

# طراحی سازوکار تدارکات براساس یادگیری Q و با سیاست انتخاب عمل مبتنی بر الگوریتم ازدحام ذرات

زهره کاهه<sup>۱</sup>، دکتر رضا برادران کاظمزاده<sup>۲\*</sup>

دانشگاه تربیت مدرس

تاریخ دریافت مقاله: ۱۳۹۴/۰۸/۱۶

تاریخ پذیرش مقاله: ۱۳۹۴/۱۱/۰۳

## چکیده

در این مقاله، مسئله مناقصه در یک شرکت خودروسازی برای تدارک قطعات مورد نیاز از تأمین‌کنندگان بالقوه از طریق الگوریتم یادگیری Q حل شده است. در این مسئله، خریدار با توجه به پیشنهادات دریافتی از تأمین‌کنندگان بالقوه که شامل قیمت و زمان تحویل پیشنهادی است، سفارش قطعات مورد نیاز خود را به تأمین‌کنندگان تخصیص می‌دهد. هدف خریدار کمینه‌سازی هزینه‌های تدارکات از طریق یادگیری از مناقصات پیشین است. این مسئله به صورت یک مسئله تصمیم‌گیری مارکوفی تعریف شده است که در آن هر عمل وابسته به عمل و وضعیت قبلی است. برای حل این مسئله یک الگوریتم یادگیری تقویتی به نام الگوریتم یادگیری Q توسعه داده شده است که در آن از الگوریتم بهینه‌سازی ازدحام ذرات به عنوان راهکاری برای یافتن و انتخاب سیاست بهینه برای انتخاب عمل در الگوریتم یادگیری Q استفاده شده است. در مقایسه این الگوریتم با حالتی که در آن سیاست انتخاب عمل مطابق با یک الگوریتم حریصانه است، این الگوریتم بسیار کارآمدتر است.

**واژه‌های کلیدی:** تدارکات، یادگیری تقویتی، الگوریتم یادگیری Q، سیاست انتخاب عمل.

## ۱- مقدمه

و خریدار برقرار بوده و منافع و محدودیت‌های طرفین در نظر گرفته شود. همچنین هزینه‌ها از جمله هزینه تدارکات، جریمه تأخیر نیز کمینه شود. در واقع هدف تدارکات این است که سفارشات و تحویل‌ها براساس زمان‌بندی و با کمترین هزینه انجام گیرند.

در برخی مطالعات اشاره شده است که طراحی مکانیزم تدارکات در دو دسته مبتنی بر حراج معکوس (مناقصه) و مبتنی بر مذاکره قرار می‌گیرد. در برخی مطالعات، مناقصه (مزایده) نوع خاصی از مذاکره در نظر گرفته شده است [۲]؛ اما در برخی مطالعات دیگر نظیر مطالعه چن و تی‌سنگ<sup>۳</sup> بین این دو مفهوم تمایز قائل شده‌اند [۳]. در این مقاله فقط بر مکانیزم تدارکات مبتنی بر مناقصه تمرکز می‌شود. در این سازوکار به طور معمول خریدار طی یک فرآیند جستجوی متوالی با فروشنده‌گان در تعامل است، تا زمانی که یک راه حل رضایت‌بخش حاصل گردد.

تدارکات در زنجیره تأمین فرآیندی است که طی آن تأمین‌کننده محصولات خود را مطابق با سفارش مشتری ارسال می‌نماید. مدیران باید برای سازوکار تدارکات مواد مستقیم - موادی که به‌طور مستقیم در ساخت محصول نهایی استفاده می‌شود - و مواد غیرمستقیم - موادی که برای پشتیبانی عملیات استفاده می‌شود - و مواد راهبردی و غیر راهبردی تصمیم‌گیری نمایند. برای تدارک هر مورد از مواد مستقیم و غیرمستقیم، و مواد راهبردی و غیر راهبردی مکانیزمی با سودآوری بیشتر برای زنجیره تأمین تعریف نمایند [۱]. به عنوان مثال یک شرکت باید تدارکات را به گونه‌ای تنظیم نماید که امکان ایجاد توافق برد-برد بین تأمین‌کننده

۱- کارشناس ارشد دانشگاه تربیت مدرس، پست الکترونیک: zohreh.kaheh@modares.ac.ir

۲- دانشیار دانشگاه تربیت مدرس، دانشکده فنی مهندسی، نویسنده پاسخگو، پست الکترونیکی: rkazem@modares.ac.ir، نشانی: تهران، بزرگراه جلال آل احمد، دانشگاه تربیت مدرس، دانشکده فنی مهندسی،

بخش مهندسی صنایع

فصلنامه علمی - ترویجی

راهبردهای مذاکره تطبیق‌پذیر و وابسته به دانش و تجربه خودشان و اطلاعات موجود را ایجاد نمایند. دانش از این نوع می‌تواند به عامل‌ها برای جستجوی فضای جواب به صورت کارا و مؤثر کمک کند و بازده مذاکره را به طور کامل بهبود بخشد.

یکی از انواع یادگیری، یادگیری تقویتی است که عبارتست از آموختن اینکه چه عملی انجام گیرد تا یک سیگنال پاداش عددی بیشینه شود. در این الگوریتم برخلاف اکثر الگوریتم‌های یادگیری ماشینی به یادگیرنده گفته نمی‌شود که کدام عمل را انجام دهد، بلکه مشخص می‌شود که انجام کدام عمل بیشترین پاداش را در پی دارد. در موارد پیچیده‌تر نه فقط پادash‌های فوری مطرح است بلکه حالات و موقعیت‌های بعدی که انجام عمل منجر به آنها شده و نیز پادash‌های آتی نیز مورد توجه قرار می‌گیرد. در واقع دو خصوصیت "جستجوی مبتنی بر سعی و خطأ" و "پادash‌های آتی" دو مشخصه اصلی یادگیری تقویتی هستند<sup>[۶]</sup>.

در این پژوهش مسئله انجام تدارکات، به عنوان یک مسئله تخصیص سفارشات به تأمین‌کنندگان در یک زنجیره تأمین با وجود یک خریدار و تعدادی تأمین‌کننده در نظر گرفته شده است. همچنین فرض شده که هیچ یک از تأمین‌کنندگان از قرارداد سایر تأمین‌کنندگان با خریدار اطلاعی ندارد و در واقع قراردادها از نوع مهر و موم شده هستند. مسئله به این شرح است که تولیدکننده (خریدار) قصد دارد تقاضای خود را برای چند نوع کالا به چند تأمین‌کننده سفارش دهد. به این صورت که مجموع سفارشات برای هر نوع کالا برابر تعداد مورد تقاضای آن باشد. همچنین خریدار یک زمان تحويل فرضی را در نظر می‌گیرد. در این مسئله لازم است جوانب مختلف تصمیم‌گیری از جمله پذیرش یا عدم پذیرش پرپوزال‌ها، ایجاد یک تعادل بین قیمت و زمان تحويل پیشنهادی در نظر گرفته شود. از طرفی هر یک از تأمین‌کنندگان یک قیمت برای تعداد حجم پیشنهادی برای هر نوع کالا (برای انواع مختلف کالا جداگانه قیمت داده می‌شود) و زمان تحويل (به روز) را مشخص می‌کنند. خریدار قصد دارد میزان مناسب تخصیص به هر یک از تأمین‌کنندگان را با این فرض که حجم‌های قابل تأمین تأمین‌کنندگان مختلف به صورت مستقل از هم از فرآیند پوآسون پیروی می‌کند، را بیاموزد، به طوری که کمترین هزینه را داشته باشد. در واقع در نظر گرفتن این مسئله به صورت یک تصمیم‌گیری مارکوفی با یک قدم با

عامل‌ها در محیط‌های چالش‌برانگیز استفاده می‌شوند، چالش برانگیز بودن محیط بدین معناست که محیط آنها عموماً (۱) پویا، (۲) غیرقابل پیش‌بینی و (۳) غیرقابل اعتماد است. (۱) پویایی محیط، ناشی از تغییرات سریع آن است، به طوری که عامل دستیابی به اهدافش نمی‌تواند فرض کند که محیط ایستا باقی می‌ماند.

(۲) غیرقابل پیش‌بینی بودن محیط ناشی از این است که موقعیت‌های بعدی در محیط قابل پیش‌بینی نیستند. این امر اغلب به این دلیل است که یک عامل - نه فقط به علت دانش اندک بلکه گاهی به علت عدم دسترسی به اطلاعات- اطلاعات کامل و جامعی از محیط خود ندارد و یا تغییرات محیط و رای اختیار یا دانش عامل می‌باشد.

(۳) غیرقابل اعتماد بودن محیط به این علت است که اعمالی که عامل انجام می‌دهد ممکن است به علتی و رای کنترل عامل، با شکست مواجه شود<sup>[۴]</sup>.

عامل‌های هوشمند اساساً بر بعد هوشمندی تمرکز دارند. یک عامل هوشمند می‌تواند برخی جنبه‌های هوش مصنوعی نظیر استدلال، انطباق‌پذیری و یادگیری را در اجرای وظایف خود به کار گیرد. مطابق با سطح هوشمندی عامل‌ها بیم و سگو<sup>[۵]</sup> عامل‌های هوشمند را به دو دسته تقسیم نمودند: (الف) عامل‌های هوشمند بدون یادگیری ماشینی: این مورد هیچ قابلیت یادگیری ندارند و به سختی می‌توانند تجربیات گذشته و اطلاعات محیط پویا را در نظر بگیرند. این نوع عامل‌ها به سادگی اجرا و تجزیه و تحلیل می‌شوند. پیشتر سیستم‌های مبتنی بر عامل کنونی متعلق به این دسته هستند. آنها با قابلیت استدلال ساده می‌توانند مذاکره را آسان نمایند.

(ب) عامل‌های هوشمند با یادگیری ماشینی: در مقابل عامل‌ها با قابلیت یادگیری ماشینی یک پشتیبان تصمیم ساختگی برای انطباق با محیط پویا و رفتار متغیر رقیان فراهم می‌آورند. به طور واضحی داشتن یک راهبرد با سیستم پشتیبان تصمیم مصنوعی برای تطبیق با شرایط پویای محیط و تغییر رفتار رقبا مرجح است. تکنیک‌های مختلف مبتنی بر هوش مصنوعی و روش‌های ابتکاری و فراتکاری برای فرآهنم آوردن رفتار تطبیق‌پذیر برای عامل‌ها نظیر الگوریتم ژنتیک، یادگیری بیزی، و شبکه‌های عصبی به وجود آمده‌اند. عامل‌های هوشمند با قابلیت یادگیری قادرند تا

غیرقطعي مواد، تقاضاي تصادفي مشترى، زمان پردازش نامعین و موجودی بافر محدود را در بر می گيرد. آنها يك الگوريتم ترکيبي يادگيري Q - شبيه‌سازی تبريد برای اين مسئله پيشنهاد دادند.

فو و فو<sup>۱۲]</sup> يك سیستم چندعاملي يکپارچه با استدلال آگاه از زمينه و موضوع<sup>۷</sup> برای بهبود مدیریت همکارانه زنجирه تأمین پيشنهاد نمودند. سیستم پيشنهادی آنها موجب يکپارچگی بيشتر و تقویت يادگيري و انباطق با محیط زنجیره تأمین می شود.

مرتضوی<sup>۸</sup> و همکاران [۱۳] از طریق يك سیستم مبتنی بر عامل و با تعییه الگوريتم يادگيري تقویتی موجب بهبود يکپارچگی در يك زنجیره تأمین چهار سطحی با تقاضای نامعین شدند.

در ادبیات چندین نوع طراحی مختلف برای عامل‌ها وجود دارد. در حالتی که عامل، پاداشی مرتبط با مطلوبیت خود دریافت می‌کند، دو نوع طراحی مختلف برای عامل در نظر گرفته می‌شود<sup>[۱۴]</sup>:

- عامل يك تابع مطلوبیت براساس وضعیت خودش يا تاریخچه وضعیت‌هایی که داشته، ياد می‌گیرد و آن را برای انتخاب عملی که خروجی آن بیشترین مطلوبیت مورد انتظار را داشته باشد، استفاده می‌نماید.

- عامل يك تابع عمل - ارزش ياد می‌گیرد که مطلوبیت مورد انتظار این عمل را در موقعیت داده شده مشخص کند. این نوع يادگيري که بهعنوان يادگيري Q معروف است، نوع خاصی از يادگيري تقویتی نحسوب می‌شود.

در این مقاله مسئله تدارکات مبتنی بر مناقصه در چند مرحله بهصورت يك مسئله تصمیم‌گیری مارکوفی تعریف می‌شود و سیاست انتخاب عمل در الگوريتم يادگيري Q براساس بهترین مقادیر شخصی و جهانی ذرات در الگوريتم PSO بهروزرسانی می‌شود که نسبت به حالتی که انتخاب عمل بهصورت حریصانه انجام می‌شود، بسیار کاربردی‌تر است. رویکرد مبتنی بر تعییه يك الگوريتم يادگیرنده در عامل خریدار (برپاکننده مناقصه) بهمنظور يادگيري درباره انتخاب پرپوزال‌ها در چند دوره مناقصه پیاپی در حوزه مطالعات مربوط به حراج معکوس (مناقصه) يك نوآوری محسوب می‌شود. همچنین بهرغم سایر مطالعات که فقط براساس قیمت‌های پيشنهادی هستند، می‌توان از نوآوری‌های

این فرض انجام می‌شود که احتمال تغییر حالت فرآیند صرفاً به حالت و عمل قبلی وابسته است و مستقل از خاطره عمل‌های قبلی است. به عبارت دیگر فرض می‌شود که پذیرش یا عدم پذیرش پيشنهاد به پذیرش پيشنهاد قبلی آن وابسته است.

## ۲- مرور ادبیات:

چهارسوقی<sup>۱</sup> و همکاران [۷] يك رویکرد جدید برای تصمیم‌گیری در مورد سیاست سفارش‌دهی اعضای زنجیره تأمین بهصورت متمرکز پيشنهاد نموده‌اند. آنها زنجیره تأمین را بهعنوان يك سیستم چند عاملی در نظر گرفته و براساس يادگيري تقویتی فرموله نموده‌اند. نتایج آنها نشان داده است که مکانیزم يادگيري تقویتی نسبت به الگوريتم ژنتیک عملکرد بهتری داشته است. لی<sup>۲</sup> و همکاران [۸] يك شرکت با سیاست تولید برای سفارش را در نظر گرفته‌اند که توانایی رد یا قبول سفارشات را دارد و می‌تواند قیمت‌ها و زمان تحويل‌ها را تنظیم نماید. آنها حالتی را که شرکت نیاز دارد تا در رابطه با اینکه چه سفارشاتی را رد یا قبول نماید بهصورتی که يك تعادل بین قیمت و زمان تحويل بهوجود آورد را در نظر گرفته‌اند. آنها این مسئله را بهعنوان يك مسئله تصمیم‌گیری مارکوف در نظر گرفته و يك يادگيري تقویتی مبتنی بر الگوريتم يادگيري Q برای این مسئله توسعه داده‌اند. ایما و کورئه<sup>۳</sup> [۹] يك الگوريتم يادگيري تقویتی جمعی مبتنی بر بهینه‌سازی انبوه ذرات بهمنظور یافتن سریع سیاست بهینه پيشنهاد دادند بهصورتی که در این الگوريتم چندین عامل وجود دارد که نه فقط از يادگيري خود استفاده می‌کنند بلکه الگوريتم PSO را بهروزرسانی می‌نمایند. در الگوريتم پيشنهادی آنها مقادیر حالت - عمل براساس بهترین جواب جمعی و جواب شخصی یافت شده توسط عامل‌ها بهروزرسانی می‌شود. گیامونکارو و پنتراندولفو<sup>۴</sup> [۱۰] يك رویکرد برای مدیریت موجودی ارائه داد که از طریق تعیین سیاست سفارش‌دهی درصد بهینه‌سازی عملکرد کل زنجیره تأمین بود.

تانگ<sup>۵</sup> و همکاران [۱۱] يك خط تولید تقاضا محور را به همراه مرکز فروش مرتبط با آن بهعنوان يك سیستم دو سطحی در نظر گرفتند. این سیستم ویژگی‌های دریافت

1- Chaharsooghi

2- Li

3- Iima & Kuroe

4- Giannoccaro & Pontrandolfo

5- Tang

مربوط به  $s_t$  و  $a_t$  پارامتر ارزش زمانی است که مقداری بزرگ‌تر یا مساوی صفر و کوچک‌تر از یک می‌باشد.

(1)

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left[ R(s_t) + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t) \right]$$

در این الگوریتمتابع ارزش- عمل آموخته شده  $Q$ ، به طور مستقیم و مستقل از سیاستی که پیگیری شده است، مقدار  $Q^*$  را تخمین می‌زند. این مطلب آنالیز الگوریتم را ساده می‌نماید و اثبات همگرایی را ممکن می‌سازد [۱۵]. الگوریتم یادگیری  $Q$  در ساده‌ترین صورت به صورت زیر می‌باشد:

- متغیر  $\gamma$  و ماتریس پاداش محیط تنظیم می‌شود.
  - مقادیر تابع ارزش با مقادیر صفر مقداردهی اولیه می‌شود.
  - برای هر تکرار:
    - ✓ موقعیت اولیه به صورت تصادفی انتخاب می‌شود.
    - ✓ تا زمانی که به موقعیت هدف دست نیافته است:
      - ❖ از میان تمام عمل‌های ممکن برای موقعیت فعلی یکی انتخاب می‌شود.
      - ❖ با استفاده از عمل ممکن گذر به حالت بعدی لحاظ می‌شود.
      - ❖ مقدار بیشینه  $Q$  برای موقعیت بعدی براساس تمام اعمال ممکن به دست آورده می‌شود.
      - ❖ حالت بعدی به عنوان حالت جاری در نظر گرفته می‌شود.
- $$Q = [Q_{1,1}, Q_{1,2}, Q_{1,3}, \dots, Q_{5,25}, Q_{5,26}]$$

#### ۴- جزئیات طراحی مکانیزم تدارکات مبتنی بر یادگیری عامل خریدار

در مکانیزم پیشنهادی، خریدار با شبیه‌سازی محیط مناقصه، به منظور دستیابی به یک توافق و براساس یک الگوریتم یادگیری به صورت تک عاملی به دنبال انجام تدارکات با هدف کاهش هزینه‌های خود است. جزئیات الگوریتم یادگیری  $Q$  که نوعی یادگیری تقویتی است در ادامه مطرح شده‌اند:

##### ۴-۱- حالت سیستم

در چارچوب یادگیری تقویتی، عامل تصمیمات خود را مبتنی بر تابعی از سیگنال‌های دریافت شده از محیط که حالت محیط نام دارد، بنا می‌کند. در واقع براساس حالت محیط، حالت عامل یادگیرنده مشخص می‌شود. در مسئله ما ورودی‌های عامل خریدار عبارتند از قیمت‌ها و زمان‌های تحویل دریافت شده از تأمین‌کنندگان. خریدار براساس شبیه‌سازی محیط باید بهترین تصمیم را برای تغییر حالت

دیگر در این زمینه به در نظر گرفتن هزینه‌های ناشی از دیرکرد در انتخاب پروپوزال تأمین‌کنندگان اشاره کرد.

### ۳- یادگیری تقویتی

مسئله یادگیری تقویتی مکانیزم یادگیری حاصل از تعاملات را به منظور دستیابی به اهداف بیان می‌کند. در این مسئله یادگیرنده و تصمیم‌گیرنده عامل نام دارد. موجودیت‌هایی که تعامل عامل با آنها صورت می‌پذیرد محیط نامیده می‌شود. در این تعامل به طور دائم عامل (در مسئله ما خریدار) اعمالی رانتخاب می‌نماید و محیط (تأمین‌کنندگان یا پیشنهادهای دهنده) در مناقصه) به این اعمال پاسخ می‌دهد و موقعیت جدید را به عامل عرضه می‌نماید. نتیجه برقراری ارتباط عامل با محیط پاداش‌ها (ارزش‌های عددی خاص که عامل سعی در بیشینه کردن آنها در طی زمان دارد) و دستیابی به موقعیت‌های جدید است [۱۵]. در هر گام زمانی عامل یک نگاشت از حالات به احتمالات انتخاب هر عمل ممکن را به کار می‌برد. این نگاشت سیاست عامل نامیده می‌شود. سیاست عامل با  $\Pi_t(s,a)$  نشان داده می‌شود که عبارت است از احتمال اینکه در دوره  $t$  حالت سیستم  $S$  باشد و عمل  $a$  انجام شود. روش‌های یادگیری تقویتی مشخص می‌نماید که عامل چگونه سیاست‌های خود را بر طبق تجربیات خود تغییر دهد. هدف عامل به طور کلی بیشینه کردن میزان کلی پاداش‌ها در دراز مدت است. هر چیزی که به صورت دلخواهانه امکان تغییر توسط عامل را نداشته باشد، جزیی از محیط محسوب می‌شود. در حقیقت ممکن است عامل درباره چگونه کار کردن محیط بداند اما آن را تحت کنترل نداشته باشد. بنابراین حدفاصل عامل- محیط نشان‌دهنده محدودیت عامل در کنترل است و نه دانش آن. یکی از مهم‌ترین نقاط قوت یادگیری تقویتی توسعه الگوریتم یادگیری  $Q$  می‌باشد [۱۶]. رابطه به روزرسانی این الگوریتم در ساده‌ترین فرم این الگوریتم که الگوریتم یادگیری  $Q$  تک قدمی نامیده می‌شود، به صورت فرمول ۱ تعریف می‌شود [۱۷]، که در آن مقدار  $Q(s,a)$  عبارت است از مجموع پاداش‌های دریافت شده هنگامی که از حالت  $S$  شروع و عمل  $a$  را انجام و خطمش موجود را دنبال نموده باشد. اندیس  $t$  و  $t+1$  اشاره به دوره قبلی و دوره فعلی دارد.  $\alpha$  نرخ یادگیری و نشان‌دهنده میزان تأثیر دوره‌های آتی است که مقداری بین صفر تا کوچک‌تر یا مساوی یک می‌گیرد.  $R_t(s,a)$  پاداش

عمل براساس بهترین مقادیر شخصی و جهانی ذرات الگوریتم بهینه‌سازی هوش ازدحامی ذرات PSO بنا شده است.

### ۳-۴- هدف

در حقیقت هدف از ایجاد این الگوریتم یادگیرنده تعیین یک تخصیص سفارشات منطقی در چند مرحله مناصله پیاپی از سوی خریدار است، به طوری که هزینه تدارکات را کمینه نماید.

### ۴-۴- تابع پاداش

یک تابع پاداش نگاشتی از حالت مشاهده شده به یک عدد واحد، پاداش نامیده می‌شود. پاداش میزان مطلوبیت حالت سیستم (یا عمل انجام شده در آن حالت) است، بنابراین تابع پاداش باید تعریف کننده اهداف در مسئله یادگیری تشخیصی باشد. پاداش به عنوان خروجی تابع پاداش یک مقدار مثبت است که هرگاه به بهترین حالت دست یافته‌ی پاداش دریافت می‌کنیم. از آنجا که هدف این الگوریتم کاهش هزینه تدارکات است، در نتیجه لازم است که تابع پاداش در برگیرنده هزینه باشد. بنابراین هزینه خریدار را براساس قیمت تدارکات و زمان‌های دیرکرد که موجب هزینه مواجهه با کسری موجودی می‌شود در نظر می‌گیرند. در واقع خریدار با تخصیص سفارش به تأمین‌کنندگان بهتر، قیمت و زمان تحويل مناسب‌تری را شاهد خواهد بود.

### ۴-۵- تابع ارزش

ارزش یک حالت عبارت است از حجم کلی پاداشی که یک عامل می‌تواند توقع داشته باشد تا در آینده با شروع از حالت اولیه اندوخته شود و برخلاف پاداش‌ها که میزان مناسب بودن حالات آنی محیط هستند ارزش‌ها نشان‌دهنده میزان مطلوبیت طولانی مدت حالات می‌باشند. با توجه به استفاده از الگوریتم Q در اینجا، لذا باید توابع ارزش عمل نیز مورد استفاده قرار گیرد. بدین منظور از رابطه (۱) که در توصیف کلی الگوریتم به آن اشاره شد، استفاده شده است. به طور کلی ارزش عمل a در حالت مفروض s برابر است با پاداشی که در نتیجه انجام عمل a در حالت s به سیستم تعلق می‌گیرد. به علاوه پاداشی که در نتیجه انجام بهترین عمل بنابر یادگیری‌های پیشین صورت گرفته در حالت بعدی سیستم که 's' است به سیستم تعلق می‌گیرد. به منظور انجام محاسبات مقادیر اولیه برای توابع ارزش عمل به طور اختیاری صفر در نظر گرفته می‌شود.

از حالت فعلی به حالت بعدی لحاظ نماید. حالت عامل عبارت است از مقدار تقاضای (باقیمانده تقاضا) خریدار در رابطه با هر قطعه مورد نیاز، به طوری که در حالت اولیه، خریدار میزان تقاضای کل برای هر نوع قطعه را نشان می‌دهد. فضای حالت مجموعه تمام حالت‌هایی است که از حالت اولیه طی توالی عملیات مختلف قبل دستیابی است که عبارت است از میزان تقاضای باقیمانده خریدار. حالت هدف برای خریدار نیز عبارت است از حالتی که در آن مانده تقاضا برابر صفر باشد و تقاضای خریدار ارض شود.

### ۲-۴- عمل و سیاست انتخاب عمل

برای حرکت عامل خریدار از حالتی به حالت دیگر باید عمل انجام بگیرد. عمل‌های امکان‌پذیر برای تغییر از حالت اولیه به حالت‌های شدنی دیگر عبارت خواهد بود از مقادیر تخصیص یافته به هر تأمین‌کننده (Q) (پیشنهادهای پذیرفته شده در هر مرحله از مناصله) که با توجه به اینکه پنج تأمین‌کننده و ۲۶ نوع قطعه در نظر گرفته شده است به صورت زیر می‌باشد که در آن  $Q_{1,3}$  یعنی میزان محصول ۳ که به تأمین‌کننده اول تخصیص داده می‌شود و  $Q_{3,10}$  یعنی میزان محصول ۱۰ که به تأمین‌کننده سوم تخصیص داده می‌شود.

سیاست انجام این عمل مطابق با سیاست حل مسئله بهینه‌سازی است. عموماً سیاست انتخاب عمل می‌تواند از روش‌های حریصانه یا سافت مکس<sup>۱</sup> که در آن انتخاب عمل به مقیاسی عددی تحت عنوان دما یا درجه حرارت بستگی دارد، استفاده می‌شود. لذا در آن درجه حرارت پارامتری مثبت است:

$$p(a_i) = \frac{e^{\frac{Q(s,a_i)}{T}}}{\sum_{j=1}^{S_k} e^{\frac{Q(s,a_j)}{T}}} \quad (2)$$

در رابطه فوق p(a<sub>i</sub>) احتمال انتخاب عمل و S<sub>k</sub> تعداد اعمال انتخاب شده در حالت s می‌باشد. حال اگر مقادیر Q هزینه مورد انتظار را بازنمایی کنند، با وارد نمودن مقادیر Q با علامت منفی در فرمول انتخاب عملی با بالاترین احتمال، کمترین هزینه را در پی خواهد داشت. عموماً درجه حرارت از مقادیر بزرگ شروع شده و به تدریج نسبت به زمان کاهش می‌یابد. در این مقاله سیاست جستجوی بهترین

تصادفی از بین تأمین‌کننده‌های ۱ تا  $n$  یک تأمین‌کننده را به صورت تصادفی انتخاب کرده و به آن به صورت تصادفی عددی در بازه ( $Q_i^{\text{rem}}$ , remaining demand) از  $\text{Min}(Q_i)$  آن قطعه سفارش داده می‌شود. پس از این عمل تقاضای باقیمانده وضعیت عامل را نشان می‌دهد. به عنوان مثال فرض کنید سه تأمین‌کننده وجود داشته و تعداد کل تقاضاً برابر ۱۰۰ باشد، از بازه [۳۱، ۶۹] به صورت تصادفی عدد ۲ یعنی تأمین‌کننده دوم انتخاب می‌شود، با توجه به اینکه هنوز تخصیصی انجام نشده است و حداقل میزانی که به آن تأمین‌کننده تخصیص می‌باید برابر ۸۰ باشد، به آن عددی تصادفی در بازه ۰ تا [۸۰، ۱۰۰] تخصیص داده می‌شود. به طور مثال به تأمین‌کننده دوم، ۴۳ عدد تخصیص می‌دهیم. حال یک عدد تصادفی دیگر از بازه ۱ تا ۳ به جز عدد انتخاب شده، مثلاً عدد ۱ انتخاب می‌شود. با فرض اینکه حداقل بتوان به آن ۱۲۰ عدد تخصیص داد و مانده تقاضاً برابر ۵۷ است، عدد تصادفی در بازه ۰ تا ۵۷ مثلاً ۵۰ عدد به تأمین‌کننده اول تخصیص داده می‌شود و در نهایت ۷ واحد مانده را به تأمین‌کننده سوم تخصیص می‌دهد. با در نظر گرفتن این فرآیند برای موضوع‌های دیگر نمایش جواب به صورت یک ماتریس  $Z^*$  خواهد بود که آرایه‌های آن مقادیر تخصیص داده شده  $q$  یعنی عمل‌های ممکن می‌باشند.

#### ۵-۲- بردار سرعت اولیه در الگوریتم PSO:

بعد از اینکه جمعیت اولیه ساخته شد یک بردار سرعت به صورت تصادفی ایجاد نمایید. توجه کنید که بردار سرعت اولیه برابر صفر در نظر گرفته شده باشد.

#### ۵-۳- ایجاد جمعیت بعدی در الگوریتم PSO

همان‌طور که بیان شد، در گام اول یک جمعیت تصادفی از ذره‌ها ساخته شد؛ حال برای ایجاد مکان و سرعت جدید و بهمنظور به روزرسانی عمل‌ها طبق فرمول‌های PSO عمل نمایید که به صورت زیر خواهد بود:

$$\begin{aligned} v_{ij}^t &= \omega v_{ij}^{t-1} + c_1 r_1 (p_{ij}^{t-1} - x_{ij}^{t-1}) + c_2 r_2 (G_j^{t-1} - x_{ij}^{t-1}) \\ x_{ij}^t &= x_{ij}^{t-1} + v_{ij}^t \end{aligned} \quad (3)$$

اگر جمع مقادیر تخصیص داده شده برای یک نوع قطعه برابر میزان تقاضاً برای آن قطعه نباشد، می‌توان اذعان کرد که جمع مقادیر تخصیص داده شده با میزان تقاضاً برای آن مقایسه می‌شود. لذا اگر تساوی برقرار بود که مشکلی وجود ندارد، اما اگر جمع مقادیر بزرگ‌تر باشد باید از میان جواب‌هایی که موقعیت جدیدشان نسبت به موقعیت قبلی

فصلنامه علمی- ترویجی

#### ۵- جزئیات الگوریتم PSO به عنوان سیاست انتخاب عمل در الگوریتم یادگیری Q

در این مقاله سیاست انتخاب عمل براساس الگوریتم بهینه‌سازی هوش ازدحامی ذرات PSO بنا شده است. اولین بار در سال ۱۹۹۵، الگوریتم بهینه‌سازی حرکت دسته جمعی (PSO) توسط کندی و ابرهارت<sup>۱</sup> معرفی شد [۱۸]. PSO از هوش جمعی الهام گرفته شده است. این روش سعی در تقلید رفتار اجتماعی ارگان‌های طبیعی نظیر دسته پرندگان و ماهی‌ها در یافتن غذا دارد. در این گونه جمعیت‌ها بدون آنکه کنترل مرکزی صورت بگیرد یک رفتار هماهنگ شده با استفاده از حرکات محلی بروز پیدا می‌کند [۱۹]. همان‌طور که اشاره شد از الگوریتم ازدحام ذرات به عنوان راهکاری برای یافتن و انتخاب سیاست بهینه برای انتخاب عمل استفاده شده است؛ در واقع به این ترتیب انتخاب اعمالی که خریدار را از حالتی به حالت دیگر انتقال می‌دهند یعنی مقادیر تخصیص اقلام‌های مختلف به تأمین‌کنندگان مختلف به وسیله الگوریتم PSO مشخص می‌شود. در واقع در این فرآیند مقادیر عمل و حالت براساس بهترین مقادیر شخصی و جهانی ذرات در الگوریتم PSO به روزرسانی می‌شود. همچنین در مسائل یادگیری تقویتی با افزایش مقیاس در مسائل بزرگ مسئله تعداد حالت‌ها افزایش می‌یابد. لذا ذخیره مقادیر همه حالت‌ها هزینه استفاده از ظرفیت حافظه را به شدت افزایش می‌دهد. در مسئله ما به این علت که خریدار در درک محیط خود با محدودیت مواجه است، لذا تعیین حالت جاری به طور کامل غیرممکن است. بنابراین عامل خریدار به این علت که نمی‌تواند به طور کامل حالت محیط خود را حس کند، دچار اشتباہ می‌شود و سیستم از خاصیت مارکوفی دور می‌افتد؛ لذا برای جلوگیری از این امر از الگوریتم‌های ابتکاری استفاده می‌شود و [۲۰، ۹]. در واقع در این مقاله از رویکردی مشابه [۹] استفاده گردیده است. جزئیات الگوریتم PSO برای انتخاب عمل در زیربخش‌های بعد آمده است.

#### ۵-۱- ایجاد جمعیت اولیه در الگوریتم PSO

به تعداد تأمین‌کننده‌ها آرایه در نظر گرفته می‌شود، به این صورت که آرایه اول مربوط به تأمین‌کننده اول، و آرایه  $n$  مربوط به تأمین‌کننده  $n$  است. این آرایه‌ها مقادیر تقاضای خریدار را در بر می‌گیرند. برای هر قطعه به صورت

و برای نرخ یادگیری مقدار  $0/6$  و برای متغیر ارزش زمانی (تخفیف) مقدار  $0/8$  مناسب است.

بهمنظور تنظیم عوامل متغیر الگوریتم PSO، این الگوریتم با ترکیب‌های مختلف سطوح مقادیر متغیرها اجرا شده است؛ به این صورت که سه سطح برای تعداد تکرارها ( $100$ ،  $120$ ،  $140$ )، دو سطح برای تعداد ذرات ( $30$  و  $40$ )، سه سطح برای یادگیری فردی ( $1/5$ ،  $2/5$ ،  $3/5$ )، سه سطح برای  $W_{\min}$  برای یادگیری جمعی ( $1/5$ ،  $2/5$ ،  $3/5$ )، سه سطح برای  $W_{\max}$  ( $0/1$ ،  $0/2$ ،  $0/3$ ) و سه سطح برای  $W_{\max}$  ( $0/8$ ،  $0/10$ ،  $0/12$ ) در نظر گرفته شده است. بهترین سطح برای مقادیر متغیرهای الگوریتم ازدحام ذرات در الگوریتم ترکیبی در جدول (۱) نشان داده شده است:

جدول (۱): بهترین مقادیر عوامل متغیر PSO

$W_{\max}$	$W_{\min}$	یادگیری جمعی ( $c_2$ )	یادگیری فردی ( $c_1$ )	تعداد ذرات	تعداد تکرارها
$0/8$	$0/1$	$2/5$	$1/5$	$40$	$120$

در ادامه نتایج حاصل از الگوریتم پیشنهادی (الگوریتم ۱) با حالتی که سیاست انتخاب عمل به روش حریصانه (الگوریتم ۲) انجام می‌شود (با ثابت نگهداشتن متغیرهای الگوریتم یادگیری تقویتی) مقایسه شده است.

قابل ذکر است که کدنویسی الگوریتم در نرمافزار Matlab R2011b با مشخصات حافظه  $4$  گیگابایت اجرا شده است. بنابراین الگوریتم با توجه به مقادیر خطای کم و سرعت حل آن کارا و کارآمد است. اشاره می‌شود که خطای بهصورت رابطه (۵) محاسبه شده است:

$$\begin{aligned} dev_{Q-PSO} &= \frac{sol_{Q-PSO} - sol_{best}}{sol_{best}} \\ dev_{Q-greedy} &= \frac{sol_{Q-greedy} - sol_{best}}{sol_{best}} \\ sol_{best} &= \min\{sol_{Q-PSO}, sol_{Q-greedy}\} \end{aligned} \quad (5)$$

نتایج مربوط به متوسط هزینه و متوسط زمان اجرا برای تکرارهای مختلف مسئله در دو الگوریتم در جداول (۲) و (۳) قابل مشاهده است. براساس نتایج جدول (۲) مشاهده می‌شود که الگوریتم پیشنهادی قادر است بهصورت کارآمد با انحراف کم نسبت به بهترین جواب یافت شده و در زمان کوتاه‌تر نسبت به حالتی که سیاست انتخاب عمل حریصانه است، به نتیجه مناسب دست یابد. در جدول (۳) درصد

آنها بزرگ‌تر است (یعنی  $0 < x_{new} - x_{old}$ )، به صورت تصادفی انتخاب شده و یک واحد یک واحد از آنها کم شود تا تساوی برقرار گردد. همچنین اگر جمع مقادیر کوچک‌تر باشد، از میان جواب‌هایی که موقعیت جدید آنها نسبت به موقعیت قبلی آنها کوچک‌تر شده است (یعنی  $0 < x_{new} - x_{old}$ ) به صورت تصادفی انتخاب شده و یک واحد یک واحد از آنها کم شود تا تساوی برقرار گردد. با انجام این کار موقعیت جدید اصلاح شده و سرعت جدید نیز طبق رابطه (۴) اصلاح می‌شود.

$$(v_{new})_{modified} = (x_{new})_{modified} - x_{old} \quad (4)$$

حال مقدار تابع هدف به ازای  $(x_{new})_{modified}$  محاسبه می‌شود. در واقع جواب‌های جدید به عنوان جمعیت جدید ذرات در نظر گرفته می‌شود. بنابراین جمعیت جدید باعث بهروزرسانی عمل‌ها و حالت‌ها می‌گردد. لازم است که مجددًا اشاره شود که عمل‌ها و حالت‌ها برای مسئله ما بر هر یک از اقلام به صورت جداگانه در نظر گرفته شده است. به عبارت دیگر برای اراضی تقاضای هر یک از انواع اقلام مورد نظر یادگیری متمایز و موازی با سایر اقلام وجود دارد، اما در نهایت هدف ما کاهش هزینه‌های تدارکات و هزینه‌های دیرکرد کلی است.

## ۶- نتایج محاسباتی

الگوریتم ارائه شده برای حل مسئله تخصیص سفارشات بهمنظور کمینه‌سازی هزینه تدارکات و دیرکرد مطابق یک مسئله در مطالعه موردي در شرکت تأمین قطعات خودروسازی استفاده شده است. در الگوریتم Q متغیرهایی به این شرح وجود دارند:  $p_s$  یا احتمال جستجوی پراکنده،  $p_e$  یا احتمال بهره‌برداری (جستجوی مرکز) و  $\alpha$  نرخ تعداد تکرار شبیه‌سازی سیستم در فاز یادگیری و  $\beta$  نرخ یادگیری که مقدار کم آن باعث می‌شود که عامل بیشتر از اطلاعات قدیمی استفاده نماید و مقدار بزرگ آن باعث می‌شود که فقط اطلاعات جدید را ملاک قرار دهد و  $\gamma$  نیز عامل متغیر ارزش زمانی (نرخ تخفیف) است که مقدار کم آن باعث می‌شود عامل بهصورت حریصانه عمل نموده و فقط پاداش‌های فعلی را در نظر بگیرد و مقدار بزرگ نرخ تخفیف باعث می‌شود به دنبال پاداش‌های تجمعی در طولانی مدت باشد. با انجام تکرارهای متعدد و تحلیل حساسیت نسبت به مقادیر متغیرها این آگاهی دست می‌دهد که برای احتمال جستجو مقدار  $0/8$  و برای احتمال بهره‌برداری مقدار  $0/2$

## ۷- نتیجه‌گیری و پژوهش‌های آتی

در این مقاله یک مسئله مناقصه چند مرحله‌ای را که در آن خریدار قصد دارد برای چند دوره پیاپی از تعدادی تأمین‌کننده مشخص، تعدادی از اقلام مورد نیاز خود را تأمین نماید را به عنوان یک مسئله تصمیم‌گیری مارکوفی مدل‌سازی نمودیم. برای حل این مسئله تصمیم‌گیری مارکوفی که انتخاب عمل در هر مرحله آن به حالت و عمل در مرحله قبل بستگی دارد یک الگوریتم یادگیری Q توسعه داده شده است که سیاست انتخاب عمل در آن براساس الگوریتم ازدحام ذرات است. در مقایسه این الگوریتم با حالتی که در آن سیاست انتخاب عمل حریصانه دارد، این الگوریتم بسیار کارآمدتر است. پژوهش‌های آتی می‌تواند حالتی را در نظر بگیرد که مناقصه در یک سیستم چند عاملی انجام شود که در آن عامل‌های خریدار و تأمین‌کننده‌گان همکی قابلیت یادگیری دارند.

## منابع

- [1] Chopra, Sunil, and Peter Meindl., “*Supply chain management*”. Strategy, planning & operation. Gabler, 2007.
- [2] Bichler,M. and Kalagnanam,J., “*A nonparametric estimator for setting: reserve prices in procurement auctions*”. ACM Conference on Electronic Commerce 2003: 254-255, 2003.
- [3] Chen, S.L. and M.M. Tseng., “*A Negotiation-Credit-Auction Mechanism for Procuring Customized Products*”. International Journal of Production Economics, 127(1): 203-210, 2010.
- [4] Padgham, Lin, and Michael Winikoff., “*Developing intelligent agent systems: A practical guide*”. Vol. 13. Wiley, 2005.
- [5] Beam, C., and Segev, A., “*Automated negotiations: A survey of the state of the art*”. Wirtschaftsinformatik 39(3), 263-268, 1997.
- [6] Sutton, R.S., editor., “*Reinforcement Learning*”. Kluwer Academic Press, Boston, MA, 1992.
- [7] Chaharsooghi, S. K., J. Heydari, et al., “*A reinforcement learning model for supply chain ordering management: An application to the beer game*”. Decision Support Systems 45(4): 949-959, 2008.
- [8] Li, X., Wang, J., & Sawhney, R., “*Reinforcement learning for joint pricing, lead-time and scheduling decisions in make-to-order systems*”. European Journal of Operational Research, 221(1), 99-109, 2012.

فصلنامه علمی - تحقیقی

کاهش هزینه‌ها با استفاده از رویکرد پیشنهادی نسبت به حالتی که سیاست انتخاب عمل حریصانه است، نشان داده شده است.

جدول (۲): نتایج مقایسه دو الگوریتم با توجه به زمان اجرا و انحراف نسبت به بهترین جواب

تعداد شرکت کننده‌گان	مناقصه	اجرا	الگوریتم Q با سیاست انتخاب عمل حریصانه	الگوریتم Q با سیاست انتخاب عمل PSO	متوجه	انحراف نسبت به زمان (ثانیه)	متوجه	انحراف نسبت به بهترین جواب
۱۵	۱		۱/۶۳۴	۰	۱/۳۷۵	۰/۰۹۵		
۳۰	۲		۴/۴۵۱	۰	۲/۹۲۳	.		
۴۵	۳		۷/۶۱۰	۰	۴/۴۳۵	۰/۰۴۳		
۶۰	۴		۹/۳۴۱	۰/۰۹۵	۷/۹۷۵	.		
۷۵	۵		۱۳/۵۲۹	۰/۱۹۰	۱۱/۹۷۰	.		
۹۰	۶		۲۲/۳۱۷	۰/۳۶۸	۱۴/۷۹۱	.		
۱۰۰	۷		۲۹/۳۴۱	۰/۴۲۱	۱۹/۸۷۱	.		
۱۲۰	۸		۳۵/۷۸۱	۰/۰۵۰	۲۳/۵۰۲	.		
۱۳۰	۹		۴۱/۹۱۲	۰/۲۰۰	۲۸/۳۷۱	.		
۱۵۰	۱۰		۴۹/۳۴۶	۰/۴۱۰	۳۴/۲۳۱	.		

جدول (۳): کاهش هزینه‌ها با استفاده از رویکرد پیشنهادی نسبت به حالتی که سیاست انتخاب عمل حریصانه است

تعداد شرکت کننده‌گان	مناقصه	اجرا	درصد کاهش هزینه تدارکات با استفاده از رویکرد پیشنهادی نسبت به حالتی که سیاست انتخاب عمل حریصانه است
۱۵	۱		%۱۸
۳۰	۲		%۲۳
۴۵	۳		%۳۱
۶۰	۴		%۲۸
۷۵	۵		%۳۶
۹۰	۶		%۲۹
۱۰۰	۷		%۴۲
۱۲۰	۸		%۳۸
۱۳۰	۹		%۳۴
۱۵۰	۱۰		%۳۹

- [14] Russell,S and Peter Norvig., “*Artficial Intelligence: A Modern Approach*”. Prentice-Hall, Saddle River, NJ, 1995.
- [15] Sutton, R.S., Barto, A.G., “*Reinforcement Learning*”. MIT Press, Cambridge,1998.
- [16] Watkins, C. J. C. H., “*Learning from delayed rewards*”(Doctoral dissertation, University of Cambridge), 1989.
- [17] Tsitsiklis, J. N., “*Asynchronous stochastic approximation and Q-learning*”. Machine Learning, 16(3), 185-202, 1994.
- [18] Kennedy, J., Eberhart, R.C., “*Swarm Intelligence*”. Morgan Kaufmann Publishers, San Francisco, 2001.
- [19] Talbi,E., “*Metaheuristics: From Design to Implementation*”. ISBN: 978-0-470-27858-1, 2009.
- [20] Abdulhai, B., Pringle, R. and Karakoulas, G.J., “*Reinforcement learning for ITS: Introduction and a case study on adaptive traffic signal control*”. Transportation Research Board 80th Annual Meeting, Washington, D.C, 2001.
- [9] Iima, H., Kuroe, Y., “*Swarm Reinforcement Learning Algorithm Based on Particle Swarm Optimization Whose PersonalBests Have Lifespans*”. Neural Information Processing, Springer Berlin Heidelberg. 5864: 169-178, 2009.
- [10] Giannoccaro, I. and P. Pontrandolfo., “*Inventory management in supply chains: a reinforcement learning approach*”. International Journal of Production Economics 78(2): 153-161, 2002.
- [11] Tang, H., Xu, L., Sun, J., Chen, Y., & Zhou, L., “*Modeling and optimization control of a demand-driven, conveyor-serviced production station*”. European Journal of Operational Research, 243(3), 839-851, 2015.
- [12] Fu, J., & Fu, Y., “*An adaptive multi-agent system for cost collaborative management in supply chains*”. Engineering Applications of Artificial Intelligence, 44, 91-100, 2015.
- [13] Mortazavi, A., Khamseh, A. A., & Azimi, P., “*Designing of an intelligent self-adaptive model for supply chain ordering management system*”. Engineering Applications of Artificial Intelligence, 37, 207-220, 2015.