

## تلفیق مبانی فازی و یادگیری تقویتی در کنترل سیستم‌های دینامیکی\*

مسعود گوهری منش<sup>(۱)</sup> علی اکبر اکبری<sup>(۲)</sup> محمد باقر نقیبی سیستانی<sup>(۳)</sup>

**چکیده** یادگیری تقویتی، روشنی است که در آن عامل یا عاملان با توجه به یک سری پاداش‌های مثبت و یا منفی، یک عمل بهینه را انجام می‌دهند. این روش، زمانی کارایی بسیار بالایی خواهد داشت که مدل سیستم به صورت طبیعی موجود نباشد و یا به دست آوردن آن موجب رحمت فراوان گردد. در این صورت می‌تران، آن را جایگزین مناسبی برای منطق‌های کنترلی دیگر دانست. یکی از معایب اساسی این روش، استفاده از عمل‌های گسسته در حین انجام آن می‌باشد. این در حالی است که خیلی از سیستم‌های دینامیکی با چنین رویکردی، عملکرد بهینه‌ای نخواهند داشت. برای جبران این نقصیه، رویکردهای متفاوتی از جمله تقریب مقادیر ظهور پیدا می‌کنند. در این مقاله از منطق فازی برای پیوسته کردن عمل‌های بهینه استفاده شده است. در این حالت، سیستم یادگیری تقویتی، قوانین بین کنترل‌کننده فازی را در جهت نیل به بهینه‌ترین عمل تنظیم می‌نماید و به این ترتیب می‌تواند عمل‌های پیوسته‌ای را تولید نماید. به این منظور مدل یک آونگ معکوس در سیم مکانیکس در نظر گرفته شده است که توسط کنترل‌کننده طراحی شده است و حرکت آن در دو حالت کنترل زاویه آونگ و کنترل کامل آونگ و ارابه مورد بررسی قرار می‌گیرد. نتایج به دست آمده نشان می‌دهند، هوش مصنوعی به کار گرفته شده به جای انتخاب قوانین موجود، می‌تواند کارایی بالاتری در کنترل سیستم‌های دینامیکی داشته باشد.

**واژه‌های کلیدی** یادگیری تقویتی، منطق فازی، آونگ معکوس.

## Combining the Principles of Fuzzy Logic and Reinforcement Learning for Control of Dynamic Systems

M. Goharimanesh

A.A. Akbari

M.B. Naghibi-Sistani

**Abstract** Reinforcement learning is a method in which agent/agents obtain a positive or negative reward to do an efficient operation. In this way, the performance will be very suitable for the systems which are naturally complicated for deriving the differential equations. This can be a good alternative to other control areas. One of the main disadvantages of this method is considering the discrete actions during it. However, many of dynamical systems couldn't be optimized by this approach. To remedy this deficiency, different approaches have emerged, including approximate methods. In this paper, fuzzy logic is used to continually optimize the operations. In this case, the reinforcement learning method sets the fuzzy control rules which are the principles of optimal control. Two approaches, stabilizing the pendulum and both of pendulum and cart are considered to control the pole- cart problem in this paper. The results show that the applied artificial intelligence can be used as a proper solution for the taken policy.

**Key Words** Reinforcement learning, Fuzzy logics, Inverse pendulum.

\*تاریخ دریافت مقاله ۹۲/۶/۱۰ و تاریخ پذیرش آن ۹۳/۸/۵ می‌باشد.

(۱) دانشجوی دکتری مهندسی مکانیک، دانشگاه فردوسی مشهد

(۲) نویسنده مسئول: دانشیار گروه مهندسی مکانیک، دانشگاه فردوسی مشهد. akbari@um.ac.ir

(۳) دانشیار گروه مهندسی برق، دانشگاه فردوسی مشهد

## مقدمه

خودرو مورد استفاده قرار گرفته است. در [11,12] کنترل واژگونی خودرو با استفاده از سیستم تعليق نيمه‌فعال کنترلی طراحی شد که با رویکرد یادگیری تقویتی، ضرایب یک قانون کنترلی به دست می‌آمد. در [13] کنترل تعليق یک خودروی سواری با یادگیری تقویتی مطرح شده است. در تعقیب مسیر و برنامه‌ریزی آن، مطالعاتی نیز صورت گرفته است که در اکثر موارد از مدل‌های روباتیکی و کوچک استفاده شده است [14]. در کنترل دینامیک خودرو، کنترلی با استفاده از فازی و کنترل واژگونی خودرو، کنترلی با استفاده از فازی و یادگیری تقویتی بر روی خودروهای سنگین صورت پذیرفت [15]. در کنترل حالت شارژ خودروهای هیبریدی، نیز الگوریتم‌های یادگیری تقویتی نیز توانسته‌اند به خوبی توانایی خود را نشان دهند [16]. در کنترل خودروهای بی‌سرنشین، مطالعات گوناگونی صورت گرفته است. در [17] کنترل یک هوایپما مدل و در [18] کنترل هلیکوپتر برای مانورهای مختلف انجام گرفته است. کنترل دوچرخه به عنوان یک خودروی ناپایدار نیز مورد مطالعه قرار گرفته است [19]. پارک خودرو، حرکت رو به عقب خودروها، مخصوصاً خودروهای تجاری و چند مفصلی نیز چالشی بزرگ می‌باشد که راه حل مناسبی با استفاده از یادگیری تقویتی می‌توان برای آن یافت. اگرچه مطالعات صورت گرفته در این مورد خاص صرفاً بر روی سینماتیک حرکت است و به رفتار دینامیکی خودرو بهایی داده نشده است [20].

به دلیل رفتار غیرخطی مواد هوشمند که اخیراً نیز کاربرد بسزایی در علوم مختلف دارا می‌باشند، نمی‌توان مدل دقیقی را برای آنها متصور شد، لذا روش‌هایی که لزوماً مبتنی بر مدل نیستند و می‌توانند با استفاده از داده‌های محیطی کنترل این مواد را به عهده بگیرند بسیار مهم هستند [21,22]. در [23] کنترل یک ماده هوشمند مغناطیسی با یادگیری تقویتی صورت گرفته است.

کنترل سیستم‌های دینامیکی، با در نظر گرفتن مدل سیستم، همواره مورد توجه قرار گرفته است. هنگامی که مدل، دست‌خوش تغییراتی چون عدم قطعیت گردد، نیز با ورود تکنیک‌هایی هم‌چون کنترل مقاوم این مسئله راه حل مناسبی پیدا می‌کند. اما چنان‌چه، مدل به‌طور شفاف مشهود نباشد و یا نتوان معادلات دینامیکی سیستم را استخراج نمود، می‌توان از کنترل بر پایه یادگیری تقویتی استفاده کرد [1]. در این شیوه، کنترل‌کننده توسط یک نقاد بیرونی تنبیه و یا تشویق می‌گردد و براساس همان مواضع، می‌تواند خبرگی لازم را در جهت کنترل دینامیک موجود به دست آورد [2]. در این روش، دینامیک سیستم، محیط نام‌گذاری می‌گردد و خروجی‌های کنترل‌کننده به عنوان عامل یا عاملان می‌توانند کارایی لازم را به وجود بیاورند. انتخاب حالت‌ها، یکی از مهم‌ترین قسمت‌های این روش می‌باشد که بایستی توسط طراح، هوشمندانه صورت پذیرد. در واقع، حالات، همان بازخوردهایی هستند که در طی حل دینامیک سیستم به کنترل وارد می‌گردند. در یادگیری تقویتی، روش‌های مختلفی برای خبره کردن هوش سیستم وجود دارد. یکی از این روش‌ها، یادگیری کیو (Q-Learning) می‌باشد [3]. در این روش، حالت‌ها و عمل‌ها به صورت یک ماتریس قرار می‌گیرند. این جدول پس از گذشت تکرارهای انجام گرفته، به یک سیاست بهینه مبدل می‌شود که عامل می‌تواند با توجه به قرارگیری حالت فعلی، عمل بهینه خود را تعیین نماید.

کاربردهای روش‌های یادگیری تقویتی طیف وسیعی را به خود اختصاص می‌دهند. در [4-6] از یادگیری تقویتی برای کنترل پرواز استفاده شده است. در [7,8] از این روش برای کنترل ربات بهره گرفته شده است. در [9] از یادگیری تقویتی برای حل مسائل بهینه‌سازی استفاده شده است. در [10] با استفاده از این روش، پارامترهای تنظیم‌کننده کنترل PID یک موتور

حالتی از سیستم در هر مرحله می‌باشد. چنان‌چه در یک سیستم، تعدد حالات زیادتری اتفاق افتاد، این امر سبب پایین آمدن کارایی الگوریتم یادگیری تقویتی می‌گردد. به همین دلیل از روش‌های تقریب به این منظور استفاده شده است. یکی از رویکردهایی که می‌توان در حل این معضل استفاده نمود، راهکاری است که توسط منطق فازی پی‌ریزی می‌شود [38,39]. از ۱۹۹۴ که برنجی [40] استفاده از فازی را به عنوان پیوسته کردن سیستم‌های دینامیکی معرفی نمود تا امروز، بیشتر رویکردهای مورد استفاده در کنترل که از یادگیری تقویتی استفاده می‌کنند، از فازی بهره گرفته‌اند.

ادامه مقاله به این صورت تنظیم شده است که ابتدا استراتژی یادگیری تقویتی و روش‌های مبتنی بر آن مرور و بررسی خواهد شد. پس از آن، طرح مسئله‌ای کلاسیک انجام می‌گیرد و مدل آونگ معکوس با در نظر گرفتن یک شبیه‌ساز خارجی، مورد مطالعه قرار خواهد گرفت. پس از آن، کنترل براساس منطق فازی و رویکرد یادگیری تقویتی معرفی و انجام می‌گیرد. در نهایت، نتایج این روش نمایش داده خواهد شد.

### استراتژی یادگیری تقویتی

روش‌های زیادی برای ایجاد یک سیاست بهینه ساخته و پرداخته شده‌اند. روش‌های برنامه‌ریزی پویا (Dynamic Programming)، روش مونت کارلو (Monte Carlo)، سارسا (SARSA) و یادگیری کیو از (Q-learning) این دست می‌باشند [1]. استراتژی مورد استفاده در این مقاله، یادگیری کیو می‌باشد. رابطه کیو، با استفاده از معادله (۱)، ارتباط منطقی میان حالت‌های شکل گرفته در مسئله و عمل‌های آن را ایجاد می‌نماید.

توصیف پارامترهای مرتبط به آن در ادامه بیان خواهد شد.

$$Q(s,a) \leftarrow Q(s,a) + \alpha \left[ r + \gamma \max_{a'} Q(s,a') - Q(s,a) \right] \quad (1)$$

در [24] کنترل مفاصل بیومکانیکی مورد مطالعه قرار گرفته است. هم‌چنین در مورد ربات‌های موازی [25]، انسان‌نما [26] و ربات‌های صنعتی، مطالعات وسیعی صورت گرفته است [27]. در این زمینه نیز، اخیراً یک مطالعه مروی در [28] انجام شده است که به کاربرد الگوریتم‌های مبتنی بر یادگیری تقویتی در رباتیک می‌پردازد. در کنترل عملگرهای مکانیکی صنعتی، موارد [29,30] مطالعاتی را پیرامون کنترل حرکت مکانیزم بال-اسکرو (Ball-Screw) انجام داده‌اند. در زمینه تولید و فرآیندهای صنعتی، [31] مطالعه‌ای را بر روی کنترل چرخه تولید توسط یادگیری تقویتی داشته است.

در مطالعه‌های بیولوژیکی نیز یادگیری تقویتی در کنترل بیماری ایدز [32]، تصفیه آب [33,34] و کنترل سرطان [35] نیز کاربرد داشته است. در برخی مطالعات از یادگیری تقویتی به عنوان یک ابزار کمکی برای بهینه کردن کننده موجود گزارش شده است. به عنوان مثال انتخاب بهینه پارامترها در یک کنترل کننده مدل لغزشی توسط یادگیری تقویتی سبب کم شدن تصادم (Chattering) کنترل کننده شده است [36]. در [37] ارتباط میان یادگیری تقویتی و کنترل تطبیقی و پیاده‌سازی روش پیشنهادی را بر روی یک ربات انسان‌نما نشان می‌دهد. کنترل آونگ معکوس در اکثر مطالعات نیز به عنوان یک مثال کلاسیک از شروع ایده‌پردازی بر روی یادگیری تقویتی و مقایسه الگوریتم‌های گوناگون مطالعه شده است.

یکی از محدودیت‌هایی که الگوریتم‌های یادگیری تقویتی دارند، استفاده غیرپیوسته از عمل‌هایی است که در حین ساخت سیاست بهینه از سوی عامل تعیین می‌شود. گستینگی در عمل‌ها، نه تنها سیاست بهینه‌ای را در حد عالی به وجود نمی‌آورد بلکه ممکن است در خیلی از سیستم‌های دینامیکی حتی کاستی‌هایی اندک را نیز برطرف ننماید. کاستی صورت گرفته به آن دلیل است که اصل یادگیری تقویتی بر پایه بروزرسانی هر

مسئله، این مقدار  $0.5$  در نظر گرفته شده است. در این نوشتاب برای مصالحة بین اکتشاف (explore) و استخراج (exploit) از الگوریتم حریصانه استفاده شده است. انتخاب عملکرد حریصانه یک وسیله عمومی و مؤثر برای تعادل اکتشاف و بهره‌برداری در یادگیری تقویتی است. این بدین معنی است که احتمال انتخاب بدترین عمل به اندازه انتخاب بهترین عمل بعدی است. در این الگوریتم، در هر مرحله، عامل برای انتخاب عمل‌های خود، تنها به این بسته می‌کند که بیشترین عمل را انتخاب نماید نه بهترین آنها را. به این ترتیب او حریصانه به دنبال مقادیر بیشتری از عمل‌های پیش‌روی خود می‌باشد. برای این‌که این رفتار عامل کاملاً حریصانه نباشد، در طی انتخاب عمل برای او می‌توان قیدی را قرار داد، به‌طوری که اگر به‌طور تصادفی، یک مقدار بیشتر از مقدار قید عامل باشد، عمل پیش‌رو حریصانه انتخاب گردد و در غیر این صورت عامل یک عمل را به صورت تصادفی انتخاب نماید تا در بین عمل‌های موجود یک کاوش منطقی نیز داشته باشد. چنین الگوریتمی را اپسیلون-گریدی ( $\epsilon$ -greedy) می‌نامند که در آن بازه تعیین مقدار اپسیلون بین صفر و یک می‌باشد. در این مسئله، مقدار پارامتر این الگوریتم  $0.01$  در نظر گرفته شده است. مثال تعیین پاداش می‌تواند به صور متفاوتی اتفاق بیفتد. مثلاً آن‌که می‌توان حالتی که منجر به زاویه و سرعت زاویه‌ای کمتر از  $1$  است را با پاداش  $1$  و سایر حالات را با پاداش منفی  $1$ ، در نظر گرفت. هم‌چنین می‌توان از فاصله اقلیدسی هر کدام از حالت‌ها با حالت تعادل آنها استفاده نمود و یکتابع پاداش هم‌چون تابع زیر در نظر گرفت.

$$R(\alpha, \omega) = \log(1 / ((\alpha - 0)^2 + (\omega - 0)^2)) \quad (2)$$

در مسئله حاضر که حالت‌ها، قوانین فی مابین منطق فازی می‌باشند، ممکن است برخی از آنها هیچ‌گاه مورد مطالعه قرار نگیرند و در جدول کیو، خالی گذارد شوند. هم‌چنین، عمل‌های مورد استفاده که در جدول کیو، مقادیر گسسته‌ای می‌باشند، پس از شکل‌گیری در منطق فازی به صورت پیوسته به سیستم القاء می‌گردند. حالت فعلی سیستم را با  $\delta$  و عمل حاضر را با  $a$  نشان می‌دهند. پس از آن‌که حالت سیستم به صورت بازخورد تحويل داده می‌شود، با بررسی به عمل آمده، پاداش او تنظیم می‌گردد. این مقدار با  $\alpha$  مشخص می‌شود. هم‌چنین، عمل صورت گرفته، عامل را به حالت بعدی  $\delta'$  نیل می‌دهد. عبارت  $\max_a Q(s, a)$  به این معنا است که مقدار بیشینه حالت آتی عامل یا همان  $\delta'$  به‌ازای عمل‌های مختلف چه مقدار می‌باشد. هم‌چنین، نرخ یادگیری با  $\alpha$  مشخص می‌شود. زمانی که نرخ یادگیری صفر در نظر گرفته شود، گویی عامل هیچ چیزی را فرا نمی‌گیرد و هر عملی را که انتخاب می‌کند بر پایه نتایج همان لحظه می‌باشد. اگر این نرخ به یک نزدیک شود، به این معنا است که عامل تنها به یافته‌های پیشین خویش بها می‌دهد و هیچ نتیجه فعلی را در روند تصمیم‌گیری قرار نداده است. به راحتی می‌توان مشاهده نمود که اگر برابر با یک شود،  $Q(s, a)$  از معادله حذف می‌گردد. در آونگ معکوس کترول شده میزان نرخ یادگیری  $\alpha$  در نظر گرفته شده است. نرخ کاهش با  $\gamma$  مشخص می‌شود. این عدد اگر صفر باشد، عامل تنها به پاداش فعلی خود بسته می‌کند. گویی تنها، در این لحظه جلوی پای خود را می‌بیند و فرست طلبی را پیش‌خود می‌نماید. در صورتی که اگر یک باشد، خود را برای یک پاداش در آینده کاری آماده می‌کند. این‌که این دو عدد چند باشند، تقریباً جواب مشخصی ندارد و برای هر مسئله می‌تواند، متفاوت به‌دست آید. در این

$$\begin{aligned} \ddot{\theta} &= \frac{g \sin(\theta) + \cos(\theta) \left( f - ml \dot{\theta}^2 \sin(\theta) + \mu_c \operatorname{sgn}(\dot{x}) \right) / (m_c + m) - \mu_p \dot{\theta} / ml}{l \left( 4/3 - m \cos^2(\theta) \right) / (m_c + m)} \\ \ddot{x} &= \frac{f + ml \left( \dot{\theta}^2 \sin(\theta) - \ddot{\theta} \cos(\theta) \right) - \mu_c \operatorname{sgn}(\dot{x})}{m_c + m} \end{aligned} \quad (3)$$

در جدول (۱) توصیف هر پارامتر آورده شده است.

جدول ۱ پارامترهای موجود در معادلات آونگ معکوس

$\theta$	زاویه آونگ، نسبت به محور عمود بر حسب درجه (مثبت در سمت چپ، منفی در سمت راست)
$\dot{\theta}$	سرعت زاویه‌ای آونگ بر حسب درجه بر ثانیه
$\ddot{\theta}$	شتاب زاویه‌ای آونگ بر حسب درجه بر ثانیه
$f$	شتاب گرانشی زمین بر حسب متر بر محدود ثانیه
$m$	نیروی وارد بر اربابه بر حسب نیوتون
$m_c$	جرم اربابه بر حسب کیلوگرم
$l$	نصف طول آونگ بر حسب متر
$\mu_c$	ضریب اصطکاک اربابه بر روی محور حرکتی
$\mu_p$	ضریب اصطکاک آونگ بر روی اربابه
$x$	موقعیت حرکتی مرکز ثقل اربابه بر حسب متر
$\dot{x}$	سرعت خطی مرکز ثقل اربابه بر حسب متر بر ثانیه
$\ddot{x}$	شتاب خطی مرکز ثقل اربابه بر حسب متر بر محدود ثانیه

یکی از مشکلاتی که اکثر معادلات آورده شده دارند، در نظر نگرفتن حالت واقعی آونگ معکوس به صورت یک جرم صلب می‌باشد. چرا که در این حالت هم اربابه و هم آونگ معکوس، ممان اینرسی مورد نظر خود را به دلیل شکل، ظاهر و توزیع وزن دارا هستند که اکثر این موارد در این معادلات بررسی نمی‌شوند. این در حالی است که استفاده از یادگیری تقویتی به همین دلیل می‌باشد که سیستم از نگاه نقاد کنترلی فاقد شناخت می‌باشد و تنها به صرف دریافت بازخوردهای لازم از محیط، عمل کنترلی انجام می‌پذیرد.

چنین تابعی سبب می‌شود که به حالات نزدیک تعادل، پاداش فوق العاده مثبتی تعلق بگیرد. در حالی که هر چقدر از آن حالات فاصله گرفته شود، پاداش، رنگ منفی تری به خود می‌گیرد. این خاصیت سبب می‌شود یک پیوستگی در تشویق و تنبیه صورت پذیرد.


در مطالعه حاضر، دو حالت مختلف برای کنترل آونگ توسط یادگیری تقویتی و فازی استفاده شده است. در مورد اول، تنها زاویه و سرعت زاویه‌ای آونگ کنترل شده است. در این حالت، تابع پاداش به این صورت تعریف می‌شود که برای زوایای کمتر از  $0/5$  درجه و سرعت زاویه‌ای کمتر از  $1$  درجه بر ثانیه، پاداش  $1$  و برای حالتی که زاویه و سرعت زاویه‌ای آونگ به ترتیب بیشتر از  $5$  درجه و  $50$  درجه بر ثانیه باشد، مقدار منفی  $1$  را لحاظ می‌کند. در سایر موارد، پاداشی برابر صفر به عامل داده می‌شود.

در نگاه دوم کنترلی که مبتنی بر کنترل تمام آونگ می‌باشد، چنان‌چه به علاوه زاویه آونگ و سرعت زاویه‌ای آن در حالت قبل، موقعیت اربابه و سرعت آن به ترتیب کمتر از  $1/0$  متر و  $1/0$  متر بر ثانیه باشند، پاداشی برابر با  $1$  و چنان‌چه این دو مورد به ترتیب بیشتر از  $0/3$  متر و  $0/5$  متر بر ثانیه باشند، پاداشی برابر با منفی یک به آن داده خواهد شد.


در مثال حاضر، آونگ در محیط سیمولینک ساخته می‌شود و سپس توسط سیگنال‌های بازخوردهای در هر لحظه مورد ارزیابی قرار می‌گیرد و عمل بهینه در هر زمان تعیین می‌شود.

### مدل‌سازی و شبیه‌سازی آونگ معکوس

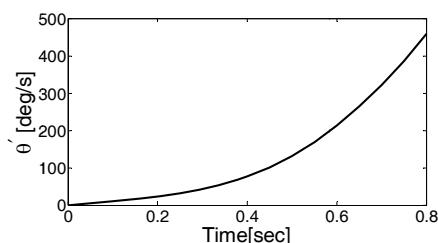
روش‌های زیادی برای مدل‌سازی و شبیه‌سازی آونگ معکوس وجود دارند. در [39] معادلات آونگ معکوس به صورت زیر آورده شده است.



شکل ۱ مدل کامل آونگ معکوس با در نظر گرفتن نیروی اصطکاک در سیم مکانیکس



شکل ۲ زاویه آونگ معکوس کنترل نشده بر حسب زمان در طی ۰.۵ ثانیه



شکل ۳ سرعت زاویه‌ای آونگ معکوس کنترل نشده بر حسب زمان در طی ۰.۵ ثانیه


### کنترل آونگ معکوس

نظریه مجموعه‌های فازی در سال ۱۹۶۵ مطرح شد [41]. بزرگ‌ترین مشکلی که سر راه سیستم‌های فازی می‌باشد ایجاد قوانین لازم برای ارتباط بین ورودی‌ها و خروجی‌ها است که بایستی توسط یک فرد خبره انجام پذیرد. در این قسمت، یادگیری تقویتی، قوانین بهینه را


در این مقاله، مدل حاضر در فضای سیم مکانیکس (Simmechanics) در متلب شبیه‌سازی می‌گردد. حلگرهایی که در این روش برای حل سینماتیک و دینامیک ربات استفاده می‌شوند براساس روش‌های تکرارپذیری انرژی حل می‌شوند. در این برنامه، آونگ به صورت تقریباً واقعی موجودیت پیدا می‌کند و با ارتباطی که میان سیستم کنترلی و نقاد مربوط صورت می‌پذیرد، عمل کنترل انجام خواهد گرفت. در تصویر (۱) مدل آونگ معکوس با در نظر گرفتن تمامی اجزای آن در فضای سیمولینک و با استفاده از سیم مکانیکس ترسیم شده است. در این نوشتار جرم ارابه و آونگ به ترتیب  $\frac{1}{5}$  و  $\frac{2}{3}$  کیلوگرم گذاشته شده است. همچنین ممان اینرسی حول محور دوران، برای ارابه و آونگ، به ترتیب  $1 \times 10^6$  و  $10^6$  کیلوگرم مترمربع در نظر گرفته شده است. اصطکاک ویسکوز نیز میان زمین و ارابه برابر با  $0.1$  قرار داده شده است. با در نظر گرفتن مقادیر اولیه  $3^\circ$  درجه برای زاویه و سرعت زاویه‌ای صفر درجه بر ثانیه برای آونگ، می‌توان شبیه‌سازی این مدل را در شکل‌های (۲) و (۳) که به ترتیب بیانگر زاویه و سرعت زاویه‌ای آونگ کنترل نشده می‌باشند، مشاهده نمود.

انجام می‌دهد.

در شکل‌های ۶ و ۵ توابع عضویت هر کدام از ورودی‌های سیستم فازی برای هر دو مجموعه فازی به نمایش گذاشته شده است. در هر کدام از این دو شکل، ۹ تابع تعلق مثلثی شکل استفاده شده است که درجه عضویت زاویه و سرعت زاویه‌ای برای هر یک بین صفر تا ۱ مشخص شده‌اند.



شکل ۴ مجموعه فازی




شکل ۵ توابع تعلق ۹ گانه مربوط به حالت زاویه و سرعت زاویه‌ای آونگ


تولید و در مدار اجرای کنترل کننده فازی قرار خواهد داد. هر سیگنالی که از سیستم دریافت می‌گردد در واقع یک ورودی برای سیستم فازی محسوب می‌شود، پس از تعیین مقدار تابع عضویت برای هر کدام از ورودی‌ها، قانون متناظر با آنها استخراج و متناظر با آن قانون، حالت مشخصه در جدول کیو تعیین می‌شود و براساس تکنیک‌هایی نظری اپسیلون گریدی ( $\epsilon$ ) برای سافت مکس (softmax)، عمل مربوط تعیین و در خروجی فازی قرار می‌گیرد. سیگنال‌های بازگشتی به عامل در قسمت اول، تنها زاویه آونگ و سرعت زاویه‌ای آن بر حسب درجه و درجه بر ثانیه می‌باشند و در قسمت دوم دو مورد موقعیت حرکت اربه و سرعت آن نیز به منظور کنترل دقیق‌تر، اضافه می‌گردند. در شبیه‌سازی اول این مقاله ۹ تابع تعلق برای ورودی اول و ۹ تابع برای ورودی دوم در نظر گرفته می‌شود. در مجموع ۸۱ حالت و یا قانون برای سیستم فازی می‌توان متصور شد. در قسمت دوم برای کاهش میزان محاسبات برای هر ورودی، ۵ تابع تعلق در نظر گرفته شده است که در مجموع ۶۲۵ قانون باشند احراز شوند. خروجی هر قانون به صورت یک عمل از یک مجموعه عمل‌های گستته تعیین می‌شود که برای مسئله حاضر می‌توان مجموعه اعداد شکل (۴) را در نظر گرفت.

$$A = \{-10, -8, -6, -4, -2, 0, 2, 4, 6, 8, 10\} \quad (4)$$

بر این اساس جدول کیو، با نعداد سطر متناظر با تعداد قوانین و ۱۱ ستون برای ارزش‌گذاری هر سلول در جهت تعیین سیاست بهینه استفاده می‌شود. شکل (۴) این ارتباط را در یک کنترل کننده فازی نشان می‌دهد. شکل اول، مربوط به مجموعه‌ای است که در آن تنها حرکت آونگ کنترل می‌شود و مجموعه دوم حالتی است که کنترل کامل آونگ و اربه را با یکدیگر




شکل ۷ سیاست بهینه به دست آمده از یادگیری آونگ براساس دو حالت زاویه و سرعت زاویه‌ای آونگ



شکل ۸ موقعیت آونگ معموس کنترل شده در زمان‌های متالی و متفاوت

همان‌طور که در شکل (۸) نشان داده شده است، شبیه‌سازی اول مقاله با در نظر گرفتن زاویه و حرکت زاویه‌ای آونگ تنها می‌تواند حالت عمودی آن را کنترل تماید و همان‌طور که در نتایج مربوط به موقعیت ارابه نشان داده شده است، حرکت ارابه هیچ کنترلی بر روی آن صورت نگرفته است. در شکل‌های (۹-۱۲) به ترتیب زاویه، سرعت زاویه‌ای آونگ، موقعیت ارابه و




شکل ۶ توابع تعلق ۵ گانه مربوط به ۴ حالت زاویه و سرعت آونگ و موقعیت و سرعت ارابه

### کنترل حرکت عمودی آونگ


در شکل (۷) سیاست بهینه مورد نظر نشان داده شده است. در واقع این شکل نشان می‌دهد که برای هر زاویه و هر سرعت زاویه‌ای چه مقدار نیرو به عنوان عمل بایستی ایجاد شود تا پایداری آونگ محرز گردد. قسمت‌های روشن‌تر به معنای مقادیر بیشتر و قسمت‌های تاریک‌تر به معنای نیروی کمتر می‌باشند.

شکل (۸) دستاورد این کنترل کننده را در یک اجرا در زمان‌های مختلف نشان می‌دهد و مشخص می‌کند که سیستم به پایداری لازم دسترسی پیدا کرده است.

پیوسته بودن نتایج یادگیری تقویتی را با استفاده از سیستم فازی نمایش می‌دهد.



شکل ۱۳ نیروی کترل آونگ معکوس کترل شده بر حسب زمان




شکل ۱۴ مقدار پاداش‌های داده شده بر حسب زمان برای آونگ مبتدی و خبره

شکل (۱۴)، مقدار پاداش‌های کسب شده براساس مدل پیشنهادی تابع پاداش در بخش‌های پیشین را در یک اجرا برای یک آونگ خبره و یک آونگ مبتدی به نمایش می‌گذارد. همان‌طور که نشان داده شده است، مقدار پاداش‌های کسب شده برای آونگ مبتدی رو به کاهش می‌باشد. این در حالی است که آونگ خبره در طی زمان به دلیل کترل زاویه و سرعت زاویه‌ای خود می‌تواند پادash‌های بیشتری را کسب نماید.


### کترل کامل آونگ و ارابه

در قسمت قبل کترول آونگ تنها به منظور حفظ حالت عمودی آونگ بود و حرکت رو به جلو و یا رو به عقب ارابه در نظر گرفته نشده است. در این بخش، دو حالت جدید یعنی موقعیت و سرعت ارابه نیز به حالت‌های پیشین اضافه و کترول آونگ به این ترتیب


سرعت آن بر حسب زمان در طی ۵ ثانیه نشان داده شده‌اند.




شکل ۹ زاویه کترول شده آونگ بر حسب زمان



شکل ۱۰ سرعت زاویه‌ای کترول شده آونگ بر حسب زمان




شکل ۱۱ موقعیت کترول نشده ارابه بر حسب زمان




شکل ۱۲ سرعت کترول نشده ارابه بر حسب زمان

در تصویر (۱۳) میزان نیرویی که جهت کترول آونگ معکوس توسط سیستم فازی-یادگیری تقویتی تأمین شده است نمایش داده می‌شود. این تصویر،


این مورد با خبرگی بیشتر عمل کرده است و موقعیت و سرعت حرکت ارباب را نیز به کنترل در آورده است. این واقعیت در تصویر (۲۵) که از لحظه نخست حرکت آونگ و به فواصل ۱۰ ثانیه گرفته شده است، این واقعیت را به خوبی نشان می‌دهد.




شکل ۱۵ زاویه کنترل شده آونگ بر حسب زمان توسط فازی و یادگیری تقویتی



شکل ۱۶ زاویه کنترل شده آونگ بر حسب زمان توسط کنترل کننده فازی



شکل ۱۷ سرعت زاویه‌ای کنترل شده آونگ بر حسب زمان توسط فازی و یادگیری تقویتی



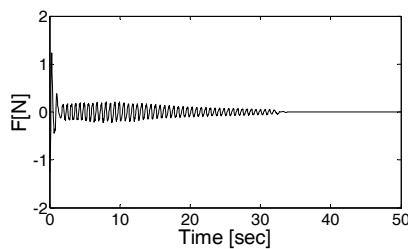
شکل ۱۸ سرعت زاویه‌ای کنترل شده آونگ بر حسب زمان توسط کنترل کننده فازی

انجام می‌گیرد. نتایج به دست آمده برای سیستم آونگ در شکل‌های (۱۵-۲۵) نشان داده شده است. برای مقایسه کنترل طراحی شده با یک کنترل کننده دیگر، منطق فازی بار دیگر استفاده می‌شود و این بار به منظور پیدا کردن تعداد بالای قوانین (۶۲۵) از ۱۶ قانون که توسط یک فرد خبره مشخص شده است، استفاده می‌گردد. در این حالت برای هر کدام از چهار حالت، دوتابع تعلق بیشتر در نظر گرفته نمی‌شود. قوانین مورد استفاده به صورت جدول (۲) می‌باشند. در این جدول، سطرها مختص موقعیت و سرعت ارباب و ستون‌ها بیانگر زاویه و سرعت زاویه‌ای آونگ می‌باشند که حرف N به معنای کمترین مقدار در تابع عضویت آن ورودی و P به معنای بیشترین مقدار آن می‌باشد. در داخل جدول نیز حروف N, P, Z و Z به معنای کمترین، بیشترین و مقدار صفر نیروی وارد شده می‌باشد که از مجموعه اعداد رابطه (۴) نتیجه می‌شوند.

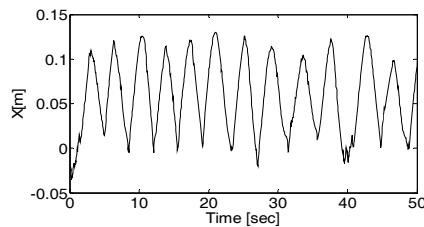
جدول ۲ قواعد فازی نگاشته شده توسط یک خبره انسانی

قوانین	پاندول	سرعت-زاویه			
		ارباب	NN	NP	PN
زاویه	ارباب	P	P	N	N
زاویه	NN	P	Z	Z	N
زاویه	NP	P	Z	Z	N
زاویه	PN	P	P	N	N
زاویه	PP	P	P	N	N





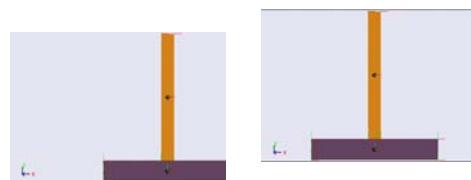
در نمودارهای (۱۵-۲۴) زاویه آونگ، سرعت زاویه‌ای آونگ، موقعیت ارباب، سرعت ارباب و نیروی اعمال شده توسط کنترل کننده ارباب برای هر دو الگوریتم فازی پیشنهادی در حالت اخیر به نمایش گذاشته شده است. در مجموعه فازی اول، قوانین توسط یادگیری تقویتی به دست آمده‌اند و در دومین مجموعه، قوانین طبق جدول (۲) گذاشته شده‌اند. همان‌طور که نمودارهای زاویه و سرعت زاویه‌ای آونگ نمایش می‌دهند، کنترل زاویه آونگ در هر دو مجموعه سبب پایداری حرکت آونگ شده است اما، طبق آنچه که نمودار موقعیت ارباب نشان می‌دهد، یادگیری تقویتی در



شکل ۲۴ نیروی کنترلی اعمال شده به ارابه توسط کنترل کننده فازی




شکل ۱۹ موقعیت کنترل شده ارابه بر حسب زمان توسط فازی و یادگیری تقویتی




الگوریتم فازی مبتنی بر یادگیری تقویتی  
قوانین انسانی


شکل ۲۵ موقعیت آونگ معکوس کنترل شده در زمان های متواالی ۱۰ ثانیه در حالت کنترل کامل آونگ و ارابه




شکل ۲۰ موقعیت کنترل شده ارابه بر حسب زمان توسط کنترل کننده فازی



شکل ۲۱ سرعت کنترل شده ارابه بر حسب زمان توسط فازی و یادگیری تقویتی



شکل ۲۲ سرعت کنترل شده ارابه بر حسب زمان توسط کنترل کننده فازی



شکل ۲۳ نیروی کنترلی اعمال شده به ارابه بر حسب زمان توسط فازی و یادگیری تقویتی

قرار گرفت. یادگیری تقویتی برای سیستم‌هایی که معادلات فیزیکی آنها به صورت کاملاً واضح مشخص نمی‌باشند، بیشتر مورد توجه قرار می‌گیرد. به همین دلیل در این مقاله از یک مدل ساخته شده در سیم مکانیکس که آونگ معکوس را شبیه‌سازی می‌نماید استفاده شد و توسط موارد به کار گرفته شده در اجرای یادگیری تقویتی، کنترل‌کننده فازی در طی آن خبره گردید. نتایج به عمل آمده با توجه به حالات مختلف استفاده از کنترل‌کننده طراحی شده و هم‌چنین در مقایسه با کنترل‌کننده‌های دیگر نشان می‌دهند که کنترل‌کننده فعلی از هوش کافی برای کنترل محیط ساخته شده برخوردار می‌باشد. چنین رویکردی می‌تواند برای هر سیستم دینامیکی مجهولی با بالاترین درجهٔ خبرگی مورد استفاده قرار گیرد.

گرچه، با بیشتر کردن تعداد قوانین جدول (۲) می‌توان به کنترل بهتری دست پیدا کرد، اما با استی تووجه داشت که افزایش تعداد قوانین، پیدا کردن آن را نیز به چالش می‌کشد و زمان زیادی را برای یک شخص به خود اختصاص می‌دهد و این در حالی است که چنان‌چه مدل آونگ دستخوش تغییرات شود، کنترل‌کننده موجود نیز باستی با یک سری قوانین تازه به کار خویش ادامه دهد در حالی که با استفاده از یادگیری تقویتی می‌توان قوانین را با تعدد بالای خود و هرگونه تغییر در مدل دینامیکی به وجود آورد.

### نتیجه‌گیری

در این مقاله رویکرد یادگیری تقویتی برای بهینه کردن قوانین فازی در کنترل یک سیستم دینامیکی مورد توجه

### مراجع

1. Sutton, R.S. and Barto, A.G., "Reinforcement learning: An introduction", Vol. 1, Cambridge Univ Press, (1998).
2. Kaelbling, L.P., Littman, M.L. and Moore, A.W. "Reinforcement learning: A survey", *Journal of Artificial Intelligence Research*, Vol. 4, pp. 237-285, (1996).
3. Watkins, C.J. and Dayan, P., "Q-learning", *Machine learning*, Vol. 8, pp. 279-292, (1992).
4. Berenji, H. Lea, R. Jani, Y., Khedkar, P., Malkani, A. and Hoblit, J., "Space shuttle attitude control by reinforcement learning and fuzzy logic", in *Fuzzy Systems, Second IEEE International Conference on* 1993, pp. 1396-1401, (1993).
5. Graepel, T. Herbrich, R. and Gold, J., "Learning to fight", in *Proceedings of the International Conference on Computer Games: Artificial Intelligence, Design and Education*, pp. 193-200, (2004).
6. Ng, A.Y., Coates, A. Diel, M., Ganapathi, V., Schulte, J., Tse, B., Berger, E. and Liang, E., "Autonomous inverted helicopter flight via reinforcement learning", *Experimental Robotics IX*, ed: Springer, pp. 363-372, (2006).
7. Lin, C.-K. "A reinforcement learning adaptive fuzzy controller for robots," *Fuzzy Sets and Systems*, Vol. 137, pp. 339-352, (2003).
8. Yung, N.H. and Ye, C. "An intelligent mobile vehicle navigator based on fuzzy logic and reinforcement learning", *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, Vol. 29, pp. 314-321, (1999).
9. Barto, A. and Crites, R., "Improving elevator performance using reinforcement learning", *Advances in neural information processing systems*, Vol. 8, pp. 1017-1023, (1996).
10. Howell, M. and Best, M.C., "On-line PID tuning for engine idle-speed control using continuous action reinforcement learning automata", *Control Engineering Practice*, Vol. 8, pp. 147-154, (2000).
11. Frost, G., Howell, M., Gordon, T. and Wu, Q., "Dynamic vehicle roll control using reinforcement

- learning", (1996).
12. Howell, M.N. Frost, G.P. Gordon, T.J. and Wu, Q.H., "Continuous action reinforcement learning applied to vehicle suspension control", *Mechatronics*, Vol. 7, pp. 263-276, (1997).
  13. Bucak, İ. and Öz, H., "Vibration control of a nonlinear quarter-car active suspension system by reinforcement learning", *International Journal of Systems Science*, Vol. 43, pp. 1177-1190, (2012).
  14. Lauer, M., "A case study on learning a steering controller from scratch with reinforcement learning," in *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pp. 260-265, (2011).
  15. Akbari, A.A. and Goharimansh, M., "Yaw Moment Control Using Fuzzy Reinforcement Learning", *Advanced Vehicle Control (AVEC14)*, (2014).
  16. Vogel, A., Ramachandran, D., Gupta, R. and Raux, A., "Improving Hybrid Vehicle Fuel Efficiency Using Inverse Reinforcement Learning", *AAAI*, (2012).
  17. Woodbury, T., Dunn, C. and Valasek, J., "Autonomous Soaring Using Reinforcement Learning for Trajectory Generation", (2014).
  18. Ng, A.Y., Kim, H.J. Jordan, M.I. Sastry, S. and Ballianda, S., "Autonomous Helicopter Flight via Reinforcement Learning", *NIPS*, (2003).
  19. Cam, B. Dembia, C. and Israeli, J., "Reinforcement learning for bicycle control", (2013).
  20. Yamashita, S., Horiuchi, T. and Kato, S., "A study on skill acquisition in trailer-truck steering problem by reinforcement learning", *SICE 2002. Proceedings of the 41st SICE Annual Conference*, pp. 810-812, (2002).
  21. Kirkpatrick, K. and Valasek, J., "Reinforcement learning for characterizing hysteresis behavior of shape memory alloys", *Journal of Aerospace Computing, Information, and Communication*, Vol. 6, pp. 227-238, (2009).
  22. Kirkpatrick, K. and Valasek, J., "Active length control of shape memory alloy wires using reinforcement learning", *Journal of Intelligent Material Systems and Structures*, Vol. 22, pp. 1595-1604, (2011).
  23. Zhou, M., Hu, B., Gao, W. and Wang, J., "Reinforcement Learning Fuzzy Neural Network Control for Magnetic Shape Memory Alloy Actuator," *International Journal of Control & Automation*, Vol. 7, No. 6, pp. 109-122, (2014).
  24. Uragami, D., Takahashi, T. and Matsuo, Y., "Cognitively inspired reinforcement learning architecture and its application to giant-swing motion control", *Biosystems*, Vol. 116, pp. 1-9, (2014).
  25. Shahriari, M. and Khayyat, A.A., "Gait analysis of a six-legged walking robot using fuzzy reward reinforcement learning", *Fuzzy Systems (IFSC), 13th Iranian Conference on*, pp. 1-4, (2013).
  26. Navarro-Guerrero, N., Weber, C., Schroeter, P. and Wermter, S., "Real-world reinforcement learning for autonomous humanoid robot docking", *Robotics and Autonomous Systems*, Vol. 60, pp. 1400-1407, (2012).
  27. Miljković, Z. Mitić, M. Lazarević, M. and Babić, B., "Neural network reinforcement learning for visual control of robot manipulators", *Expert Systems with Applications*, Vol. 40, pp. 1721-1736, (2013).
  28. Kober, J., Bagnell, J.A. and Peters, J., "Reinforcement learning in robotics: A survey," *The International Journal of Robotics Research*, Vol. 32, pp. 1238-1274, (2013).
  29. Fernandez-Gauna, B., Lopez-Gude, J.M. and Graña, M., "Transfer learning with partially constrained models: application to reinforcement learning of linked multicomponent robot system control", *Robotics and Autonomous Systems*, Vol. 61, pp. 694-703, (2013).
  30. Fernandez-Gauna, B., Ansoategui, I. Etxeberria-Agiriano, I. and Graña, M., "Reinforcement learning of ball screw feed drive controllers", *Engineering Applications of Artificial Intelligence*, (2014).
  31. Zarandi, M.H.F. Moosavi, S.V. and Zarinbal, M., "A fuzzy reinforcement learning algorithm for

- inventory control in supply chains", *The International Journal of Advanced Manufacturing Technology*, Vol. 65, pp. 557-569, (2013).
32. Parbhoo, S., "A reinforcement learning design for HIV clinical trials", (2014).
33. Syafie, S. Tadeo, F. and Martinez, E., "Model-free learning control of neutralization processes using reinforcement learning", *Engineering Applications of Artificial Intelligence*, Vol. 20, pp. 767-782, (2007).
34. Syafie, S. Tadeo, F., Martinez, E. and Alvarez, T., "Model-free control based on reinforcement learning for a wastewater treatment problem", *Applied Soft Computing*, Vol. 11, pp. 73-82, (2011).
35. Zhao, Y., Zeng, D., Socinski, M.A. and Kosorok, M.R. "Reinforcement learning strategies for clinical trials in nonsmall cell lung cancer", *Biometrics*, Vol. 67, pp. 1422-1433, (2011).
36. Farjadian, A.B. Yazdanpanah, M.J. and Shafai, B., "Application of Reinforcement Learning in Sliding Mode Control for Chattering Reduction", *Proceedings of the World Congress on Engineering*, (2013).
37. Khan, S.G., Herrmann, G., Lewis, F.L., Pipe, T. and Melhuish, C., "Reinforcement learning and optimal adaptive control: An overview and implementation examples", *Annual reviews in control*, Vol. 36 ,pp. 42-59, (2012).
38. Berenji, H., and Jamshidi, M., "Fuzzy reinforcement learning for System of Systems (SOS)," *IEEE International Conference on Fuzzy Systems, FUZZ 2011, June 27, 2011 - June 30, 2011*, Taipei, Taiwan, pp. 1689-1694, (2011).
39. Berenji, H.R., "A reinforcement learning—based architecture for fuzzy logic control", *International Journal of Approximate Reasoning*, Vol. 6, pp. 267-292, (1992).
40. Lee, C.-C. and Berenji, H., "An intelligent controller based on approximate reasoning and reinforcement learning", *Intelligent Control, 1989. Proceedings., IEEE International Symposium*, pp. 200-205, (1989).
41. Zadeh, L.A., "Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic", *Fuzzy Sets and Systems*, Vol. 90, pp. 111-127, (1997).