

ارائه الگوریتم یادگیری انتقالی برای بهبود سرعت و صحت همگرایی در اتوماتای یادگیر سلولی

سید امیرهادی مینوفام، اعظم باستان فرد و محمدرضا کیوانپور

نام دارد. در قاعده محلی، حالت پیشین سلول‌های همسایه و احتمالاً حالت خود سلول مورد بررسی قرار می‌گیرند [۵]. اتوماتای سلولی در گام‌های زمانی گسسته تکامل می‌یابد. حالت سراسری اتوماتای سلولی که بیانگر حالات تمام سلول‌های آن است پیکربندی نامیده می‌شود. قاعده محلی به همراه پیکربندی اولیه اتوماتای سلولی، موجب تکامل اتوماتا در هر گام زمانی می‌گردد [۶] و [۷].

اتوماتای یادگیر (LA) نیز متشکل از یک عامل هوشمند ساده است که برای تصمیم‌گیری وقفی در محیط‌های تصادفی ناشناخته به کار می‌رود. کاربردهای ابتدایی آن در زمینه روان‌شناسی بوده و بعدها در حوزه مهندسی در محث یادگیری تقویتی توسعه یافته است [۸] و [۹]. نام‌گذاری اتوماتای یادگیر، قابلیت یادگیری آن با یادگیری تقویتی و نیز تبعیت خودکار از یک قاعده محلی ساده را نشان می‌دهد [۱۰] و [۱۱]. هر اقدام در اتوماتای یادگیر دارای یک احتمال دریافت پاداش از محیط است که اتوماتا از مقدار آن ناآگاه است. اتوماتای یادگیر در طول گام‌های زمانی، از میان مجموعه اقدامات خود، اقدامات متفاوت را می‌آزماید و اقدام جدید را بر مبنای پاسخ پیشین دریافتی از محیط انتخاب می‌کند [۱۲]. هدف از این روال، دستیابی به اقدام بهینه است که بالاترین احتمال دریافت پاداش از محیط را دارد [۱۳]. امکان ایجاد ساختارهای پیچیده مبتنی بر ساختار ساده این واحد یادگیرنده، یکی از ویژگی‌های جالب اتوماتای یادگیر است که آن را برای حل مسایل توانمند ساخته است [۱۲]، [۱۴] و [۱۵].

از ترکیب اتوماتای سلولی و اتوماتای یادگیر، مدل تازه‌ای به نام اتوماتای یادگیر سلولی (CLA) حاصل شده که قدرت محاسباتی را از اتوماتای سلولی و قابلیت یادگیری از محیط ناشناخته را از اتوماتای یادگیر کسب کرده است [۱۶]. اتوماتای یادگیر سلولی، یک اتوماتای سلولی است که در هر سلول آن یک یا چند اتوماتون یادگیر قرار دارد. اقدام انتخابی توسط اتوماتای یادگیر مقیم در هر سلول، تعیین‌کننده حالت آن سلول است. مشابه اتوماتای سلولی، یک قاعده محلی وجود دارد که اتوماتای یادگیر سلولی بر مبنای آن کار می‌کند. طبق قاعده محلی، اتوماتای یادگیر در هر سلول به بررسی اقدامات انتخابی از سوی سلول‌های همسایه می‌پردازد و سیگنال تقویتی برای آن سلول را محاسبه می‌کند. اتوماتون‌های یادگیر در سلول‌های همسایه، محیط محلی آن سلول و تمام سلول‌های شبکه، محیط سراسری را تشکیل می‌دهند. همچنین محتوای هر سلول که توسط خود آن قابل مشاهده است، محیط انحصاری نام دارد. اتوماتای یادگیر سلولی از نظر توانایی یادگیری نسبت به اتوماتای سلولی و از نظر توانایی تعامل میان واحدهای مجزا نسبت به اتوماتای یادگیر برتری دارد [۱۷]. اخذ خاصیت توزیع‌شدگی محاسبات از اتوماتای سلولی و خاصیت تصمیم‌گیری مبتنی بر احتمالات از اتوماتای یادگیر، مدل اتوماتای یادگیر سلولی را برای حل مسایل پیچیده توانمند ساخته است.

چکیده: اتوماتای یادگیر سلولی، یک مدل هوشمند به صورت آمیزه‌ای از اتوماتای سلولی و اتوماتای یادگیر است. پایین‌بودن سرعت همگرایی در اتوماتای یادگیر سلولی یکی از چالش‌های اساسی به شمار می‌رود. در این مطالعه، الگوریتم گسترش‌یافته‌ای از اتوماتای یادگیر سلولی مبتنی بر یادگیری انتقالی به نام TL-CLA پیشنهاد می‌گردد که از یادگیری انتقالی به عنوان راهکاری برای کاهش محاسبات و کمینه‌سازی چرخه یادگیری بهره می‌گیرد. مدل گسترش‌یافته پیشنهادی بر اساس تابع شایستگی و بردار نگرش برای انتقال یادگیری طراحی شده است. در الگوریتم TL-CLA، ابتدا مقدار تابع شایستگی بر اساس محیط محلی و مقدار بردار نگرش بر مبنای محیط سراسری اتوماتا محاسبه می‌شود. زمانی که این دو معیار حد آستانه مقرر را کسب کنند، انتقال بردار احتمالات اقدام‌ها سبب انتقال یادگیری از اتوماتای یادگیر سلولی منبع به اتوماتای یادگیر سلولی مقصد می‌شود. نتایج آزمایش‌ها نشان می‌دهند که مدل پیشنهادی TL-CLA در محیط‌های عملیاتی استاندارد با دو اقدام و چند اقدام، به طور میانگین، به ترتیب به اندازه ۲۷٪ و ۲۲٪ از نظر صحت همگرایی افزایش یافته است. نرخ همگرایی نیز به طور میانگین، به ترتیب ۸٪ و ۲٪ بهبود داشته است. اتوماتای یادگیر سلولی TL-CLA پیشنهادی در انتقال دانش حاصل از یادگیری یک وظیفه برای وظیفه‌ای مشابه کاربرد دارد.

کلیدواژه: اتوماتای یادگیر سلولی، انتقال دانش، نرخ همگرایی، یادگیری انتقالی.

۱- مقدمه

اتوماتای سلولی (CA)، یک مدل محاسباتی متشکل از سلول‌های مستقل از یکدیگر است و این سلول‌ها مؤلفه‌های ساده‌ای هستند که در یک ساختار مشبک سازماندهی شده‌اند [۱] و [۲]. بخش عمده‌ای از کاربردهای اولیه این مدل برای شبیه‌سازی سیستم‌های فیزیکی و زیستی بوده است. نام‌گذاری اتوماتای سلولی بدین خاطر است که از یک سو شامل عناصر درون یک شبکه به صورت سلول‌های مجزا است و از سوی دیگر به شکل اتوماتیک، پیرو یک قاعده محلی ساده است [۳]. هر سلول از میان مجموعه متناهی از حالات، حالتی را برمی‌گزیند [۴]. مبنای این انتخاب، حالات پیشین مجموعه مشخصی از سلول‌ها است و قاعده محلی

این مقاله در تاریخ ۳۱ فروردین ماه ۱۳۹۹ دریافت و در تاریخ ۶ تیر ماه ۱۴۰۰ بازنگری شد.

سید امیرهادی مینوفام، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران، (email: minoofam@qiau.ac.ir).

اعظم باستان فرد (نویسنده مسئول)، گروه مهندسی کامپیوتر، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران، (email: bastanfard@kiau.ac.ir).

محمدرضا کیوانپور، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه الزهراء، تهران، ایران، (email: keyvanpour@alzahra.ac.ir).

نشان می‌دهند. اتوماتای یادگیر سلولی مبتنی بر یادگیری انتقالی دارای پارامترهای مستقل از کاربرد است. لذا در تمام کاربردهایی که انتقال یادگیری یک وظیفه مشابه برای بهبود در فرایند یادگیری وظیفه دیگر، مد نظر باشد می‌تواند به عنوان یک راه حل الگوریتمی استفاده شود. بخش‌های پیش رو در پژوهش حاضر به صورت زیر سازمان یافته‌اند. در بخش ۲، کارهای مرتبط در دو حوزه اتوماتای یادگیر سلولی و یادگیری انتقالی مورد بررسی قرار می‌گیرند. در بخش ۳، مدل پیشنهادی TL-CLA و الگوریتم آن ارائه می‌شوند. در بخش ۴، نتایج آزمایش‌ها و مقایسه آنها بر مبنای معیارهای ارزیابی نشان داده می‌شوند و سرانجام، بخش ۵ نتیجه‌گیری و کارهای آتی را مورد بحث قرار می‌دهد.

۲- کارهای مرتبط

در این بخش، تحقیقات مرتبط با پژوهش حاضر در دو حوزه، مورد بررسی قرار می‌گیرند که پیش‌زمینه‌های لازم برای روش پیشنهادی را تشکیل می‌دهند. این دو زیربخش عبارتند از اتوماتای یادگیر سلولی و یادگیری انتقالی.

۲-۱ اتوماتای یادگیر سلولی (CLA)

اتوماتای یادگیر سلولی یک اتوماتای سلولی است که در هر سلول آن تعدادی اتوماتای یادگیر وجود دارد. هر اتوماتای یادگیر مقیم در یک سلول، اقدام خود را بر اساس بردار احتمال اقدام برمی‌گزیند. مشابه اتوماتای سلولی، در اینجا نیز یک قاعده محلی وجود دارد که CLA بر اساس آن عمل می‌کند. قاعده محلی CLA و اقدامات انتخاب‌شده از سوی اتوماتون‌های یادگیر همسایه، سیگنال تقویتی اتوماتای یادگیر را مشخص می‌کند. محیط محلی هر اتوماتای یادگیر، غیر ایستا است زیرا بردارهای احتمال اقدام متعلق به اتوماتون‌های یادگیر همسایه، در طول تکامل CLA تغییر می‌کنند. عملکرد CLA شامل مراحل زیر است که تا حصول نتیجه مورد نظر، تکرار می‌شوند:

- ۱) حالت درونی (اقدام) هر سلول بر اساس بردار احتمال اقدام مربوط به اتوماتای یادگیر درون آن مشخص می‌شود.
 - ۲) قاعده محلی CLA سیگنال تقویتی را برای اتوماتای یادگیر آن سلول تعیین می‌کند.
 - ۳) هر اتوماتای یادگیر، بردار احتمال اقدام خود را بر اساس سیگنال تقویتی و اقدام انتخابی به روز رسانی می‌کند.
- تعریف رسمی CLA به صورت زیر است [۱۶]:
- تعریف ۱:** اتوماتای یادگیر سلولی d بعدی یک پنج‌تایی به شکل $Z^d = \langle Z^d, \Phi, A, N, F \rangle$ است که در آن:
- Z^d : شبکه‌ای شامل d سطر از اعداد صحیح است که می‌تواند متناهی، نیمه‌متناهی یا نامتناهی باشد.
 - $\Phi = \{\phi_1, \phi_2, \dots, \phi_r\}$: مجموعه متناهی از حالات (اقدام) است و حالت سلول c_i با ϕ_i نمایش می‌یابد که بر اساس بردار احتمال اقدام اتوماتای یادگیر تعیین می‌شود.
 - A : مجموعه‌ای از اتوماتون‌های یادگیر است که هر کدام به یک سلول تخصیص می‌یابد.
 - $N = \{x_1, x_2, \dots, x_m\}$: زیرمجموعه‌ای متناهی از Z^d است که بردار همسایگی نام دارد و در آن $x_i \in Z^d$ است.
 - $F: \phi_i \rightarrow \beta$: قاعده محلی CLA در هر سلول c_i است که در آن β مجموعه مقادیر مجاز برای سیگنال تقویتی است.
 - برای $\beta \in \{0, 1\}$ اتوماتا از نوع P ، برای $\beta \in [0, 1]$ و به صورت

برخی از کاربردهای اتوماتای یادگیر و اتوماتای یادگیر سلولی عبارتند از: شبکه‌های سلولی [۱۸]، شبکه‌های حسگر [۱۹]، رایانش ابری [۲۰]، داده‌کاوی [۲۱]، پردازش تصویر [۲۲]، اینترنت اشیا [۲۳]، بهینه‌سازی [۲۴] و [۲۵]، مسایل گراف [۲۶]، سیستم‌های پیشنهادگر [۲۷]، سیستم‌های چندعامله [۲۸]، بازی‌های تصادفی [۲۹] و شبکه‌های اجتماعی [۳۰] و [۳۱].

اکثر مسایل یادگیری ماشین نیازمند صدها یا هزاران مثال آموزشی هستند و زمان زیادی را برای یادگیری این مثال‌ها صرف می‌کنند. از یک سو، فراهم‌آوردن مجموعه‌های بزرگ از مثال‌های آموزشی، دشوار و هزینه‌بر است و از سوی دیگر، زمان و هزینه پردازشی که برای یادگیری یک مسأله صرف شده است، برای مسأله دیگر حتی در صورت مشابهت، بی‌استفاده خواهد بود. یادگیری انتقالی راهکاری برای آموزش از طریق تعداد اندکی مثال آموزشی با قابلیت استفاده مجدد در مسایل مشابه است [۳۲]. در یادگیری انتقالی، دانش عمومی حاصل از یادگیری در حل یک مسأله به فضای یادگیری مسأله جدید انتقال می‌یابد [۳۳]. آزمایش‌ها نشان داده‌اند که یادگیری انتقالی یک رویکرد پربازده است و علاوه بر صرفه‌جویی در زمان و پردازش، می‌تواند دانش لازم برای طبقه‌بندی داده‌ها را از تعدادی اندک یا حتی از یک نمونه آموزشی استخراج نماید [۳۴] و [۳۵].

در اینجا لازم است به تمایز میان یادگیری همکارانه^۱ و یادگیری انتقالی اشاره شود. در سیستم‌های چندعامله، تعدادی عامل هوشمند با برقراری ارتباط با همدیگر در راستای دستیابی به هدفی مشترک همکاری دارند [۳۶]. بدین ترتیب، مجموعه‌ای از عامل‌ها یک تیم را تشکیل می‌دهند که هر عضو آن رفتاری سازگار با دیگران بر اساس شناخت خود از محیط و تأثیر ورودی‌های دریافتی از دیگر عامل‌ها دارند [۳۷]. در یادگیری همکارانه، هر عامل سهم فعالیت خود را در رسیدن به هدف مشترک گروه بر عهده دارد [۳۸] و بنابراین سه تفاوت بنیادی میان یادگیری همکارانه و یادگیری انتقالی می‌توان برشمرد. اولاً در یادگیری همکارانه تمام عامل‌ها برای برآورده‌ساختن یک وظیفه واحد همکاری دارند، در حالی که در یادگیری انتقالی، برآورده‌ساختن دو وظیفه منبع و مقصد مد نظر است [۳۹]. ثانیاً در یادگیری همکارانه الزاماً چند عامل وجود دارند ولی یادگیری انتقالی مبتنی بر یک عامل است که در انتقال یادگیری از یک وظیفه به وظیفه دیگر تلاش می‌کند [۴۰]. ثالثاً در یادگیری همکارانه، هر عامل بخشی از روال یادگیری برای وظیفه مشترک را بر عهده دارد اما در یادگیری انتقالی یک عامل، تمام روند یادگیری برای دو وظیفه را طی می‌کند [۴۱].

در این پژوهش، الگوریتم TL-CLA به عنوان یک رویکرد مبتنی بر یادگیری انتقالی برای بهبود نرخ همگرایی و افزایش میزان صحت در اتوماتای یادگیر سلولی پیشنهاد می‌گردد. یادگیری انتقالی موجب کاهش محاسبات و تسریع در چرخه یادگیری را فراهم می‌آورد. مدل پیشنهادی TL-CLA، محیط سراسری و محیط محلی اتوماتا را به ترتیب با میارهای بردار نگرش و بردار شایستگی مورد پیش قرار می‌دهد. پس از دستیابی به حد آستانه مناسب برای بردارهای نگرش و شایستگی، امکان انتقال یادگیری فراهم می‌گردد. از آنجایی که روش انتقال یادگیری در الگوریتم TL-CLA یک روش مبتنی بر مدل است، بنابراین پارامتر احتمالات اقدام برای انتقال مورد استفاده قرار می‌گیرد. نتایج آزمایش‌ها، بهبود مدل را بر مبنای ملاک‌های نرخ و صحت همگرایی و معیار آنتروپی

جدول ۱: مقایسه مهم‌ترین انواع اتوماتای یادگیر سلولی.

مرجع	سال	نام اتوماتا	موقعیت استفاده
[۱۶]	۲۰۰۳	بسته	تخصیص کانال در شبکه‌های سلولی، انتشار شایعه در شبکه‌های اجتماعی، پردازش تصویر
[۴۴]	۲۰۰۷	باز	تخصیص کانال در شبکه‌های سلولی
[۴۵]	۲۰۰۸	ناهمگام	تخصیص کانال در شبکه‌های سلولی
[۴۶]	۲۰۱۴	نامنظم	شبکه‌های حسگر
[۴۷]	۲۰۱۷	تداعی‌گر	طبقه‌بندی، خوشه‌بندی، قطعه‌بندی
[۴۸]	۲۰۱۸	پویا	شبکه‌های فوق نظیر

سیگنال تقویتی به اتوماتا منتقل نمی‌شود. **اتوماتای تداعی‌گر:** یک ورودی اضافی از محیط به اتوماتا منتقل می‌شود تا شرایط محیط را برای آن یادآوری و تداعی نماید. مقایسه‌ای از انواع CLA در جدول ۱ آمده است. همچنین پژوهش‌های متعددی برای بهبود کارایی مدل اتوماتای یادگیر سلولی در کاربردهای مختلف صورت گرفته است که در اینجا به طور مختصر مورد بررسی قرار می‌گیرند.

توسعه الگوریتم‌های استاندارد اتوماتای یادگیر به منظور یادگیری زیرمجموعه بهینه اقدامات از طریق سیگنال‌های تقویتی موازی صورت گرفته است. این سیگنال‌های تقویتی موازی، میزان مورد علاقه بودن هر اقدام در زیرمجموعه انتخاب‌شده از اقدامات را نشان می‌دهد. CLA قابلیت مدل‌سازی چند نهاد تصمیم‌گیرنده را دارد که به صورت محلی به هم متصل شده‌اند [۴۲].

الگوریتم CLA-OCD برای تشخیص انجمن‌های همپوشان در شبکه‌های اجتماعی پیشنهاد گردیده است. در این الگوریتم، گروهی از اتوماتون‌های یادگیر برای یافتن انجمن‌های همپوشان با هم همکاری دارند. کارایی CLA-OCD با آزمایش در شبکه‌های مصنوعی و شبکه‌های واقعی ارزیابی شده و بهبود قابل توجهی در پیمانه‌بندی، F-score و اطلاعات انحصاری بهنجار^۴ (NMI) داشته است [۴۳].

ساختار ICLA به عنوان شکل نامنظم CLA، مدل ریاضی قدرتمندی برای کاربردهای نامتمرکز است و می‌تواند در محیط‌هایی با میزان تصادفی بودن و عدم قطعیت بالا عمل نماید. به همین دلیل در مدل‌سازی ارائه‌دهندگان خدمات اینترنت و روابط میان آنها به کار رفته است. ارائه‌دهندگان خدمات به سلول‌ها نگاشت می‌یابند و روابط میان آنها بر اساس همسایگی‌های میان سلول‌ها تعریف می‌شوند. هدف ارائه‌دهندگان خدمات، رسیدن به توافق اشتراک ضرر بهینه^۵ (LSA) پارتو است. با به کارگیری ICLA، یافتن LSAهای بهینه پارتو نیازمند اطلاعات مفصل درباره توزیع فقدان‌ها و توابع سودمند مربوط به همسایگی‌های ارائه‌دهندگان خدمات نیست [۴۹].

الگوریتم CLA-WCD برای یافتن انجمن در شبکه‌های وزن‌دار به کار می‌رود که می‌تواند ساختارهای انجمنی نزدیک به بهینه را با زمان اجرای معقول بیابد. این الگوریتم از قابلیت موازی‌سازی و یادگیری بهره می‌گیرد که به ترتیب در اتوماتای سلولی و اتوماتای یادگیر نهفته است. الگوریتم CLA-WCD برای مقایسه با روش‌های متداول کشف انجمن در شبکه‌های مصنوعی و واقعی اعمال شده است [۵۰].

الگوریتم SIG-CLA با کمک ICLA برای تشخیص ساختار انجمن‌ها در شبکه‌های اجتماعی به کار رفته است. در این الگوریتم ICLA با شبکه ورودی ساخته می‌شود و سپس انجمن‌ها با تعامل میان محیط محلی و محیط سراسری با تابع معنی‌دار در ICLA مشخص می‌گردند. نتایج، نشان‌دهنده برتری این الگوریتم از نظر پیمانه‌بندی و NMI است [۵۱].

۲-۲ یادگیری انتقالی

الگوریتم‌های یادگیری ماشین سنتی برای حل مسایل به صورت مجزا از مسأله دیگر طراحی شده‌اند [۵۲]. این الگوریتم‌ها هر مدل را بر اساس یک دامنه خاص، داده‌ها و وظیفه مربوط، به شکل مجزا مورد آموزش قرار می‌دهند [۵۳]. در مقابل، یادگیری انتقالی روشی است که بر اساس

مجموعه‌ای متناهی از اعداد، اتوماتا از نوع Q و برای $\beta \in [0, 1]$ و به صورت اعداد تصادفی، اتوماتا از نوع S است.

قاعده محلی، سیگنال تقویتی برای هر اتوماتای یادگیر را بر اساس اقدامات انتخابی همسایگانش محاسبه می‌کند. پس از اعمال قاعده محلی، بردار احتمال اقدام اتوماتا به ازای اقدام انتخابی $\varphi(t)$ و سیگنال تقویتی $\beta(t)$ بر اساس (۱) و (۲) به روز رسانی می‌شود

$$p_i(t+1) = p_i(t) + \left[\frac{b}{r-1} - b \cdot p_i(t) \right] - [1 - \beta(t)] \cdot a \cdot p_i(t) \quad (1)$$

$$\varphi(t) \neq \varphi_{rew}$$

$$p_i(t+1) = p_i(t) - \beta(t) \cdot b \cdot p_i(t) + [1 - \beta(t)] \cdot a \cdot (1 - p_i(t)) \quad (2)$$

$$\varphi(t) = \varphi_{rew}$$

در (۱) و (۲)، r تعداد اقدامات (حالات) اتوماتا، φ_{rew} حالت پاداش گرفته کنونی و a و b به ترتیب بیانگر پارامترهای پاداش و جریمه هستند. اگر $a = b$ باشد الگوریتم از نوع LRP^۱، اگر $a \ll b$ باشد الگوریتم از نوع LRE^۲ و اگر $b = 0$ باشد الگوریتم از نوع LRI^۳ است.

انواع مختلفی از CLA در پژوهش‌ها مطرح شده‌اند که مهم‌ترین آنها به اختصار در اینجا معرفی می‌شوند.

اتوماتای بسته: انتخاب اقدام هر اتوماتون یادگیر فقط به سلول‌های همسایه بستگی دارد.

اتوماتای باز: انتخاب اقدام هر اتوماتون یادگیر نه فقط به سلول‌های همسایه که به محیط سراسری و محیط انحصاری اتوماتون نیز وابسته است.

اتوماتای همگام: تمام سلول‌ها بر اساس یک ساعت سراسری، قاعده محلی خود را اعمال می‌کنند.

اتوماتای ناهمگام: هر سلول بر اساس ساعت محلی خود یا بر اساس یک دنباله ثابت یا تصادفی، فعال می‌شود.

اتوماتای منظم: ساختار CLA به صورت شبکه‌ای با d سطر از اعداد صحیح است.

اتوماتای نامنظم: ساختار CLA با یک گراف غیر جهت‌دار تعریف می‌شود.

اتوماتای ایستا: ساختار سلولی و عناصر دخیل در آن در طول تکامل اتوماتا تغییر نمی‌کند.

اتوماتای پویا: ساختار، قاعده محلی یا شعاع همسایگی در طول زمان تغییر می‌کند.

اتوماتای غیر متداعی: هیچ اطلاعات اضافی از محیط، به جز

1. Linear Reward-Penalty
2. Linear Reward-Epsilon Penalty
3. Linear Reward-Inaction

4. Normalized Mutual Information

5. Loss Sharing Agreement

$$d_{opt} = \arg \max_{o^i \in O} \{d(i, o^i)\} \quad (۴)$$

با داشتن مجموعه داده‌های آموزشی به صورت $E_t = \{e_1, e_2, \dots, e_n\}$ و برچسب‌های آنها به صورت $L_t = \{l_1, l_2, \dots, l_n\}$ و بردار احتمال اقدام $\mathbb{D}_S = \{P_S, P_S(\Pi)\}$ ، دامنه منبع به صورت $\Pi = \{\pi_1, \pi_2, \dots, \pi_p\}$ تعریف می‌شود که در آن، \mathbb{P}_S فضای احتمالاتی منبع و $P_S(\Pi)$ توزیع احتمال حاشیه‌ای مربوط به یک نمونه داده‌ای خاص Π است. در اینجا، $\Pi = \{\pi_1, \pi_2, \dots, \pi_p\} \in \mathbb{P}_S$ فضای تمام احتمالات اقدام منبع و π_i به معنی i امین احتمال اقدام منبع است.

همچنین دامنه مقصد به صورت $\mathbb{D}_T = \{P_T, P_T(\Pi')\}$ تعریف می‌شود که در آن فضای احتمالاتی مقصد و $P_T(\Pi')$ توزیع احتمال حاشیه‌ای مربوط به یک نمونه داده‌ای خاص Π' است. در این تعریف از دامنه مقصد، $\Pi' = \{\pi'_1, \pi'_2, \dots, \pi'_p\} \in \mathbb{P}_T$ فضای تمام احتمالات اقدام مقصد و π'_i به معنی i امین احتمال اقدام مقصد است.

به علاوه، وظیفه یادگیری T به صورت $T = \{\mathcal{L}, f(\cdot)\}$ تعریف می‌شود که در آن فضای برچسب و $f(\cdot)$ تابع قابل پیش‌بینی هدف است. گرچه $f(\cdot)$ قابل مشاهده نیست ولی از داده‌های آموزشی، قابل یادگیری است. این داده‌ها شامل جفت‌های $\{i_j, o_j\}$ هستند که در آن $i_j \in I$ و $o_j \in O$ است. بنابراین تابع $f(\cdot)$ می‌تواند برای پیش‌بینی برچسب متناظر $f(f)$ مربوط به یک نمونه داده‌ای به کار رود. از دیدگاه احتمالاتی $f(f) = P\{f|o\}$ در نظر گرفته می‌شود و بدین ترتیب اتوماتای یادگیر سلولی مبتنی بر یادگیری انتقالی TL-CLA به صورت زیر تعریف می‌گردد:

تعریف ۳: TL-CLA یک هفت‌تایی به شکل $\langle Z^d, \Phi, \Theta, A, M_S, N, F \rangle$ است که در آن:

Z^d : شبکه‌ای شامل d سطر از اعداد صحیح است که به صورت دوبعدی نشان داده می‌شود.

Φ : مجموعه حالات سلول‌ها است که اقدام انتخابی هر سلول را نشان می‌دهد.

Θ : بردار نگرش اتوماتا است و زمان انتقال احتمالات را تعیین می‌کند.

A : مجموعه LAها است که هر یک از آنها به یک سلول از CLA نسبت داده می‌شوند.

M_S : بردار شایستگی $M_S = \langle \mu_1, \mu_2, \dots, \mu_m \rangle$ مربوط به وظیفه منبع است که محیط سراسری اتوماتا را تشکیل می‌دهد.

N : مجموعه $N = \{x_1, x_2, \dots, x_k\}$ بردار همسایگی است به طوری که $x_i \in Z^d$ و سیگنال تقویتی بر مبنای آن تولید می‌شود.

F^i : قاعده محلی CLA در هر سلول c_i است که در آن $\underline{\beta}$ مجموعه مقادیر مجاز برای سیگنال تقویتی است.

الگوریتم CLA مبتنی بر یادگیری انتقالی در شکل ۱ آمده است. در شکل ۲ سلول منبع C_S و سلول مقصد C_T برای TL-CLA نشان داده شده‌اند. در این شکل، ساختار داخلی هر سلول حاوی یک اتوماتای یادگیر و قاعده محلی مربوط به آن است. هر اتوماتای یادگیر با محیط محلی و سراسری در ارتباط است. حالت سلول‌ها (φ_i) بر اساس محیط محلی و انتقال دانش مبتنی بر مدل [۵۶] بر اساس بردار شایستگی M_S از سلول منبع در اختیار محیط سراسری قرار می‌گیرد. پس از احراز شرایط آستانه، پارامتر بردار احتمالات اقدام به سلول مقصد انتقال می‌یابد.

شرح مراحل الگوریتم TL-CLA به این صورت است: ابتدا ورودی‌های الگوریتم مشخص می‌شوند که این ورودی‌ها عبارتند از: تعداد اقدامات

استفاده مجدد، یک مدل یا دانش حاصل از یادگیری مسأله‌ای را برای حل یک مسأله مرتبط دیگر به کار می‌گیرد [۴۰] و [۴۱]. مزایای یادگیری انتقالی عبارتند از [۵۴] و [۵۵]:

بهبود کارایی اولیه: با انتقال دانش از مدل منبع، کارایی اولیه در شروع یادگیری برای مدل مقصد بهبود می‌یابد.

بهبود زمان توسعه مدل: انتقال دانش از مدل منبع، موجب بهبود زمان لازم برای توسعه و یادگیری در مدل مقصد می‌شود.

بهبود کارایی: در یادگیری انتقالی می‌توان به کارایی نهایی بالاتری دست یافت.

تعریف رسمی یادگیری انتقالی به صورت زیر است [۳۹]:

تعریف ۲: با داشتن دامنه منبع \mathbb{D}_S و وظیفه یادگیری منبع \mathbb{T}_S ، دامنه مقصد \mathbb{D}_T و وظیفه یادگیری مقصد \mathbb{T}_T ، هدف یادگیری انتقالی کمک به بهبود یادگیری تابع قابل پیش‌بینی مقصد $f_T(\cdot)$ در دامنه \mathbb{D}_T با استفاده از دانش موجود در \mathbb{D}_S و \mathbb{T}_S است که در آن $\mathbb{D}_S \neq \mathbb{D}_T$ یا $\mathbb{T}_S \neq \mathbb{T}_T$ می‌باشد.

در طول فرایند یادگیری انتقالی، سه سؤال مهم زیر باید پاسخ داده شوند [۳۹] و [۵۶]:

چه باید انتقال یابد: در این گام مشخص می‌شود کدام بخش از دانش می‌تواند از منبع به مقصد انتقال یابد تا کارایی وظیفه مورد نظر را بهبود بخشد. همچنین تعیین می‌شود که کدام بخش از دانش، منحصر به منبع است و چه مواردی میان منبع و مقصد مشترک است [۵۷].

چه وقت باید انتقال یابد: ممکن است در شرایطی انتقال دانش به جای بهبودبخشیدن، وضعیت را بدتر نماید که به نام انتقال منفی شناخته می‌شود. در حالی که هدف مطلوب این است که کارایی و نتایج وظیفه مقصد بهبود یابد نه این که کاسته شود. بنابراین لازم است بررسی شود که انتقال چه وقت صورت پذیرد و چه موقع انجام نگیرد [۵۸].

چگونه باید انتقال یابد: هنگامی که به دو سؤال چه و چه وقت پاسخ داده شد، می‌توان به شناسایی راه‌هایی پرداخت که چگونه دانش در میان دامنه‌ها و وظایف انتقال یابد. این مقوله شامل انجام تغییرات در الگوریتم‌های موجود و تکنیک‌های گوناگون است [۵۹].

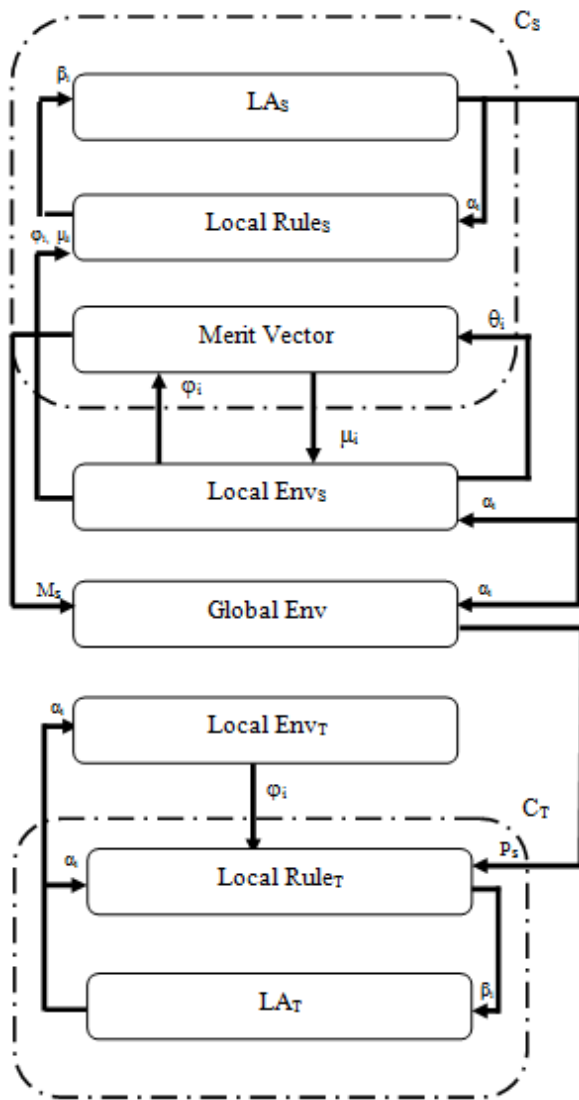
در این تحقیق، الگوریتم TL-CLA برای اتوماتای یادگیر سلولی مبتنی بر یادگیری انتقالی ارائه می‌شود و برای پرسش‌های فوق در مراحل بیان الگوریتم پاسخ مناسب ارائه می‌گردد.

۳- روش پیشنهادی TL-CLA

اگر $I = \{i_1, i_2, \dots, i_r\}$ مجموعه متناهی از ورودی‌های یک ماشین یادگیری تقویتی باشد، به ازای هر ورودی $i_i \in I$ ، خروجی o_i متعلق به مجموعه $O = \{o_1, o_2, \dots, o_k\}$ وجود دارد. بنابراین به ازای ورودی $i \in I$ و خروجی متناظر $o^i \in O$ ، رابطه میان ورودی و خروجی به صورت احتمالاتی با احتمال پاداش $d(i, o^i)$ تعریف می‌شود. احتمال پاداش، معیاری برای عدم قطعیت موجود در بررسی ورودی‌ها و خروجی‌ها است. قوی‌ترین رابطه میان ورودی i و خروجی متناظر o_m^i مربوط به بزرگ‌ترین احتمال پاداش است که در (۳) آمده است

$$d(i, o_m^i) = \max_{o^i \in O} \{d(i, o^i)\} \quad (۳)$$

وظیفه ماشین یادگیر یافتن اقدام (خروجی) بهینه به ازای هر ورودی $i \in I$ است که به صورت (۴) مشخص می‌شود



شکل ۲: ساختار داخلی سلول‌ها و تعامل با محیط در TL-CLA.

اساس (۵) و (۶) محاسبه می‌شود

$$\mu(c_i) = \max \left\{ \frac{1}{N} \sum_{c_j \in \text{Neighbor}(c_i)} \left[1 - \frac{d(c_i, c_j)}{\eta} \right] \right\} \quad (5)$$

در (۵)، $d(c_i, c_j)$ فاصله اقلیدسی میان محتوای دو سلول c_i و c_j است که سلول‌های c_j همسایگان سلول c_i را نشان می‌دهند. η یک مقدار ثابت بین صفر و یک است. هرچه مقدار $\mu(c_i)$ بیشتر باشد، میزان شایستگی آن سلول برای انتقال بیشتر است. برای تعیین مناسب بودن تابع شایستگی از (۶) استفاده می‌شود

$$q(c_i) = \frac{m}{\mu(c_i) + P_m} \quad (6)$$

در (۶)، m تعداد کل سلول‌های اتوماتای یادگیر سلولی است و P_m بیشترین مقدار بردار احتمالات اقدام در سلول c_i را نشان می‌دهد. محاسبه مقدار $q(c_i)$ به ازای تمام اعضای بردار M_S و رسیدن آن به مقدار آستانه h_μ شرط لازم برای انتقال بردار احتمالات اقدام از سلول منبع به سلول مقصد است.

گام ۶: مقدار $\zeta(k)$ به عنوان تعداد سلول‌هایی محاسبه می‌شود که مقدار تابع شایستگی آنها یعنی $\mu_j(k)$ کمتر از مقدار تابع شایستگی سلول جاری یعنی $\mu_i(k)$ است.

TL-CLA Algorithm

Input: r : the number of actions, m : the number of attitudes, n : the resolution parameter, h_θ, h_μ, h_p : thresholds for attitudes and merits

respectively, $\Delta = \frac{1}{rn}$

Output: the optimal action

Begin Procedure

- 1: **Initialization:** $\mu_i(0) = 0, i = 1, 2, \dots, m, p_j(0) = \frac{1}{r}, j = 1, 2, \dots, r$
- 2: **For** each cell i in the CLA **do**
- 3: Let $\alpha(k) = \alpha_i$ be an action selected according to the probability vector $P(k) = [p_1(k), p_2(k), \dots, p_r(k)]^T$
- 4: Get a feedback from stochastic environment $\beta(k) \in \{0, 1\}$
- 5: Compute $\mu_i(k)$ using relations (5) and (6)
- 6: Denote $\zeta(k)$ as the number of cells that $\mu_j(k) > \mu_i(k)$
- 7: Update the probability vector according to θ as

For each $j, j \neq i$ such that $\mu_j(k) > \mu_i(k)$ **do**

$$p_j(k+1) = \min \left\{ p_j(k) + \frac{\Delta}{\zeta(k)} \right\}$$

For each $j, j \neq i$ such that $\mu_j(k) < \mu_i(k)$ **do**

$$p_j(k+1) = \max \left\{ p_j(k) + \frac{\Delta}{\zeta(k)} \right\}$$

Set for current action i

$$p_i(k+1) = 1 - \sum_{j \neq i} p_j(k)$$

- 8: **If** $\max \{ p_j(k+1), j = 1, 2, \dots, r \} \geq h_p$ **then** the convergence is accured for cell i **else** goto step 2 for target CLA
- 9: Set $\theta_i(k)$ according to the cell and its environment
- 10: **If** $\forall \{ \theta_j(k+1), j = 1, 2, \dots, s \} \geq h_\theta$ and $\forall \{ \mu_j(k+1), j = 1, 2, \dots, r \} \geq h_\mu$ **then** transfer the P vector from source to the target CLA and repeat the procedure from step 2 for target CLA **else** goto Step 2 source CLA

End Procedure

شکل ۱: الگوریتم CLA مبتنی بر یادگیری انتقالی: TL-CLA.

(r)، تعداد نگرش (m) برابر با تعداد سلول‌های اتوماتای یادگیر سلولی، پارامتر تفکیک‌پذیری یادگیری برای تعیین سطح گسسته‌سازی (n)، مقادیر آستانه h_θ, h_μ, h_p که به ترتیب برای بردار نگرش، بردار شایستگی و بردار احتمال اقدام تعیین می‌شوند و Δ که مقدار آن به صورت $0 < \Delta < 1/r$ است. خروجی اتوماتای یادگیر سلولی، اقدام بهینه خواهد بود.

گام‌های اجرای الگوریتم در ادامه تشریح می‌شوند.

گام ۱: مقداردهی اولیه برای بردار نگرش برابر با صفر و برای بردار احتمالات برابر با $1/r$ تنظیم می‌شود.

گام ۲: به ازای تمام سلول‌های اتوماتای یادگیر سلولی منبع، در هر مرحله زمانی، اجرای گام‌های ذیل صورت می‌پذیرد.

گام ۳: یک اقدام $\alpha(k)$ از مجموعه اقدامات اتوماتا بر اساس بردار احتمالات اقدام $P(k) = [p_1(k), p_2(k), \dots, p_r(k)]^T$ انتخاب می‌شود که در آن k مرحله زمانی و T ترانهاده را نشان می‌دهد.

گام ۴: به ازای اقدام انتخابی، بازخورد $\beta(k)$ بر مبنای اتوماتای مدل p از محیط دریافت می‌شود.

گام ۵: مقدار شایستگی $\mu_i(k)$ برای انتقال پارامترهای مدل، بر

اگر بردار نگرش به حد آستانه برسد، بدین معنا است که CLA در حال همگرایی است. بنابراین تمام سلول‌ها با توجه به محیط سراسری، به میزان مؤثری در عملیات یادگیری پیشرفت داشته‌اند. شرط دوم، حصول شرایط آستانه h_μ برای بردار شایستگی است. این شرط نشان می‌دهد که مقادیر احتمالات اقدام در محیط محلی برای هر سلول به عدد یک نزدیک شده‌اند و بدین ترتیب انتقال منفی کاهش می‌یابد [۶۱]. بنابراین برقراری دو شرط مذکور، CLA منبع را از دید محیط محلی و سراسری برای انتقال مورد ارزیابی قرار می‌دهند که در شکل ۲ نیز مشهود است.

چه طور انتقال صورت گیرد: برای انجام انتقال کافی است که احتمالات اقدام سلول‌ها که مقدار p_i را تشکیل می‌دهند، مطابق شکل ۲ در قالب بردار P_S از CLA منبع به CLA مقصد منتقل شوند. از آنجایی که CLA مقصد، روال یادگیری متفاوتی را نسبت به CLA منبع انجام می‌دهد، بنابراین لازم است بردار احتمالات آن در ابتدا مقداردهی اولیه شوند. اما این مقداردهی اولیه به جای شروع از احتمالات برابر برای اقدامات، مقادیر انتقال یافته P_S از CLA منبع خواهند بود.

بدین ترتیب انتظار می‌رود یادگیری وظیفه مقصد که گرچه متفاوت ولی مشابه با وظیفه یادگیری منبع است، سریع‌تر همگرا شود. بررسی نتایج پیاده‌سازی در بخش ۴ و مقایسه آنها این فرضیه را تأیید می‌کند.

۴- نتایج آزمایش‌ها و بحث

در این بخش قصد بر این است که مقایسه‌ای میان روش پیشنهادی TL-CLA و CLA انجام شود. بررسی مقالات پژوهشی در زمینه اتوماتای یادگیر نشان می‌دهند که چند معیار برای مقایسه الگوریتم‌ها متداول است. معیار اول، نرخ همگرایی^۳ بر حسب تعداد تکرار مورد نیاز برای همگرایی است که تحت محیط‌های محک‌زنی مورد مقایسه قرار می‌گیرد [۶۲]. معیارهای دوم و سوم بیانگر صحت^۴ و آنتروپی^۵ اتوماتا هستند که تعاریف آنها در ادامه می‌آید [۴۷] و [۶۳]. معیارهای بعدی واریانس، انحراف معیار و خطای استاندارد هستند.

تعریف ۴: معیار صحت در اتوماتای یادگیر سلولی به صورت (۷) تعریف می‌شود

$$E[P_{opt}(\infty)] = \sum_{i=1}^N \frac{i}{N} p_i \quad (7)$$

که در آن E امید ریاضی، P_{opt} احتمال اقدام بهینه و N تعداد حالات اتوماتا است.

تعریف ۵: معیار آنتروپی در اتوماتای یادگیر سلولی به صورت زیر تعریف می‌شود

$$\overline{H}_{CLA} = \frac{\sum_{k=1}^n \sum_{i=1}^m p_{ij}(k) \cdot \ln(p_{ij}(k))}{k} \quad (8)$$

که در آن \overline{H}_{CLA} میانگین آنتروپی، n تعداد تکرار اتوماتا، m تعداد سلول‌ها، r تعداد اقدامات و $p_{ij}(k)$ بیانگر احتمال اقدام در تکرار k ام است.

جدول ۲: پیکره‌بندی پارامترها و مقادیر تنظیم‌شده.

پارامتر	توصیف	مقدار
$DL_{RP} a$	پارامتر پاداش L_{RP}	۰٫۵
$DL_{RP} b$	پارامتر جریمه L_{RP}	۰٫۲
Δ	اندازه گام	۰٫۲
λ	پارامتر یادگیری	۱
h_θ	آستانه نگرش	۰٫۲۵
h_μ	آستانه شایستگی	۰٫۶
h_p	آستانه احتمال	۰٫۸

گام ۷: بردار احتمالات اقدام اتوماتا بر مبنای بردار نگرش اتوماتا (Θ) به روز رسانی می‌شود. بردار Θ نگرش اتوماتا را به سوی همگرایی نشان می‌دهد و از برآیند حالت سلول‌های مجاور به دست می‌آید.

گام ۸: اگر بیشترین مقدار بردار احتمالات اقدام به میزان آستانه رسیده باشد، آن سلول همگرا شده و در تکرارهای بعدی الگوریتم مورد بررسی و به روز رسانی قرار نخواهد گرفت. در غیر این صورت برای CLA مقصد، رویه مجدداً از گام ۲ تکرار می‌شود.

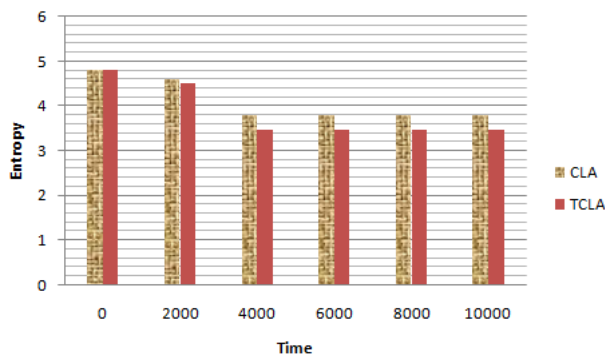
گام ۹: مقدار بردار نگرش بر حسب محیط سراسری تعیین می‌شود. گام ۱۰: اگر مقدار بردار نگرش و مقدار بردار شایستگی به حد آستانه مورد نظر رسیده باشند آن گاه بردار P از CLA منبع به CLA مقصد منتقل می‌شود. در غیر آن صورت، گام ۲ تا گام ۱۰ برای CLA منبع تکرار خواهد گردید.

پیکره‌بندی و پارامترهای CLA بر اساس نتایج عملیاتی در جدول ۲ ذکر شده است. این مقادیر بر حسب یک نقطه تعادل مقداردهی شده‌اند تا از بیش‌برازش^۱ و زیربرازش^۲ پیشگیری شود. چهار پارامتر اول مربوط به تنظیم عمومی اتوماتای یادگیر هستند که بر حسب تنظیمات بهینه در [۱۰] و [۶۰] مقداردهی شده‌اند.

از آنجایی که همه پارامترهای یادگیری انتقالی به صورت مقادیر آستانه هستند، هر گونه تغییرات در آنها کاهش کارایی الگوریتم را در پی دارد. به عنوان مثال، مقدار آستانه بیشتر منجر به بیش‌برازش و کاهش کارایی می‌گردد و در مقابل، مقادیر آستانه کمتر موجب زیربرازش و کاهش کارایی می‌شود. عنصر کلیدی در رویکرد پیشنهادی، کنترل مقادیر آستانه به منظور جلوگیری از انتقال منفی است.

در الگوریتم پیشنهادی TL-CLA پاسخ پرسش‌های سه‌گانه یادگیری انتقالی که در پایان زیربخش ۲-۲ مطرح شدند به فرم زیر آشکار می‌گردد: چه باید انتقال یابد: در الگوریتم پیشنهادی، پارامترهای مدل منبع انتقال می‌یابند و بنابراین الگوریتم یادگیری انتقالی پیشنهادی از نوع مبتنی بر مدل (پارامتری) است [۴۱]. پارامتر مؤثر در اتوماتای یادگیر سلولی، بردار احتمالات اقدام می‌باشد و لذا این بردار به صورت P_S که احتمالات اقدام منبع را در بر دارد طبق شکل ۲ انتقال می‌یابد.

چه وقت انتقال انجام شود: عمل انتقال یادگیری، زمانی صورت می‌گیرد که دو شرط در الگوریتم پیشنهادی برقرار باشند. شرط اول این است که بردار نگرش Θ به میزان حد آستانه h_θ رسیده باشد که این شرط، وضعیت سراسری CLA منبع را مشخص می‌کند.



شکل ۳: آنتروپی CLA و TL-CLA در اتوماتا با دو اقدام.

بحث

در جدول ۳، نرخ همگرایی در هر سه محیط با الگوریتم TL-CLA بهبود یافته است. مقایسه میان نتایج نرخ همگرایی نشان می‌دهد که یادگیری محیط ساده‌تر E_1 و به کارگیری آن برای انتقال یادگیری در محیط‌های پیچیده‌تر E_7 و E_8 بهبود کمتری در یادگیری حاصل نموده است. در حالی که یادگیری در محیط پیچیده E_7 موجب بهبود بیشتری در یادگیری برای محیط‌های E_1 و E_7 گردیده است. کارایی CLA و TL-CLA از نظر میزان صحت در جدول ۴ آمده است. مقایسه نتایج صحت نشان می‌دهد که صحت یادگیری در محیط ساده‌تر E_1 نسبت به محیط پیچیده‌تر E_7 بهبود بیشتری داشته است. بدین ترتیب به طور میانگین، میزان نرخ همگرایی به اندازه ۸٪ کاهش و میزان صحت به اندازه ۲٫۷٪ افزایش داشته است.

بحث

شکل ۳ میزان آنتروپی CLA و TL-CLA را نشان می‌دهد. در این نمودار آنتروپی به مرور زمان کاهش یافته و بعد از همگرایی در یک مقدار ثابت باقی مانده است. میزان کاهش آنتروپی TL-CLA بیشتر بوده است. آنتروپی کمتر به معنای کاهش یافتن میزان تصادفی بودن نتایج است.

ب) مثال عددی با چند اقدام

محیط‌های تعریف‌شده با چند اقدام به عنوان معیار محک‌زنی در مقالات اتوماتای یادگیر [۶۶] تا [۶۸] در اینجا برای ارزیابی TL-CLA استفاده می‌شوند

$$E_A : D = \{0, 70, 0, 50, 0, 30, 0, 20, 0, 40, 0, 50, 0, 40, 0, 30, 0, 50, 0, 20\}$$

$$E_B : D = \{0, 10, 0, 45, 0, 84, 0, 76, 0, 20, 0, 40, 0, 60, 0, 70, 0, 50, 0, 30\}$$

E_A یک محیط بسیار ساده است زیرا واریانس آن نسبتاً کم و تفاوت میان اقدامات در آن نیز نسبتاً زیاد است. در مقابل، E_B یک محیط پیچیده است زیرا گرچه واریانس کمتری نسبت به E_A دارد ولی تفاوت میان اقدامات نیز کمتر شده است. برای شبیه‌سازی از اتوماتای یادگیر از نوع DL_{RP} در هر سلول استفاده شده و تعداد آزمایش‌ها برابر با 1×10^6 مرتبه است. علت افزایش آزمایش‌ها نسبت به حالت با دو اقدام، افزایش تعداد اقدامات در این حالت و اثر آن بر کاهش سرعت همگرایی است.

بحث

نرخ همگرایی CLA و TL-CLA در جدول ۵ نشان داده شده است. در این جدول، نرخ همگرایی در هر دو محیط با الگوریتم TL-CLA بهبود یافته است. مقایسه میان نتایج نرخ همگرایی نشان می‌دهد که یادگیری محیط ساده‌تر E_A و به کارگیری آن برای انتقال یادگیری در محیط پیچیده‌تر E_B بهبود کمتری در یادگیری حاصل نموده است. در

جدول ۳: مقایسه کارایی CLA و TL-CLA از نظر نرخ همگرایی.

محیط	نرخ همگرایی					
	$\frac{E_1}{E_7}$	$\frac{E_1}{E_8}$	$\frac{E_7}{E_1}$	$\frac{E_7}{E_8}$	$\frac{E_8}{E_1}$	$\frac{E_8}{E_7}$
CLA	۲۵۷۸		۲۸۹۳		۳۹۸۱	
TL-CLA	۲۲۸۴	۲۴۵۷	۲۲۲۷	۲۵۳۵	۳۴۷۲	۳۶۸۹

جدول ۴: مقایسه کارایی CLA و TL-CLA از نظر صحت.

محیط	صحت همگرایی					
	$\frac{E_1}{E_7}$	$\frac{E_1}{E_8}$	$\frac{E_7}{E_1}$	$\frac{E_7}{E_8}$	$\frac{E_8}{E_1}$	$\frac{E_8}{E_7}$
CLA	۸۷٫۷		۸۴٫۲		۸۱٫۹	
TL-CLA	۹۱٫۳	۸۹٫۵	۸۵٫۶	۸۵٫۲	۸۲٫۴	۸۳٫۴

تعریف ۶: معیار واریانس در اتوماتای یادگیر سلولی به صورت زیر تعریف می‌شود

$$S^2 = \frac{\sum (x_i - \bar{x})^2}{n-1} \quad (9)$$

که در آن x_i مقدار همگرایی مشاهده‌شده، \bar{x} میانگین همگرایی‌ها و n تعداد آزمایش‌ها است.

تعریف ۷: انحراف معیار استاندارد در اتوماتای یادگیر سلولی به صورت زیر تعریف می‌شود

$$\sigma = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n}} \quad (10)$$

که در آن x_i مقدار همگرایی مشاهده‌شده، \bar{x} میانگین همگرایی‌ها و n تعداد آزمایش‌ها است.

تعریف ۸: خطای استاندارد در اتوماتای یادگیر سلولی به صورت زیر تعریف می‌شود

$$SE = \frac{\sigma}{\sqrt{n}} \quad (11)$$

که در آن σ انحراف معیار استاندارد و n تعداد آزمایش‌ها است. شبیه‌سازی‌های اولیه در قالب دو نمونه از TL-CLA ارائه می‌شوند که در نوع اول فقط از دو اقدام و در نوع دوم از ده اقدام استفاده می‌گردد. سپس سه آزمایش پیچیده‌تر با ساختار TL-CLA انجام می‌شود.

الف) مثال عددی با دو اقدام

محیط‌های تعریف‌شده با دو اقدام به عنوان معیار محک‌زنی در مقالات اتوماتای یادگیر [۶۴] تا [۶۶] در اینجا برای ارزیابی TL-CLA استفاده می‌شوند. در این محیط‌ها احتمالات پاداش اقدامات عبارتند از

$$E_1 : D = \{0, 90, 0, 60\}$$

$$E_7 : D = \{0, 80, 0, 50\}$$

$$E_8 : D = \{0, 80, 0, 60\}$$

E_1 ساده‌ترین محیط است که دارای واریانس کم و تفاوت زیاد میان دو اقدام است. E_7 دارای همان میزان تفاوت ولی با واریانس بیشتر است. E_8 تفاوت میان دو اقدام را کاهش داده و بنابراین محیط مشکل‌تری به حساب می‌آید. برای شبیه‌سازی از اتوماتای یادگیر از نوع DL_{RP} در هر سلول استفاده شده و تعداد آزمایش‌ها برابر با 10000 است.

جدول ۵: مقایسه کارایی CLA و TL-CLA از نظر نرخ همگرایی.

محیط	نرخ همگرایی	
	E_A	E_B
CLA	۸۷۷۰۳۷	۹۸۸۵۴۶
TL-CLA	$E_A : E_B$	$E_A : E_B$
	۸۷۶۳۳۲	۹۸۷۳۲۱

جدول ۶: مقایسه کارایی CLA و TL-CLA از نظر صحت.

محیط	صحت همگرایی	
	E_A	E_B
CLA	۷۸٫۳	۷۳٫۶
TL-CLA	$E_A : E_B$	$E_A : E_B$
	۷۹٫۲	۷۷٫۸

جدول ۷: خطای استاندارد در محیط‌های TL-CLA.

خطای استاندارد	محیط	TL-CLA
$\pm ۰٫۱۳$	E_1	
$\pm ۰٫۴۲$	E_r	دو اقدام
$\pm ۰٫۸۳$	E_r	
$\pm ۰٫۵۴$	E_A	چند اقدام
$\pm ۰٫۷۲$	E_B	


بحث

جدول ۷ مقادیر خطای استاندارد به ازای اتوماتای با دو اقدام و اتوماتای با چند اقدام را نشان می‌دهد. مقدار خطای استاندارد در محیط‌های پیچیده مانند E_r و E_B نسبت به محیط‌های ساده بیشتر است. همچنین شکل‌های ۵ و ۶ همگرایی اتوماتا را با تنظیمات مختلف پارامترها نشان می‌دهد. در تنظیمات مختلف دو پارامتر a و b نرخ همگرایی بالا است و همگرایی به یک اقدام پیش از رسیدن به تعداد معینی از تکرار رخ می‌دهد. حتی در مواردی که تنظیمات بهینه پارامترها انجام نشده است (مانند شکل ۵) نیز سرعت همگرایی بالا است، لیکن با تنظیم مقادیر بهینه مانند شکل ۶ سرعت همگرایی بسیار افزایش می‌یابد. واریانس TL-CLA در مقایسه با CLA به ازای محیط‌های دو اقدام و چند اقدام به ترتیب در شکل‌های ۷ و ۸ آمده است. انحراف معیار استاندارد برای محیط‌های دو اقدام و چند اقدام در شکل‌های ۹ و ۱۰ آمده است. مقایسه این مقادیر نشان می‌دهد که TL-CLA دارای مقادیر واریانس و انحراف معیار کمتری نسبت به CLA است.


سه آزمایش دیگر نیز از میان مسایل محک متداول [۶۹] برای اتوماتای یادگیر سلولی انتخاب شده‌اند که برای اثبات کارایی روش پیشنهادی TL-CLA و مقایسه آن با روش‌های مشابه در ذیل آورده شده است.

ج) قطعه‌بندی تصاویر


به منظور ارزیابی کارایی TL-CLA در قطعه‌بندی تصویر از تصاویر استاندارد پایگاه داده دانشگاه برکلی استفاده شده است [۷۰]. در این آزمایش روش پیشنهادی TL-CLA بر داده‌های آزمون اعمال شده است. با عنایت به اندازه داده‌های آزمون، ابعاد TL-CLA به صورت 4×4 تعریف شده و بنابراین هر تصویر به ۱۶ بخش تقسیم می‌شود.



شکل ۴: آنتروپی CLA و TL-CLA در اتوماتا با چند اقدام.



شکل ۵: نرخ همگرایی به ازای $a=۰٫۱$ و $b=۰٫۴$.



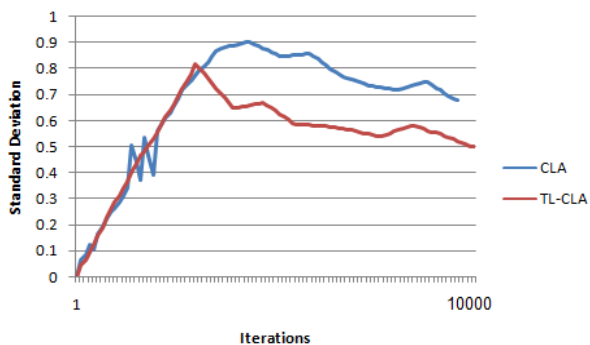
شکل ۶: نرخ همگرایی به ازای $a=۰٫۵$ و $b=۰٫۲$.

حالی که یادگیری در محیط پیچیده E_B موجب بهبود بیشتری در یادگیری برای محیط E_A گردیده است.


کارایی CLA و TL-CLA از نظر میزان صحت در جدول ۶ آمده است. مقایسه نتایج صحت نشان می‌دهد که صحت یادگیری در محیط ساده‌تر E_A نسبت به محیط پیچیده‌تر E_B بهبود بیشتری داشته است. بدین ترتیب به طور میانگین، میزان نرخ همگرایی به اندازه ۲٪ کاهش و میزان صحت به اندازه ۲٫۲٪ افزایش داشته است.

بحث


در نمودار شکل ۴ آنتروپی به مرور زمان کاهش یافته و بعد از همگرایی در یک مقدار ثابت باقی مانده است. مقایسه شکل‌های ۳ و ۴ نشان می‌دهند که میزان کاهش آنتروپی در اتوماتا با دو اقدام بیش از میزان کاهش آنتروپی در اتوماتا با چند اقدام بوده است. این نتیجه به دلیل اثر انتقال منفی در محیط‌های E_A و E_B است که از تفاوت اقدام بهینه در این دو محیط حاصل می‌شود. از آنجایی که شباهت میان دو محیط در حالت چند اقدام کمتر است، بنابراین اثر انتقال منفی نمود بیشتری نسبت به محیط‌های دارای دو اقدام داشته است.




شکل ۱۰: انحراف معیار استاندارد TL-CLA با چند اقدام.




شکل ۷: واریانس TL-CLA با دو اقدام.



شکل ۱۱: نتایج برای قطعه‌بندی تصاویر، (الف) تصویر اولیه، (ب) K-means و (ج) TL-CLA.



شکل ۸: واریانس TL-CLA با چند اقدام.



شکل ۹: انحراف معیار استاندارد TL-CLA با دو اقدام.

نرخ طبقه‌بندی درست^۱ (CCR) برای هر طبقه در هر تکرار محاسبه شده و میانگین آنها در جدول ۸ آمده است. نتایج این جدول نشان می‌دهند که CCR مربوط به TL-CLA مشابه KNN می‌باشد و SVM از آن بهتر عمل می‌کند. گرچه نتایج SVM از TL-CLA بهتر است ولی تفاوت آنها اندک است و در اکثر موارد CCR مشابه دارند.

ه) طبقه‌بندی نیمه‌نظارتی

برای انجام طبقه‌بندی نیمه‌نظارتی از همان مجموعه داده‌های طبقه‌بندی استفاده شده است. الگوریتم TL-CLA برای این مسأله با $n \times 20$ سلول پیکربندی شده و برای آماده‌سازی مجموعه داده‌های استاندارد به منظور طبقه‌بندی نیمه‌نظارتی، برچسب‌های مربوط به ۲ درصد از داده‌ها حذف شده است. برای تضمین قابلیت اطمینان نتایج، هر یک از الگوریتم‌ها ۱۰ بار اجرا شده‌اند و میانگین حاصل از آنها به عنوان نرخ طبقه‌بندی الگوریتم ذکر گردیده است.

بحث

همان‌طور که جداول ۹ و ۱۰ نشان می‌دهند با افزایش درصد داده‌های بدون برچسب، میزان CCR الگوریتم‌ها کاهش می‌یابد. علت این امر، کاهش میزان صحت نمونه‌های آموزشی است که منجر به افزایش نرخ خطا در نمونه‌های آزمون می‌شود. الگوریتم TL-CLA دارای صحت کمتر از SVM و در اکثر موارد بیشتر از KNN است. بنابراین الگوریتم پیشنهادی دارای کارایی قابل قبول در طبقه‌بندی نیمه‌نظارتی است.

بحث

مقایسه نتایج مدل پیشنهادی با الگوریتم K-means در شکل ۱۱ نشان می‌دهد که TL-CLA تقریباً در تمام موارد بهتر عمل می‌کند. همچنین TL-CLA در تمام آزمایش‌ها دارای ساختار ثابت است ولی الگوریتم K-means نیازمند گرفتن تعداد خوشه‌ها در هر آزمایش خواهد بود.

د) طبقه‌بندی

برای ارزیابی کارایی TL-CLA در طبقه‌بندی، پنج مجموعه داده در نظر گرفته شده‌اند و نتایج با طبقه‌بندی‌های SVM و KNN مقایسه شده‌اند. پیکربندی TL-CLA به صورت یک ساختار $n \times 20$ است که n تعداد طبقات در مجموعه داده‌ها است.

بحث

به طور کلی، تعداد ستون‌ها یک پارامتر تجربی است و از طریق آزمون و خطا حاصل می‌شود. از روش اعتبارسنجی 10 -fold استفاده شده و هر الگوریتم طبقه‌بندی ۱۰ بار تکرار شده و در هر تکرار ۱۰٪ از داده‌ها برای آزمون و مابقی برای آموزش به کار رفته‌اند.

- [2] S. A. H. Minoofam and A. Bastanfard, "A novel algorithm for generating Muhammad pattern based on cellular automata," in *Proc. WSEAS 13th Int. Conf. on Applied*, pp. 339-344, Puerto De La Cruz, Spain, 15-17 Dec. 2008.
- [3] E. Fredkin, "An informational process based on reversible universal cellular automata," *Phys. D Nonlinear Phenom.*, vol. 45, no. 1-3, pp. 254-270, Sept. 1990.
- [4] S. A. H. Minoofam, M. M. Dehshibi, A. Bastanfard, and P. Eftekhari, "Ad-hoc ma'qeli script generation using block cellular automata," *J. Cell. Autom.*, vol. 7, pp. 321-334, 2012.
- [5] S. Wolfram, *Cellular Automata and Complexity: Collected Papers*, CRC Press, 2018.
- [6] J. L. Schiff, *Cellular Automata: A Discrete View of the World*, vol. 45, John Wiley & Sons, 2011.
- [7] S. A. H. Minoofam, M. M. Dehshibi, A. Bastanfard, and J. Shanbehzadeh, "Pattern formation using cellular automata and L-systems: a case study in producing Islamic patterns," in *Cellular Automata in Image Processing and Geometry*, Ch. 12, pp. 233-252, Switzerland: Springer, 2014.
- [8] K. S. Narendra and M. A. L. Thathachar, "Learning automata-a survey," *IEEE Trans. Syst. Man. Cybern.*, vol. 4, no. 4, pp. 323-334, Jul. 1974.
- [9] F. Esmaily and M. R. Keyvanpour, "WMat algorithm based on Q-Learning algorithm in taxi-v2 game," in *Proc. 4th Int. Conf. on Smart City, Internet of Things and Applications, SCIoT'20*, pp. 112-118, Mashhad, Iran, 16-17 Sept. 2020.
- [10] A. Rezvanian, A. M. Saghiri, S. M. Vahidipour, M. Esnaashari, and M. R. Meybodi, *Recent Advances in Learning Automata*. Springer, 2018.
- [11] Z. Movahedi and A. Bastanfard, "Toward competitive multi-agents in polo game based on reinforcement learning," *Multimed. Tools Appl.*, vol. 80, no. 17, pp. 26773-26793, May 2021.
- [12] M. Savargiv, B. Masoumi, and M. R. Keyvanpour, "A new random forest algorithm based on learning automata," *Comput. Intell. Neurosci.*, vol. 2021, Article No.: 5572781, 19 pp., 2021.
- [13] S. A. H. Minoofam and A. Bastanfard, "Learning automata: a comparative analysis of estimator algorithms," in *Proc. 25th Iran. Conf. Electr. Eng.*, pp. 1772-1778, Tehran, Iran, 2-4 May 2017.
- [14] M. A. L. Thathachar and P. S. Sastry, *Networks of Learning Automata: Techniques for Online Stochastic Optimization*, Springer Science & Business Media, 2011.
- [15] M. Savargiv, B. Masoumi, and M. R. Keyvanpour, "A new ensemble learning method based on learning automata," *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 4, pp. 1-16, Apr. 2020.
- [16] M. R. Meybodi, H. Beigy, and M. Taherkhani, "Cellular learning automata and its applications," *Sharif J. Sci. Technol.*, vol. 19, no. 25, pp. 54-77, Autumn 2003.
- [17] H. Beigy and M. R. Meybodi, "A mathematical framework for cellular learning automata," *Adv. Complex Syst.*, vol. 7, no. 03n04, pp. 295-319, 2004.
- [18] M. N. Qureshi, M. I. Tiwana, and M. Haddad, "Distributed self optimization techniques for heterogeneous network environments using active antenna tilt systems," *Telecommun. Syst.*, vol. 70, no. 3, pp. 379-389, Jul. 2019.
- [19] M. Torshizi and M. J. Sheikhzadeh, "Optimum k-coverage in wireless sensor network with no redundant node by cellular learning automata," *Wirel. Pers. Commun.*, vol. 110, no. 2, pp. 1-18, Oct. 2019.
- [20] M. J. Moghaddam, A. Esmailzadeh, M. Ghavipour, and A. K. Zadeh, "Minimizing virtual machine migration probability in cloud computing environments," *Cluster Comput.*, vol. 23, no. 4, pp. 3029-3038, Feb. 2020.
- [21] M. K. Sohrabi and R. Roshani, "Frequent itemset mining using cellular learning automata," *Comput. Human Behav.*, vol. 68, no. C, pp. 244-253, Mar. 2017.

[۲۲] ا. حضرتی بی‌شک، ک. فائز، ح. برقی جند و س. قطعی "انتخاب زیرمجموعه

بهبه از ویژگی‌های استخراج شده توسط عملگر بهینه‌شده LBP بر مبنای CLA -

EC در سیستم بازشناسی چهره، "نشریه مهندسی برق و مهندسی کامپیوتر ایران، ب- مهندسی کامپیوتر، سال ۱۲، شماره ۲، صص. ۶۷-۷۴ زمستان ۱۳۹۳.

[23] C. Di, B. Zhang, Q. Liang, S. Li, and Y. Guo, "Learning automata-based access class barring scheme for massive random access in machine-to-machine communications," *IEEE Internet Things J.*, vol. 6, no. 4, pp. 6007-6017, Aug. 2018.

[۲۴] م. رضایپور میرصالح و م. ر. میبیدی "ارائه یک مدل جدید ممیزی مبتنی بر اتوماتای یادگیر ساختار ثابت،" "نشریه مهندسی برق و مهندسی کامپیوتر ایران،

ب- مهندسی کامپیوتر، سال ۱۶، شماره ۳، صص. ۱۹۵-۱۸۳، پاییز ۱۳۹۷.

جدول ۸: مقایسه نتایج CCR در طبقه‌بندی با TL-CLA.

مجموعه داده‌ها	SVM	KNN	TL-CLA
IRIS	۰.۹۷	۰.۹۷	۰.۹۵
WINE	۰.۹۶	۰.۶۸	۰.۸۷
PROTEIN	۰.۷۶	۰.۷۷	۰.۷۴
WDBC	۰.۹۵	۰.۹۲	۰.۹۲
DIABETES	۰.۷۵	۰.۷۴	۰.۷۲

جدول ۹: نتایج CCR در TL-CLA در طبقه‌بندی نیمه‌نظارتی با $r = ۰.۳$.

مجموعه داده‌ها	SVM	KNN	TL-CLA
IRIS	۰.۹۷	۰.۹۶	۰.۹۳
WINE	۰.۹۲	۰.۶۶	۰.۸۶
PROTEIN	۰.۷۴	۰.۷۸	۰.۷۲
WDBC	۰.۹۴	۰.۹۴	۰.۹۲
DIABETES	۰.۷۷	۰.۷۶	۰.۷۶

جدول ۱۰: نتایج CCR در TL-CLA در طبقه‌بندی نیمه‌نظارتی با $r = ۰.۸$.

مجموعه داده‌ها	SVM	KNN	TL-CLA
IRIS	۰.۸۷	۰.۹۵	۰.۸۵
WINE	۰.۹۴	۰.۶۸	۰.۸۲
PROTEIN	۰.۵۵	۰.۶۳	۰.۶۱
WDBC	۰.۸۹	۰.۹۲	۰.۸۶
DIABETES	۰.۶۵	۰.۷۳	۰.۶۲

۵- نتیجه‌گیری و کارهای آتی

در این پژوهش، اتوماتای یادگیر سلولی مبتنی بر یادگیری انتقالی با نام TL-CLA به عنوان نوع توسعه‌یافته‌ای از اتوماتای یادگیر سلولی (CLA) مطرح گردید. برخلاف CLA که روال یادگیری برای هر وظیفه جدید را از پایه آغاز می‌کند، مدل پیشنهادی TL-CLA یادگیری وظایف مشابه در CLA مقصد را مبتنی بر نتایج دست‌یافته در CLA منبع، آغاز می‌نماید. بررسی مثال‌های عددی برای ارزیابی عملکرد الگوریتم بر مبنای استفاده از مدل‌های اتوماتای یادگیر DL_{RP} مورد بررسی قرار گرفت. نتایج شبیه‌سازی‌ها نشان داد که الگوریتم پیشنهادی TL-CLA نسبت به CLA دارای عملکرد بهتری است و به نتایج مطلوب‌تری دست می‌یابد. از مزایای این الگوریتم می‌توان به همگرایی با تعداد تکرار کمتر، داشتن آنتروپی کمتر و نیز انعطاف‌پذیری بیشتر به دلیل وجود پارامترهای تنظیم‌شونده اشاره نمود. لازم به ذکر است که شرایط مندرج در الگوریتم پیشنهادی مستقل از کاربرد می‌باشند و لذا الگوریتم می‌تواند برای کاربردهای گوناگون مورد استفاده قرار گیرد.

یکی از کارهای آتی نویسندگان، ارائه الگوریتم یادگیری انتقالی برای مدل‌های متنوع از اتوماتای یادگیر سلولی است. همچنین تعریف معیارهای جدید برای ارزیابی رفتار TL-CLA از موضوعات پژوهشی آینده به شمار می‌آید. به علاوه، بررسی راهکارهای کاهش اثر انتقال منفی نیز یکی از مسائلی است که نیاز به پژوهش عمیق‌تر دارد.

مراجع

- [1] S. A. H. Minoofam and A. Bastanfard, "Square kufic pattern formation by asynchronous cellular automata," in *Proc. Int Conf. on Cellular Automata*, pp. 79-82, Ascoli Piceno, Italy, 21-24 Sept. 2010.

- [46] M. Esnaashari and M. R. Meybodi, "Irregular cellular learning automata," *IEEE Trans. Cybern.*, vol. 45, no. 8, pp. 1622-1632, Oct. 2014.
- [47] M. Ahangaran, N. Taghizadeh, and H. Beigy, "Associative cellular learning automata and its applications," *Appl. Soft Comput.*, vol. 53, pp. 1-18, Apr. 2017.
- [48] A. M. Saghiri and M. R. Meybodi, "An adaptive super-peer selection algorithm considering peers capacity utilizing asynchronous dynamic cellular learning automata," *Appl. Intell.*, vol. 48, no. 2, pp. 271-299, Jul. 2018.
- [49] R. Vafashoar, H. Morshedlou, A. Rezvanian, and M. R. Meybodi, "Cellular learning automata for collaborative loss sharing," in *Cellular Learning Automata: Theory and Applications*, vol. 307, pp. 255-284, Springer, 2021.
- [50] M. M. D. Khomami, A. Rezvanian, A. M. Saghiri, and M. R. Meybodi, "Utilizing cellular learning automata for finding communities in weighted networks," in *Proc. 6th Int. Conf. on Web Research, ICWR'20*, pp. 325-329, Tehran, Iran, 22-23 Apr. 2020.
- [51] M. M. D. Khomami, A. Rezvanian, A. M. Saghiri, and M. R. Meybodi, "SIG-CLA: a significant community detection based on cellular learning automata," in *Proc. 8th Iranian Joint Congress on Fuzzy and Intelligent Systems, CFIS'20*, pp. 39-44, Mashhad, Iran, 2-4 Sept. 2020.
- [52] L. Zuo, M. Jing, J. Li, L. Zhu, K. Lu, and Y. Yang, "Challenging tough samples in unsupervised domain adaptation," *Pattern Recognit.*, vol. 110, Article No.: 107540, Feb. 2021.
- [53] S. Niu, Y. Liu, J. Wang, and H. Song, "A decade survey of transfer learning (2010-2020)," *IEEE Trans. Artif. Intell.*, vol. 1, no. 2, pp. 151-166, Feb. 2020.
- [54] D. Sarkar, R. Bali, and T. Ghosh, *Hands-On Transfer Learning with Python: Implement Advanced Deep Learning and Neural Network Models Using TensorFlow and Keras*, Packt Publishing Ltd, 2018.
- [55] M. Arora, P. Mangipudi, and M. K. Dutta, "Deep learning neural networks for acrylamide identification in potato chips using transfer learning approach," *J. Ambient Intell. Humaniz. Comput.*, vol. 2, no. 12, pp. 10601-10614, Jan. 2021.
- [56] Q. Yang, Y. Zhang, W. Dai, and S. J. Pan, *Transfer Learning*, Cambridge University Press, 2020.
- [57] Q. Sun, Y. Liu, Z. Chen, T. S. Chua, and B. Schiele, "Meta-transfer learning through hard tasks," *IEEE Trans. Pattern Anal. Mach. Intell.*, Early access, Aug. 2020.
- [58] B. Al-Helali, Q. Chen, B. Xue, and M. Zhang, "Multi-tree genetic programming with new operators for transfer learning in symbolic regression with incomplete data," *IEEE Trans. Evol. Comput.*, Early access, May 2021.
- [59] Q. Gu, Q. Dai, H. Yu, and R. Ye, "Integrating multi-source transfer learning, active learning and metric learning paradigms for time series prediction," *Appl. Soft Comput.*, vol. 109, Article No.: 107583, Sept. 2021.
- [60] R. Vafashoar, H. Morshedlou, A. Rezvanian, and M. R. Meybodi, *Cellular Learning Automata: Theory and Applications*, Springer 2019.
- [61] M. He, J. Zhang, and J. Zhang, "Restoring latent factors against negative transfer using partial-adaptation nonnegative matrix factorization," *CCF Trans. Pervasive Comput. Interact.*, vol. 2, no. 1, pp. 42-50, Oct. 2020.
- [62] C. Di, S. Li, F. Li, and K. Qi, "A novel framework for learning automata: a statistical hypothesis testing approach," *IEEE Access*, vol. 7, pp. 27911-27922, Feb. 2019.
- [63] A. M. Saghiri and M. R. Meybodi, "On expediency of closed asynchronous dynamic cellular learning automata," *J. Comput. Sci.*, vol. 24, no. 1, pp. 371-378, Jan. 2018.
- [64] H. Ge, H. Huang, Y. Li, S. Li, and J. Li, "Two approaches on accelerating bayesian two action learning automata," in *Proc. Int. Conf. on Intelligent Computing*, pp. 239-247, Lanzhou, China, 2-5 Aug. 2016.
- [65] H. Ge, Y. Yan, J. Li, Y. Guo, and S. Li, "A parameter-free gradient bayesian two-action learning automaton scheme," in *Proc. of the Int. Conf. on Communications, Signal Processing, and Systems*, pp. 963-970, Chengdu, China, 23-24 Oct. 2016.
- [66] Y. Guo, H. Ge, and S. Li, "A loss function based parameterless learning automaton scheme," *Neurocomputing*, vol. 260, pp. 331-340, Oct. 2017.
- [67] Y. Guo and S. Li, "A non-monte-carlo parameter-free learning automata scheme based on two categories of statistics," *IEEE Trans. Cybern.*, vol. 49, no. 12, pp. 4153-4166, Aug. 2018.
- [68] H. Ge, J. Li, S. Li, W. Jiang, and Y. Wang, "A novel parallel framework for pursuit learning schemes," *Neurocomputing*, vol. 228, pp. 198-204, Mar. 2017.
- [۲۵] م. ر. ملاخلیلی میبیدی و م. ر. میبیدی، "یک معیار مبتنی بر وارینانس برای ارزیابی یادگیری اتوماتای یادگیر در حل مسایل بهینه‌سازی گراف تصادفی،" *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، ب- مهندسی کامپیوتر، سال ۱۵، شماره ۱، صص. ۱۳-۱، بهار ۱۳۹۶.
- [۲۶] م. ر. ملاخلیلی میبیدی و م. ر. میبیدی، "یک چارچوب مبتنی بر اتوماتای یادگیر توزیع شده توسعه یافته برای حل مسأله یافتن زیرگراف بهینه تصادفی،" *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، ب- مهندسی کامپیوتر، سال ۱۲، شماره ۲، صص. ۸۵-۹۵، زمستان ۱۳۹۳.
- [۲۷] م. طهماسبی، ف. فتوحی و م. اسماعیلی، "پیشنهاددهنده تطبیقی منابع آموزشی بر اساس سبک یادگیری، بازخورد کاربر و الگوریتم اتوماتای یادگیر،" *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، ب- مهندسی کامپیوتر، سال ۱۸، شماره ۱، صص. ۶۰-۷۱، بهار ۱۳۹۸.
- [۲۸] م. ر. خجسته و م. ر. میبیدی، "همکاری در سیستم‌های چند عامله با استفاده از اتوماتاهای یادگیر،" *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، سال ۱، شماره ۲، صص. ۸۱-۱۱، پاییز و زمستان ۱۳۸۲.
- [۲۹] ب. معصومی و م. ر. میبیدی، "مدلی مبتنی بر آنتروپی و اتوماتاهای یادگیر برای حل بازی‌های تصادفی،" *نشریه مهندسی برق و مهندسی کامپیوتر ایران*، سال ۸، شماره ۲، صص. ۹۷-۱۰۶، تابستان ۱۳۸۹.
- [30] A. Rezvanian, B. Moradabadi, M. Ghavipour, M. M. D. Khomami, and M. R. Meybodi, *Learning Automata Approach for Social Networks*, vol. 820, Springer 2019.
- [۳۱] س. روح‌الهی، ع. خطیبی بردسیری و ف. کی‌نیا، "نمونه‌گیری از شبکه‌های اجتماعی به کمک بهره‌گیری از واحد ارزیاب در ماشین‌های یادگیر با ساختار ثابت،" *مجله هوش مصنوعی و داده‌کاوی*، سال ۸، شماره ۱، صص. ۱۴۸-۱۲۷، زمستان ۱۳۹۹.
- [32] T. Tommasi, F. Orabona, and B. Caputo, "Learning categories from few examples with multi model knowledge transfer," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 5, pp. 928-941, May 2014.
- [33] L. Fei-Fei, R. Fergus, and P. Perona, "One-shot learning of object categories," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 28, no. 4, pp. 594-611, Feb. 2006.
- [34] S. Rahman, S. Khan, and F. Porikli, "A unified approach for conventional zero-shot, generalized zero-shot, and few-shot learning," *IEEE Trans. Image Process.*, vol. 27, no. 11, pp. 5652-5667, Jul. 2018.
- [35] X. Dong, L. Zheng, F. Ma, Y. Yang, and D. Meng, "Few-example object detection with model communication," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 41, no. 7, pp. 1641-1654, Jun. 2018.
- [36] A. Rezvanian and M. R. Meybodi, "LACAIS: learning automata based cooperative artificial immune system for function optimization," in *Proc. Int. Conf. on Contemporary Computing*, vol. 2, pp. 64-75, Noida, India, August 9-11 Aug. 2010.
- [37] M. Mozafari, M. E. Shiri, and H. Beigy, "A cooperative learning method based on cellular learning automata and its application in optimization problems," *J. Comput. Sci.*, vol. 11, no. 1, pp. 279-288, Nov. 2015.
- [38] M. R. Khojasteh and M. R. Meybodi, "Evaluating learning automata as a model for cooperation in complex multi-agent domains," *Robot Soccer World Cup*, vol. 4434, pp. 410-417, 19-20 Jun. 2006.
- [39] F. Zhuang, et al., *A Comprehensive Survey on Transfer Learning*, arXiv Prepr. arXiv1911.02685, 2019.
- [40] Z. Wan, R. Yang, M. Huang, N. Zeng, and X. Liu, "A review on transfer learning in EEG signal analysis," *Neurocomputing*, vol. 421, pp. 1-14, 15 Jan. 2021.
- [41] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345-1359, Oct. 2010.
- [42] R. Vafashoar, H. Morshedlou, A. Rezvanian, and M. R. Meybodi, "Learning from multiple reinforcements in cellular learning automata," in *Cellular Learning Automata: Theory and Applications*, Springer, vol. 307, pp. 111-156, 2021.
- [43] M. M. D. Khomami, A. Rezvanian, A. M. Saghiri, and M. R. Meybodi, "Overlapping community detection in social networks using cellular learning automata," in *Proc. 28th Iranian Conf. on Electrical Engineering*, 6 pp., Tabriz, Iran, 4-6 Aug. 2020.
- [44] H. Beigy and M. R. Meybodi, "Open synchronous cellular learning automata," *Adv. Complex Syst.*, vol. 10, no. 04, pp. 527-556, Dec. 2007.
- [45] H. Beigy and M. R. Meybodi, "Asynchronous cellular learning automata," *Automatica*, vol. 44, no. 5, pp. 1350-1357, May 2008.

اعظم باستان فرد استادیار دانشگاه آزاد اسلامی واحد کرج هستند. ایشان مدرک کارشناسی ارشد و دکترا را از مؤسسه فناوری توکیو و مدرک فوق دکترا را از دانشگاه ژنو دریافت نمودند. موضوعات تحقیقاتی ایشان عبارتند از پردازش چندرسانه‌ای، هوش مصنوعی، پردازش تصویر و گرافیک کامپیوتری.

محمدرضا کیوان پور دانشیار دانشگاه الزهرا در رشته مهندسی نرم‌افزار هستند. ایشان مدرک کارشناسی خود را در رشته مهندسی نرم‌افزار از دانشگاه علم و صنعت ایران دریافت نمود. همچنین وی مدارک کارشناسی ارشد و دکترا مهندسی نرم‌افزار را از دانشگاه تربیت مدرس اخذ نموده است. حوزه‌های پژوهشی مورد علاقه ایشان عبارتند از مهندسی نرم‌افزار، یادگیری ماشین و داده‌کاوی.

[69] D. Neider, R. Smetsers, F. Vaandrager, and H. Kuppens, "Benchmarks for automata learning and conformance testing," in *Models, Mindsets, Meta: the What, the How, and the Why Not?*, pp. 390-416, Springer, 2019.

[70] C. Carson, S. Belongie, H. Greenspan, and J. Malik, "Blobworld: image segmentation using expectation-maximization and its application to image querying," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 8, pp. 1026-1038, Nov. 2002.

سید امیرهادی مینوفام در سال ۱۳۸۸ مدرک کارشناسی ارشد را از دانشگاه آزاد قزوین دریافت نمود. او هم‌اکنون دانشجوی دکترا سیستم‌های نرم‌افزاری در دانشگاه آزاد قزوین است. همچنین وی از سال ۱۳۹۲ عضو هیأت علمی دانشگاه آزاد اسلامی نظرآباد در استان البرز است. موارد پژوهشی مورد علاقه وی، سیستم‌های یادگیر، پردازش تصویر و گرافیک کامپیوتری است.