم یادگیری Q باید:

۱) در مرحلهٔ ٤ نمودار ۱ $U(x_{t+1})$ را با $\max_a Q(x_{t+1}, a)$ جایگزین کرد.

۲) مرحلهٔ ٦ نمودار ۱ و مرحله ۵-ب نمودار ۲ را به صورت زیر پیاده‌سازی نمود:

$$update^{\beta}\left(Q, x_{[m-1]}, a_{[m-1]}, z - Q\left(x_{[m-1]}, a_{[m-1]}\right)\right) \quad (۳۵)$$

برای به دست آوردن فوریت کاری از الگوریتم یادگیری Q بر اساس TTD عمومی، در کنار تجزیه موارد ارائه تابع، فرد می‌بایست برخی مکانیزم‌های انتخاب تابع عمل را پیاده‌سازی نماید، تعیین کند که در هر گام زمانی کدام عمل بر اساس مقادیر فعلی Q اجرا شود. در این کار مکانیزم انتخاب احتمالی بر مبنای توزیع استاندارد بولتزمن مورد استفاده قرار گرفته است، که بر طبق آن احتمال انتخاب عمل a^* در حالت x مساوی است با:

$$prob(x, a^*) = \frac{\exp\left(Q(x, a^*)/T\right)}{\sum_a \exp\left(Q(x, a^*)/T\right)} \quad (۳۶)$$

که در آن درجه حرارت $T > 0$ مقدار اتفاقی را تنظیم می‌کند.

۵- $CMAC$: یک جدول جستجوی بد کد شده

$CMAC$ (کنترل‌کننده بیان مدل مغزی) توسط آلباس در سال ۱۹۸۱ که قسمتی به عنوان مدلی از عملکرد مغز و قسمتی به عنوان روش مفید نگهداری تابع و تقریب، پیشنهاد شد. مزایای آن به طور وسیع تا پایان دهه هشتاد شناخته شده نبود، از آن زمان این روش بیشتر و بیشتر با موفقیت در کنترل خودکار بکار رفت.[9][1]

پیاده‌سازی ویژه $CMAC$ بکار رفته در این مقاله کاملاً از توصیف اصلی آلباس پیروی می‌نماید. برای به دست آوردن ایده‌ای کلی از چگونگی کار آن، ممکن است به آن به عنوان یک جدول جستجوی بد کد شدهٔ پراکنده بنگریم که از پوشش‌های چندگانه روی هم برای پوشاندن فضای ورودی استفاده می‌کند، به نحوی که هر نقطه ورودی در شماری از پوشش‌های روی هم قرار می‌گیرد. پوشش‌ها نسبت به هم در فواصل زمانی ثابت جابجا می‌شوند به طوریکه فضای حالت به شکلی کارآمد به مناطق کوچک تقسیم می‌گردد، اندازه این تقسیمات قطعیت نمودار را تعیین می‌کند. هر پوشش، متناظر با یک عنصر از بردارهای وزن‌های $CMAC$ می‌باشد.

فرض کنید تعداد k پوشش وجود داشته باشد که روی هم قرار گرفته اند و شامل بردار ورودی مفروض x و $t_1(x), t_2(x), ..., t_K(x)$ باشند. هریک از آنها می‌تواند به یک عنصر از بردار وزن‌های $k_1(x), k_2(x), ..., k_K(x)$, متناظر شود. سپس تابع برای x می‌تواند به سادگی به عنوان مجموع این وزن‌ها محاسبه شود $w[k_1(x)] + w[k_2(x)] + ... + w[k_K(x)]$. جهت بروزآوری مقدار تابع برای x با استفاده از مقدار خطای Δ و نرخ یادگیری β، هریک از وزن‌های متناظر k باید طبق قاعده زیر تنظیم گردند:

$$w[k] := w[k] + \frac{\beta}{K}\Delta \quad (۳۷)$$

که در آن: $K = k_1(x), k_2(x), ..., k_K(x)$.

تعداد وزن‌ها برای نگهداری تابع جمع شده‌اند و برای عملیات بروزآوری تابع تنظیم گردیده‌اند که ثابت و مساوی k می‌باشد، و معمولاً کسر بسیار کوچکی از کل تعداد وزن‌ها است. این امر، $CMAC$ را از نظر محاسباتی در مقایسه با اکثر شبکه‌های عصبی مصنوعی بسیار کارآمد می‌سازد. برای استفاده از روش ارائه تابع فوق با الگوریتم یادگیری Q، طبیعی است که یک جدول مجزای $CMAC$ را به هریک از عمل‌های ممکن تخصیص می‌دهیم. هریک از این جدول‌های $CMAC$ حالاتی را به عنوان ورودی دریافت می‌نماید و به صورت فزاینده مقادیر Q را برای عمل متناظر و تمام حالات یاد می‌گیرد.

۶- مطالعات تجربی

مطالعات تجربی با ترکیب الگوریتم یادگیری Q بر مبنای TTD و $CMAC$ انجام گردیده است. هدف این آزمایش‌ها ارزیابی عملکرد سیستم یادگیری تقویتی در کارهایی با فضاهای حالت پیوسته برای چندین مقدار λ بود.

۶-۱- وظایف یادگیری

دو مورد یادگیری مورد آزمایش قرار گرفت. اولین آنها پارک کردن خودرو که توسط سیچوز [20][5] برای ارزیابی مفید بودن دستورالعمل TTD انجام شد و دیگری نسخه‌ای از کار با خودرو در کوهستان [4] که اخیرا برای الگوریتم‌های یادگیری تقویتی با تابع تقریب، مشهور شده است. [15][7]

۶-۱-۱- پارک کردن خودرو

پارک کردن خودرو در شکل شماره (۲) تشریح شده است. یک مستطیل نشانگر خودرو است که در ابتدا در جایی داخل محدوده مرزبندی شده به نام محوطه رانندگی قرار دارد. عامل ملزم به پارک کردن خودرو در گاراژ می‌باشد به نحویکه خودرو کاملا در داخل آن قرار گیرد. مراحل این کار به صورت مرحله‌ای است و شامل شماری از آزمون‌های مستقل می‌شود. وقتی که خودرو وارد گاراژ می‌شود و یا وقتی که به دیوار برخورد می‌کند آزمون به انتها می‌رسد. بعد از هر امتحان خودرو دوباره به محل اولیه خود برمی‌گردد.

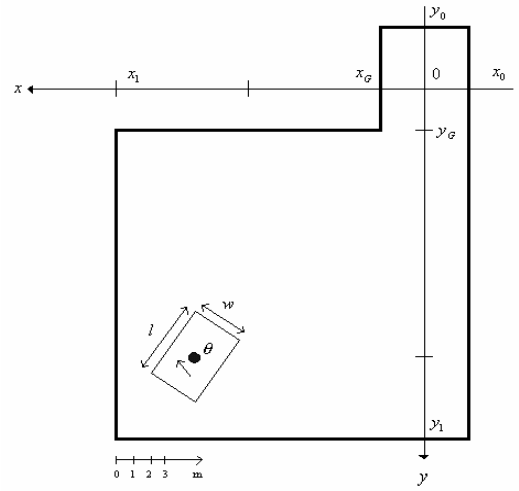

شکل ۲: مسئله پارک اتومبیل اندازه ابعاد شکل عبارتند از:
$w = 2m, l = 4m, x_0 = -1.5m, x_0 = -1.5m, x_G = 1.5m$
$x_1 = 8.5m, y_0 = -3m, y_G = 3m, y_1 = 13m$

نمودار حالت شامل سه متغیر است: مختصات مستطیلی مرکز خودرو، x, y و زاویه θ بین محور خودرو و محور x از سیستم مختصات. محل استقرار اولیه خودرو ثابت بوده و بدین شکل توصیف می‌گردد:

$x = 6.15m, y = 10.47m, \theta = 3.7rad$

عمل‌های قابل پذیرش عبارتند از: *"مستقم برایند"* *"به چپ بپیچید"* *"به راست بپیچید"*. اثرهای این اعمال، معادلات حرکت دقیق، و دیگر جزئیات در ضمیمه الف ارائه شده است. عامل هرگاه خودرو را با موفقیت در گاراژ پارک می‌کند یک تقویت با مقدار ۱ (یک پاداش) دریافت می‌کندو هرگاه به دیوار برخورد کند یک تقویت با مقدار ۱- (یک جریمه). در دیگر گام‌های زمانی تقویت صفر است.

۶-۱-۲- کار با خودرو در کوهستان

این کار در شکل (۳) تشریح شده است. عامل ملزم است که خودرو را تا بالای یک تپه با شیب تند براند. موتور برای آنکه مستقیما از نقطه توقف شتاب گرفته و شیب را طی کند بسیار ضعیف است. برای رسیدن به هدف، خودرو می‌بایست ابتدا از آن نقطه دور شود. آموزش در این کار شامل یک سری امتحانات می‌شود که هر یک از حالت غیر هدف اولیه شروع می‌شود و تا رسیدن به هدف ادامه می‌یابد.

وضعیت خودرو در کوهستان با دو متغیر نمایش داده می‌شود، وضعیت افقی خودرو یعنی x و سرعت آن یعنی v. برد مجاز آنها به ترتیب عبارتند از:

$$0.1 \le x \le -0.1, 0.2 \le v \le -0.2$$

هر وضعیتی با $x > 0.5$ وضعیت هدف است. وضعیت ابتدایی خودرو ثابت بوده و به صورت $v = 0.0$ و $x = -0.5$ ارائه می‌گردد.

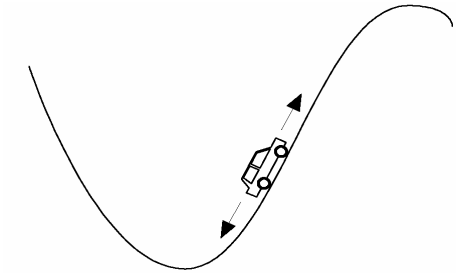

شکل ۳: مسئله خودرو در کوهستان

سه عمل ممکن وجود دارد، *"راندن به جلو" "راندن به عقب" و "راندن به صورت دنده خلاص"*. اثرات آنها طبق روال شبیه‌سازی در ضمیمه «ب» توصیف شده است.

۶-۲- طرح تجربی و نتایج آن

برای هر دو کار یک سری آزمایش‌ها با مقادیر λ مختلف اجرا گردیده است. پارامترهای مورد استفاده برای این آزمایش‌ها در جدول (۲) نشان داده شده است.

جدول ۲: پارامترهای مورد استفاده در آزمایشات

خودرو در کوهستان					پارک کردن اتومبیل				
T	β	γ	m	λ	T	β	γ	m	λ
	0.5			0		0.5			0
	0.5			0.3		0.5			0.3
0.1856	0.5	0.982	26	0.5	0.0168	0.5	0.975	35	0.5
	0.25			0.7		0.25			0.7
	0.1			0.9		0.25			0.9

برای کار پارک کردن خودرو از 6 پوشش *CMAC* استفاده شد که هر یک شامل $5\times5\times5$ پوشش بود. در فضای وضعیتی تعیین شده بوسیله $-0.5 \le x \le 7.5$ و $0.0 \le y \le 12.0$ و $0.9\pi \le \theta \le 1.6\pi$. قطعیت این نمودار $8.0/30 = 0.267$ برای x، $12.0/30 = 0.4$ برای y و $0.7\pi/30 = 0.023\pi$ برای θ است، برای کار خودرو در کوهستان، 5 تا پوشش استفاده شده که هریک شامل 5×5 پوشش روی فضای حالت تعیین شده بوسیله $-0.1 \le x \le 0.5, -2.0 \le v \le 2.0$ می‌باشد. این امرز قطعیت $1.5/25 = 0.06$ برای x، $4.0/25 = 0.16$ برای v محقق می‌نماید.

نتایج هر آزمایش بطور متوسط ۲۵ بار اجرا شده که تنها در مقادیر اولیه تولید کننده عدد تصادفی متفاوت بود. هر دور برای ۲۵۰ امتحان در مورد پارک کردن خودرو و ۱۵۰ امتحان برای راندن خودرو در کوهستان ادامه داده شده است. برای کار اولی، نتایج به صورت قطعه‌هایی از تقویت میانگین در هر گام زمانی در ۵ امتحان متوالی قبلی ارائه می‌شود. برای کار بعدی، نتایج به صورت قطعه‌های زمان امتحان میانگین (تعداد

گام‌ها در هر امتحان) در مورد پنج امتحان متوالی قبلی نسبت به تعداد امتحان‌ها ارائه می‌گردد.

شکل (۵) منحنی‌های یادگیری حاصله را نشان می‌دهد. لذا می‌توان ملاحظه کرد که:

- برای هر دو کار، ترکیب یادگیری Q بر مبنای TTD و $CMAC$، قادر به یادگیری موفقیت‌آمیز بود.
- استفاده از $\lambda > 0$ به ما این اجازه را داد تا شتاب قابل ملاحظه‌ای در یادگیری بدست آوریم.
- مقادیر متوسط λ بهترین عملکرد را محقق نمود.
- λ افزاینده باعث ایجاد ضرورت کاهش نرخ یادگیری برای جلوگیری از همگرایی زودرس به سیاست‌های زیر بهینه گردید.

تاثیرات استفاده از مقادیر m متفاوت برای λهای با مقدار نسبتاً بزرگ و ثابت برای مثال پارک کردن خودرو نیز بررسی گردیده است. تقریباً بهترین مقدار $\lambda = 0.9$ و کوچکترین مقدار تست شده برای $m = 5$ است که تشخیص داده شده که این مقدار نسبتاً کوچک و قابل قبول است.

۷- نتیجه‌گیری

این مقاله عملکرد موفقیت‌آمیز ترکیب دستورالعمل TTD و تقریب زننده تابع $CMAC$ را به نمایش گذارده است. همچنین تاثیرات تغییر پارامتر m نیز تحت شرایط خاص برای مثال اول مورد مطالعه قرار گرفت. مورد مفید بودن TTD قبلا بوسیله شماری از مطالعات تجربی نشان داده شده است. [6][5] به طور مشابه، از $CMAC$ نیز در سیستم‌های یادگیری تقویتی قبلاً توسط تعدادی از مؤلفین بهره گرفته شده است. [17][15] به هر حال کار قبلی روی TTD بطور انحصاری محدود به ارائه یک تابع جدول جستجو بود و کار قبلی بر روی کاربرد $CMAC$ به یادگیری تقویتی متمرکز شده بر ترکیب آن با ساده‌ترین نسخه $TD(0)$ از الگوریتم‌های RL و یا استفاده از آثار وجود شرایط پیاده‌سازی $TD(\lambda)$.

در مورد اولی نمی‌توانیم از پتانسیل شتاب یادگیری که با $\lambda > 0$ ممکن می‌شود بهره گرفت. در مورد بعدی، مزایای کارآیی محاسباتی $CMAC$ که وابسته به جمع‌بندی یا تنظیم شمار بسیار کوچکی از وزن‌ها در حین هر عمل که عملیات را ذخیره یا بروز می‌کند است (کسر کوچکی از تعداد کل وزن‌ها)، بطور کامل بوسیله بار تنظیم تمام وزن‌ها از بین می‌رود و علاوه بر آن آثار وجود شرایط برای همه وزن‌ها در خلال هر عمل بروزآوری. دستورالعمل TTD به ما اجازه می‌دهد که $TD(\lambda)$ را برای λ عمومی با نگاهداشتن هزینه‌های محاسباتی پایین $CMAC$ استفاده کنیم.

نتایج تجربی ارائه شده نشان می‌دهد که الگوریتم یادگیری Q بر مبنای TTD با استفاده از $CMAC$ برای نمایش تابع قادر به یادگیری بطور خستگی‌ناپذیر در دو کار با وضعیت مداوم بود. بطور معمول، دستورالعمل TTD به ما اجازه می‌داد که شتاب یادگیری قابل ملاحظه‌ای تحت $TD(0)$ بدون هزینه‌های اضافی چشمگیری بدست آوریم. با ترکیب TTD و $CMAC$، این کار، بطور موثری یادگیری سریع، کارآیی محاسباتی و توانمندی‌های تعمیم را ترکیب نمود. این یک گام کوچک است به سوی سنجش یادگیری تقویتی در قلمروهای بزرگ دنیای واقعی.

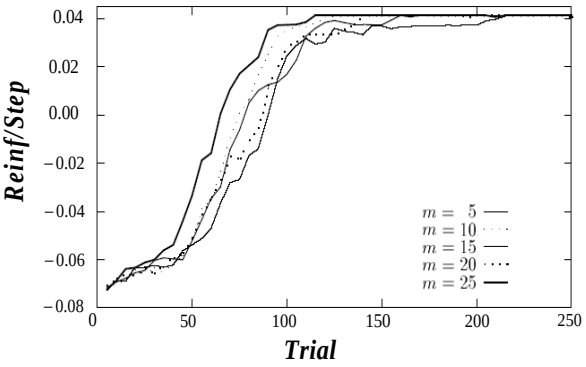

شکل ۴: مسئله پارک خودرو برای مطالعه و بررسی تاثیرات m با ازای λهای با مقدار نسبتاً بزرگ

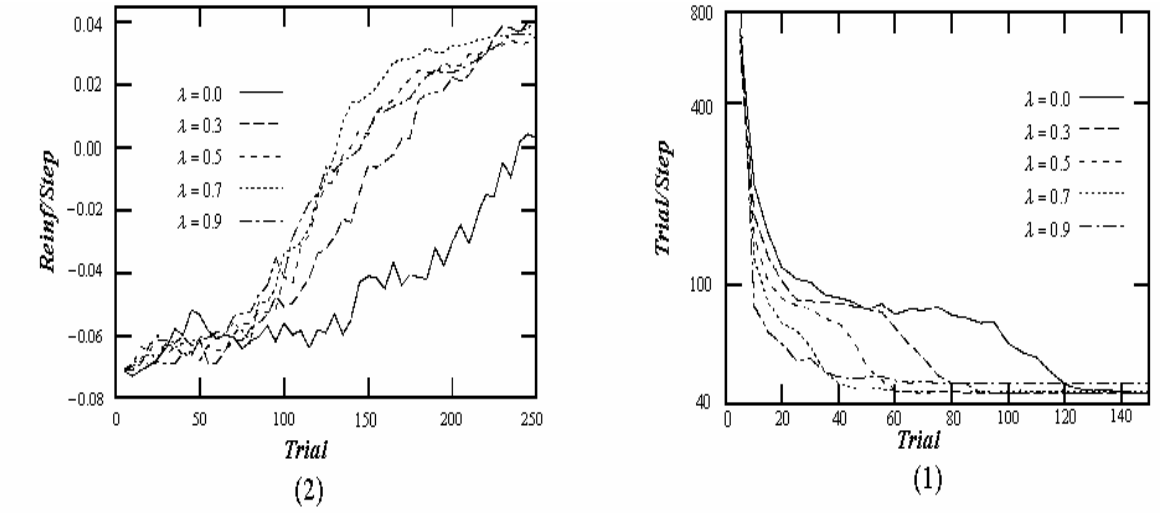

شکل ۵: منحنی‌های یادگیری،(۱) مسئله پارک کردن خودرو، (۲) مسئله خودرو در کوهستان

ضمائم:

الف) جزئیات مسئله پارک کردن اتومبیل

برای شبیه‌سازی حرکت اتومبیل در هر گام زمانی از معادلات زیر استفاده شده است:

1. if $r \neq 0$ then

(a) $\theta(t+\tau) := \theta(t) + \tau\frac{v}{r}$;

(b) $x(t+\tau) := x(t) - r\sin\theta(t) + r\sin\theta(t+\tau)$;

(c) $y(t+\tau) := y(t) + r\cos\theta(t) - r\sin\theta(t+\tau)$;

2. if $r = 0$ then

(a) $\theta(t+\tau) := \theta(t)$;

(b) $x(t+\tau) := x(t) + \tau v\cos\theta(t)$;

(c) $y(t+\tau) := y(t) + \tau v\sin\theta(t)$;

که در اینجا r زاویه چرخش، v سرعت اتومبیل، و τ گام زمانی شبیه‌سازی است. در شبیه‌سازی عملی $r = -5$ متر برای عمل گردش به چپ و $r = 5$ متر برای عمل گردش به راست و $r = 0$ برای راه مستقیم در نظر گرفته شده است. سرعت ثابت و برابر یک متر بر ثانیه و گام‌های شبیه‌سازی $\tau = 0.5$ ثانیه در نظر گرفته شده است.

ب) جزئیات مسئله اتومبیل کوهستان

برای شبیه‌سازی حرکت اتومبیل در کوهستان از معادلات زیر استفاده شده است:

1. if $x_t < 0.0$ then $q := 2x_t + 1$

else $q := \frac{1}{\left(\sqrt{5x^2+1}\right)^3}$;

2. $a_t := \frac{F_t}{\sqrt{q^2+1}} - g\frac{q}{q^2+1}$;

3. $x_{t+\tau} := bound\left(x_t + \tau v_t + 0.5\tau^2 a_t\right)$;

4. $v_{t+\tau} := bound\left(v_t + \tau a_t\right)$;

که $g = 9.81$ و F_t نیروی وارد شده در زمان t که مقدار آن برای عمل رو به جلو 4.0 و برای عمل رو به عقب -

4.0 و برای عمل سر خوردن مقدار آن برابر صفر است. گام زمانی شبیه‌سازی 0.03 ثانیه و رنج قابل تغییر $-1.0 \le x \le 1.0$ و $-2.0 \le v \le 2.0$ در نظر گرفته شده است.

مراجع

[1] J. S. Albus, *"Brain, Behavior, and Robotics"*. BYTE Books, 1981

[2] L. C. Barid, *"Residual Algorithms: Reinforcement Learning with Function Approximation"*, In Proceedings of the 12th International Conference on Machine Learning (ML-95), Morgan Kaufmann, 1995

[3] A. G. Barto, R. S. Sutton, and C. W. Anderson, *"Neurolike Adaptive Elements that can also Difficult Learning Control Problems"*, IEEE Transaction on system, Man, and Cybernetics, 13:835-846, 1983

[4] J. Boyan, and A. W. Moore, *"Generalization in Reinforcement Learning: Safely Approximation the Value Function"*, In Advances in Neural Information Processing Systems, 7 Morgan Kaufmann, 1995

[5] P. Cichosz and J. J. Mulawka, *"Fast and Efficient Reinforcement Learning with Truncated Temporal Differences"*, In Proceedings of the 12th International Conference on Machine Learning (ML-95), Morgan Kaufmann, 1995

[6] P.Cichosz, *"Truncating Temporal Differences: On the Efficient Implementation of TD(λ) for Reinforcement Learning"*, Journal of Artificial Intelligence Research, 2:287-318, 1995

[7] G. J. Gordon, *"Stable Function Approximation in Dynamic Programming"*, In Proceedings of the 12th International Conference on Machine Learning (ML-95), Morgan Kaufmann, 1995

[8] Long-Ji Lin, *"Reinforcement Learning for Robots Using Neural Network"*, PHD Thesis, School of Computer Science, Carnegie-Mellon University, January 1993

[9] W. T. Miller, F.H. Glanz, and L. G. Kraft, *"CMAC: An associative Neural Network Alternative to Back propagation"*, Proceedings of the IEEE, 78:1561-1567, 1990

[10] D. Mitchie and R. A. Chambers, *"BOXES: An Experiment in Adaptive Control"*, Machine Intelligence, 2:137-152, 1968

[11] A. W. Moore, *"Efficient Memory-Based Learning for Robot Control"*, PHD Thesis, University of Cambridge Computer Laboratory, 1990

[12] S. P. Singh and R. C. Yee, *"Technical Note: An Upper Bound on the Loss from Approximate optimal Value Functions"*, Machine Learning, 16:227-233, 1994

[13] R.S. Sutton, *"Temporal Credit Assignment in Reinforcement Learning"*, PHD Thesis, Department of Computer and Information Science, University of Massachusetts, 1984

[14] R. S. Sutton, *"Learning to Predict by the Methods of Temporal Differences"*, Machine Learning, 3:9-44,1988

[15] R. S. Sutton, *"Generalization in Reinforcement Learning: Successful Examples Using Sparse Coarse Coding"*, To Appear in Advances in Neural Information Processing Systems 8, 1995

[16] S. B. Thurn and A. Schwartz, *"Issues in Using Function Approximation for Reinforcement Learning"*, In Proceedings of 4th Connectionist Model Summer School, Lawrence Erlbaum, 1993

[17] C. J. C. H. Watkins, *"Learning From Delayed Rewards"*, PHD thesis, King's College, Cambridge, 1989

[18] J. Abdi, C. Lux, A. K. Sedigh and A. Famil Khalili, *"Truncated Temporal Difference Learning with Function Approximation"* 11th Internation Conference on Electrical Engineering, ICEE'03, Shiraz, Iran, p.p. 283-290, 2003

[19] Tesauro, G., "Practical issues in temporal difference learning", Machine Learning, Vol. 8, p.p 257-277, 1992

[20] P. Cichosz ,*"Truncated Temporal Differences and Sequential Replay: Comparison, Integration, and Experiments"*, In Proceedings of the 13th International Conference on Machine Learning, 1996