

Improving Memory for Solving Dynamic Distributed Factory Coordination Problem

Roohallah Daneshpayeh*

Assistant Professor, Department of Mathematics,
Payame Noor University, p.o.box. 19395-4697,
Tehran, Iran.

Majid Mohammadpour

Ph.D. Student in Computer Engineering, Yazd
University, Yazd, Iran.

Abstract

Many real-world problems involve the coordination of multiple agents in dynamic environments. Machines in a factory may need to coordinate the scheduling and execution of jobs to ensure smooth operation as customer demands shift. In the domain of factory operations, adaptive, self-organizing agent-based approaches have been shown to provide very robust solutions. However, these adaptive approaches may require non-trivial amounts of time to respond to large environmental shifts. Techniques exist that have been shown to help many different approaches perform better when problems are dynamic. One common technique is the use of information from the past to improve current performance. In many dynamic problems, the current state of the environment is often similar to previously seen states. Using information from the past may help to make the system more adaptive to large changes in the environment and to perform better over time. One way to maintain and exploit information from the past is the use of memory, where solutions are stored periodically and can be retrieved and refined when the environment changes. This paper introduces several density-estimation memory systems that are inspired by estimation of distribution for solving one of the hard dynamic problems (Factory coordination). In this proposed method, instead of storing only single points in memory, we propose to store clusters of points in each memory entry and to create a model of the points in each cluster. In this proposed method we will be able to store many more points, the computation overhead required for the memory will remain low. The experimental results show the efficiency of the proposed algorithm in comparison with other methods.

Keywords: density estimation memory, *R – wasps*, factory coordination, dynamic problem

Received: 24/February/2023

Accepted: 15/August/2023

ISSN: 2980-8936

* Corresponding Author: Rdaneshpayeh@pnu.ac.ir

بهبود حافظه برای حل مسئله هماهنگ‌سازی کارخانه‌های پویای توزیع شده

روح اله دانش پایه *

استادیار گروه ریاضی، دانشگاه پیام نور، تهران، ایران.

مجید محمدپور

دانشجوی دکتری مهندسی کامپیوتر، دانشگاه یزد، ایران.

چکیده

در دنیای واقعی، مشکلات بسیاری روند هماهنگ‌سازی عامل‌های چندگانه را در محیط‌های پویا تهدید می‌کند. دستگاه‌ها و ماشین‌های موجود در کارخانه اصولاً به یک برنامه‌ریزی مشخص احتیاج دارند تا بدین وسیله بتوانند عملیات را با اطمینان بیشتر و مطابق با تقاضای مشتری انجام دهند. در حیطه فعالیت‌ها و عملیات کارخانه، رویکردهای مبتنی بر عامل‌های خودسازمانده و انطباقی، اصولاً قادر هستند راه‌حل‌های قوی و معتبری فراهم کنند. با این حال، رویکردهای انطباقی به میزان مشخصی زمان برای پاسخ‌دهی به تغییرات محیطی احتیاج دارند. به هنگام رویارویی با مسائل پویا، تکنیک‌هایی که در دست دارید می‌تواند به بهتر انجام‌شدن روش‌های مختلف دیگر کمک کند. یکی از این روش‌های معمول، استفاده از اطلاعات گذشته به منظور بهبود و ارتقاء عملکردهای فعلی می‌باشد. در بسیاری از مسائل پویا، وضعیت کنونی محیط شباهت قابل توجهی با حالت‌هایی که در گذشته مشاهده شده است، دارد. استفاده از اطلاعات پیشین با گذشت زمان ممکن است به منطبق‌سازی هرچه بیشتر سیستم با تغییرات وسیع محیطی و اجرای بهتر کمک کند. یکی از راه‌هایی که به موجب آن می‌توان اطلاعات گذشته را حفظ و نگهداری کرد استفاده از حافظه‌ای است که راه‌حل‌ها را به صورت دوره‌ای ذخیره کرده، بازایی نموده و به هنگام اعمال تغییرات محیطی آن‌ها را تصحیح نماید. مقاله حاضر قصد دارد چندین سیستم حافظه ارزیابی چگالی را که از تخمین الگوریتم‌های توزیع، الهام گرفته‌اند ارائه نموده و از این سیستم برای حل یکی از مشکل‌ترین مسائل پویا (مسئله هماهنگ‌سازی توزیع‌شده پویا) استفاده نماید. در سیستم‌های حافظه ارائه‌شده، به جای ذخیره کردن تنها نقاط تکی در حافظه، خوشه‌هایی از نقاط در هر مدخل حافظه ذخیره می‌شوند و مدلی از هر نقاط در هر خوشه ایجاد می‌شود. این نوع حافظه، قادر به ذخیره کردن نقاط بیشتری بوده و سربار محاسباتی برای این نوع حافظه کم است. نتایج آزمایش‌ها، حاکی از برتری روش پیشنهادی نسبت به سایر روش‌ها است.

کلیدواژه‌ها: حافظه تخمین تراکم، $R - wasps$ ، هماهنگ‌سازی کارخانه، مسئله پویا

۱- مقدمه

در مسائل جهان واقعی عامل‌های چندگانه با مشکلاتی مواجه هستند که روند هماهنگی عامل‌ها را در یک محیط پویا مورد تهدید قرار می‌دهد. ابزار موجود در کارخانه به یک برنامه‌ریزی مشخص نیاز دارند تا بتوانند عملیات را با قابلیت اعتماد بیشتری و سازگار با تقاضای مشتریان انجام دهند. در یک کارخانه، گروهی از روبات‌ها ممکن است نیاز به هماهنگ‌سازی و تخصیص صحیح وظایف داشته باشند. بدین ترتیب، آن‌ها می‌توانند در محیط‌های جدید و در حال تغییر نیز کار کنند. عامل‌های مبتنی بر وب به هماهنگ‌سازی خدماتی از قبیل جمع‌آوری اطلاعات بسته به نوع ورودی یا تغییر تقاضای مربوطه مستلزم می‌باشند. عموماً، یک رویکرد مطابق با ماهیت مسئله انتخاب می‌شود که قادر است مسائل پویا را به طرق مختلفی حل کند. تغییرات به وجود آمده بایستی سرتاسر با رویه حل مسائل در هر برهه زمانی که اتفاق می‌افتد، هم‌خوانی داشته باشد. استفاده از شیوه بهینه‌سازی متمرکز به مرور زمان راه‌حل خوبی را کشف کرده، مدل توزیع شده ثابتی را با تغییرات وفق داده و مدل جدیدی را جهت هماهنگ‌سازی رویکردها فرا می‌گیرد. در حیطه فعالیت‌ها و عملیات کارخانه، رهکارهای مبتنی بر عامل‌های خودسازمانده و انطباقی، قادر هستند راه‌حل‌های قوی و معتبری فراهم کنند. یک مرکز تولیدی اساساً محیطی پویا و در عین حال پیچیده است که تغییرات در میزان تقاضای محصول و در دسترس بودن منابع آن به صورت کاملاً ثابت و معین رخ می‌دهد. این نوع تغییرات اغلب اوقات با تلاش برای ایجاد برنامه‌های پیشرفته تناقض دارد. به واسطه استفاده از روش‌های انطباقی مذکور، یک زمان‌بند می‌تواند نسبت به رویدادهای غیرقابل پیش‌بینی حساس بوده و از برنامه‌ریزی‌های غیرمجاز جلوگیری کند. با این حال، رویکردهای انطباقی ذکر شده نیاز به زمان زیادی برای پاسخ به تغییرات محیطی دارند. به هنگام مواجهه با مسائل پویا، روش‌های موجود، می‌توانند به انجام شدن بهتر روش‌های آتی کمک کنند. یکی از این روش‌های معمول، استفاده از راه‌حل‌های گذشته به منظور بهبود عملکردهای فعلی می‌باشد. در بسیاری از مسائل پویا، وضعیت فعلی محیط شباهت قابل توجهی با حالت‌هایی که در گذشته مشاهده شده؛ دارد. استفاده از اطلاعات گذشته ممکن است با گذشت زمان به منطبق‌سازی هرچه بیشتر سیستم با تغییرات وسیع محیطی و اجرای بهتر کمک کند. یکی از راه‌هایی که به موجب آن می‌توان اطلاعات گذشته را حفظ و نگهداری کرد، استفاده از حافظه‌ای است که راه‌حل‌ها را به صورت دوره‌ای ذخیره کرده، بازیابی نموده و به هنگام اعمال تغییرات محیطی آن‌ها را تصحیح نماید. پیرامون مسائل پویا، آن رویکردی که به خوبی تهیه و ارائه شده باشد اصولاً می‌تواند رویه کار حافظه را تسهیل بخشیده و مستقیماً تعداد مشخصی از راه‌حل‌های گذشته را ذخیره کند. به محض این که تعداد حالات محیطی امکان‌پذیر در یک مسئله پویا افزایش یابد، حافظه‌ای که حجم مشخص و ثابتی دارد با دشواری‌های بسیاری جهت ذخیره راه‌حل‌ها مواجه خواهد شد. در صورتی که حجم حافظه را بتوان افزایش داد، آن‌گاه میزان سربار مشخص می‌کند که از چه مقدار حافظه می‌توان به صورت مؤثر استفاده کرد. مقاله حاضر قصد دارد چندین سیستم حافظه ارزیابی چگالی را که از تخمین الگوریتم‌های توزیع الهام گرفته‌اند، مورد بحث و بررسی قرار دهد. شایان ذکر است که این الگوریتم‌ها اصولاً موجب بهبود سیستم‌های حافظه استاندارد و در عین حال، جلوگیری از افزایش وسیع سربار می‌شوند. عملکرد چنین حافظه‌هایی را می‌توان بر مبنای مسئله هماهنگ‌سازی کارخانه و ساخت پویای توزیع شده، ارزیابی کرد. این مسئله اصولاً به یک توافق‌نامه پویا با برنامه‌هایی تحت شرایط شبیه‌سازی شده احتیاج دارد. در صورتی که محصولات از انواع و اقسام گوناگونی برخوردار باشند، آن‌گاه می‌بایست هر دستگاه را به یک روند پردازش مشخص اختصاص داد. زمانی که دستگاه از یک نوع فرآوری محصول به نوع دیگر تغییر وضعیت می‌دهد، زمان برپایی، اندکی متضرر می‌شود. مقاله حاضر، مسئله هماهنگ‌سازی توزیع شده و بعضی از رویکردهای مبتنی بر عامل را توضیح خواهد داد. هم‌چنین، راجع به گوناگونی جدید این مسائل، رویکرد پایه مبتنی بر وب و نقاط ضعف آن نیز صحبت خواهد کرد. سپس، نحوه استفاده از حافظه را جهت بهبود

عملکرد مسئله هماهنگ‌سازی توزیع‌شده پویا معرفی کرده و تعدادی سیستم حافظه ارزیابی چگالی را ارائه خواهد نمود. در نهایت نیز عملکرد سیستم پیشنهادی را با سیستم‌های حافظه معرفی‌شده مقایسه خواهد کرد. نوآوری اساسی این مقاله، ارائه چندین نوع حافظه برای حل مسئله هماهنگ‌سازی کارخانه می‌باشد. روش حافظه پیشنهادی در این مقاله، نقاط ضعف حافظه استاندارد را برطرف نموده است.

بخش‌بندی این مقاله بدین صورت آرایش یافته است:

در بخش اول مقدمه و کلیات موضوع بیان شده است. بخش دوم پیش‌زمینه تحقیق و مروری بر کارهای گذشته را بیان می‌کند. بخش سوم روش پیشنهادی را بیان می‌کند. بخش چهارم آزمایش‌ها و نتایج تجربی را توصیف می‌کند. در بخش پنجم نتیجه‌گیری و کارهای آتی تشریح شده است.

۲- پیش‌زمینه تحقیق و مروری بر کارهای گذشته

فرآیندهای ساخت و تولید، اغلب مثال‌های جالب توجهی پیرامون مسائل پویا ارائه می‌کنند. به عنوان مثال، مسئله هماهنگ‌سازی مرکز تولید مرسوم به مسئله تخصیص وظائف پویا اساساً شامل کارهای مخصوصی برای دستگاه‌ها می‌شود که در نهایت عملکرد پردازش را به دنبال خواهد داشت. با گذشت زمان، کارها واگذار شده و زمان‌بند اطلاعات اندکی راجع به کار به دست خواهد آورد. در صورت عدم اطلاعات کافی، به جای استفاده از یک زمان‌بند متمرکز جهت محاسبه برنامه‌های مطلوب، سیستم‌های زمان‌بندی انطباقی، به ازای انواع و اقسام مسائل این چنینی ارائه می‌گردد. دانشمندی به نام مورلی نمونه‌ای از مسئله هماهنگ‌سازی کارخانه را از کارخانه الکتریکی عمومی ارائه داد (Morrison & De Jong, 1999). در این مسئله، هر کامیون را متناسب با رنگ اتاقک آن مشخص کرده و بدین وسیله، عامل‌ها را تخصیص داد. کامیون‌هایی که به خط مونتاژ می‌رسیدند می‌بایست رنگ شده و سپس برای رنگ اتاقک در صف گذاشته می‌شدند. رنگ هر کامیون از روی احتمال بر اساس توزیع رنگ‌ها مشخص می‌گردد. هر اتاقک دارای صفی از کامیون می‌باشد که منتظر است رنگ شوند. تمامی اتاقک‌ها می‌توانند با هر رنگی که در همان نقطه در دسترس می‌باشد رنگ شوند؛ اما زمانی که یک اتاقک بین رنگ‌ها تعویض می‌گردد، می‌بایست با جریان سریع رنگ قبلی شسته شود که این امر در زمان برپایی، یک وقفه ایجاد کرده و هزینه رنگ را بالا می‌برد. اتاقک‌هایی که تنها با یک رنگ مشخص نقاشی می‌شوند عملاً برپایی‌های کمتری را متضرر می‌گردند. مورلی ثابت کرد که یک رویکرد مبتنی بر بازار می‌بایست قبل از این که اتاقک‌ها برای سوار شدن روی کامیون به خط مونتاژ برسند، یک زمان‌بند متمرکز داشته باشد تا به واسطه فروشگاه مورد استفاده قرار گرفته شود (Morrison & De Jong, 1999). این سیستم تقریباً یک میلیون دلار طی ۹ ماه اول استفاده صرفه‌جویی می‌کند. در این رویکرد، بر اساس طول فعلی صف اتاقک و همچنین تشخیص این که آیا وقفه زمانی جهت پردازش کامیون لازم است یا خیر، اتاقک رنگ‌آمیزی‌شده بر روی یکی از کامیون‌ها سوار می‌شود. کمپوس^۱ و همکاران (۲۰۰۰) و سیرلو^۲ و همکاران (۲۰۰۴) هر کدام به صورت جداگانه رویکردهای مبتنی بر عامل را به ازای مسئله هماهنگ‌سازی کارخانه که از تخصیص وظیفه خودسرانه جنبنده-های اجتماعی نظیر مورچه‌ها و زنبورها الهام گرفته شده است، مورد بحث و بررسی قرار دادند (Campos et al., 2000; Cicirello & Smith, 2004). همانند شیوه مورلی، اتاقک‌ها همچنان در مقابل دیگری صف کشیده‌اند، ولیکن به جای یک سیاست مشخص، عامل‌هایی که هر اتاقک را نشان می‌دهند می‌بایست از روش یادگیری تقویتی به منظور توسعه سیاست‌ها استفاده کنند. عامل‌ها اغلب از مفهوم آستانه پاسخ برای تشخیص پیشنهاد برای هر کامیون بهره می‌گیرند. به واسطه چنین الهامی، تفاوت‌های قابل توجهی در بین این رویکردها به وجود می‌آید. سیرلو و همکاران

(۲۰۰۴) سیستم‌های خود را با سیستم پیرامون شش مسئله مقایسه نمودند (Campos et al., 2000): مسئله اصلی، نسخه‌ای با زمان‌های برپایی مشخص‌تر، نسخه‌هایی با دو احتمال مجزا به ازای از کارافتادگی دستگاه، نسخه‌ای با توزیع رنگ کامیون‌ی‌دکی و نسخه‌ای که در آن توزیع رنگ کامیون در وسط کار تغییر پیدا می‌کند. *R - Wasp* قبل از سایر رویکردها علی‌الخصوص به منظور به حداقل رساندن تعداد تنظیمات (برپایی) مورد نیاز به کار گرفته شد. محمدپور و پروین (۱۳۹۵) نیز انواع مسائل مربوط به فروشگاه رنگ و نقاشی را به منظور تجزیه و تحلیل هرچه بهتر عملکرد الگوریتم نشان دادند. در این رابطه، انواع کارهای N ، به واسطه دستگاه‌های چند منظوره M که به صورت موازی فعالیت می‌کنند، پردازش گردید. کارها از روی احتمال و بر اساس انواع و اقسام آن مشخص می‌شوند. هر کار دارای $15 + N(0,1)$ واحد زمانی می‌باشد. به هر دستگاه اجازه داده می‌شود تا یک صف نامتناهی داشته باشد. تنظیمات یک ماشین طی واحدهای زمانی ۳۰ ممکن است تغییر پیدا کند. سیسیرلو و همکاران (۲۰۰۴) مسائل را در حضور ۲ نوع کار در ۲ یا ۴ دستگاه مورد بحث و بررسی قرار دادند (Cicirello & Smith, 2004). آن‌ها وضعیت را هم به وسیله یک نوع توزیع کار و هم بین دو نوع توزیع کار آزمایش کردند. یکی از یافته‌ها ثابت کرد که این رویکرد ممکن است جهت انطباق با تغییرات موجود در حیطه توزیع انواع و اقسام کار، اندکی آهسته عمل کند.

برای حل مسائل پویا راهکارهای متعددی اخیراً توسط محققین ارائه شده است. در ادامه برخی از این راهکارها تشریح شده است.

محمدپور و پروین (۲۰۱۶) یک حافظه صریح را پیشنهاد دادند که از این حافظه برای حداکثرسازی تنوع در جمعیت استفاده شده است (Mohammadpour & Parvin, 2016). در این حافظه از یک راهکار مناسب برای به‌روزرسانی حافظه استفاده شده است.

اوسویدان و بایکاسوگلو^۱ (۲۰۱۵) از راهکار چند جمعیتی همراه با روش تکاملی کرم شب‌تاب برای حل مسائل پویا استفاده کرده‌اند (Ozsoydan & Baykasoglu, 2015). در این تحقیق نشان داده شده است که روش‌های چند جمعیتی به بهبود کارایی الگوریتم‌ها در حل مسائل پویا کمک می‌کند.

براوو^۲ و همکاران (۲۰۱۶) یک روش مبتنی بر حافظه را برای حل مسائل بهینه‌سازی پویا ارائه نمودند (Bravo et al., 2016). در این مقاله از یک حافظه با ترکیب سه الگوریتم ژنتیک، ازدحام ذرات و جستجوی محلی تپه‌نوردی استفاده شده است. در این روش از حافظه ارائه‌شده برای حفظ سطح مناسبی از تنوع استفاده شده است. این حافظه در این مقاله تحت عنوان حافظه سراسری^۳ نام‌گذاری شده است.

صادقی و همکارانش (۲۰۱۵) یک الگوریتم مبتنی بر ازدحام ذرات برای حل مسائل بهینه‌سازی پویا ارائه نموده‌اند (Sadeghi et al., 2015). در این روش برای ردیابی سریع بهینه تغییر یافته از یک حافظه صریح استفاده شده است. در این الگوریتم بهترین راه‌حل‌های گذشته که خیلی قدیمی نباشند در حافظه ذخیره شده است.

یزدانی و میبدی روشی برای حل مسائل بهینه‌سازی پویا ارائه نموده‌اند (Nasiri & Meybodi, 2012). این روش بر مبنای مفهوم «اجزای» طراحی شده است که مرکز یک جزء، دانه جزء نامیده می‌شود. دانه جزء ذره‌ای است که همواره بهترین برازش را در آن جزء دارد. همه ذراتی که در شعاع از پیش تعریف شده دانه جزء واقع شوند در همان جزء قرار می‌گیرند.

1. Ozsoydan & Baykasoglu

2. Bravo

3. Global Memory

4. species

ریچر و یانگ^۱ (۲۰۰۸ و ۲۰۰۹) حافظه‌ای ارائه دادند که به جای ذخیره مستقیم راه‌حل‌ها، چکیده‌ای از راه‌حل‌ها را ذخیره می‌نمود و با نگه‌داشتن یک ماتریس، فضای جستجو را درون سلول‌ها تقسیم می‌کرد (Richter & Yang, 2008a, 2008b, 2009). هنگامی که یک راه‌حل به حافظه اضافه می‌شد، شمارنده مربوط به سلول ماتریس افزایش می‌یافت. این امر به ماتریس اجازه می‌داد تا به عنوان یک مدل چکیده از راه‌حل‌های خوب عمل کند. بعد از یک تغییر، راه‌حل‌ها به وسیله نمونه‌برداری از ماتریس و مقداردهی مجدد به بخشی از جمعیت، بازیابی می‌شدند. در یک کار تخمین توزیع جمعیت، یانگ^۲ (۲۰۰۶ و ۲۰۰۷) حافظه انجمنی را معرفی کرد که یک راه‌حل و یک تخمین توزیع را با هم در یک مدخل حافظه ذخیره می‌کند (Yang, 2006, 2007a, 2007b). بعد از یک تغییر، راه‌حل‌های تمام مدخل‌های حافظه محاسبه می‌شوند. توزیعی از مدخل حافظه با بهترین راه‌حل برای مقداردهی مجدد به بخشی از جمعیت انتخاب می‌گردد. حافظه انجمنی با حافظه مستقیم و یک حالت ترکیبی از حافظه مستقیم و انجمنی مقایسه شده است. استفاده از حافظه انجمنی به طور قابل توجهی بهتر از حافظه مستقیم تنها بوده و حالت ترکیبی بهترین عملکرد را در بین آن‌ها داشته است.

برنک و متفلد^۳ (۲۰۱۲) یک مدل عمومی‌تر از حافظه ارائه کردند که نیازی به ذخیره اطلاعات محیط نداشت (Branke, 2012; Branke & Mattfeld, 2002). حافظه تلاش می‌کرد تا به صورت تناوبی بهترین اعضای جمعیت را ذخیره کند. حافظه یک اندازه محدود و مشخص داشت و در زمان پرشدن حافظه از یک راه‌حل جایگزینی استفاده می‌شد که تصمیم می‌گرفت آیا نیازی به جایگزینی بهترین عضو جمعیت با یکی از مدخل‌های حافظه هست یا خیر. محققین سیستم‌های حافظه مختلفی را ارائه نموده‌اند و هر کدام از سیستم‌های ارائه شده به نوعی برای حل مسائل پویا استفاده شده‌اند (Bendtsen & Krink, 2002; Chen et al., 2015; Chrysosolouris & Subramaniam, 2001; Eggermont & Lenaerts, 2002; Eggermont et al., 2001; Ramsey & Grefenstette, 1993).

۲-۱- مسئله هماهنگی کارخانه‌های توزیع‌شده پویا

در بخش حاضر، نسخه توسعه‌داده شده مسئله هماهنگ‌سازی کارخانه توزیع‌شده پویا، شبیه به گفته‌های سسیرلو و همکاران مورد بحث و بررسی قرار خواهد گرفت. در نسخه‌های پیشین از این مسئله، الگوریتم‌ها طی بازه زمانی کوتاه، به سبب بروز چندین تغییر در روند توزیع کارها ارزیابی شدند. در حیطه مسئله هماهنگ‌سازی کارخانه پویایی که هم‌اکنون توصیف شد، عملکرد طی بازه زمانی بلندمدت و با در نظر گرفتن تغییرات انواع و اقسام کار، ارزیابی می‌شود. در این مسئله، کارخانه‌ها N فرآورده تولید می‌کنند (N نوع کار) که به وسیله M دستگاه چندمنظوره به صورت موازی پردازش می‌شوند. طول صف کار یک دستگاه، اصولاً نامحدود می‌باشد. زمان تنظیمات (برپایی) هر ماشین، بسته به نوع کاری که قرار است انجام دهد برابر با ۳۰ واحد زمانی است. زمان پردازش هر کار $15 + N(0,1)$ واحد است. مدت زمان‌های بیشتر از ۱۵ واحد زمانی به صورت عدد صحیح گرد می‌شود، در حالی که مقادیر کمتر از آن زیر ۱۵ گرد می‌شوند. کارها به کف کارخانه بسته به توزیع انواع و اقسام کار واگذار می‌گردد؛ این توزیع به مرور زمان تغییر پیدا می‌کند. به عنوان مثال، مطابق با دو نوع کار به نسبت ۶۰ به ۳۰ و فرصت ۱۰ درصدی به وجود آمدن یک کار جدید در هر بازه زمانی، توزیع برابر $D = [0.06, 0.04]$ خواهد بود. تنها یک کار ممکن است در هر بازه زمانی وجود داشته باشد. بدین ترتیب، نرخ میانگین ۰/۰۵ به ازای هر دستگاه جهت نمایش کارخانه‌ای با قابلیت بارگذاری سیستم تعریف می‌شود که $L = 1.00$ میزان معمول بار را نشان می‌دهد. مقادیر بزرگ‌تر اصولاً سیستم را درون

1. Richter & Yang

2. Yang

3. Branke & Mattfeld

وضعیت ازدیاد بار قرار می‌دهند. متوسط زمان ورود $\lambda = 0.5ME$ می‌باشد. این وضعیت طی بازه زمانی ۱۵۰۰۰۰ سپری شده و به ۵۰ دوره ۳۰۰۰ تایی تقسیم می‌شود؛ در هنگام آغاز هر دوره، نحوه توزیع نوع کار تغییر پیدا می‌کند.

۲-۲- الگوریتم یادگیری مبتنی بر عامل $R - Wasps$

ما از الگوریتم $R - Wasps$ به عنوان رویکردی پایه در مسئله فعلی استفاده می‌کنیم (Cicirello & Smith, 2004). در $R - Wasps$ ، هر دستگاه متناسب با عامل مسیریابی مشخص می‌شود. هر عامل دارای آستانه پاسخ می‌باشد:

$$\Theta_w = \{\theta_{w,0}, \dots, \theta_{w,N-1}\} \quad (1)$$

در این معادله $\theta_{w,j}$ آستانه w نسبت به کارهای نوع j می‌باشد. کارهای تخصیص نشده باعث پخش محرک s_j متناسب با طول مدت زمانی که کار منتظر توافق می‌باشد، می‌شود. این عامل قادر است محرک s_j را با احتمال ذیل نشان بدهد:

$$P(bid | \theta_{w,j}, s_j) = \frac{S_j^2}{S_j^2 + \theta_{w,j}^2} \quad (2)$$

در غیر این صورت، عامل به کار مربوطه پیشنهاد نمی‌شود. هرچه آستانه مزبور به ازای کار مشخصی کمتر باشد، احتمال پیشنهاد عامل به کار مربوطه نیز بیشتر می‌شود. مقادیر آستانه در بازه $[\theta_{min}, \theta_{max}]$ متفاوت است. هر عامل مسیریابی w می‌بایست کاملاً نسبت به وضعیت دستگاه آگاه باشد، ولی نباید هیچ اطلاعاتی پیرامون سایر دستگاه‌های موجود در کارخانه داشته باشد. از دانش مذکور اغلب جهت تنظیم آستانه‌ها در هر بازه زمانی استفاده می‌شود. اگر ماشین یک نوع کار j را پردازش کند، آن‌گاه:

$$\theta_{w,j} = \theta_{w,j} - \delta_1 \quad (3)$$

اگر دستگاه، پیرامون یک نوع کار j را پردازش کند، آن‌گاه:

$$\theta_{w,j} = \theta_{w,j} + \delta_2 \quad (4)$$

در صورتی که دستگاه برای مدت زمان t بی‌کار بوده و دارای صف خالی نیز باشد، آن‌گاه به ازای همه نوع کار j خواهیم داشت:

$$\theta_{w,j} = \theta_{w,j} - \delta_3 \quad (5)$$

مقادیر پارامترهای سیستم که به کار گرفته شده‌اند، عبارت است از:

$$\theta_{min} = 1, \theta_{max} = 1000, \delta_1 = 2, \delta_2 = 1, \delta_3 = 1.001 \quad (6)$$

زمانی که بیش از یک عامل پیرامون شغلی پیشنهاد داده می‌شود، یک تناقض قابل توجه به وجود می‌آید. نیروی F_w یک عامل عبارت است از: $F_w = 1.0 + T_p + T_s$.

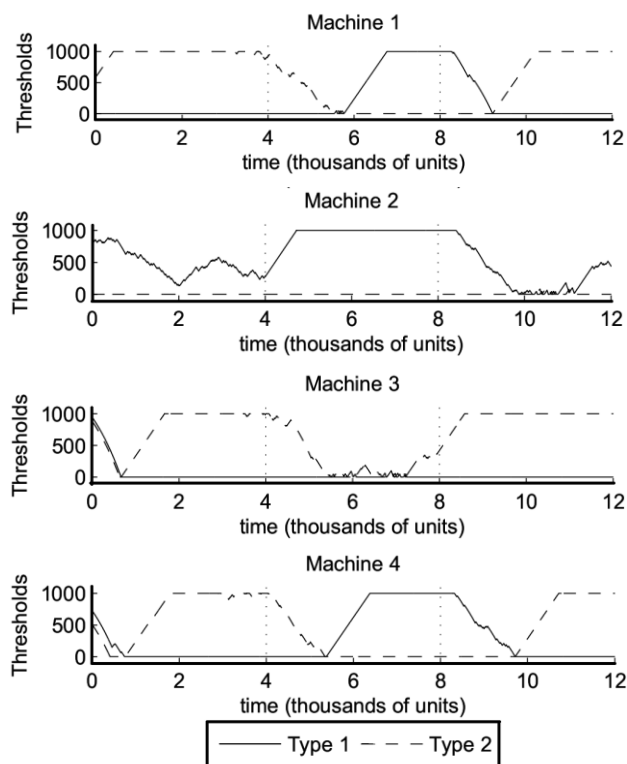
در این معادله T_p و T_s به ترتیب مجموع زمان‌های پردازش و زمان‌های تنظیمات را به ازای تمامی کارهای موجود در صف نشان می‌دهد. فرض کنید F_1 و F_2 به ترتیب نیروهای عامل ۱ و ۲ هستند. در آن صورت، عامل ۱ تناقض احتمال مربوطه را خواهد برد.

$$P(Agent\ wins | F_1, F_2) = \frac{F_2^2}{F_1^2 + F_2^2} \quad (7)$$

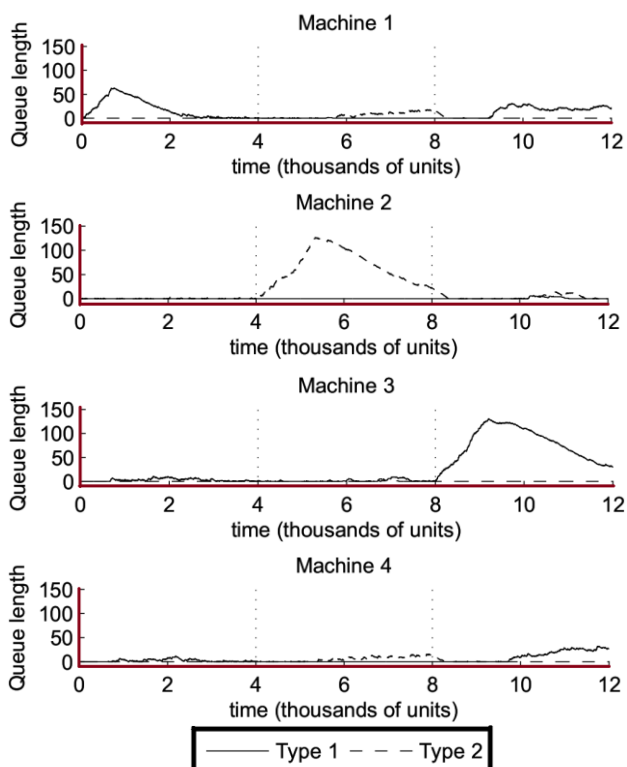
اگر بیش از دو عامل پیرامون کار معرفی شود، از یک تناقض مشخص جهت تعیین پیشنهاد برنده استفاده می‌شود (Cicirello & Smith, 2004).

۲-۳- نقاط ضعف الگوریتم *R - Wasps*

R - Wasps بر مبنای مسئله هماهنگ سازی کارخانه توزیع شده عمل می کند؛ اما از آن جایی که یادگیری آستانه ها زمان بسیار زیادی می برد، پس ممکن است، رویه انطباق با تغییرات توزیع این نوع کار، اندکی آهسته صورت گرفته شود. اگر توزیع کار مربوطه هم چنان با گذشت مدت زمان به همان صورت باقی بماند، آن وقت سیستم می تواند هر گونه مشکلی که انطباق پدید آورده است را برطرف سازد. با این حال، طی بازه زمانی کوتاه، این امر ممکن است تأثیر منفی بر عملکرد داشته باشد. به عنوان مثال، یک مسئله با چهار ماشین را در نظر بگیرید. دو نوع کار طی سه دوره زمانی با طول ۴۰۰۰ واحد زمانی حضور دارد. در اولین دوره زمانی، ۸۵ درصد کارها در نوع ۱ و ۱۵ درصد در نوع ۲ وارد می شوند. در ابتدا، هر ماشین قادر است آستانه خود را جهت پذیرفتن مؤثر کارها تطبیق بدهد. در دومین دوره، زمانی که توزیع کارها به ۱۵ درصد نوع ۱ و ۸۵ درصد نوع ۲ تغییر پیدا می کند، هر ماشین می تواند خود را با توزیع جدید وفق دهد. در سومین دوره، توزیع به ۸۵ درصد از نوع ۱ و ۱۵ درصد از نوع ۲ بازمی گردد. همان گونه که در شکل ۱ نشان داده شده است، اعمال تغییر در توزیع احتمالاً بیشتر از نخستین انطباق در طی اولین مرحله، زمان می برد. این عملکرد بنا به چند دلیل رخ می دهد. اولاً، توزیع آشکارا بسیار آهسته تر از توزیع مربوطه رخ می دهد؛ بدین ترتیب کارهایی که طی اولین دوره زمانی توزیع ارائه می شوند هم چنان در آغاز دومین دوره به صورت پردازش نشده باقی می مانند. دوماً، تغییرات توزیع ممکن است منجر به درهم ریختگی صف شود. این امر را به وضوح می توان در شکل ۲ مشاهده کرد؛ در این حالت صف به ازای ماشین ۳ پس از اعمال تغییر نوع دوم بسیار وسیع رشد پیدا می کند. این امر اغلب زمانی رخ می دهد که ماشین در پردازش یک نوع کار نسبت به سایرین از تخصص بیشتری برخوردار باشد. در صورتی که کار مربوطه بسیار متداول باشد، آن گاه ماشین پیشنهاد مربوطه را تا زمانی که سایر ماشین ها فرصتی برای تخلیه صف دارند، خواهد برد. در آن هنگام، سایر ماشین ها حرفه ای تر عمل کرده و ماشینی که دچار ازهم پاشیدگی صف شده است روند پذیرش کارها را متوقف می سازد. این واقعه ممکن است منجر به بیکاری سیستم شود، ولیکن مسئله واقعی این است که دوره زمانی بزرگ و بزرگ تر شده و سپس، سیستم دچار انطباق پذیری کمتری خواهد شد. یکی از دلایل اصلی این امر بدین صورت است که به هنگام تغییر توزیع یک نوع کار، تمامی ماشین ها در صف خود دارای کار می باشند. در مثال نشان داده شده، سه ماشین در ازای نخستین بازه در حیطه کار نوع ۱ تخصصی عمل می کنند. زمانی که رویه توزیع تغییر پیدا می کند، کار نوع ۲ برجسته تر می شود. ماشین ۲ نیز که قبلاً در این نوع کار حرفه ای بوده است جهت پیشنهاد کار، مزیت های قابل توجهی پیدا می کند. تحت چنین شرایطی، آستانه پیشنهاد کمتر از قبل با سایر دستگاه ها مقایسه می شود. در زمانی که دستگاه های دیگر صف های خود را تخلیه می کنند، صف دستگاه ۲ درهم ریخته شده و چرخه های زمانی بزرگ تری در صف حضور پیدا می کنند. همین موضوع به ازای دستگاه ۳ نیز در طی دوره سوم رخ می دهد. این عملکرد از چندین مکانیسم *R - Wasp* نشأت گرفته می شود و بدین سبب، به هنگام تغییر توزیع بسیار موفق عمل خواهد کرد. بهبود عملکرد در طی نسخه پایه *R - Wasp* احتمالاً موجب کاهش این مدت زمان انطباق متناسب با تغییرات توزیع کار مربوطه می شود. از آن جایی که اعمال تغییر مکانیسم *R - Wasp* به صورت مستقیم امکان پذیر است؛ پس می توان گفت که به جای اعمال تغییر، بهتر است در اکثر موارد، عملکردها به همان صورت حفظ شوند.



شکل ۱: نمونه اجرای چهار دستگاه که نشان می‌دهد چه مدت زمان آستانه‌ها به ازای هر تغییر منطبق باقی می‌مانند.



شکل ۲: نمونه اجرای چهار دستگاه که رشد صف را برای هر دستگاه در طول زمان نشان می‌دهد.

۱-۳-۲- حافظه تخمین تراکم (روش پیشنهادی)

به جای ذخیره کردن تنها نقاط تکی در حافظه، پیشنهاد می شود خوشه هایی از نقاط در هر مدخل حافظه ذخیره شوند و مدلی از هر نقاط در هر خوشه ایجاد شود. اگر چه ما قادر به ذخیره کردن نقاط بیشتری خواهیم بود، سربار محاسباتی برای حافظه کم می شود.

اولین سیستم حافظه تخمین تراکم، DEM_c ، از خوشه بندی اقلیدسی افزایشی جهت ذخیره کردن نقاط در حافظه استفاده می کند. هر حافظه ماشین شامل تعداد محدودی از مدخل های حافظه است. هر مدخل حافظه، یک خوشه از نقاط ذخیره شده و وضعیت های ماشین در یک زمان به خصوص است. آن نقاط معادل نقاط ذخیره شده برای حافظه استاندارد است: آستانه های پاسخ θ_w و توزیع نوع کار D_t است.

هر مدخل حافظه، میانگین مقادیر تمام نقاط در خوشه خودش را گرفته و یک مدل خوشه ای ساده تشکیل شده از مرکز توزیع C_d و یک مرکز آستانه C_θ را ایجاد می کند. این مقادیر زمان فعل و انفعالاتی با آن مدخل حافظه استفاده می شود. حافظه با فرکانس یکسان، همانند حافظه استاندارد به روزرسانی می شود. وقتی نقطه جدیدی ذخیره می شود، یک مدخل حافظه جدید ایجاد می شود که شامل تنها آن نقطه است و به حافظه اضافه می شود. آن گاه دو مدخل در حافظه که مراکز توزیعشان نزدیک به یکدیگر هست را پیدا نموده و خوشه های آنها درون یک مدخل حافظه تکی ادغام می شود و دوباره C_d و C_θ محاسبه می شوند. یک مدخل مانند روش های مدل حافظه استاندارد بازیابی می شود.

دومین حافظه تخمین تراکم، DEM_g ، از خوشه بندی گاوسی افزایشی جهت ذخیره کردن نقاط در حافظه استفاده می کند. استفاده از مدل گاوسی بازیابی مدخل های حافظه را بعد از تغییر توزیع، بهبود می بخشد. علاوه بر C_d و C_θ ، یک مدل گاوسی از توزیع های نوع کار در آن خوشه، m_d ، را ایجاد می کند. برای خوشه هایی با تعداد کمتر از ۱۰ نقطه، مدل انباشته شده به وسیله نقاط تصادفی اضافی اطراف C_d است (به طور یکنواخت توزیع شده در هر بعد در فاصله $[-0.125, 0.125]$). به جای محاسبه فاصله بین توزیع نوع کار جاری و توزیع در هر مدخل حافظه، مدل گاوسی در هر مدخل به محاسبه احتمال آن مدخل حافظه که متعلق به مدل گاوسی است استفاده می کند. آن مدخل با بالاترین احتمال انتخاب می شود و آستانه های ماشین به C_θ تغییر می کنند. همه دیگر اجزاء سیستم حافظه شبیه DEM_c هستند.

سومین حافظه تخمین تراکم، DEM_{gw} می باشد. DEM_g و DEM_{gw} را با استفاده از یک مدل گاوسی در سرتاسر سیستم حافظه توسعه می دهد. علاوه بر استفاده از این مدل محیطی، زمانی که مدخلی از حافظه بازیابی می شود، این مدل جهت ارزیابی احتمال، وقتی که نقاط جدیدی به حافظه اضافه می شوند، استفاده می شود. اندازه گیری مسافت میان مدخل ها زمانی تصمیم به ادغام می شوند که یک میانگین احتمالی محاسبه شود. میانگین احتمال از هر نقطه در مدخل ۱ در آن مدل، برای مدخل ۲ می باشد و برعکس. دو مدخل با بالاترین احتمال، ادغام می شوند. مانند DEM_g ، مدل گاوسی در DEM_{gw} از بازیابی یک مدخل بعد از تغییر توزیع اساسی که کشف شد، استفاده می شود. به جای تغییر دادن آستانه ماشین به C_θ ، یک وزن مرکزی جدید محاسبه شده است. برای هر نقطه در مدخل حافظه، یک وزن w_j به وسیله یافتن احتمالی که کار نوع توزیع برای نقطه j قسمتی از m_d است محاسبه شده است، سپس وزن ها به وسیله تقسیم آن ها بر جمع کل وزن ها نرمال می شوند. یک مجموعه آستانه های وزندهی شده به وسیله ضرب وزن برای هر نقطه، از طریق آستانه θ_w تشکیل داده می شوند. وزن مرکزی wC_θ میانگین تمام آستانه های وزندهی شده است.

پس به طور کلی سه حافظه پیشنهادی به صورت زیر تعریف می شوند:

حافظه تخمین تراکم خوشه بندی اقلیدسی افزایشی: این الگوریتم با خوشه بندی افزایشی، راه حل ها را درون مدخل های حافظه معجزا می کند. مراکز خوشه به عنوان مدل ها در حافظه استفاده می شوند. این ساده ترین نوع حافظه تخمین تراکم است.

حافظه تخمین تراکم خوشه‌بندی گاوسی افزایشی: این الگوریتم از خوشه‌بندی افزایشی به شکل مدخل‌های حافظه استفاده می‌کند، سپس مدل‌های گاوسی را برای هر مدخل از حافظه ایجاد می‌کند. این اجرا تخمین تراکم خوبی از راه‌حل‌های قبلی فراهم می‌کند.

حافظه تخمین تراکم مدل ترکیبی گاوسی: برای مسائلی که زمان بیشتری برای ساخت مدل دارند، یک مدل ترکیبی گاوسی از حافظه تخمین تراکم ارائه شده است. این پیاده‌سازی به ایجاد یک مدل روی همه راه‌حل‌ها در حافظه نیاز دارد که هزینه پیاده‌سازی بیشتری نسبت به خوشه‌بندی افزایشی دارد.

۱-۱-۳-۲- ذخیره‌سازی راه‌حل‌ها در حافظه تخمین تراکم

در حافظه استاندارد، یک نقطه اصولاً با استفاده از راهکار جایگزینی در حافظه ذخیره می‌شود. شایان ذکر می‌باشد که این رویکرد وظیفه تصمیم‌گیری راجع به نحوه جایگزینی یک نقطه درون یکی از مدخل‌های حافظه موجود بر عهده دارد. اکثر راهکارهای جایگزینی، تنوع در حافظه را حفظ می‌کنند. به عنوان مثال، راهکار جایگزینی ابتدا یک نقطه جدید به حافظه اضافه می‌کند، سپس دو مدخل حافظه نزدیک به یکدیگر پیدا کرده و آن که از شایستگی کم‌تری برخوردار می‌باشد را حذف می‌کند.

به غیر از مدخل‌های از بین رفته، حافظه تخمین تراکم مدخل‌ها را با هم ادغام می‌نماید. در وهله نخست، نقطه جدید اضافه‌شده به حافظه به دلیل ایجاد مدخل حافظه جدید، مورد استفاده قرار می‌گیرد. پس از این که مدل‌ها برای این مدخل جدید ساخته شد، دو مدخل که در حافظه بیشتر از همه به یکدیگر شبیه می‌باشند پیدا شده و ادغام می‌گردند. زمانی که فضای جستجوی جدیدی برای نخستین بار ساخته می‌شود، نقطه جدید نیز جهت آغاز مدل‌سازی این ناحیه از حافظه، مورد استفاده قرار خواهد گرفت.

به‌واسطه افزایش نقاط خوشه‌بندی، ناحیه‌های جدید فضای جستجو را می‌توان بسته به تغییرات محیط پویا مدل-سازی کرد. به محضی که خوشه‌ها ادغام شدند، خوشه‌ها متشکل از چندین نقطه خواهند شد. هم‌چنین، چنان‌چه تراکم آن نقاط افزایش یابد، یک مدل مناسبی نیز جهت برآورد مناسب از مکان راه‌حل‌های خوب در آن ناحیه ارائه خواهد شد.

شایان ذکر می‌باشد که حافظه تخمین تراکم همانند حافظه استاندارد شدیداً به الگوریتم بهینه‌سازی یا یادگیری وابسته است. حافظه تخمین تراکم اصولاً مدل‌ها را بر مبنای نقاط ذخیره‌شده در حافظه می‌سازد، ولیکن اگر الگوریتم مزبور راه‌حل‌های ضعیفی را ذخیره کند، آن‌گاه مدل‌های موجود در حافظه راه‌حل خوبی را نمایش نخواهند داد. در صورتی که راه‌حل‌های خوبی از سوی الگوریتم معرفی گردد، آن‌گاه حافظه تخمین تراکم به الگوریتم کمک خواهد کرد تا ناحیه امیدبخش موردنظر را کشف کند، ولیکن قبل از آن الگوریتم باید بتواند به‌خوبی عملیات جستجو را در آن ناحیه انجام دهد.

زمانی که نقاط جدید در حافظه ذخیره می‌شوند تا حد زیادی به الگوریتم‌های بهینه‌سازی یا یادگیری و نوع مسئله بستگی دارد. زمانی که از الگوریتم تکاملی استفاده می‌شود، نقطه جدید ممکن است در هر چند نسل ذخیره گردد. هم‌چنین، موقعی که از الگوریتم یادگیری تقویتی بهره گرفته می‌شود، بهترین راه این است که نقاط جدید در زمان یادگرفتن راه‌حل‌های مطلوب ذخیره شوند (در ذخیره نقاط جدید یک بار راه‌حل‌های خوب را آموزش ببینند). در بعضی از مسائل هنگامی که تغییرات به‌وضوح قابل‌رؤیت باشد، بهترین حالت این است که راه‌حل‌ها قبل از اعمال تغییر ثبت شوند. در رابطه با مسائل دیگری که تغییرات در آن به صورت تدریجی رخ می‌دهد، بهتر است که نقاط به‌طور

دوره های ذخیره شوند. ذخیره سازی یک راه حل، درست بعد از اعمال تغییر، اصلاً کار مطلوبی نیست زیرا که هیچ فرصتی برای تطبیق آن وجود ندارد.

سربار محاسباتی استفاده از حافظه تخمین تراکم به مسئله و مدل های احتمالاتی به کار گرفته شده در حافظه وابسته می باشد. زمانی که نقاط خوشه بندی افزایش می یابد، می توان انتخاب دو مدخل برای ادغام در $O(m^2)$ انجام داد. در این حالت، m تعداد مدخل های حافظه تلقی می شود. وقتی از مدل های گاوسی درون حافظه تخمین تراکم استفاده می شود، کوواریانس در $O(nd^2)$ محاسبه می گردد؛ که n تعداد نقاط موجود در مدخل حافظه و d تعداد ابعاد موجود در داده های کنترلی یا محیطی می باشد. از آن جایی که حافظه به چندین خوشه تقسیم می شود، n عمدتاً کم تر از تعداد کل نقاط موجود در حافظه انتخاب می گردد. اگر چه استفاده از حافظه، مقداری سربار محاسباتی دارد، زمان لازم برای ارزیابی راه حل ها به طور معمول بر زمان مورد نیاز جهت نگهداری حافظه غالب است. از آن جایی که حافظه تخمین تراکم اساساً به ارزیابی راه حل های اضافی احتیاجی ندارد، در نتیجه سربار حافظه تخمین تراکم تنها به واسطه ساخت و نگهداری مدل های احتمالاتی موجود در حافظه حاصل می شود.

در بعضی از مسائلی که داده های کنترلی یا محیطی، ابعاد بسیار زیادی دارند، ممکن است زمان زیادی جهت ساخت حافظه صرف شود و قبل از بازیابی از حافظه می تواند در جهت بهبود کارایی مؤثر باشد. هر چه ابعاد داده بیشتر باشد، نقاط بیشتری جهت ارائه تخمین تراکم خوب مورد نیاز است. در رابطه با این مسائل، بهتر است که ابتدا حافظه ساخته شود تا این که به صورت خالی باشد.

۲-۱-۳-۲- بازیابی راه حل ها از حافظه تخمین تراکم

راه حل ها در حافظه تخمین تراکم شبیه به حافظه استاندارد بازیابی می شوند. پیرامون الگوریتم های جستجوی مبتنی بر جمعیت، راه حل ها ممکن است از حافظه بازیابی شوند یا در کل اجرا و یا بلافاصله بعد از تغییر شناسایی شوند. رایج است که راه حل ها در هر نسل از الگوریتم تکاملی از حافظه بازیابی می شوند.

زمانی که مدخل های حافظه تنها به هنگام ذخیره سازی نقاط جدید به حافظه تغییر پیدا می کنند، راه حل های ارائه شده به واسطه بازیابی از حافظه می تواند در هر نسل به وسیله الگوریتم جستجو مورد استفاده قرار گیرد. برای الگوریتم های یادگیری که تنها یک نقطه را جستجو می کنند، راه حل ها می بایست از حافظه با تکرار کم تر و انتخاب بیشتر بازیابی شوند. از آن جایی که بازیابی از حافظه در هر مرحله باعث می شود که الگوریتم راه حل مربوطه را اصلاح کند، راه حل ها یا به صورت دوره ای یا در هر نسل بازیابی می شوند. در مقاله حاضر، راه حل حاصل از حافظه، زمانی بازیابی می گردد که راه حل جاری ضعیف عمل کرده و محیط کنونی نیز کاملاً با یکی از مدخل های حافظه منطبق باشد. برخلاف حافظه استاندارد، راه حل های بازیابی شده از حافظه چندان شباهتی به تک تک راه حل های ذخیره شده ندارند. به واسطه تجمع بسیاری از نقاط موجود در مدخل حافظه، راه حل بازیابی شده از حافظه تحت تأثیر راه حل های قبلی که در محیط مشابه به خوبی عمل می کرده اند، قرار خواهد گرفت.


۲-۱-۳-۳- ساختار حافظه تخمین تراکم

یک حافظه تخمین تراکم نقاط را در تعداد محدودی از مدخل های حافظه ذخیره سازی می کند. اطلاعات ذخیره شده در یک مدخل حافظه را می توان به دو دسته تقسیم کرد: اطلاعات محیطی و اطلاعات کنترلی. اطلاعات محیطی کمک می کند تا تصویری از وضعیت فعلی مسئله داشته باشیم. در صورت تغییر مسئله، اطلاعات محیطی ممکن است برای تعیین شباهت بین محیط فعلی و محیطی که در مدخل حافظه ذخیره شده؛ استفاده شود.

اطلاعات محیطی برای حفظ حافظه استفاده می‌شود و زمانی که مدخل‌های جدید موجود هستند تصمیم‌گیری می‌کنند که مدخل‌ها باید در حافظه ذخیره شوند. اطلاعات کنترلی شامل اطلاعاتی است که در فرآیند جستجو استفاده می‌شود. برای مثال اطلاعات کنترلی ممکن است فقط یک راه‌حل ذخیره‌شده در قبل باشد که می‌تواند دوباره در جمعیت جاگذاری شود یا ممکن است حاوی یک مدل احتمالی از جمعیت بر اساس الگوریتم تکاملی باشد که می‌تواند برای دوباره مقداردهی اولیه جمعیت بعد از یک تغییر استفاده شود. در حافظه استاندارد، هر مدخل حافظه می‌تواند یک نقطه تکی را ذخیره کند؛ ولی در حافظه تخمین تراکم، هر مدخل ممکن است تعدادی نقاط را ذخیره کند. یک حافظه ممکن است تا $|M|$ مدخل داشته باشد. هر مدخل اصولاً از مجموعه‌ای نقاط، یک مدل از اطلاعات محیطی در آن نقاط و همچنین یک مدل از اطلاعات کنترلی در آن نقاط تشکیل شده است.

شکل ۳ ساختار یک حافظه تخمین تراکم را نشان می‌دهد. مدل‌ها در حافظه تخمین تراکم ممکن است ساده‌شده‌ای از میانگین تمام نقاط باشند یا از مدل‌های احتمالی پیچیده‌ای نیز استفاده کرده باشند. در این مقاله آن مدل‌های عامی که به کار برده می‌شوند تا یک مدخل حافظه را نشان دهند مدل خوشه‌بندی گاوسی چندمتغیره هستند. در نسخه گاوسی، متوسط و کوواریانس همه نقاط موجود در مدخل حافظه به جهت توصیف مدل مورد استفاده قرار می‌گیرند. زمانی که مدخل‌ها برای نخستین بار ساخته می‌شوند، ممکن است برای محاسبه کوواریانس معتبر، نقاط کافی نباشد. در این حالت، نقاط تصادفی اطراف میانگین به صورت موقت برای تکمیل مدل اضافه می‌شوند. در ادامه، راجع به حافظه تخمین تراکم که از مدل‌های گاوسی بهره می‌گیرند صحبت خواهد شد.

از آن جایی که مدخل حافظه شامل نقاط متعددی می‌باشد، فقط مدل محیطی و مدل کنترلی جهت برقراری تعامل با آن مدخل لازم است. هم‌چنین به سبب این که مدخل‌ها از هزاران نقطه تشکیل شده‌اند، این مسئله میزان سربار حافظه تخمین تراکم را پایین نگه می‌دارد.




شکل ۳: حافظه تخمین تراکم از تعداد محدودی از مدخل‌ها ایجاد شده است. هر مدخل شامل مجموعه‌ای از نقاط است که هر نقطه شامل داده محیطی و کنترلی از زمانی که آن نقطه ذخیره شده بوده است.

شکل ۴ نحوه عملکرد متفاوت حافظه تخمین تراکم را از حافظه استاندارد نشان می‌دهد. در این مثال، یک فضای جستجوی یک‌بعدی وجود دارد که شامل چهار قله با شکل‌ها و شایستگی مختلف است. فرض کنید که الگوریتم جستجو سعی دارد تا نقاط علامت‌گذاری‌شده با خطوط ممتد را طی مدت زمانی مشخص درون حافظه ثبت کند. حافظه استاندارد نقطه با بهترین شایستگی را انتخاب می‌کند؛ از این رو همیشه نقطه مزبور نزدیک‌ترین نقطه به مرکز حافظه

است. حافظه تخمین تراکم نقاط را بر اساس قله خوشه‌بندی می‌کند و آن‌گاه به ازای هر خوشه یک مدل می‌سازد. در بالای شکل یک مدل گاوسی به ازای هر قله نشان داده شده است. پیرامون این مثال، مقدار میانگین محاسبه‌شده به ازای هر خوشه شایستگی بیش‌تری دارد و نزدیک‌ترین نقطه به قله بیشینه می‌باشد. فراتر از استفاده از هندسه اقلیدسی، مدل‌های گاوسی اطلاعات بیش‌تری را به هنگام افزودن یک نقطه جدید به حافظه ارائه می‌کنند. قله در قسمت چپ به حد کافی بزرگ است و هر چه نقاط از حد متوسط دور‌تر باشند، احتمال پذیرفته‌شدن آن‌ها نیز بیش‌تر است. پیرامون خوشه‌هایی که تا به حال مدل دقیقی برای آن‌ها ارائه نشده است، مدل می‌بایست ضمن افزودن نقاط به حافظه اصلاح گردد. چنان‌چه مدل‌ها دقیق‌تر از قبل شوند، راه‌حل‌های بازیابی شده از حافظه نیز بهتر خواهند شد. الگوریتم جستجو در راستای بهبود راه‌حل‌های بازیابی شده از حافظه عمل می‌کند. این حلقه بازخورد نیز در جهت بهبود مدل‌های ذخیره‌شده در حافظه گام برمی‌دارد.

یک نوع از خوشه‌بندی برای حافظه‌های تخمین تراکم، خوشه‌بندی گاوسی^۱ است که مدل‌های تخمین تراکم غنی‌تری برای استفاده حافظه فراهم می‌کند. در این روش، هر مدخل حافظه یک مدل گاوسی از نقاط درون آن مدخل را محاسبه می‌کند. ماتریس میانگین و کوواریانس برای محاسبه این که نقطه جدید به خوشه موجود متعلق است و یا احتمال این که دو خوشه می‌بایست ادغام شوند، استفاده می‌شود.



شکل ۴: حافظه تخمین تراکم مثالی از یک فضای جستجو با ۴ قله مختلف است. هر دو حافظه استاندارد و تخمین تراکم نقاط یکسانی را می‌بینند. مدخل‌های حافظه برای حافظه استاندارد با نقطه نشان داده شده است، در صورتی که مدل‌های گاوسی محاسبه‌شده برای هر خوشه در حافظه تخمین تراکم در بالای آن فضای جستجو نشان داده شده است.

۳- آزمایش‌ها

در این بخش روش‌های حافظه پیشنهادی با روش‌های زیر در سناریوهای مختلف مورد مقایسه قرار گرفته‌اند:

$R - wasps$ استاندارد، نسخه حافظه بهبودیافته از $R - wasps$ ، حافظه استاندارد و حافظه $-\infty$.

حافظه $-\infty$ دقیقاً شبیه به سیستم حافظه استاندارد است ولی محدودیت در تعداد مدخل‌های حافظه ندارد. هر یک

از حافظه‌های دیگر، حداکثر ذخیره ۵ مدخل را اجازه می‌دهند (۵ خوشه برای حافظه‌های تخمین تراکم).

ما مسائل را با چهار ماشین و چهار نوع کار بررسی کرده‌ایم. هر سناریو ۱۵۰۰۰ واحد زمان طول می‌کشد و به ۵۰ دوره ۳۰۰ واحد زمان تقسیم می‌شود. در شروع هر دوره، نوع کار توزیع باعث ایجاد کار جدید وارده شده و تغییر آن به توزیع جدید می‌شود. این توزیع به طور تصادفی از ۱۰ توزیع ساخته‌شده در ابتدای این سناریو انتخاب شده است. توزیع برای این دوره به طور تصادفی است؛ بنابراین توزیع‌ها دقیقاً تکرار نمی‌شوند.

برای شناسایی تغییرات توزیع، از $\omega_1 = \omega_2 = 100N$ و $\varepsilon = 0.25, \phi = 2.5$ استفاده شده است؛ در حالی که N تعداد انواع کار است. مقادیر پارامترها برای $R - wasps$ در بخش‌های قبل توضیح داده شده است. سناریوها با سه مقدار $l \in \{1.00, 1.25, 1.50\}$ اجرا شده و روش پیشنهادی ۳۰ بار مورد اجرا قرار داده شده است. برای ارزیابی سناریوها، از چهار آمار استفاده شده است: توان عملیاتی (*throughput*)، راه‌اندازی (*setups*)، زمان چرخه (*cycle time*)، و طول صف (*queue length*). توان عملیاتی بر اساس درصد تمام کارها در سناریو که توسط ماشین پردازش می‌شوند اندازه‌گیری می‌شود. برپای شامل تعداد کل برپایی به وسیله همه ماشین‌ها در سیستم است. زمان چرخه، میانگین زمانی است که یک کار در سیستم وارد می‌شود، پردازش می‌گردد و پایان می‌یابد. طول صف، متوسط تعداد کارها در یک صف ماشین است.

نتایج

جدول‌های ۱، ۳ و ۵ میانگین نتایج از ۲۰ سناریو با مقادیر $l \in \{1.00, 1.25, 1.50\}$ را نشان می‌دهند. در جدول‌های ۲، ۴ و ۶ روش‌ها با هم مقایسه می‌شوند و درصد بهبود روش‌های حافظه نشان داده شده است. وقتی نتایج از لحاظ آماری معنادار هستند، نتایج بر این اساس مشخص است. برای تمام آزمایش‌ها در این قسمت، آمار معنادار نتایج با استفاده از آزمایش *kruskal-walis* با در نظر گرفتن اطمینان ۹۵٪ آزمایش شده است. آزمایش *kruskal-walis* یک راه آنالیز واریانس به وسیله رتبه‌بندی، یک معادله بدون پارامتریک تجزیه و تحلیل یک طرفه کلاسیک واریانس (*ANOVA*) است که فرض نمی‌کند داده‌ها در یک توزیع نرمال آمده‌اند.

وقتی $l = 1$ ، سیستم یک بار، متوسط به بالا دارد؛ تمام ۶ روش توان عملیاتی بیشتر از ۹۸٪ دارند. کارهای ناتمام باقی‌مانده که در انتهای سناریو موجود است بیشتر به این دلیل است که کارهای وارد شده خیلی دیر پردازش شده‌اند، در حالی که کارها به طور بالقوه یک‌بار می‌توانند وارد شوند. از آن جا که نسخه استاندارد $R - wasps$ بیش از ۹۹٪ کارها را تکمیل می‌کند، تعداد زیادی جای خالی برای بهبود در توان عملیاتی وجود ندارد. حافظه‌های تخمین تراکم به طور قابل توجهی، تعداد راه‌اندازی، زمان چرخه و طول صف را برای این سناریوها کاهش می‌دهند. حافظه استاندارد در واقع باعث آسیب در همه ناحیه‌ها می‌شود.

وقتی که $l = 1.25$ است سیستم، بار بالا دارد. نتایج برای ۶ روش متنوع است. روش استاندارد $R - wasps$ فقط ۸۴ تا ۸۹ درصد وظایف را میانگین انجام می‌دهد، در حالی که وقتی حافظه استفاده شود این میانگین بالای ۹۳٪ برای هر نوع حافظه است. یک‌بار دیگر، حافظه‌های تخمین تراکم عملکرد بهتری، با کاهش در تعداد راه‌اندازی، میانگین زمان چرخه و میانگین طول صف دارند.

وقتی که $l = 1.5$ است، سیستم بیش از حد بار دارد. در مقایسه با سناریوهای با بارهای بالاتر، توان عملیاتی برای همه روش‌ها با میانگین کمتر از ۸۰٪ برای $R - wasps$ استاندارد کاهش می‌یابد. وجود حافظه تخمین تراکم باعث بهبود قابل توجهی در $R - wasps$ استاندارد می‌شود.

DEM_g بهترین توان عملیاتی و زمان چرخه را دارد. بیشترین بهبود در $R - wasps$ استاندارد، کاهش تعداد راه‌اندازی می‌باشد.

جدول ۱: متوسط نتایج برای سناریوهایی با $\ell = 1.00$

روش ها	توان عملیاتی	راه اندازی	زمان چرخه	طول صف
<i>R - wasps</i>	۹۹/۰۵	۲۰۲۹/۲۵	۲۰/۰۲	۵۹/۰۴
<i>Memory</i>	۹۸/۶۴	۲۴۸۷/۲۰	۲۲/۹۶	۶۸/۹۴
<i>Memory - ∞</i>	۹۹/۲۷	۱۹۱۳/۴۵	۱۶/۲۰	۴۸/۰۳
<i>DEM_c</i>	۹۹/۴۳	۱۳۷۵/۴۵	۱۱/۳۱	۳۳/۷۶
<i>DEM_g</i>	۹۹/۶۵	۱۲۱۳/۱۰	۱۰/۱۰	۲۹/۸۰
<i>DEM_{gw}</i>	۹۹/۳۶	۱۵۵۰/۳۰	۱۳/۹۳	۴۱/۷۱

جدول ۲: درصد بهبود روش ۱ روی روش ۲ برای هر معیار با $\ell = 1.00$ (نتایج از نظر آماری به اطمینان ۹۵٪ معنی دار هستند که با + یا - نوشته می شوند)

روش ۱	روش ۲	توان عملیاتی	راه اندازی	زمان چرخه	طول صف
<i>Memory</i>	<i>R - wasps</i>	-۰/۴۱	-۲۲/۱۲ (-)	-۱۴/۶۶	-۱۶/۷۶
<i>Memory - ∞</i>	<i>R - wasps</i>	۰/۲۲	۵/۷۱	۱۹/۱۰	۱۸/۶۶
<i>Memory - ∞</i>	<i>Memory</i>	۰/۶۴	۲۲/۷۹ (+)	۲۹/۴۴ (+)	۳۰/۳۳ (+)
<i>DEM_c</i>	<i>R - wasps</i>	۰/۳۸	۳۲/۴۲ (+)	۴۳/۵۳ (+)	۴۲/۸۳ (+)
<i>DEM_c</i>	<i>Memory</i>	۰/۸۰ (+)	۴۴/۶۶ (+)	۵۰/۷۵ (+)	۵۱/۰۳ (+)
<i>DEM_c</i>	<i>Memory - ∞</i>	۰/۱۶	۲۸/۳۳ (+)	۳۰/۱۹ (+)	۲۹/۷۱
<i>DEM_g</i>	<i>R - wasps</i>	۰/۶۰ (+)	۴۰/۲۲ (+)	۴۹/۵۸ (+)	۴۹/۵۲ (+)
<i>DEM_g</i>	<i>Memory</i>	۱/۰۲ (+)	۵۱/۰۵ (+)	۵۶/۰۲ (+)	۵۶/۷۷ (+)
<i>DEM_g</i>	<i>Memory - ∞</i>	۰/۳۸ (+)	۳۶/۶۰ (+)	۳۷/۶۷ (+)	۳۷/۹۵ (+)
<i>DEM_g</i>	<i>DEM_c</i>	۰/۲۲	۱۱/۵۵	۱۰/۷۱	۱۱/۷۲
<i>DEM_{gw}</i>	<i>R - wasps</i>	۰/۳۲	۲۳/۶۰ (+)	۳۰/۴۵ (+)	۲۹/۳۶
<i>DEM_{gw}</i>	<i>Memory</i>	۰/۷۴ (+)	۳۷/۴۴ (+)	۳۹/۳۴ (+)	۳۹/۵۰ (+)
<i>DEM_{gw}</i>	<i>Memory - ∞</i>	۰/۰۹	۱۸/۹۸	۱۴/۰۳	۱۳/۱۶
<i>DEM_{gw}</i>	<i>DEM_c</i>	-۰/۰۷	-۱۳/۰۴	-۲۳/۱۶	-۲۳/۵۵
<i>DEM_{gw}</i>	<i>DEM_g</i>	-۰/۲۸	-۲۷/۸۰	-۳۷/۹۳	-۳۹/۹۵

جدول ۳: متوسط نتایج برای سناریوهایی با $\ell = 1.25$

روش ها	توان عملیاتی	راه اندازی	زمان چرخه	طول صف
<i>R - wasps</i>	۸۹/۸۴	۲۵۱۴/۰۵	۱۳۷/۷۰	۵۳۸/۰۶
<i>Memory</i>	۹۳/۱۶	۱۸۲۱/۰۰	۱۰۶/۷۹	۴۰۳/۸۷
<i>Memory - ∞</i>	۹۳/۱۰	۱۸۴۱/۴۵	۱۱۰/۳۷	۴۱۹/۲۸
<i>DEM_c</i>	۹۵/۲۹	۱۲۰۸/۱۰	۸۵/۸۴	۳۲۳/۹۱
<i>DEM_g</i>	۹۴/۸۶	۱۲۹۹/۰۵	۹۰/۷۹	۳۴۴/۴۱
<i>DEM_{gw}</i>	۹۶/۵۰	۸۲۰/۹۵	۶۱/۱۷	۲۳۴/۵۱

جدول ۴: درصد بهبود روش ۱ روی روش ۲ برای هر معیار با $\ell = 1.25$ (نتایج از نظر آماری به اطمینان ۹۵٪ معنی‌دار هستند که با + یا - نوشته می‌شوند)

روش ۱	روش ۲	توان عملیاتی	راه‌اندازی	زمان چرخه	طول صف
Memory	$R - wasps$	(+) ۳/۷۰	(+) ۲۷/۵۷	(+) ۲۲/۴۴	(+) ۲۴/۳۴
Memory - ∞	$R - wasps$	(+) ۳/۶۳	۲۶/۷۵	۱۹/۸۵	۲۲/۹۸
Memory - ∞	Memory	-۰/۰۷	-۱/۱۲	-۳/۳۵	-۱/۷۹
DEM _c	$R - wasps$	(+) ۶/۷۰	(+) ۵۱/۹۵	(+) ۳۷/۶۶	(+) ۳۸/۶۳
DEM _c	Memory	(+) ۲/۲۹	(+) ۳۳/۶۶	۱۹/۶۲	۱۸/۸۹
DEM _c	Memory - ∞	(+) ۲/۳۶	(+) ۳۴/۳۹	۲۲/۲۲	(+) ۲۰/۳۲
DEM _g	$R - wasps$	(+) ۵/۵۹	(+) ۴۸/۳۳	(+) ۳۴/۰۶	(+) ۳۵/۶۰
DEM _g	Memory	(+) ۱/۸۲	(+) ۲۸/۶۶	۱۴/۹۸	۱۴/۸۸
DEM _g	Memory - ∞	(+) ۱/۸۹	(+) ۲۹/۴۶	۱۷/۷۴	۱۶/۳۸
DEM _g	DEM _c	-۰/۴۵	-۷/۵۳	-۵/۷۷	-۴/۹۴
DEM _{gw}	$R - wasps$	(+) ۷/۴۱	(+) ۶۵/۳۷	(+) ۵۵/۵۸	(+) ۴۹/۶۴
DEM _{gw}	Memory	(+) ۳/۵۸	(+) ۵۴/۹۲	(+) ۴۲/۷۲	(+) ۳۳/۴۵
DEM _{gw}	Memory - ∞	(+) ۳/۶۵	(+) ۵۵/۴۲	(+) ۴۴/۵۸	(+) ۳۴/۶۲
DEM _{gw}	DEM _c	۱/۲۶	(+) ۳۲/۶۵	(+) ۲۸/۷۵	(+) ۱۷/۹۵
DEM _{gw}	DEM _g	۱/۷۳	(+) ۳۶/۸۰	(+) ۳۲/۶۳	(+) ۲۱/۸۱

جدول ۵: متوسط نتایج برای سناریوهایی با $\ell = 1.50$

روش‌ها	توان عملیاتی	راه‌اندازی	زمان چرخه	طول صف
$R - wasps$	۷۹/۳۳	۱۹۳۵/۱۵	۲۶۲/۸۳	۱۲۲۹/۶۵
Memory	۸۲/۷۱	۱۱۶۹/۸۵	۲۳۳/۷۸	۱۰۷۳/۸۵
Memory - ∞	۸۱/۱۰	۱۴۸۹/۷۰	۲۴۴/۲۶	۱۱۴۸/۹۷
DEM _c	۸۱/۷۱	۱۳۷۴/۰۰	۲۴۱/۲۷	۱۱۱۴/۷۶
DEM _g	۸۳/۰۸	۱۰۵۷/۱۵	۲۲۵/۵۷	۱۰۵۱/۸۰
DEM _{gw}	۸۳/۰۶	۱۰۴۶/۰۰	۲۲۶/۸۷	۱۰۴۱/۶۶

جدول ۶: درصد بهبود روش ۱ روی روش ۲ برای هر معیار با $\ell = 1.50$ (نتایج از نظر آماری به اطمینان ۹۵٪ معنی‌دار هستند که با + یا - نوشته می‌شوند)

روش ۱	روش ۲	توان عملیاتی	راه‌اندازی	زمان چرخه	طول صف
Memory	$R - wasps$	(+) ۴/۲۷	(+) ۳۹/۵۵	۱۱/۰۵	۱۲/۶۷
Memory - ∞	$R - wasps$	۲/۲۳	۲۳/۰۲	۷/۰۶	۶/۵۶
Memory - ∞	Memory	-۱/۹۵	-۲۷/۳۴	-۴/۹۴	-۷/۰۰
DEM _c	$R - wasps$	۳/۰۰	۲۹/۰۰	۸/۲۰	۹/۳۴
DEM _c	Memory	-۱/۲۱	-۱۷/۴۵	-۳/۲۰	-۳/۸۲
DEM _c	Memory - ∞	۰/۷۵	(+) ۳۴/۳۹	۲۲/۲۲	(+) ۲۰/۳۲
DEM _g	$R - wasps$	(+) ۴/۷۳	(+) ۴۵/۳۷	(+) ۱۴/۱۸	(+) ۱۴/۴۶
DEM _g	Memory	۰/۴۴	۹/۶۳	۳/۵۱	۲/۰۵
DEM _g	Memory - ∞	۲/۴۴	۲۹/۰۴	۷/۶۵	۸/۴۵
DEM _g	DEM _c	۱/۶۷	۲۳/۰۶	۶/۵۱	۵/۶۵

روش ۱	روش ۲	توان عملیاتی	راه‌اندازی	زمان چرخه	طول صف
DEM_{gw}	$R - wasps$	۴/۷۱ (+)	۴۵/۹۵ (+)	۱۳/۶۸ (+)	۱۵/۲۹ (+)
DEM_{gw}	Memory	۰/۴۲	۱۰/۵۹	۲/۹۵	۳/۰۰
DEM_{gw}	Memory - ∞	۲/۴۲	۲۹/۷۶	۷/۱۲	۹/۳۴
DEM_{gw}	DEM_c	۱/۶۶	۲۳/۸۷	۵/۹۷	۶/۵۷
DEM_{gw}	DEM_g	-۰/۰۲	۱/۰۵	-۰/۵۸	۰/۹۷

نتیجه‌گیری

در این مقاله یک حافظه مبتنی بر توزیع تخمین تراکم برای حل مسئله هماهنگ‌سازی کارخانه توزیع‌شده پویا ارائه شده است. نتایج حاصله نشان می‌دهد که حافظه پیشنهادی نسبت به $R - wasps$ استاندارد و سایر روش‌ها دارای عملکرد مناسب‌تری در حل مسئله هماهنگ‌سازی کارخانه توزیع‌شده پویا می‌باشد. هم‌چنین در حافظه ارائه‌شده نقاط ضعف حافظه استاندارد برطرف گردیده است. در یک حافظه استاندارد فضای ذخیره‌سازی محدود می‌باشد و اگر تعداد راه‌حل‌های یک مسئله زیاد باشند، حافظه به سرعت پر می‌شود. حافظه ارائه‌شده در این مقاله این ضعف را برطرف نموده است. در سیستم‌های حافظه ارائه‌شده در این مقاله، به جای ذخیره کردن تنها نقاط تکی در حافظه، خوشه‌هایی از نقاط در هر مدخل حافظه ذخیره شوند و مدلی از هر نقاط در هر خوشه ایجاد می‌شود. این نوع حافظه، قادر به ذخیره کردن نقاط بیشتری بوده و سربار محاسباتی برای این نوع حافظه کم است. روش‌های حافظه ارائه‌شده در این مقاله در سناریوهای مختلفی با دیگر روش‌ها مورد مقایسه قرار گرفته است. نتایج آماری ارائه‌شده نشان می‌دهند که روش‌های حافظه ارائه‌شده از لحاظ عملکرد نسبت به سایر روش‌های مشابه بهتر می‌باشند. برای کارهای آتی پیشنهاد می‌شود که روش‌های حافظه ارائه‌شده را با یکی از الگوریتم‌های تکاملی ترکیب نموده و برای حل مسئله‌های تولیدات کارگاهی پویا و محک قله‌های متحرک مورد بررسی قرار داد تا میزان عملکرد این روش‌ها در حل این مسئله‌ها نیز مورد بررسی قرار گیرد.

منابع

- محمدپور، مجید و پروین، حمید. (۱۳۹۵). الگوریتم ژنتیک آشوب گونه مبتنی بر حافظه و خوشه‌بندی برای حل مسائل بهینه‌سازی پویا. *مجله مهندسی برق دانشگاه تبریز*، ۴۶(۳).
- Bendtsen, C. N., & Krink, T. (2002). Dynamic memory model for non-stationary optimization. Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No. 02TH8600),
- Branke, J. (2012). *Evolutionary optimization in dynamic environments* (Vol. 3). Springer Science & Business Media.
- Branke, J., & Mattfeld, D. C. (2002). Anticipatory scheduling for dynamic job shop problems. AIPS Workshop on On-line Planning and Scheduling,
- Bravo, Y., Luque, G., & Alba, E. (2016). Global memory schemes for dynamic optimization. *Natural computing*, 15, 319-333.
- Campos, M., Bonabeau, E., Theraulaz, G., & Deneubourg, J.-L. (2000). Dynamic scheduling and division of labor in social insects. *Adaptive Behavior*, 8(2), 83-95.
- Chen, X., Zhang, D., & Zeng, X. (2015). A stable matching-based selection and memory enhanced MOEA/D for evolutionary dynamic multiobjective optimization. 2015 IEEE 27th International Conference on Tools with Artificial Intelligence (ICTAI),
- Chrysosolouris, G., & Subramaniam, V. (2001). Dynamic scheduling of manufacturing job shops using genetic algorithms. *Journal of Intelligent Manufacturing*, 12, 281-293.
- Cicirello, V. A., & Smith, S. F. (2004). Wasp-like agents for distributed factory coordination. *Autonomous Agents and Multi-agent systems*, 8, 237-266.

- Eggermont, J., & Lenaerts, T. (2002). Dynamic optimization using evolutionary algorithms with a case-based memory. Proceedings of the Fourteenth Belgium-Netherlands Conference on Artificial Intelligence (BNAIC),
- Eggermont, J., Lenaerts, T., Poyhonen, S., & Termier, A. (2001). Raising the dead: Extending evolutionary algorithms with a case-based memory. Genetic Programming: 4th European Conference, EuroGP 2001 Lake Como, Italy, April 18–20, 2001 Proceedings 4,
- Mohammadpour, M., & Parvin, H. (2016). Genetic algorithm based on explicit memory for solving dynamic problems. *Journal of Advances in Computer Research*, 7(2), 53-68.
- Morrison, R. W., & De Jong, K. A. (1999). A test problem generator for non-stationary environments. Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406),
- Nasiri, B., & Meybodi, M. R. (2012). Speciation based firefly algorithm for optimization in dynamic environments. *International Journal of Artificial Intelligence*, 8(S12), 118-132.
- Ozsoydan, F. B., & Baykasoglu, A. (2015). A multi-population firefly algorithm for dynamic optimization problems. 2015 IEEE International Conference on Evolving and Adaptive Intelligent Systems (EAIS),
- Ramsey, C. L., & Grefenstette, J. J. (1993). Case-Based Initialization of Genetic Algorithms. ICGA,
- Richter, H., & Yang, S. (2008a). Learning in abstract memory schemes for dynamic optimization. 2008 Fourth International Conference on Natural Computation,
- Richter, H., & Yang, S. (2008b). Memory based on abstraction for dynamic fitness functions. Applications of Evolutionary Computing: EvoWorkshops 2008: EvoCOMNET, EvoFIN, EvoHOT, EvoIASP, EvoMUSART, EvoNUM, EvoSTOC, and EvoTransLog, Naples, Italy, March 26-28, 2008. Proceedings,
- Richter, H., & Yang, S. (2009). Learning behavior in abstract memory schemes for dynamic optimization problems. *Soft Computing*, 13, 1163-1173.
- Sadeghi, S., Parvin, H., & Rad, F. (2015). Particle swarm optimization for dynamic environments. 14th Mexican Int. Conf. Artificial Intelligence, (MICAI 2015),
- Yang, S. (2006). Associative memory scheme for genetic algorithms in dynamic environments. Applications of Evolutionary Computing: EvoWorkshops 2006: EvoBIO, EvoCOMNET, EvoHOT, EvoIASP, EvoINTERACTION, EvoMUSART, and EvoSTOC, Budapest, Hungary, April 10-12, 2006. Proceedings,
- Yang, S. (2007a). Explicit memory schemes for evolutionary algorithms in dynamic environments. *Evolutionary computation in dynamic and uncertain environments*, 3-28.
- Yang, S. (2007b). Genetic algorithms with elitism-based immigrants for changing optimization problems. Applications of Evolutionary Computing: EvoWorkshops 2007: EvoCoMnet, EvoFIN, EvoIASP, EvoINTERACTION, EvoMUSART, EvoSTOC and EvoTransLog. Proceedings,

