

یک روش ترکیبی جدید یادگیری تقویتی فازی

فرزانه قربانی^۱، ولی درهمی^۲، حسین نظام آبدی پور^۳

^۱ فارغ‌التحصیل کارشناسی ارشد مهندسی کامپیوتر، گروه مهندسی کامپیوتر، دانشگاه یزد، f.ghorbani@stu.yazd.ac.ir

^۲ دانشیار، دانشکده مهندسی برق و کامپیوتر، گروه مهندسی کامپیوتر، دانشگاه یزد، vderhami@yazd.ac.ir

^۳ استاد، دانشکده فنی و مهندسی، گروه مهندسی برق، دانشگاه شهید باهنر کرمان، nezam@uk.ac.ir

(تاریخ دریافت مقاله ۱۳۹۳/۱/۱۳، تاریخ پذیرش مقاله ۱۳۹۳/۳/۸)

چکیده: در این مقاله یک روش جدید یادگیری تقویتی پیوسته برای مسائل کنترل ارائه شده از ترکیب روش "تکرار سیاست کمترین مربعات" با یک سیستم فازی سوگنی مرتبه صفر حاصل شده و "تکرار سیاست کمترین مربعات فازی" نامیده شده است. در اینجا برای هر قاعده فازی تعدادی عمل نامزد در نظر گرفته می‌شود. هدف، یافتن مناسب‌ترین عمل نامزد (تالی) برای هر قاعده می‌باشد. با استفاده از بردار شدت آتش قواعد فازی و عمل‌های نامزد مربوط به قواعد، توابع پایه حالت-عمل به گونه‌ای تعریف شده‌اند که شرایط قضایای روش تکرار سیاست کمترین مربعات را برآورده می‌نمایند. با استفاده از توابع پایه حالت-عمل تعریف شده و بهره‌گیری از الگوریتم تکرار سیاست کمترین مربعات، یک روش جدید برای تازه‌سازی پارامترهای وزن تالی قواعد ارائه می‌شود. تحلیل ریاضی که برای این الگوریتم آورده می‌شود، کران خطابی برای اختلاف تابع مقدار ارزش حالت-عمل واقعی و تخمین تابع ارزش حالت-عمل حاصل از الگوریتم ارائه شده، تعریف می‌کند. نتایج شبیه‌سازی در مساله معروف قایق، حاکی از سرعت آموزش بالاتر و نیز کیفیت عملکرد بهتر روش پیشنهادی نسبت به دو روش یادگیری کیوی فازی و یادگیری سارسا فازی است. از مزایای دیگر روش ارائه شده، عدم نیاز به تعیین نرخ آموزش است.

کلمات کلیدی: یادگیری تقویتی، تکرار سیاست کمترین مربعات، تقریب تابع ارزش حالت-عمل، سیستم فازی.

A Novel approach in Fuzzy Reinforcement Learning

Farzaneh Ghorbani, Vali Derhami, Hossein Nezamabadipour

Abstract: In this paper, we present a novel continuous reinforcement learning approach. The proposed approach, called "Fuzzy Least Squares Policy Iteration (FLSPI)", is obtained from combination of "Least Squares Policy Iteration (LSPI)" and a zero order Takagi Sugeno fuzzy system. We define state-action basis function based on fuzzy system so that LSPI conditions are satisfied. It is proven that there is an error bound for difference of the exact state-action value function and approximated state-action value function obtained by FLSPI. Simulation results show that learning speed and operation quality for FLSPI are higher than two previous critic-only fuzzy reinforcement learning approaches i.e. fuzzy Q-learning and fuzzy Sarsa learning. Another advantage of this approach is needlessness to learning rate determination.

Keywords: Reinforcement learning; least squares policy iteration, state-action function approximation, fuzzy system.

۱- مقدمه

ریاضی تکرار سیاست (PI)^۳ [۱۱] بیان شده است. در LSPI نحوه

تعریف دقیق توابع پایه بیان نشده است. مرجع [۱۲]^۴ این روش را به صورت LSPI برخط^۵، برای فضای حالت نامتناهی اصلاح کرده است، اما در این روش نیز توابع پایه به صورت دقیق بیان نشده است و هیچ تحلیل ریاضی و تضمین همگرایی برای این روش (در فضای نامتناهی) وجود ندارد.

در این مقاله از سیستم‌های فازی به عنوان یک تقریب زننده جامع [۱۳-۱۵] برای تقریب تابع ارزش حالت-عمل در روش LSPI استفاده شده و منجر به تعریف روش تکرار سیاست کمترین مرباعات فازی (FLSPI)^۶ شده است. در واقع از سیستم‌های فازی برای تعریف توابع استفاده در FLSPI، سیستمی است که نیاز به تنظیم تالی‌های قواعد دارد و می‌توان گفت از LSPI برای تنظیم تالی‌های این سیستم فازی استفاده شده است.

آن‌چه که در ادامه این مقاله خواهد آمد به این صورت بخش بنده شده است: در بخش دوم مروری کوتاه بر یادگیری تقویتی به طور کلی و سپس الگوریتم LSPI به عنوان یکی از روش‌های مورد استفاده در یادگیری تقویتی انجام شده است. در بخش سوم به روش FLSPI که برای اولین بار در این مقاله ارائه شده پرداخته می‌شود. بخش چهارم در بردارنده نتایج شیوه سازی مساله قایق با استفاده از FLSPI است و در بخش پنجم، جمع‌بندی و نتایج حاصل از به کارگیری این الگوریتم آمده است.

۲- یادگیری تقویتی

در یک سیستم مبتنی بر عامل با یادگیری تقویتی، در هر قدم زمانی t ، عامل، حالت فعلی s_t از فضای حالت S مشاهده نموده و عملی را از فضای عمل متناهی A ، بر اساس سیاست π انتخاب و به محیط اعمال می‌کند. در پی آن، محیط به حالت جدید s_{t+1} از فضای حالت S با احتمال انتقال $\mathcal{R}(s_t, a_t)$ رفته و عامل سیگنال تقویتی $\mathcal{P}(s_t, a_t, s_{t+1})$ را دریافت می‌کند [۶۱].

سیاست که با (s, a) π نشان داده می‌شود، احتمال انتخاب عمل a در حالت s می‌باشد. مبنای کار در یادگیری تقویتی بر اساس پاداش و جریمه است و هدف، حداکثر کردن مجموع پاداش‌های دریافته در طول یادگیری می‌باشد. بر این اساس عامل یاد می‌گیرد عملی را انتخاب کند که او را به حالتی با بیش ترین ارزش برساند. ارزش حالت s تحت سیاست π توسط تابع زیر تعریف می‌شود [۶۱]:

$$V^\pi(s) = E_\pi[\sum_{t=0}^{\infty} \gamma^t \mathcal{R}_t | s_t = s] \quad 0 \leq \gamma \leq 1 \quad (1)$$

با توجه به ویژگی‌های مطلوب یادگیری تقویتی مانند عدم نیاز به داده‌های آموزشی در مسائلی که داده‌های آموزشی در دسترس نیست و همچنین آموزش، تنها با استفاده از یک سیگنال اسکالر، این روش‌ها مورد توجه هستند. روش‌های یادگیری تقویتی، قادر تند هستند، اما روش‌های یادگیری تقویتی استاندارد بر روی فضای حالت و عمل گستته، عمل می‌کنند. این روش‌ها در مسائل با فضای بزرگ یا فضای پیوسته چهار چالش می‌شوند، زیرا گستره سازی این فضاهای مشکل است و آموزش، نیاز به زمان و فضای زیاد دارد. این مشکل در فضاهای بزرگ، نفرین یا تنگنای ابعاد^۷ نام دارد. برای رفع مشکل تنگنای ابعاد، از ترکیب تقریب زننده‌های تابع با روش‌های یادگیری تقویتی استفاده شده است. این روش‌ها از ترکیب تقریب زننده‌های مانند سیستم‌های فازی و شبکه‌های عصبی با روش‌های یادگیری تقویتی به وجود می‌آیند. استفاده از تقریب زننده‌ها در زمرة کاربردهای موفق روش‌های یادگیری تقویتی قرار دارند. اول به دلیل این که نیاز به نگهداری جدولی اطلاعات تابع ارزش حالت-عمل و لذا حافظه زیاد ندارند. دوم این که نیاز به اطلاعات دقیق محیط ندارند. در ضمن استفاده از آن‌ها ساده است و عملکردشان واضح و شفاف می‌باشد، لذا از لحاظ تحلیل و اشکال زدایی ساده می‌باشند [۱].

تمرکز ما در این مقاله بر روی روش‌های یادگیری تقویتی فازی با معماری نقاد-نها است. الگوریتم‌های یادگیری کیوی فازی [۷-۲] و یادگیری سارسای فازی [۸] از جمله الگوریتم‌های دیده در یادگیری تقویتی فازی با معماری نقاد-نها هستند. این روش‌ها از لحاظ ارائه تحلیل ریاضی مثبت در فضاهای پیوسته و وابستگی به نرخ آموزش چهار چالش هستند. ما در این مقاله به دنبال ارائه روشی هستیم که چالش‌های مذکور را برطرف نموده و نسبت به روش‌های قبل، دارای کارایی بهتری باشد.

یکی از روش‌های یادگیری تقویتی که دارای تحلیل ریاضی مثبت، عدم وابستگی به نرخ آموزش و کارایی مناسب است، تکرار سیاست کمترین مرباعات (LSPI)^۸ [۱۰، ۹، ۱] می‌باشد. برای پیاده سازی و استفاده از LSPI، تعریف توابع پایه مشخص نشده است. (الف) ارزیابی تکراری است که در هر تکرار دارای دو مرحله است: (الف) ارزیابی سیاست، مقدار تابع ارزش حالت-عمل را برای سیاست جاری محاسبه می‌کند و (ب) بهبود سیاست، با استفاده از تابع ارزش حالت-عمل مرحله قبل سیاست جدید را تعریف می‌کند. روش LSPI بر روی فضای حالت و عمل متناهی ارائه شده است. تحلیل ریاضی LSPI با استناد به تحلیل

3 Policy Iteration (PI)

4 Online

5 Fuzzy Least Squares Policy Iteration

1 Curse of dimensionality

2 Least Squares Policy Iteration (LSPI)

تقریب آن یعنی \hat{Q} را محاسبه می‌نماید. مبنای LSPI، از بین بردن خطای حاصل از \hat{Q} و تصویر آن تحت عملگر بلمن است.

در حالت کلی می‌توان از یک ترکیب خطی وزن دار برای تقریب تابع ارزش حالت-عمل به صورت زیر استفاده کرد:

$$\hat{Q}^\pi = \Phi W \quad (7)$$

که در آن W ماتریس وزن‌ها و Φ ماتریس توابع پایه حالت-عمل هستند:

$$\Phi = \begin{pmatrix} \emptyset(s_1, a_1)^T \\ \vdots \\ \emptyset(s_i, a_i)^T \\ \vdots \\ \emptyset(s_{|S|}, a_{|A|})^T \end{pmatrix} \quad (8)$$

به طوری که

$$\emptyset(s, a) = \begin{pmatrix} \emptyset_1(s, a) \\ \vdots \\ \emptyset_k(s, a) \end{pmatrix}. \quad (9)$$

که $|S||A| \ll k$ تعداد توابع پایه، \emptyset توابع پایه حالت-عمل می‌باشد.

در [۱] LSPI پس از انجام محاسبات نتیجه گرفته شده که می‌توان \hat{Q}^π را از حل معادله (۱۰) به دست آورد:

$$\hat{Q}^\pi = \Phi(\Phi^T \Phi)^{-1} \Phi T_\pi \hat{Q}^\pi \quad (10)$$

از ساده سازی رابطه بالا (پس از انجام محاسبات مبسوط که مجال بیان آن‌ها در این مقاله نیست)، می‌توان به نتایج زیر رسید [۱]:

$$AW = b \quad (11)$$

$$A_{new} = A_{old} + \emptyset(s, a) \left(\emptyset(s, a) - \gamma \emptyset(s', \pi(s')) \right)^T \quad (12)$$

$$b_{new} = b_{old} + \emptyset(s, a) R \quad (13)$$

که R پاداش انتقال از حالت s به حالت s' است وقتی که عمل انتخاب شده باشد. γ ، نرخ کاهش است و ماتریس A و بردار b که به صورت تکراری محاسبه می‌شوند، برای محاسبه بردار وزن W مورد استفاده قرار می‌گیرند.

که γ نرخ کاهش و E_π امید ریاضی می‌باشد. به طور مشابه، تابع ارزش حالت-عمل برای عمل a و حالت s که مشخص می‌کند در حالت s ارزش انجام عمل a چه اندازه است، به صورت زیر تعریف می‌شود [۶۱]:

$$Q^\pi(s, a) = E_\pi \left[\sum_{t=0}^{\infty} \gamma^t \mathcal{R}_t | s_t = s, a_t = a \right] \quad (2)$$

۲-۱- تکرار سیاست کمترین مربعات

روش تکرار سیاست (PI) [۷۱] یکی از روش‌های یادگیری تقویتی است که سیاست بهینه را برای هر زنجیره تصمیم مارکوف به وسیله تولید دنباله‌ای از سیاست‌ها در فضای گسته به دست می‌آورد. PI، یک الگوریتم تکراری است که در تکرار m آن دو مرحله وجود دارد: ارزیابی سیاست، مقدار تابع Q^{π_m} را از سیاست فعلی π_m محاسبه می‌کند:

$$Q^{\pi_m}(s, a) = \mathcal{R}(s, a) + \gamma \sum_{s' \in S} \mathcal{P}(s, a, s') \sum_{a' \in A} \pi(s', a') Q^{\pi_m}(s', a') \quad (3)$$

بهبود سیاست، سیاست حریصانه بهبود یافته π_{m+1} را روی Q^{π_m} تعریف می‌کند:

$$\pi_{m+1}(s) = \underset{a \in A}{argmax} Q^{\pi_m}(s, a) \quad (4)$$

این روش در فضای حالت و عمل متاهی دارای کارایی بالایی است و کران خطایی برای آن تعریف شده است [۱۱].

مقدار دقیق Q^{π_m} را می‌توان از حل معادله زیر به دست آورد:

$$T_{\pi_m} Q = Q \quad (5)$$

که T_π عملگر بلمن تحت سیاست π می‌باشد و به صورت زیر تعریف می‌شود [۱]:

$$(T_\pi Q)(s, a) = \mathcal{R}(s, a) + \gamma \sum_{s' \in S} \mathcal{P}(s, a, s') \sum_{a' \in A} \pi(s', a') Q(s', a') \quad (6)$$

این روش مانند روش‌های دیگر یادگیری تقویتی در فضاهای بزرگ، دچار مشکل تنگنای ابعاد می‌باشد.

مرجع [۱] روش تکرار سیاست کمترین مربعات را با استفاده از روش تکرار سیاست برای رفع مشکل تنگنای ابعاد، ارائه نموده است. این روش از روش‌هایی است که به جای محاسبه دقیق تابع ارزش حالت-عمل Q ،

-۳- تکرار سیاست کمترین مربعات
کن:

a. با استفاده از رابطه (۱۴) عمل نهایی a_t را محاسبه کن.

b. با اعمال a_t به محیط، حالت s_{t+1} را مشاهده کن و پاداش r_{t+1} را دریافت کن.

c. ماتریس A را با استفاده از رابطه زیر به روزرسانی کن:

(۱۶)

$$A_{t+1} = A_t + \emptyset(s_t, a_t) \left(\emptyset(s_t, a_t) - \gamma \emptyset(s_{t+1}, \pi(s_{t+1})) \right)^T$$

بردار b را با استفاده از رابطه زیر به روزرسانی کن:

$$b_{t+1} = b_t + \emptyset(s_t, a_t) r_{t+1} \quad (۱۷)$$

$t \leftarrow t + 1$ e
- رابطه ۴

$$\frac{1}{t-1} A_t W_k = \frac{1}{t-1} b_t \quad (۱۸)$$

را برای به دست آوردن W_k حل کن و ۱

تا زمانی که شرط توقف برقرار نیست، قرار بده $s_0 = s_t$ و مراحل ۲ تا ۴ را تکرار کن.

که شرط توقف یا رسیدن به هدف (با خطای تعریف شده توسط کاربر) و یا تعداد تکرار خاصی که توسط کاربر تعریف می‌شود، است.

به روزرسانی ماتریس A و بردار b، توسط روابط (۱۶) و (۱۷)، در هر قدم زمانی و به روزرسانی بردار وزن W توسط رابطه (۱۸)، در هر ایزوود آنچه می‌شود. پارامترهای A و b، همان پارامترهای مطرح شده در روابط (۱۳) تا (۱۵) هستند که برای محاسبه بردار وزن W مورد استفاده قرار می‌گیرند. به عبارت دیگر، سیاست در طول یک ایزوود، تغییر نمی‌کند. در صورتی که این الگوریتم برای موارد غیر ایزوود یک استفاده شود، به جای به روزرسانی بردار وزن بعد از هر ایزوود، این بردار، بعد از تعداد مشخصی قدم زمانی به روزرسانی می‌شود. شرط توقف رسیدن به هدف با یک خطای قابل قبول یا تعداد تکرار مشخصی می‌باشد.

لازم به یادآوری است که به روزرسانی بردار W در واقع به روز رسانی \hat{Q} می‌باشد و منجر به استخراج سیاست جدید می‌شود.

۴- تحلیل ریاضی روش پیشنهادی

در این بخش، مباحثی مطرح می‌شود که منجر به تعریف کران برای خطای تقریب تابع حالت-عمل و مقدار بهینه تابع حالت-عمل می‌شود. با استفاده از مرجع [۱۳]، قضیه زیر را داریم.

تبصره ۱ (قضیه استون-وایرشتراوس): اگر Z یک مجموعه از توابع پیوسته روی فضای محدب X باشد و اگر
الف) Z یک جبر باشد یعنی نسبت به جمع و ضرب اسکالار و ضرب بسته باشد.
آنچه این بحث را می‌گیرد، این است که آیا مجموعه ای از توابع

۳- تکرار سیاست کمترین مربعات فازی (FLSPI)

در این بخش با استفاده از سیستم‌های فازی به عنوان تقریب زننده روش تکرار سیاست کمترین مربعات فازی (FLSPI) ارائه می‌شود. FLSPI، از سیستم فازی سوگنو مرتبه صفر استفاده می‌نماید. R قاعده سیستم به شکل زیر تعریف می‌شود:

$R_i: If x_1 is L_{i1} and ... and If x_n is L_{in}, Then$

$(o_{i1} with weight w^{i1} or ... or o_{im} with weight w^{im})$

که $S = (x_1, \dots, x_n)$ برداری از فضای ورودی n-بعدی و $L_i = L_{i1} \times \dots \times L_{in}$ فازی قاعده آم دارای مرکز یکتا هستند. m، تعداد عملهای ممکن برای هر قاعده و O_{ij} ، زمین عمل نامزد برای قاعده آم با وزن w^{ij} می‌باشد. مشخصات توابع عضویت، تعداد عملها و مقدار عملها وابسته به مساله بوده و با توجه به تجربه طراح تعیین می‌شوند.

برای قاعده آم با توجه به وزن هر عمل و استفاده از روش انتخاب عمل شبیه حریصانه، عمل O_{ii+} (اندیس عمل مورد نظر است) انتخاب می‌شود و عمل نهایی به صورت زیر محاسبه می‌شود:

$$a_t(s_t) = \sum_{i=1}^R \mu_i(s_t) O_{ii+} \quad (۱۴)$$

که (μ_i) شدت آتش نرمال شده قاعده آم به ازای ورودی S است.

هدف از آموزش سیستم تقریب w^{ij} به صورت برخط، برای رسیدن به سیاست بهینه است.

شدت آتش هر قاعده از حاصل ضرب مقدمهای مجموعه‌های فازی به دست می‌آید و با استفاده از توابع شدت آتش نرمال شده قواعد، توابع پایه حالت-عمل را به صورت زیر تعریف می‌نماییم:

$$\varphi(s, a) = \left[\overbrace{0 \dots \mu_1(s) \dots 0}^m \overbrace{0 \dots \mu_2(s) \dots 0}^m \dots \overbrace{0 \dots \mu_R(s) \dots 0}^m \right]^T \quad (۱۵)$$

که در آن، m تعداد عملها می‌باشد. لازم به ذکر است تعداد عملهای نامزد و این پارامتر توسط کاربر، بر اساس مساله و تجربه کاربر تعیین می‌شود.

روال الگوریتم FLSPI را می‌توان به صورت زیر خلاصه کرد:

۱- حالت اولیه s_0 را مشاهده کن.

۲- در مجموعه عملهای نامزد هر قاعده، یکی از عملهای را با توجه به مقدار وزنشان و روش انتخاب عمل شبیه حریصانه^۱ انتخاب کن.

۱ ε-greedy

اگون با استفاده از دو رابطه زیر شرط قسمت (الف) تبصره ۱ را
بررسی می کنیم:

$$\begin{aligned} \left(\sum_i p_i b_i \right) \left(\sum_j c_j \right) + \left(\sum_j q_j c_j \right) \left(\sum_i b_i \right) \\ = \sum_i \sum_j (p_i + q_j)(b_i c_j) \end{aligned} \quad (۲۳)$$

$$\left(\sum_i a_i \right) \left(\sum_j b_j \right) = \sum_i \sum_j a_i b_j \quad (۲۴)$$

دوتابع دلخواه \hat{Q}_1 با R_1 قاعده و \hat{Q}_2 با R_2 قاعده از Z را در نظر
بگیرید:

$$\hat{Q}_1(s, a) = \frac{\sum_{i=1}^{R_1} W_{ii^+} \prod_{l=1}^n \mu_i^l(s_l)}{\sum_{i=1}^{R_1} \prod_{l=1}^n \mu_i^l(s_l)}$$

$$\hat{Q}_2(s, a) = \frac{\sum_{j=1}^{R_2} W_{jj^+} \prod_{l=1}^n \mu_j^l(s_l)}{\sum_{j=1}^{R_2} \prod_{l=1}^n \mu_j^l(s_l)}$$

با استفاده از رابطه (۲۳) داریم:

$$\begin{aligned} \hat{Q}_1(s, a) + \hat{Q}_2(s, a) \\ = \frac{\sum_{i=1}^{R_1} \sum_{j=1}^{R_2} (W_{ii^+} + W_{jj^+}) (\prod_{l=1}^n \mu_i^l(s_l) \mu_j^l(s_l))}{\sum_{i=1}^{R_1} \sum_{j=1}^{R_2} (\prod_{l=1}^n \mu_i^l(s_l) \mu_j^l(s_l))} \end{aligned}$$

در نتیجه $\hat{Q}_1(s, a) + \hat{Q}_2(s, a) \in Z$ پس Z نسبت به جمع بسته
است.

حال با استفاده از رابطه (۲۴) خواهیم داشت:

$$\begin{aligned} \hat{Q}_1(s, a) \cdot \hat{Q}_2(s, a) \\ = \frac{\sum_{i=1}^{R_1} \sum_{j=1}^{R_2} (W_{ii^+} \cdot W_{jj^+}) (\prod_{l=1}^n \mu_i^l(s_l) \mu_j^l(s_l))}{\sum_{i=1}^{R_1} \sum_{j=1}^{R_2} (\prod_{l=1}^n \mu_i^l(s_l) \mu_j^l(s_l))} \end{aligned}$$

و در نتیجه $\hat{Q}_1(s, a) \cdot \hat{Q}_2(s, a) \in Z$ یعنی Z نسبت به ضرب بسته
است. به وضوح Z نسبت به ضرب اسکالر هم بسته است. لذا Z یک جبر
است.

برای بررسی قسمت (ب) تبصره ۱، فرض کنید

$$v = (s_1, a_1), h = (s_2, a_2) \in X$$

دو بردار دلخواه باشند که $v \neq h$. سیستم فازی با دو قاعده را در

نظر بگیرید که دارای دوتابع عضویت به شکل زیر است:

$$\mu_1^l(x_l) = \exp(-\frac{1}{2}(x_l - v_l)^2)$$

$$\mu_2^l(x_l) = \exp(-\frac{1}{2}(x_l - h_l)^2)$$

و همچنین تالیهای:

$$o_{11} = a_1/2, o_{12} = (a_2/2) \exp\left(\frac{1}{2}\|v - h\|^2\right)$$

$$o_{21} = (a_1/2) \exp\left(\frac{1}{2}\|v - h\|^2\right), o_{22} = a_2/2$$

ب) نقاط روی X را جدا کند:

$$\forall x_1, x_2 \in X, x_1 \neq x_2; \exists F \in Z \text{ s.t } F(x_1) \neq F(x_2)$$

ج) Z روی هیچ نقطه‌ای از X صفر نشود:

$$\forall x \in X; \exists F \in Z \text{ s.t } F(x) \neq 0$$

آنگاه برای هر تابع پیوسته $G(x)$ روی X و هر $\epsilon > 0$ دلخواه، یک
وجود دارد به طوری که $F \in Z$

$$\|F(x) - G(x)\|_\infty < \epsilon$$

лем ۱- برای هر تابع پیوسته Q و هر $\epsilon > 0$ دلخواه، تابع

$$\hat{Q} = \sum_{i=1}^R \mu_i^l(s) W_{ii^+}$$

$$\|\hat{Q} - Q\|_\infty < \epsilon$$

اثبات- X را فضای حاصل از ضرب دکارتی فضایی حالت

(زیرفضایی محدب از \mathbb{R}^m) و فضای عمل (زیرفضایی محدب از \mathbb{R}^{n+m}) در نظر بگیرید، در این صورت X زیرفضایی محدب از \mathbb{R}^{n+m} است که

n بعد فضای حالت و m بعد فضای عمل می‌باشد. همچنین Q روی این

فضای تابعی پیوسته است. اگون با تعریف Z به عنوان فضای همه توابع

که W یک بردار است و $\Phi W = \hat{Q}$ که W مشخص می‌شود،

کافی است شرایط قضیه ۱ ارضا شود تا اثبات کامل شود:

تعریف می کنیم:

$$\hat{Q}: X \rightarrow Y, y = \hat{Q}(s, a), X \subseteq \mathbb{R}^{n+m}, Y \subseteq \mathbb{R}$$

همچنین R قاعده به به صورت تعریف شده در بخش ۳، در نظر

می‌گیریم:

$R_i: If s_1 is L_{i1} and ... and If s_n is L_{in}, Then$

$(o_{i1} with weight w^{i1} or ... or o_{im} with weight w^{im})$

اگون \forall را به این شکل تعریف می کنیم:

$$y = \hat{Q}(s, a) = \sum_{i=1}^R \mu_i^l(s) W_{ii^+} \quad (۱۹)$$

که در آن W_{ii^+} وزن مربوط به عمل انتخاب شده در قاعده A_m و

$\mu_i^l(s)$ شدت آتش نرمال شده قاعده A_m به ازای ورودی S است:

$$\mu_i^l(s) = \frac{\alpha_i^l(s)}{\sum_{j=1}^R \alpha_j^l(s)} \quad (۲۰)$$

که $\alpha_i^l(s)$ شدت آتش قاعده A_m به ازای ورودی S می‌باشد:

$$\alpha_i^l(s) = \prod_{l=1}^n \mu_i^l(s_l) \quad (۲۱)$$

$\mu_i^l(s_l)$ درجه عضویت s_l در A_m تابع عضویت تعریف شده

می‌باشد. لذا داریم:

$$\hat{Q}(s, a) = \frac{\sum_{i=1}^R W_{ii^+} \prod_{l=1}^n \mu_i^l(s_l)}{\sum_{i=1}^R \prod_{l=1}^n \mu_i^l(s_l)} \quad (۲۲)$$

اثبات- چون این مساله یک مساله کاهشی با نرخ کاهش γ است، با وزن‌های:
■ با استناد به مرجع [۱۱] اثبات کامل می‌شود.

لم ۴- فرض کنید π_k سیاست تولید شده توسط k امین تکرار از الگوریتم FLSPI و $\epsilon_k \geq 0$ دلخواه باشد بهطوری که $\|\hat{Q}^{\pi_k} - Q^{\pi_k}\|_{\infty} \leq \epsilon_k$

$$Q^{\pi_{k+1}}(s, a) \leq Q^{\pi_k}(s, a) + \frac{2\gamma\epsilon_k}{1-\gamma}, \forall(s, a) \quad (۲۹)$$

اثبات- تعریف می‌کنیم $e_k = \sup_{(s, a)} (Q^{\pi_{k+1}}(s, a) - Q^{\pi_k}(s, a))$

$$\begin{aligned} Q^{\pi_{k+1}}(s, a) &\leq Q^{\pi_k}(s, a) + e_k, \forall s, a \\ \text{اما چون } T_{\pi} Q^{\pi} &= Q^{\pi} \text{ و با استفاده از (۲۶)} \end{aligned}$$

$$\begin{aligned} Q^{\pi_{k+1}}(s, a) &= T_{\pi_{k+1}} Q^{\pi_{k+1}}(s, a) \\ &\leq T_{\pi_{k+1}} (Q^{\pi_k}(s, a) + e_k) \\ &= T_{\pi_{k+1}} Q^{\pi_k}(s, a) + \gamma e_k \end{aligned}$$

از طرفی در LSPPI به دلیل عدم نیاز به نمایش تقریب سیاست، همه خطاهای عملگر صفر هستند [۱]. لذا برای هر k داریم:

$$T_{\pi_{k+1}} Q^{\pi_k} = T_{\pi_k} Q^{\pi_k}. \quad \text{بنابراین:}$$

$$\begin{aligned} Q^{\pi_{k+1}}(s, a) - Q^{\pi_k}(s, a) &\leq T_{\pi_{k+1}} Q^{\pi_k}(s, a) + \gamma e_k \\ &- Q^{\pi_k}(s, a) \\ &= T_{\pi_{k+1}} Q^{\pi_k}(s, a) - T_{\pi_{k+1}} \hat{Q}^{\pi_k}(s, a) \\ &+ T_{\pi_{k+1}} \hat{Q}^{\pi_k}(s, a) - Q^{\pi_k}(s, a) \\ &+ \gamma e_k \end{aligned}$$

در نتیجه با استفاده از (۲۸) می‌توان نوشت:

$$\begin{aligned} T_{\pi_{k+1}} Q^{\pi_k}(s, a) - T_{\pi_{k+1}} \hat{Q}^{\pi_k}(s, a) &+ T_{\pi_{k+1}} \hat{Q}^{\pi_k}(s, a) \\ &- Q^{\pi_k}(s, a) + \gamma e_k \\ &\leq \gamma |\hat{Q}^{\pi_k}(s, a) - Q^{\pi_k}(s, a)| \\ &+ \gamma |\hat{Q}^{\pi_k}(s, a) - Q^{\pi_k}(s, a)| + \gamma e_k \\ &\leq 2\gamma\epsilon_k + \gamma e_k \end{aligned}$$

لذا داریم:

$$\begin{aligned} \sup_{(s, a)} (Q^{\pi_{k+1}}(s, a) - Q^{\pi_k}(s, a)) &\leq 2\gamma\epsilon_k + \gamma e_k \\ \Rightarrow e_k &\leq 2\gamma\epsilon_k + \gamma e_k \\ \Rightarrow e_k &\leq \frac{2\gamma}{1-\gamma}\epsilon_k. \quad \blacksquare \end{aligned}$$

لم ۵- فرض کنید π_k سیاست تولید شده توسط k امین تکرار الگوریتم FLSPI و $\epsilon_k \geq 0$ دلخواه باشد بهطوری که $\|\hat{Q}^{\pi_k} - Q^{\pi_k}\|_{\infty} \leq \epsilon_k$

$$W_{11} = W_{12} = 0, W_{21} = W_{22} = 1$$

که اندیس‌های منتخب برای a_1 ، قاعده اول اندیس اول، قاعده دوم اندیس اول و برای a_2 ، قاعده اول اندیس دوم و قاعده دوم اندیس دوم می‌باشد.

شدت آتش‌ها به صورت زیر به دست می‌آیند:

$$\alpha_1(x) = \prod_{l=1}^n \mu_1^l(s_l) = \exp(-\frac{1}{2} \|x - v\|_2^2)$$

$$\alpha_2(x) = \prod_{l=1}^n \mu_2^l(s_l) = \exp(-\frac{1}{2} \|x - h\|_2^2)$$

لذا داریم:

$$\hat{Q}(s_1, a_1) = \frac{\exp(-\frac{1}{2} \|v - h\|_2^2)}{1 + \exp(-\frac{1}{2} \|v - h\|_2^2)}$$

$$\hat{Q}(s_2, a_2) = \frac{1}{1 + \exp(-\frac{1}{2} \|v - h\|_2^2)}$$

در نتیجه $\hat{Q}(h) \neq \hat{Q}(v)$. پس Z نقاط روی X را جدا می‌کند.
برای بررسی قسمت (ج) کافی است با تعاریف قسمت قبل $W_{ij} > 0$ برای همه i ها. در این صورت به ازای هر x $\hat{Q}(x, a_i) \neq 0$. پس Z روی هیچ نقطه‌ای از X صفر نمی‌شود.

آنچه از لم ۱ نتیجه می‌شود این است که برای هرتابع دلخواه می‌توان تابعی از سیستم فازی استفاده شده در الگوریتم FLSPI یافت که با هر دقت دلخواهی آن را تقریب بزند.

لم ۲- برای سیاست ایستای π و اسکالر دلخواه X داریم:

$$T(Q + xe)(s, a) = TQ(s, a) + \gamma x \quad (۲۵)$$

$$T_{\pi}(Q + xe)(s, a) = T_{\pi}Q(s, a) + \gamma x \quad (۲۶)$$

که در آن e همانی است.

اثبات- چون این مساله یک مساله کاهشی^۱ با نرخ کاهش γ است، با استناد به مرجع [۱۱] اثبات کامل می‌شود.

لم ۳- برای سیاست ایستای π داریم:

$$\|TQ - T\hat{Q}\|_{\infty} \leq \gamma \|Q - \hat{Q}\|_{\infty} \quad (۲۷)$$

$$\|T_{\pi}Q - T_{\pi}\hat{Q}\|_{\infty} \leq \gamma \|Q - \hat{Q}\|_{\infty} \quad (۲۸)$$

$$\Rightarrow \limsup_{k \rightarrow \infty} f_k \leq \frac{2\gamma}{(1-\gamma)^2} \varepsilon$$

و همچنین فرض کنید

$$\limsup_{k \rightarrow \infty} \|Q^{\pi_k} - Q^*\|_\infty \leq \frac{2\gamma}{(1-\gamma)^2} \varepsilon$$

از طرفی

$$\|\hat{Q}^{\pi_k} - Q^*\|_\infty = \|\hat{Q}^{\pi_k} - Q^{\pi_k} + Q^{\pi_k} - Q^*\|_\infty$$

$$\leq \|\hat{Q}^{\pi_k} - Q^{\pi_k}\|_\infty + \|Q^{\pi_k} - Q^*\|_\infty$$

$$\Rightarrow \limsup_{k \rightarrow \infty} \|\hat{Q}^{\pi_k} - Q^*\|_\infty \leq \limsup_{k \rightarrow \infty} \|\hat{Q}^{\pi_k} - Q^{\pi_k}\|_\infty + \limsup_{k \rightarrow \infty} \|Q^{\pi_k} - Q^*\|_\infty$$

$$\leq \varepsilon + \frac{2\gamma}{(1-\gamma)^2} \varepsilon$$

اثبات - با توجه به فرض داریم

$$Q^{\pi_k}(s, a) \leq Q^*(s, a) + f_k, \quad \forall(s, a)$$

اما T عملگری غیر نزولی است [۱۱]، پس با استفاده از (۲۵) و این که $TQ^* = Q^*$

$$TQ^{\pi_k}(s, a) \leq T(Q^*(s, a) + f_k) = TQ^*(s, a) + \gamma f_k$$

$$= Q^*(s, a) + \gamma f_k$$

از طرفی اگر $a < b + \varepsilon$ ، آنگاه $|a - b| < \varepsilon$ و $b < a + \varepsilon$ با استفاده از این مطلب در فرض قضیه و (۲۵)

$$\Rightarrow \limsup_{k \rightarrow \infty} \|\hat{Q}^{\pi_k} - Q^*\|_\infty \leq \frac{1+\gamma^2}{(1-\gamma)^2} \varepsilon.$$

بنابراین

$$T_{\pi_{k+1}} Q^{\pi_k}(s, a) \leq T_{\pi_{k+1}} (\hat{Q}^{\pi_k}(s, a) + \varepsilon_k)$$

$$= T_{\pi_{k+1}} \hat{Q}^{\pi_k}(s, a) + \gamma \varepsilon_k$$

$$= T \hat{Q}^{\pi_k}(s, a) + \gamma \varepsilon_k$$

$$\leq T(Q^{\pi_k}(s, a) + \varepsilon_k) + \gamma \varepsilon_k$$

$$= TQ^{\pi_k}(s, a) + \gamma \varepsilon_k + \gamma \varepsilon_k$$

$$\leq Q^*(s, a) + \gamma f_k + 2\gamma \varepsilon_k$$

بنابراین

$$Q^{\pi_{k+1}}(s, a) = T_{\pi_{k+1}} Q^{\pi_{k+1}}(s, a)$$

$$\leq T_{\pi_{k+1}} (Q^{\pi_k}(s, a) + \varepsilon_k)$$

$$= T_{\pi_{k+1}} Q^{\pi_k}(s, a) + \gamma \varepsilon_k$$

$$\leq Q^*(s, a) + \gamma f_k + 2\gamma \varepsilon_k + \gamma \varepsilon_k$$

$$\Rightarrow Q^{\pi_{k+1}}(s, a) - Q^*(s, a) \leq \gamma f_k + \gamma \varepsilon_k + 2\gamma \varepsilon_k, \forall(s, a)$$

$$\Rightarrow f_{k+1} \leq \gamma f_k + \gamma \varepsilon_k + 2\gamma \varepsilon_k.$$

■

قضیه ۱ - فرض کنید π_1, \dots, π_{k+1} دنباله‌ای از سیاست‌های تولید شده توسط FLSPI باشد، در این صورت:

$$\limsup_{k \rightarrow \infty} \|\hat{Q}^{\pi_k} - Q^*\|_\infty \leq \frac{1+\gamma^2}{(1-\gamma)^2} \varepsilon \quad (۳۱)$$

که در آن $\varepsilon = \limsup_{k \rightarrow \infty} \varepsilon_k$.

اثبات - با استفاده از لم ۴ داریم

$$\limsup_{k \rightarrow \infty} f_k \leq \gamma \limsup_{k \rightarrow \infty} f_k + \gamma \limsup_{k \rightarrow \infty} \varepsilon_k + 2\gamma \varepsilon_k$$

اکنون با استفاده از لم ۳ داریم:

$$\limsup_{k \rightarrow \infty} \varepsilon_k \leq \frac{2\gamma}{1-\gamma} \varepsilon$$

بنابراین

$$(1-\gamma) \limsup_{k \rightarrow \infty} f_k \leq \frac{2\gamma}{1-\gamma} \varepsilon + 2\gamma \varepsilon = \frac{2\gamma}{1-\gamma} \varepsilon$$

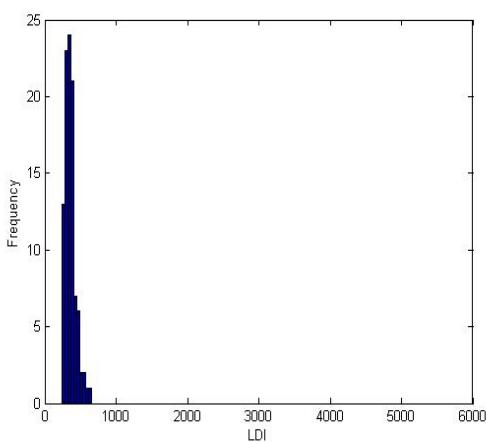
۵- شبیه سازی

در این بخش، برای نمایش کارایی روش FLSPI، این روش را در مساله قایق [۲] پیاده سازی کرده‌ایم. هدف، هدایت قایق با شروع از هر موقعیت در سمت چپ رودخانه‌ای با جریان آب غیر خطی قوی به اسکله سمت راست است. این مسئله دارای دو متغیر حالت پیوسته x و y (مختصات دماغه قایق) در دامنه $0 \leq x \leq 200$ است. مرکز اسکله در موقعیت $(100, 200)$ قرار دارد و عرض آن برابر با 5 می‌باشد. فضای عمل این مساله، زوایای سکان قایق نسبت به محور افقی است. هدف استفاده از یادگیری تقویتی در این مساله، یادگرفتن زاویه (عمل) مناسب در هر حالت (موقعیت قایق در رودخانه با جریان آب مربوط به آن موقعیت)، با استفاده از سیگنال تقویتی (پاداش) می‌باشد.

جدول ۱: مقایسه نتایج شبیه سازی

Initial parameters	Method	Avg. DEI	Avg. LDI	Std. (LDI)	Failure Rate	Avg. Time (Sec)
$\delta = 0.01$ $\alpha = 0.01$	FQL	8.69	733	1084	6.7	83.81
$\delta = 1$ $\alpha = 0.1$	FSL	4.45	1010	1065	2.825	41.97
	FLSPI	3.06	360.9	76.04	1.17	14.45

هیستو گرام یادگیری FLSPI و FSL در شکل های ۱ و ۲ آمده است. همانطور که دیده می شود در FLSPI، به ازای ۱۰۰ اجرای متمایز، هیچ مورد واگرایی وجود ندارد. و در همه اجراهای، یادگیری با تعداد اپیزود کمتر از ۶۷۰ صورت گرفته است. در شکل ۳ تغییرات وزن های قاعده اول در اپیزودهای متواتی، از این پیاده سازی برای FLSPI نشان داده شده است. همانطور که دیده می شود تغییرات وزن ها بعد از حدود ۳۰۰ تکرار بسیار کم شده است و می توان گفت که بعد از حدود ۱۰۰۰ تکرار تقریباً بدون تغییر هستند. لذا وزن ها در FLSPI خیلی سریع همگرا می شوند. برای نمونه، نتیجه آزمایش الگوریتم FLSPI روی ۴۰ داده آزمایشی در شکل ۴ آمده است. همانطور که ملاحظه می شود یادگیری به صورت مطلوبی اتفاق افتاده است. در واقع یادگیری به ازای همه نقاط فضا به صورت کامل می باشد.



شکل ۱: هیستو گرام یادگیری برای FLSPI

پنج مجموعه فازی برای تقسیم بندی متغیرهای ورودی X و U در نظر گرفته شده است. لذا ۲۵ قاعده فازی خواهیم داشت. خروجی کنترلگر زاویه حرکت قایق می باشد. برای تالی هر قاعده دوازده عمل (زاویه حرکت) گسته لحظه گردیده است: $A = \{ -100, -90, -80, -75, -60, -45, -35, -15, 0, 15, 45, 75, 90 \}$ البته می توان برای هر قاعده مجموعه عمل های گسته متفاوتی در نظر گرفت، لیکن در اینجا یکسان فرض می شوند. همچنین مقادیر اویله وزن (W) برای عمل های یکسان و برابر صفر لحظه شده است. کنترل گر با ترکیب این عمل های گسته، خروجی پیوسته را تولید می کند. هدف از یادگیری پیدا کردن عمل مناسب برای تالی قواعد است.

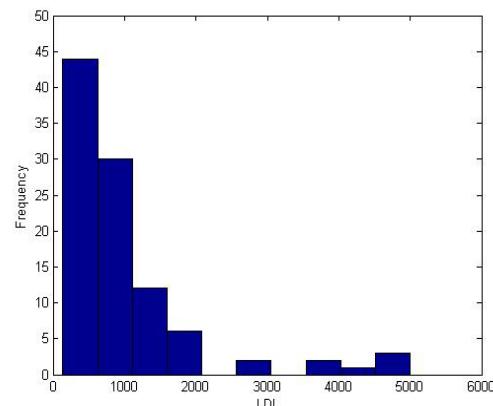
نتایج هر آزمایش متوسط ارزیابی انجام شده از ۱۰۰ اجرا است. هر اجرا شامل دو بخش یادگیری و آزمون می باشد. برای بخش یادگیری، ابتدا ۱۰۰ دسته موقعیت تصادفی تولید می شود. هر دسته شامل ۵۰۰۰ تصادفی شروع حرکت قایق ($x=10, y=random$) می باشد. اگر تعداد اپیزودها (منظور از یک رویداد شروع از نقطه آغاز و رسیدن به طرف دیگر ساحل است) از ۵۰۰۰ بیشتر شود یا تعداد دفعات متواتی که قایق به ناحیه غیر شکست رسانیده است به ۴۰ برسد بخش یادگیری پایان می یابد. بخش آزمون شامل ۴۰ رویداد با شروع از ۴۰ نقطه با $x=10$ و $y=1$ بخش شده با فواصل مساوی در رنج ۰ تا ۲۰۰ است.

نتایج حاصل از ۱۰۰ اجرای مجزای این الگوریتم در جدول ۱ با بهترین نتیجه های روش های FQL و FSL [۸] مقایسه شده است. در این جدول، متوسط تعداد اپیزود در یادگیری (Avg. LDI)، انحراف معیار اپیزودها در یادگیری (std. LDI)، میانگین فاصله در آزمایش (Avg. DEI)، نرخ شکست^۱ در آزمایش و همچنین میانگین زمان اجرا (Avg. time) آمده است. سیستم کامپیوتری مورد استفاده در این آزمایش دارای پردازنده intel core i7 (2.20GHz) و ۸ گیگابایت حافظه می باشد.

همانطور که در جدول ۱ مشاهده می شود، نتیجه بسیار بهتری FLSPI نسبت به FQL و FSL دارد. برای مثال، برای FQL، نسبت به FSL، از نظر زمان آموزش (LDI)، ۲/۸ برابر، از نظر کیفیت یادگیری (DEI)، ۲/۸ و ۱/۵ برابر و از لحظه نرخ شکست، ۵/۷ و ۲/۴ برابر بهتر شده است. از لحظه زمان اجرا نیز مشاهده می شود که FLSPI نسبت به FQL و FSL به ترتیب ۵/۸ و ۲/۹ برابر سریع تر است.

1 Failure Rate

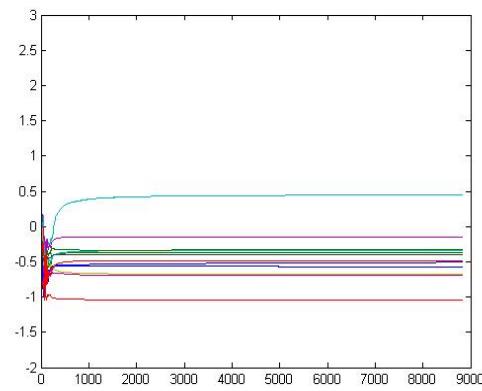
همچنین اثبات شد که خطای تابع ارزش عمل تقریب زده شده با مقدار واقعی محدود بوده و کمتر از مقدار کرانی است که در این مقاله بدست آمده است. جهت ارزیابی FLSPI، عملکرد آن در مساله شناخته شده FSL مقایسه با دو روش یادگیری تقویتی فازی نقاد-تنها به نام های FQL و FSL مقایسه شد. از دیگر مزیت های روش ارائه شده، عدم وابستگی آن به نرخ یادگیری می باشد. همچنین عدم وجود واگرایی، از ویژگی های قابل توجه FLSPI می باشد. نتایج شبیه سازی نشان داد که همگرایی وزن ها در این الگوریتم خیلی سریع اتفاق می افتد. در ضمن این که زمان اجرای این الگوریتم، آن را برای مسائلی که نیاز به الگوریتم های بلاذرنگ دارند، مناسب می کند.



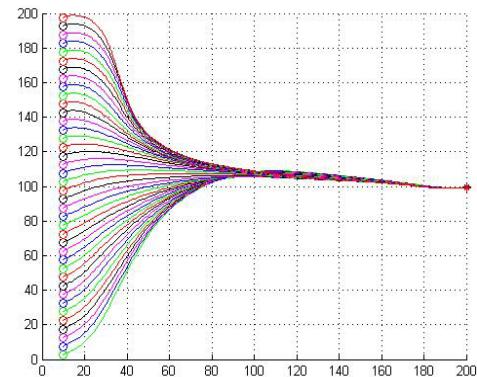
شکل ۲: هیستوگرام یادگیری برای FSL

مراجع

- [1] Lagoudakis M. G., and Parr, R., "Least-squares policy iteration", Journal of Machine Learning Research, vol. 4, p. 1107-124, 2003.
- [2] Jouffe, L., "Fuzzy inference system learning by reinforcement methods", IEEE Trans. Syst., Man, Cybern. C, vol. 28, p. 338-35, 1998.
- [3] Berenji, H., " Fuzzy Q-learning: a new approach for fuzzy dynamic programming", IEEE World Congress on Computational Intelligence, 1994.
- [4] Panahi, F.H., Ohtsaki, T., "Optimal Channel-Sensing Scheme for Cognitive Radio Systems Based on Fuzzy Q-Learning", IEICE TRANSACTIONS on Communications, Vol.E97-B, No.2, pp.283-29, 2014.
- [5] Shamshirband, S., Patelc, A., Anuarb, N.B., Mat Kiahb, M.L., Abrahame, A., "Cooperative game theoretic approach using fuzzy Q-learning for detecting and preventing intrusions in wireless sensor networks", Engineering Applications of Artificial Intelligence, 2014.
- [6] Muñoz, P., Barco, R., De la Bandera, I., "Optimization of load balancing using fuzzy Q-Learning for next generation wireless networks", Expert Systems with Applications Volume 40, Issue 4, Pages 984–994, March 2013.
- [7] Glorenne, P.Y. and Jouffe, L., "Fuzzy Q-learning", Proc. IEEE Int. Conf. Fuzzy Systems, vol 2, p. 659-662, July 1997.
- [8] Derhami, V., Majd , V.J., and Ahmadabadi, M.N., "Fuzzy sarsa learning and the proof of existence of its stationary points", Asian Journal of Control, vol 10, p. 535-549, September 2008.
- [9] Rovcanin M., De Pooreter, E., Moerman, I., Demeester, P., "A reinforcement learning based solution for cognitive network cooperation between co-located, heterogeneous wireless sensor networks", Ad Hoc Netw, vol 17, p. 98-113, June 2014.



شکل ۳: تغییرات وزن های قاعده اول FLSPI



شکل ۴: نتیجه الگوریتم FLSPI پس از آموخته، روی داده های تست

۵- نتیجه گیری

در این مقاله یک روش جدید یادگیری تقویتی فازی با استفاده از FLSPI ارائه شد. الگوریتم ارائه شده FLSPI نامیده شد. نحوه تعریف توابع پایه ارزش - عمل، و بروز رسانی پارامترهای وزن در شرح داده شد.

ابتدا اثبات شد که FLSPI شرایط مربوط به قضایای بیان شده در FLSPI را برآورده نموده و لذا نتایج آن قضایا برای FSLPI صادق است.

-
- [14] Razavi, R., Klein, S., and Claussen, H., "Self-Optimization of Capacity and Coverage in LTE Networks Using a Fuzzy Reinforcement Learning Approach", 21st Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications, 2010.
 - [15] Castro, J.L., "Fuzzy logic controllers are universal approximators", vol 25, p. 629-63, April 1995.
 - [16] Du, K.L., Swamy, M. N. S., "Reinforcement Learning. Neural Networks and Statistical Learning", pp 547-561, 2014.
 - [17] Howard, R.A., "Dynamic Programming and Markov Processes", MIT Press, Cambridge, Massachusetts, 1960.
 - [10] Thiery, C., Scherrer, B.L., "east-Squares λ Policy Iteration: Bias-Variance Trade-off in Control Problems", International Conference on Machine Learning, 2010.
 - [11] Bertsekas, D.P., and Tsitsiklis, J.N., "Neuro-Dynamic Programming", Athena Scientific, Belmont, Massachusetts, 1996.
 - [12] Busoniu, L., Ernst, D., De Schutter, B., "Online least-squares policy iteration for reinforcement learning control", American Control Conference (ACC-10), Baltimore, US, 30 June – 2 July 2010.
 - [13] Jang, J.S.R., Sun, C.T., and Mizutani, E., "Neuro-Fuzzy and soft computing", Prentice-Hall, 1997.