

پیدا کردن موتیف در نواحی بالادست زن‌های همبیان بر اساس الگوریتم بهینه‌سازی فاخته و سرمایش تدریجی

مهری ملالو^۱، کارشناسی ارشد، فاطمه زارع میرک آباد^۲، عضو هیات علمی

۱- دانشکده ریاضی و علوم کامپیوتر - دانشگاه صنعتی امیرکبیر - تهران - ایران - m.mollalo@aut.ac.ir

۲- دانشکده ریاضی و علوم کامپیوتر - دانشگاه صنعتی امیرکبیر - تهران - ایران - fzare@aut.ac.ir

چکیده: در این مقاله برای حل مسئله کشف موتیف یک روش ترکیبی جدید بر اساس الگوریتم بهینه‌سازی فاخته، روش سرمایش تدریجی و بهینه‌سازی زمان انتظار به نام SA-COAMF ارائه می‌شود. این روش ترکیبی در همگرایی بهینه سراسری بسیار کارآمد است. یکی دیگر از ویژگی‌های شاخص این الگوریتme، بهره بردن از هر دو مدل نمایش موتیف (توالی اجماع و ماتریس احتمالاتی) است. عملکرد الگوریتم پیشنهادی بر روی یک مجموعه از داده‌های زیستی (پایگاه داده SCPD) تست شده و با تعدادی از الگوریتم‌های معروف کشف موتیف (MEME، PSO+، GA-DPAF) مقایسه می‌گردد. نتایج به دست آمده نشان‌دهنده توانایی بالای الگوریتم پیشنهادی است. واژه‌های کلیدی: الگوریتم بهینه‌سازی فاخته، سرمایش تدریجی، زن‌های همبیان، کشف موتیف، ماکریم‌سازی زمان انتظار.

Motif Finding in upstream regulatory regions of co-expressed genes using Cuckoo optimization Algorithm and Simulated Annealing

M. Mollalo, Master Of Science¹, F. Zare-Mirakabad, Assistant Professor²

1- Faculty of Computer Science & Mathematics, Amirkabir University of Technology, Tehran, Iran, Email: m.mollalo@aut.ac.ir

2- Faculty of Computer Science & Mathematics, Amirkabir University of Technology, Tehran, Iran, Email: fzare@aut.ac.ir

Abstract: In this paper, a novel hybrid algorithm is represented named SA-COAMF by using cuckoo optimization algorithm, simulated annealing and expected maximization for motif finding problem. SA-COAMF is very efficient in global optimal convergence. In the algorithm, two models of motif representation, consensus and probability matrix representations, are applied to take the advantage of them. SA-COAMF is run on experimental datasets (SCPD database). The results are compared with some well-known algorithms (GA-DPAF, PSO+ and MEME) to show that our algorithm is efficient.

Keywords: Cuckoo optimization algorithm, simulated annealing algorithm, coexpressed genes, motif finding, expected maximization.

تاریخ ارسال مقاله: ۱۳۹۴/۱/۲۳

تاریخ اصلاح مقاله: ۱۳۹۴/۰۳/۰۵

تاریخ پذیرش مقاله: ۱۳۹۴/۰۶/۲۴

نام نویسنده مسئول: فاطمه زارع میرک آباد

نشانی نویسنده مسئول: خیابان حافظ شماره ۴۲۴-دانشکده ریاضی و علوم کامپیوتر

الگوریتم‌های هیوریستیکی GibbsSampler [۵] و MEME [۱۵]

جز اولین الگوریتم‌های غیرقطعی هستند که برای این مسئله ارائه شد. یکی از مشکلات مشترک در هر دورش، گیرافتدان در بهینه‌های محلی است. جهت غلبه بر این مشکل، اخیراً الگوریتم‌های متاهیوریستیکی در حل مسئله کشف موتیف بسیار مورد توجه قرار گرفته است. زیرا این الگوریتم‌ها فضای جستجو را به صورت وسیع‌تری بررسی می‌کنند [۲۳-۲۴].

هدف اصلی اکثر الگوریتم‌های ارائه شده، زمان محاسباتی پایین و کشف موتیف‌های با کیفیت بالا است. نکته قابل توجه این است که دو هدف، محاسبات پایین و پیش‌گویی موتیف با کیفیت بالا، در تضاد با هم هستند.

از این‌رو در این مقاله، برای ایجاد یک مصالحه بین این دو هدف، یک الگوریتم ترکیبی جدید بر اساس ترکیب الگوریتم بهینه‌سازی فاخته^۴، تکنیک سرمایش تدریجی (SA^۵) و پیشینه‌سازی زمان انتظار (EM^۶) بنام SA-COAMF^۷ ارائه می‌شود. روش پیشینه‌سازی زمان انتظار ابتدا هر فاخته را به بهینه محلی اش نزدیک می‌کند و سپس با روش سرمایش تدریجی هر فاخته از بهینه محلی اش خارج می‌شود تا به جواب بهینه سراسری دست پیدا کند. در این الگوریتم از مدل ماتریس احتمالاتی برای نمایش موتیف‌ها استفاده می‌شود، زیرا این مدل حامل اطلاعات بیشتری نسبت به توالی اجماع است. با توجه به اینکه در الگوریتم ارائه شده هدف یافتن یک ماتریس احتمالاتی بهینه است و فضای جستجوی این ماتریس‌ها بسیار وسیع است، برای مهاجرت فاخته‌ها، از نمایش توالی اجماع استفاده می‌گردد. وجود این دو مدل نمایش، باعث می‌شود که الگوریتم از دقت مدل ماتریس احتمالاتی و سرعت بالای توالی اجماع بهره مند گردد.

یکی دیگر از مزایای الگوریتم پیشنهادی این است که الگوریتم فاخته استاندارد را به صورتی توسعه می‌دهد که بتواند یک مسئله با فضای گسته را حل نماید.

نتایج اجرای الگوریتم پیشنهادی بر روی ۹ عامل الگوبرداری موجود در پایگاه داده SCPD، نشان‌دهنده قابل رقابت بودن الگوریتم SA-COAMF با الگوریتم‌های MEME [۲۴]، GA-DPAF [۲۵] و PSO+ [۲۱] است.

در بخش ۲ از این مقاله، ابتدا تعاریف اولیه موردنیاز برای مسئله کشف موتیف ارائه و سپس الگوریتم بهینه‌سازی فاخته در حالت کلی شرح داده می‌شود. الگوریتم SA-COAMF به همراه جزئیات در بخش سوم مورد بررسی قرار می‌گیرد. در بخش چهارم، معیار ارزیابی الگوریتم‌های پیداکردن موتیف و پایگاه داده SCPD معرفی می‌شود. سپس در بخش پنجم الگوریتم پیشنهادی با الگوریتم فاخته استاندارد بر روی ۹ مجموعه داده‌ی منتخب از پایگاه داده SCPD، اجرا و مقایسه می‌گردد و همچنین عملکرد SA-COAMF با الگوریتم‌های MEME، GA-DPAF و PSO+ مقایسه می‌شود. سپس زمان پردازش و پیچیدگی زمانی الگوریتم پیشنهادی با دو الگوریتم تکاملی- GA-

۱- مقدمه

یک مجموعه از زیرتوالی‌های حفاظت شده در توالی‌های زیستی (ساختار اول مولکول‌های RNA و پروتئین) را موتیف می‌گویند به طوری که این زیرتوالی‌ها دارای ساختار و عملکرد های مشابهی هستند. موتیف‌ها نقش کارایی در تعیین ساختار و عملکرد یک مولکول دارند. مسئله کشف موتیف یکی از مسئله‌های مهم و با اهمیت در زیست‌شناسی مولکولی شناخته شده است [۱] به طوری که حل این مسئله می‌تواند کمک شایانی به زیست‌شناسان‌ها در تشخیص بیماری‌های مانند آزاریمیر بنماید [۲]. یک نوع از موتیف‌های مهم در زیست‌شناسی، موتیف‌های موجود در نواحی پروموتور ژن‌های هم‌بیان است. تعدادی از عوامل الگوبرداری (TF) می‌توانند این موتیف‌ها را به صورت خاص شناسایی کنند و این نواحی را برای ورود سایر TF‌ها و الگوبرداری ژن‌ها آماده نمایند [۳]. برای کشف موتیف، روش‌های آزمایشگاهی مختلفی وجود دارد، اما این روش‌ها بسیار زمان بیرونی هستند. از این‌رو زیست‌شناسان‌ها بر آن شدند تا از محاسبات کامپیوتری در تحقیقات خود بهره گیرند.

در مسئله محاسباتی کشف موتیف، هدف یافتن یک موتیف نا شناخته به طول t است که در t توالی زیستی با بیشترین انطباق رخ داده باشد [۴]. به هر یک از این رخدادهای تقریبی در هر یک از توالی‌های زیستی یک مصدقاق از موتیف گفته می‌شود. دو روش استاندارد توالی اجماع^۸ و ماتریس احتمالاتی (PFM)^۹ برای نمایش یک مجموعه از مصدقاق‌های موتیف وجود دارد [۵, ۶].

در نمایش توالی اجماع، موتیف به صورت یک توالی نمایش داده می‌شود که در هر موقعیت آن غالباً ترین نوکلئوتید از مصدقاق‌های موتیف در آن موقعیت، قرار می‌گیرد [۷]. در مدل نمایش ماتریس احتمالاتی، موتیف به صورت یک ماتریس نمایش داده می‌شود که هر عنصر از موقعیت i و j این ماتریس نشان‌دهنده احتمال رخداد نوکلئوتید A در موقعیت i,j است.

اولین بار در سال ۱۹۹۵، مسئله کشف موتیف به عنوان یک مسئله محاسباتی، تعریف شد [۸] و امروزه به عنوان یکی از مسئله‌های چالش برانگیز در حوزه بیوانفورماتیک معرفی می‌گردد. با توجه به این که در سال ۲۰۰۰ ثابت شد این مسئله NP-کامل است [۹]، محققان علوم کامپیوتر در پی یافتن یک الگوریتم هستند که بتواند با زمان مناسب یک فضای وسیع از زیرتالی‌های موجود را برای یافتن موتیف اصلی جستجو کند. در راستای رسیدن به این هدف، تا به امروز الگوریتم‌های قطعی و غیرقطعی متنوعی برای حل این مسئله ارائه شده است. الگوریتم‌های Weeder [۱۰]، YMF [۱۱]، MultiProfiler [۱۲] و Projection [۱۳] را می‌توان به عنوان الگوریتم‌های قطعی و الگوریتم‌های EM [۱۴]، MEME [۱۵]، AlignACE [۱۶]، BioProspector [۱۷] را به عنوان الگوریتم‌های غیرقطعی معرفی نمود. واضح است که NP-کامل بودن این مسئله باعث شده که الگوریتم‌های غیرقطعی کارآمدتر باشند.

اساس روابط (۳) و (۴) استخراج می‌شود. سپس مجموعه مصدق = $U = \{u_1, \dots, u_7\}$ که متناظر با جدول ۲ است و مجموعه موقعیت شروع مشخص می‌گردد.

جدول ۱: توالی‌های ورودی مثال ۱

$s_1 = aa$	AGTGAAA taataaa	$s_2 = gtgga$	ATTGGAA ttg
$s_3 = tct$	AGTTTGA aaaca	$s_4 = tttcta$	TATTGAA ag
$s_5 = tgac$	AGTTGTA acaa	$s_6 = a$	ATATGCT gtcaaca
$s_7 = tgtg$	ATTTCTT gcaa		

جدول ۲: مجموعه مصدق‌های موتیف مثال ۱

$u_1 = AGTGAAA,$	$u_2 = ATTGGAA,$
$u_3 = AGTTTGA,$	$u_4 = TATTGAA,$
$u_5 = AGTTGTA,$	$u_6 = ATATGCT,$
	$u_7 = ATTTCTT$

اگر موتیف اصلی بر اساس ماتریس احتمالاتی $W_{4 \times \ell}$ تعریف گردد، یک زیرتوالی s_i از توالی s به عنوان مصدق معتبر u برای موتیف اصلی انتخاب می‌شود اگر دارای بیشترین شباهت به ماتریس احتمالاتی W باشد. میزان شباهت هر زیرتوالی s_i با W بر اساس رابطه زیر به دست می‌آید:

$$Score(s_i, W) = \sum_{k=1}^{\ell} \log_2 \frac{W[s_i[j+k-1], k]}{b[s_i[j+k-1]]}, \quad (5)$$

که $W[\alpha, i]$ و $b[\alpha]$ به ترتیب احتمال رخداد نوکلئوتید α در ستون i ام از ماتریس W و احتمال رخداد نوکلئوتید α در مجموعه S است. جدول ۳ ماتریس احتمالاتی مربوط به مجموعه مصدق‌های مثال ۱ که در جدول ۱ مشخص شده است را نشان می‌دهد.

جدول ۳: ماتریس احتمالاتی مثال ۱

	۱	۲	۳	۴	۵	۶	۷
A	۰/۸۶	۰/۱۴	۰/۸۶	۰	۰/۱۴	۰/۴۴	۰/۷۱
C	۰	۰	۰	۰	۰/۱۴	۰/۱۴	۰
G	۰	۰/۴۳	۰	۰/۲۹	۰/۵۸	۰/۱۴	۰
T	۰/۱۴	۰/۴۳	۰/۱۴	۰/۷۱	۰/۱۴	۰/۲۸	۰/۲۹

۱-۲ - الگوریتم بهینه‌سازی فاخته

الگوریتم بهینه‌سازی فاخته یکی از الگوریتم‌های تکاملی جدید است که توسط رامین رجبیون در سال ۲۰۱۱ برای مسئله‌های بهینه‌سازی خطی پیشنهاد شد [۲۷]. این الگوریتم از زندگی یک دسته پرندگان که فاخته نامیده می‌شود الهام گرفته شده است.

PSOT و DPAF مقایسه می‌گردند. در نهایت در بخش نتیجه‌گیری، یک جمع‌بندی از الگوریتم پیشنهادی و کارهای آن را نمایش می‌دهند.

۲- تعاریف اولیه

در این بخش مفاهیم اولیه مورد نیاز برای حل مسئله کشف موتیف معرفی می‌شوند.

یک توالی DNA ، دنباله‌ای از نوکلئوتیدهای $\Sigma = \{A, C, G, T\}$ است و یک مجموعه از t توالی $S = \{s_1, \dots, s_t\}$ به صورت $s_i = s_i[1] \dots s_i[n_i]$ DNA تعریف می‌گردد. طول هر توالی s_i است، برابر n_i است. یک زیرتوالی از توالی s_i که در موقعیت z به طول ℓ رخ می‌دهد، به صورت $s_i[z:j] = s_i[z] \dots s_i[j + \ell - 1]$ نمایش داده می‌شود.

در مسئله کشف موتیف هدف پیدا کردن یک مجموعه از زیرتوالی‌ها به طول ℓ از مجموعه S است که به هر یک از زیرتوالی‌های به دست آمده یک مصدق از موتیف گفته می‌شود. یک مجموعه از مصدق‌های موتیف را می‌توان بر اساس رابطه زیر نمایش داد:

$$U = \{u_1, \dots, u_t\} \quad (1)$$

که u_i یک زیرتوالی بنام مصدق موتیف از توالی s_i در موقعیت z_i به طول ℓ است. مجموعه $P = \{p_1, \dots, p_t\}$ نمایش دهنده موقعیت‌های شروع مصدق‌های موتیف در مجموعه توالی S است. ارزش هر مجموعه مصدق U (برازش) بر اساستابع محظوظ اطلاعاتی (IC^A) که در رابطه زیر تعریف شده است، به دست می‌آید:

$$IC = \sum_{\alpha \in \Sigma} \sum_{i=1}^t W[\alpha, i] \times \log_2 \frac{W[\alpha, i]}{b[\alpha]}, \quad (2)$$

به طوری که $W[\alpha, i]$ احتمال رخداد کاراکتر α در موقعیت i ام از مجموعه مصدق‌های موتیف و $b[\alpha]$ احتمال رخداد کاراکتر α در مجموعه توالی S است [۲۶].

با توجه به تعاریف ارائه شده می‌توان مسئله کشف موتیف را به این صورت تعریف کرد که هدف، پیدا کردن یک مجموعه مصدق U با بیشترین مقدار IC است.

اگر توالی اجماع $e = e[1], \dots, e[\ell]$ نماینده موتیف اصلی از مجموعه S باشد، میزان شباهت زیرتوالی s_i با توالی اجماع e بر اساس رابطه زیر محاسبه می‌شود:

$$MS(s_i, e) = \sum_{k=1}^{\ell} \chi(s_i[j+k-1], e[k]), \quad (3)$$

که تابع M میزان شباهت دو کاراکتر a و b را بر اساس رابطه زیر محاسبه می‌نماید:

$$\chi(a, b) = \begin{cases} 1 & \text{if } a = b, \\ 0 & \text{otherwise.} \end{cases} \quad (4)$$

مثال ۱: با توجه به توالی اجماع داده شده $e = ATTTGAA$ ، از هر رشته ورودی s_i در جدول ۱ یک زیرتوالی با حداکثر میزان شباهت بر

۳- الگوریتم پیشنهادی SA-COAMF

در این مقاله یک الگوریتم ترکیبی جدید بنام SA-COAMF بر اساس روش بهینه‌سازی فاخته، تکنیک سرمایش تدریجی و پیشنهادی زمان انتظار جهت کشف موتیف ارائه می‌شود که این الگوریتم توانایی جستجوی سراسری و همگرایی به جواب بهینه را داشته و از ترکیب فواید هر دو روش‌های توالی اجماع و ماتریس احتمالاتی جهت نمایش موتیف استفاده می‌نماید. این الگوریتم، یک مجموعه توالی (S) و طول موتیف (ℓ) را به عنوان ورودی دریافت می‌کند. مراحل الگوریتم پیشنهادی SA-COMF در شبهه کد (۱) بیان می‌گردد.

۱-۱- جمعیت اولیه

در گام اول الگوریتم، یک جمعیت اولیه از فاخته‌ها به تعداد $\sum_{i=1}^t n_i$ ، numCuckoos = $(15 \times t)$ موتیف در مجموعه S است، ساخته می‌شود. عدد ۱۵ بیشترین طول موتیف در توالی‌ها است، زیرا طول موتیف‌ها در نواحی پر و موتور معمولاً بین ۱۵-۱۰ است.

هر فاخته i در الگوریتم SA-COAMF یک مجموعه موقعیت $\{p_{ji}, p_{ji}^*, \dots, p_{ji}^{*\ell}\}$ است که هر p_{ji} ، $1 \leq i \leq t$ ، موقعیت شروع مصدقاق n_i در توالی s_i را نشان می‌دهد. به p_{ji} ، یک موقعیت تصادفی در محدوده $[n_i - \ell, n_i]$ نسبت داده می‌شود. برای هر فاخته i مجموعه $P_i = \{p_{ji}, p_{ji}^*, \dots, p_{ji}^{*\ell}\}$ بر اساس روش EM به صورت زیر به روز می‌گردد:

مجموعه مصدقاق U_i بر اساس بردار موقعیت فاخته Z_m ، P_i ، ساخته می‌شود به طوری که طول هر مصدقاق برابر ℓ است. سپس بر اساس مجموعه مصدقاق‌های U_i ، ماتریس احتمالاتی W_j حاصل می‌گردد. با استفاده از ماتریس احتمالاتی W_j در تمامی توالی‌های مجموعه S جستجوی شود تا در هر توالی s_i ، یک زیرتوالی مانند u_j به طول ℓ پیدا گردد که نسبت به ماتریس احتمالاتی W_j و با توجه به رابطه (۵) دارای بیشترین میزان شباهت باشد. به این ترتیب بردار موقعیت جدیدی بنام P_j^* به دست می‌آید. به ازای P_j^* و P_j دو مجموعه مصدقاق Z_j و U_j ساخته می‌گردد و سپس برآش هر یک از آن‌ها بر اساس رابطه (۲) محاسبه می‌شود. اگر برآش P_j^* از P_j بهتر است، P_j^* به جای P_j قرار می‌گیرد و مجدداً الگوریتم EM اجرا می‌گردد، در غیر این صورت الگوریتم خاتمه می‌یابد.

جمعیت اولیه فاخته‌ها و محاسبه نتایج برآش در یک لیست بنام Cuckoos ثبت می‌شود.

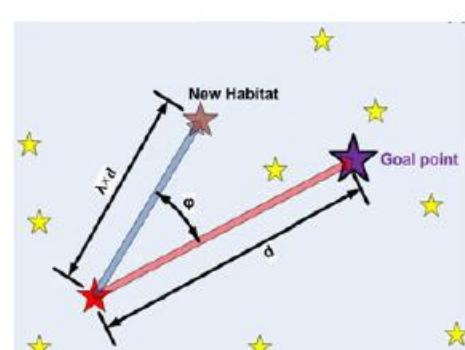
در ادامه G فاخته با بیشترین مقدار برآش، به عنوان جواب هدف در لیست Goals نگهداری می‌شود.

فاخته‌ها پرندگانی هستند که به صورت زیرکانه پرورش تخم‌ها و جوجه‌های خود را بر عهده پرندگان دیگر قرار می‌دهند، بدون آنکه پرندگان میزبان متوجه شوند تخم‌های درون لانه، مربوط به خودشان نیست.

مشابه سایر الگوریتم‌های تکاملی، الگوریتم بهینه‌سازی فاخته با یک جمعیت اولیه شروع می‌شود. این پرندگان تخم‌های خود را در لانه سایر پرندگان قرار می‌دهند و صبر می‌کنند تا آن‌ها در کنار تخم‌های خود تخم‌های این پرندگان را نیز نگهداری کنند. برخی از پرندگان میزبان، تخم‌های فاخته‌ها را در لانه‌های خود تشخیص داده و آن‌ها را از لانه بیرون می‌اندازند [۲۸]. بنابراین واضح است، تخم‌های با شماحت بیشتر به تخم‌های پرنده میزبان، شناسی بیشتری برای زنده ماندن و تبدیل به فاخته بالغ دارند. از طرف دیگر، جوجه‌های فاخته زودتر از تخم‌های پرنده میزبان از تخم بیرون می‌آیند و زودتر هم رشد می‌کنند. در اکثر موارد جوجه فاخته، تخم‌ها و یا جوجه‌های پرنده میزبان را از لانه بیرون می‌اندازد و در نهایت در هر لانه یک تخم شناس رشد پیدا می‌کند. در طبیعت هر فاخته بین ۱ تا ۲۰ تخم را در یک دامنه مشخص می‌گذارد که حداقل دامنه تخم‌گذاری (ELR^۱) می‌نامند. هر فاخته دارای ELR مخصوص به خود است.

وقتی جوجه‌های فاخته‌ها رشد کرده و تبدیل به فاخته بالغ می‌شوند، پرنده‌های فاخته با میزانی فاصله و انحراف به سمت بهترین منطقه فعلی درین تمام فاخته‌ها که شناس زنده ماندن تخم‌ها بیشتر است، مهاجرت می‌کنند. همان طور که در شکل ۱ دیده می‌شود هر فاخته فقط درصدی از کل مسیر را به سمت هدف ایده‌آل فعلی طی می‌کند و میزانی انحراف نیز دارد. این دو پارامتر به فاخته‌ها کمک می‌کنند تا محیط بیشتری را جستجو و کنند و از گیرافتادن در بهینه‌های محلی اجتناب نمایند.

وقتی تمام فاخته‌ها به سمت نقطه هدف مهاجرت کرده و نقاط سکونت جدید هر کدام مشخص شد، دوباره مراحل تخم‌گذاری و محاسبه ELR برای هر یک از فاخته‌ها انجام می‌شود. با توجه به این واقعیت که همیشه تعادلی بین جمعیت پرندگان در طبیعت وجود دارد، معادل با حداقل تعداد فاخته‌هایی که می‌توانند در یک محیط زندگی کنند؛ تعریف می‌گردد.



شکل ۱: مهاجرت یک نمونه فاخته به سمت محل اقامت هدف

شبکه (۱): مراحل الگوریتم SA-COAMF

```

SA_COAMFO {
    Inp uts:
        Sequences :  $S = \{s_1, \dots, s_t\}$ 
         $\ell$  : the length of the motif
    Parameters:
        T: The temperature for Simulated Annealing;
         $\alpha$ : amount of decrees in temperature;
        maxIter: maximum iteration of the algorithm;
        Nmax: maximum number of cuckoos that can live at the same time;
        G: maximum number of goal points;
    1. (Cuckoos, numCuckoos) = Generate Initial Population;
    2. Create a list called Goal to save G numbers of Cuckoos with the highest fitness values;
    3. for iter=1 to maxIter do begin
    4.     for j=1: numCuckoos do begin
            Cuckoos[j] lay eggs
                A. Initialize number of eggs for each cuckoo  $P_j$  and called Egg;
                B. Calculate ELR for each egg of  $P_j$  and called  $E_k$ ;
                C. Based on computed  $E_k$ 's, find a nest for each egg  $P_j^k$  of  $P_j$ ;
                D. If  $P_j^k \notin Cuckoos$ , compute fitness function for  $P_j^k$  and add it to the list Cuckoos;
        end
    6. while (numCuckoos > Nmax) do begin
            i. Remove each cuckoo with the worst fitness values from Cuckoos list;
            ii. numCuckoos = numCuckoos - 1;
        end
    7. Update Goal list based on Cuckoos list
    8. Immigration of cuckoo;
end

9. Goal List is declared as a list of predicted motifs

```

در گام ششم، فاخته‌هایی که برازش کمتری دارند تا رسیدن به سقف N_{max} . حداکثر تعداد فاخته در طبیعت، از لیست حذف می‌شوند.

در گام هفتم، لیست *Goal* بر اساس لیست *Cuckoos* جدید بهروز می‌گردد.

پیچیدگی زمانی تخم‌گذاری هر فاخته برابر $O(n t^2 \log_2 t)$ است، به طوری که $t \log_2 t$ تعداد تخم‌های هر فاخته و بهروزرسانی هر تخم $O(n t^2 \ell)$ زمان نیاز دارد.

۳-۳- مهاجرت فاخته‌ها

در گام هشتم الگوریتم SA-COAMF، عمل مهاجرت فاخته‌ها انجام می‌شود. با توجه به اینکه در این الگوریتم چندین هدف وجود دارد که فاخته‌ها می‌توانند به سمت آن‌ها مهاجرت کنند، برای پیدا کردن هدف برای هر فاخته j ، مراحل زیر انجام می‌شود:

برای هر فاخته j ، بر اساس بردار موقعیت P_j و مجموعه مصدقه‌های U_i ، توالی اجماع محاسبه می‌گردد. سپس عمل ساخت توالی اجماع برای هریک فاخته‌های لیست *Goal* نیز انجام می‌شود. میزان شباهت توالی اجماع برای هریک فاخته را با محاسبه می‌گردد. از لیست *Goal* فاخته d که توالی اجماع آن شباهت بیشتری با توالی اجماع فاخته j دارد، ان‌تاخته می‌شود و فاخته j ، P_j ، با میزانی انحراف به سمت فاخته d ، P_d ، حرکت می‌کند تا مجموعه موقعیت جدید P_j^*

پیچیدگی زمانی محاسبه هر فاخته برابر $O(\ell m^2 \ell)$ است، زیرا برای جستجوی هر مجموعه مصدقه از موتیف $O(n t \ell)$ زمان نیاز است و در ضمن هر فاخته t بار بر اساس الگوریتم EM بهروزرسانی می‌شود.

۲-۳- تخم‌گذاری هر فاخته

در گام پنجم الگوریتم، هر فاخته ز در سه مرحله تخم‌گذاری می‌کند که در ادامه هر یک از این مراحل به صورت کامل شرح داده می‌شود.

در مرحله A، تعداد تخم‌های هر فاخته j ، Egg، در محدوده $1, \dots, \log_2 t$ به صورت تصادفی تعریف می‌شود. این شرط باعث می‌شود که احتمال قرار گرفتن یک تخم از چند فاخته را در یک لانه کاهش دهد. در مرحله B، به ازای هر تخم از فاخته j ، شعاع تخم‌گذاری، E_k ، در محدوده $t, \dots, 1$ به صورت تصادفی مشخص می‌گردد به طوری که $k = 1 \dots Egg$ است. این محدودیت باعث می‌شود که احتمال قرار گرفتن چندین تخم از یک فاخته را در یک لانه کاهش دهد.

در مرحله C، برای هر تخم k از فاخته j ، P_j^k معادل P_j تعریف می‌گردد، سپس E_k عنصر از P_j^k تصادفی انتخاب می‌شوند و هر یک از آن‌ها به صورت زیر تغییر می‌کند:

فرض کنید p_{jj}^k یک عنصر انتخاب شده از P_j^k باشد. در این شرایط، با احتمال $5/0$ از سمت چپ، $p_{jj}^k \dots 1$ ، یا راست، $n_i \dots p_{jj}^k$ ، توالی s_i یک موقعیت به تصادف مشخص می‌گردد و با p_{jj}^k جایگزین می‌شود. در پایان، P_j^k حاصل بر اساس روش EM بهروز می‌شود. در مرحله D، برازش فاخته تولیدشده که معادل هیچیک از فاخته‌های لیست *Cuckoos* نیست بر اساس رابطه (۲) محاسبه و بهمراه فاخته‌اش به لیست اضافه می‌شود.

۴- ارزیابی الگوریتم SA-COAMF

۱-۴- معیار ارزیابی الگوریتم‌های پیدا کردن موتیف

برای مطالعه صحت پیش‌بینی نتایج الگوریتم‌های پیدا کردن موتیف از معیار ضربی کارایی نوکلئوتید (PC^{۱۲}) که بر اساس رابطه زیر تعریف می‌شود، استفاده می‌گردد:

$$PC = \frac{TP}{TP + FP + FN} \quad (10)$$

مقادیر^{۱۳}, FN^{۱۴} و TP^{۱۵} و FP^{۱۶} بر اساس موقعیت‌های روی مجموعه توالی S که در شرایط آزمایشگاهی ثابت شده موتیف هستند و موقعیت‌هایی که توسط الگوریتم پیش‌گویی می‌شوند، متناظر با جدول ۴ قابل تعریف است.

جدول ۴: تعریف FP, TP, FN و

FN:	تعداد موقعیت‌هایی که موتیف هستند و پیش‌گویی نشده است.
TP:	تعداد موقعیت‌هایی که صحیح پیش‌گویی می‌شوند.
FP:	تعداد موقعیت‌هایی که به صورت ناصحیح، به عنوان موتیف پیش‌گویی می‌شوند.

مقدار ضربی کارایی همیشه بین صفر و یک است و هرچه مقدار این معیار بیشتر باشد نشان‌دهنده صحت بیشتر پیش‌بینی نوکلئوتیدهای پیش‌گویی شده به عنوان مصدقه‌های موتیف است.

۴-۲- پایگاه داده

در این مقاله برای بررسی و ارزیابی صحت و دقیقت عملکرد الگوریتم SA-COAMF، عامل الگوبرداری از پایگاه داده SCPD استخراج شده است. پایگاه داده SCPD توسط ژو^{۱۷} و ژانگ^{۱۸} در سال ۱۹۹۹ ارائه شد [۲۹]. این پایگاه داده شامل عوامل الگوبرداری و جایگاه پیوند خوردن آنها در مخمر است. جزئیات مربوط به هر یک از عوامل الگوبرداری انتخاب شده در جدول ۵ مشاهده می‌شود. ستون اول این جدول نام عامل الگوبرداری استخراج شده از پایگاه داده SCPD را نشان می‌دهد. برای هر یک از عوامل الگوبرداری در ستون دوم یک توالی اجماع از مصدقه‌های موتیف آزمایشگاهی نشان داده شده است. ستون سوم از این جدول تعداد توالی‌های هر عامل الگوبرداری را نشان می‌دهد به طوری که هر توالی نشان‌دهنده منطقه‌ای از ۸۰۰ تا ۵۰۰+ از ناحیه بالادست ژن‌های همبیان است. ستون چهارم طول هر توالی را مشخص می‌کند.

۵- تحلیل و نتایج آزمایش‌ها

در این بخش ابتدا الگوریتم SA-COAMF را با الگوریتم فاخته استاندارد (COA) بر روی عوامل الگوبرداری جدول ۵ مقایسه می‌کنیم. در ادامه، نتایج حاصل از شبیه‌سازی و اجرای الگوریتم SA-COAMF بر روی MEME عامل الگوبرداری معرفی شده در جدول ۵ با الگوریتم‌های GA-DPAF [۲۴]، PSO+ [۲۵] و GA-DPAF [۲۱] مقایسه و مورد ارزیابی قرار می‌گیرد. سپس به تحلیل زمان پردازش و پیچیدگی زمانی الگوریتم پیشنهادی با دو الگوریتم تکاملی GA-DPAF و PSO+ پرداخته

تولید شود. جابه‌جاوی هر p_{ji} به سمت p_{di} که $t \leq i \leq t+1$ ، بر اساس رابطه زیر انجام می‌شود:

$$P_{ji}^* = \begin{cases} \text{int}(p_{ji} - (r(1) \times (p_{ji} - p_{di}))), & p_{di} < p_{ji} \\ \text{int}(p_{di} - (r(1) \times (p_{di} - p_{ji}))), & \text{else} \end{cases} \quad (6)$$

به طوری که $r(1)$ یک عدد تصادفی بین صفر تا یک است.

بعد از انجام عمل مهاجرت، با استفاده از تکنیک سرمایش تدریجی^{*} با P_j در لیست Cuckoos جایگزین می‌شود. اگر مقدار P_j بیشتر از P_i باشد، بردار موقعیت^{*} P_j جایگزین بردار P_i می‌شود و به عنوان فاخته نسل بعد در جمعیت قرار می‌گیرد. در غیر این صورت، روش SA با احتمال کمتر از $\text{fit}(P)^{1/2}$ بردار^{*} P_j را جایگزین P_i در جمعیت نسل بعد می‌نماید که $\text{fit}(P)$ میزان برازش بردار موقعیت P از یک فاخته را نشان می‌دهد.

مقدار کاهش تدریجی دما در هر نسل باعث می‌شود که الگوریتم در نسل‌های بالاتر از پذیرش^{*} P_j با مقدار تابع برازش پایین اجتناب نماید و الگوریتم به سمت جواب بهینه سراسری همگرا شود. پیچیدگی زمانی مهاجرت هر فاخته معادل $O(G\ell t)$ است.

۴-۳- اعلام جواب نهایی

پس از اجرای maxIter نسل، الگوریتم خاتمه یافته و لیست **Goal** به عنوان جواب‌های نهایی انتخاب می‌شوند. بر اساس بردارهای موقعیت هر یک از فاخته‌های لیست **Goal** یک پروفایل احتمالاتی مانند W تولید می‌شود. به هر زیرتوالی^{*} s_j به طول ℓ از توالی S، بر اساس رابطه زیر امتیاز داده می‌شود:

$$\text{NScore}(s_j, W) = \frac{\text{Score}(s_j, W) - \text{Min}}{\text{Max} - \text{Min}} \quad (7)$$

مقادیر Min و Max به ترتیب بر اساس رابطه‌های زیر تعریف می‌شوند:

$$\text{Min} = \sum_{j=1}^J \min_{\alpha \in \Sigma} \log \frac{W[\alpha, j]}{b[\alpha]}, \quad (8)$$

$$\text{Max} = \sum_{j=1}^J \max_{\alpha \in \Sigma} \log \frac{W[\alpha, j]}{b[\alpha]}. \quad (9)$$

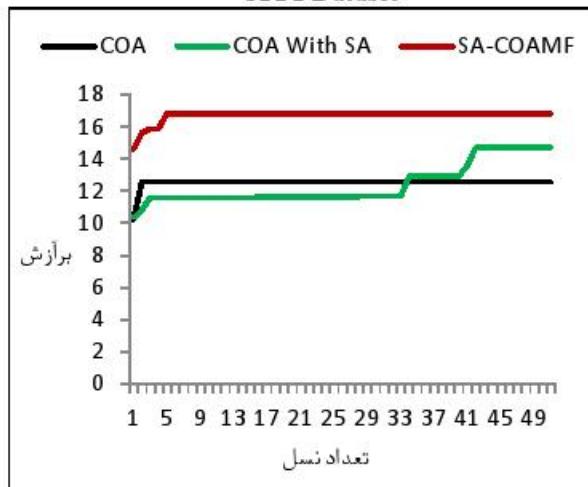
زیرتوالی‌هایی به عنوان مصدقه‌های معتبر انتخاب می‌شوند که مقدار آنها با توجه به رابطه (7) از یک حد استانداری بیشتر باشد. از نظر زیست‌شناسی، موتیف‌های قوی موتیف‌هایی هستند که مصدقه‌های آنها در موقعیت‌های بیشتری باهم تطابق دارند و بر عکس موتیف‌های ضعیف در موقعیت‌های کمتری باهم تطابق دارند. حد استانداره برای موتیف‌های قوی ۹۰٪ و برای موتیف‌های ضعیف ۸۰٪ در نظر گرفته می‌شود [۲۵].

نتایج حاصل از اجرای هر دو الگوریتم COA و SA-COAMF بر روی تمامی عوامل الگوبرداری جدول ۵ در نسل ۵۰ نسل، در شکل ۲ قابل مشاهده است. همه الگوریتم‌ها در ۵۰ نسل اجرا شده‌اند.

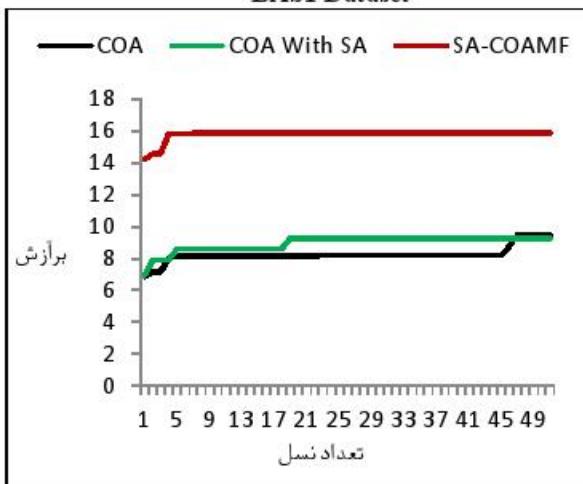
با بررسی شکل ۲ می‌توان نتیجه گرفت که الگوریتم COA حتی بعد از ۵۰ نسل اجرا به جواب بهینه و یا نزدیک به بهینه نخواهد رسید و در بهینه محلی گیر می‌افتد. درحالی‌که ترکیب روش سرمایش تدریجی با الگوریتم فاخته استاندارد (COA With SA) کمک شایانی به الگوریتم می‌کند که از بهینه‌های محلی خارج شود. در روش سرمایش تدریجی دمای اولیه $T = 100$ و ضریب کاهش دما در هر نسل $\alpha = 0.9$ درنظر گرفته می‌شود.

همان‌طور که در شکل ۲ دیده می‌شود، با افزودن تابع EM به الگوریتم (SA-COAMF) COA With SA سرعت همگرایی الگوریتم به جواب بهینه اصلی رشد چشمگیری دارد. نتایج حاصل از اجرای الگوریتم SA-COAMF بر روی تمامی عوامل الگوبرداری جدول ۵ در شکل ۲ قابل مشاهده است.

CPFI Dataset



BAS1 Dataset



شکل ۲: نتایج اجرای سه الگوریتم COA، COA With SA و SA-COAMF بر روی عوامل الگوبرداری جدول ۵

می‌شود و برقراری توازن بین زمان اجرا و کیفیت موتیف‌های کشف شده توسط الگوریتم SA-COAMF مورد بحث و بررسی قرار می‌گیرد.

تمام نتایج حاصل که در ادامه شرح داده می‌شود بر روی سیستمی با ۱۶ گیگابایت حافظه اصلی و پردازندۀ ای با سرعت ۲/۴ گیگاهرتز به دست آمده است.

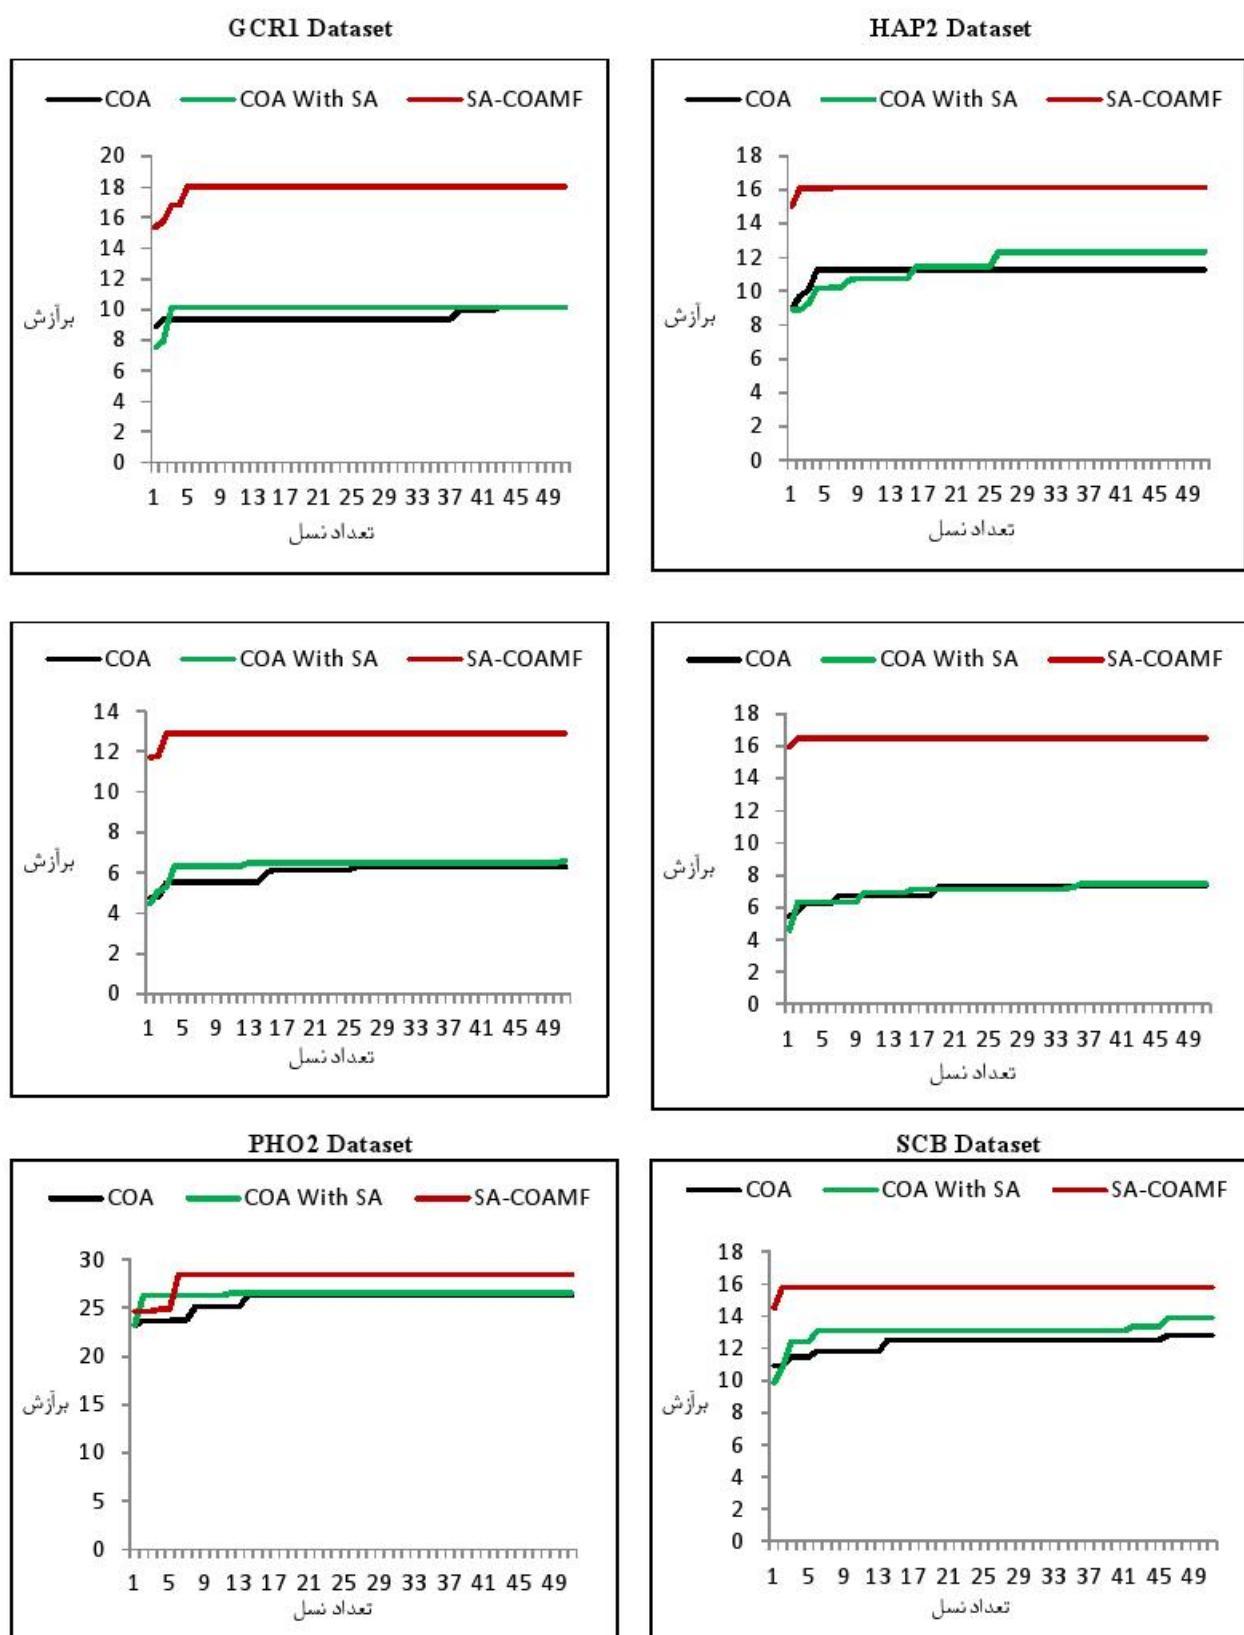
جدول ۵: مشخصات عوامل الگوبرداری پایگاه داده SCPD

عامل الگوبرداری	اجماع	تعداد توالی‌ها	طول
BAS1	-	۶	۸۵۰
CPF1	TCACGTG	۳	۸۵۰
GCR1	CWTCC	۶	۸۵۰
HAP2	-	۴	۸۵۰
MCB	WCGCGW	۶	۸۵۰
PDR3	TCCGYGGA	۷	۸۵۰
PHO2	-	۳	۸۵۰
SCB	CNCGAAA	۳	۸۵۰
SFF	GTS AACAA	۳	۸۵۰

۱-۵- تحلیل نتایج COA در مقابل SA-COAMF

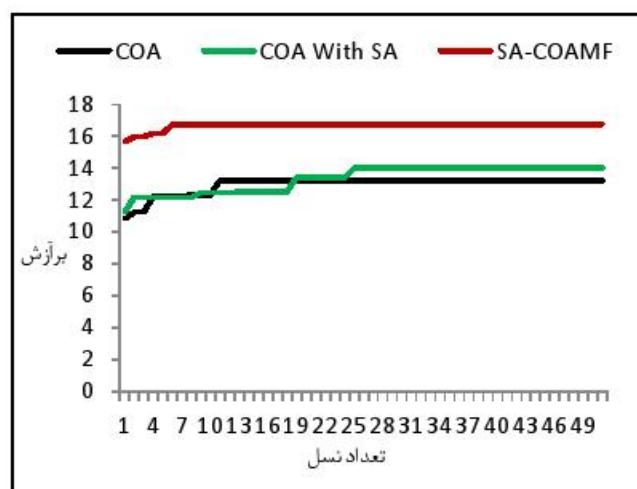
در این بخش SA-COAMF با الگوریتم فاخته استاندارد، COA مقایسه می‌شود. در الگوریتم فاخته استاندارد یک فاخته سراسری وجود دارد که تمام فاخته‌ها به سمت آن حرکت می‌کنند. مسئله کشف موتیف با این ویژگی الگوریتم هم راست نیست، زیرا در توالی‌های زیستی ممکن است چندین موتیف وجود داشته باشد که هدف الگوریتم یافتن همه آن سیگنال‌ها است. درنهایت زیست‌شناس تشخیص می‌دهد که موتیف (سیگنال) موردنظر کدام است. بهمین دلیل، این الگوریتم به‌گونه‌ای توسعه یافته است که فاخته‌ها قادر هستند از بین چندین فاخته سراسری، فاخته موردنظر را برای مهاجرت به سمت آن انتخاب نمایند. بنابراین G فاخته از بهترین فاخته‌ها به عنوان فاخته‌های سراسری انتخاب می‌گردد.

با توجه به تعریف زیستی از پرومотор حدوداً ممکن است بین ۵ تا ۱۰ سیگنال در این نوع از توالی‌ها باشد. ما در الگوریتم پیشنهادی خود، در هر نسل از اجرای الگوریتم، ۱۰ فاخته با بهترین برآذش، $G=10$ ، را به عنوان فاخته هدف انتخاب می‌کنیم. همچنین با توجه به اینکه طول هر توالی ۸۵۰ و طول موتیف‌ها بین ۱۰ تا ۱۵ است جمعیت اولیه از فاخته‌ها، به صورت میانگین به تعداد ۶۰ فاخته تعریف می‌شود. در ادامه SA-COAMF بر روی عوامل الگوبرداری جدول ۵ اجرا می‌شود. سپس الگوریتم COA را که بدون تکنیک‌های سرمایش تدریجی (SA)، بیشینه‌سازی زمان انتظار (EM) و استفاده از یک فاخته هدف برای مهاجرت است نیز بر روی عوامل الگوبرداری جدول ۵ اجرا می‌گردد. در هر نسل از اجرای این دو الگوریتم، برآذش بهترین موتیفی که الگوریتم توانسته است پیدا کند، به عنوان خروجی اعلام می‌شود.



ادامه شکل ۲: نتایج اجرای سه الگوریتم SA-COAMF و COA With SA و COA بر روی عوامل الگوبرداری جدول ۵.

SFF Dataset



ادامه شکل ۲: نتایج اجرای سه الگوریتم SA-COAMF، COA With SA، COA بر روی عوامل الگوپردازی جدول ۵

در حالی که الگوریتم‌های GA-DPAF و PSO+ و GA-DPAF به سمت یک سیگنال (موتیف) حرکت می‌کنند و در مواردی ممکن است بهترین سیگنالی که پیدا می‌کنند موتیف موردنظر ریست‌شناس نباشد. همچنین در الگوریتم پیشنهادی با استفاده از روش EM در هر لحظه هر فاخته به بهترین خودش (بهینه محلی) نزدیک می‌شود، در صورتی که دو الگوریتم GA-PSO+ و DPAF در شکل ۳، میانگین نتایج مقادیر موجود در جدول ۶ بر روی پایگاه SCPD داده شده است. در این شکل می‌توان به صحت و دقت قابل مشاهده SA-COAMF نسبت به سه الگوریتم GA-DPAF، PSO+، MEME و PSO+ و DPAF بروی پایگاه داده اضافه شده است.

جدول ۶: نتایج الگوریتم‌های SA-COAMF، GA-DPAF، PSO+، MEME و PSO+ بر روی عوامل الگوپردازی پایگاه داده SCPD

عوامل الگوپردازی	MEME	PSO+	GA-DPAF	SA-COAMF
BAS1	.130	.111	.108	.117
CPF1	.149	.127	.174	.174
GCR1	.120	.114	.122	.126
HAP2	.100	.105	.114	.109
MCB	.115	.124	.199	.198
PDR3	.143	.175	.173	.180
PHO2	.100	.104	.100	.115
SCB	.181	.101	.152	.138
SSF	.103	.101	.125	.126

۲-۵ بررسی صحت و دقت SA-COAMF

همان طور که در بخش قبل گفته شد، SA-COAMF نسبت به COA With SA و COA دقیق‌تر عمل کرده و توانایی قابل ملاحظه‌ای در پیدا کردن جواب بهینه از خود نشان می‌دهد. از این‌رو در این بخش، SA-COAMF با سه الگوریتم PSO+ و MEME با توجه به فرمول ضریب کارایی بر روی عوامل الگوپردازی جدول ۵ مقایسه می‌شود و نتایج در جدول ۶ قابل مشاهده است (مقادیر الگوریتم MEME از [۳۰]، GA-DPAF از [۲۵] و PSO+ از [۲۱] بر اساس پیاده‌سازی [۲۱] استخراج شده است).

الگوریتم‌ها بر روی مجموعه داده‌های ریستی جدول ۵ تست شده‌اند. الگوریتم پیشنهادی در ۱۰ نسل اجرا شده است زیرا همان‌طور که در شکل ۲ مشاهده می‌شود، الگوریتم پس از ۱۰ نسل تقریباً به شرایط همگرایی می‌رسد.

با توجه به اینکه نتایج الگوریتم MEME از [۳۰] و GA-DPAF از [۲۵] استخراج شده است و در این مقاله‌ها ذکر شده که هر الگوریتم ۳ بار روی هر داده اجرا شده است و سپس در هر اجراء از بین ۱۰ فرد برتر، فردی که ضریب کارایی بالاتری دارد (PC) به عنوان موتیف اصلی برگزیده می‌شود، بنابراین الگوریتم SA-COAMF با همین شرایط اجرا می‌گردد و نتایج در جدول ۶ قابل مشاهده است.

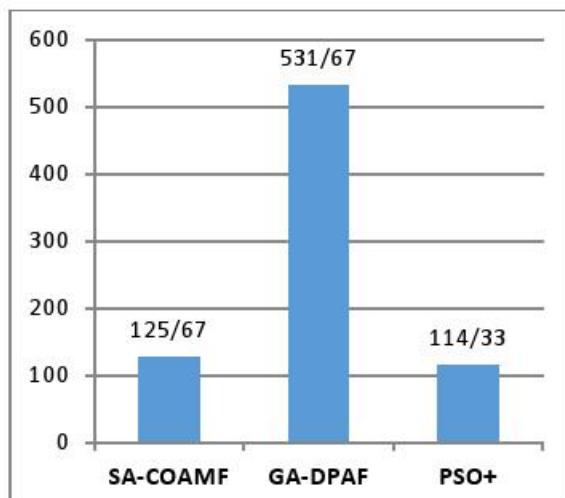
با بررسی نتایج اعلام شده در جدول ۶، می‌توان به برتری الگوریتم پیشنهادی نسبت به سه الگوریتم دیگر پرید، زیرا SA-COAMF بهتر و دقیق‌تر از دیگر الگوریتم‌ها در کشف موتیف عمل می‌کند. همان‌طور که پیش‌تر اشاره شد، دلیل برتری SA-COAMF نسبت به الگوریتم‌های MEME و PSO+، GA-DPAF فاخته جهت افزایش سرعت همگرایی، روش بیشینه‌سازی زمان انتظار در پیدا کردن بهینه‌های محلی برای هر فاخته، روش سرمایش تدریجی در اجتناب کردن از گیرافتدان در بهینه‌های محلی است. یکی دیگر از ویژگی‌های باز این الگوریتم در نظر گرفتن G تا فاخته هدف است

جدول ۸: زمان پردازش سه الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+** بر حسب میانگین ثانیه

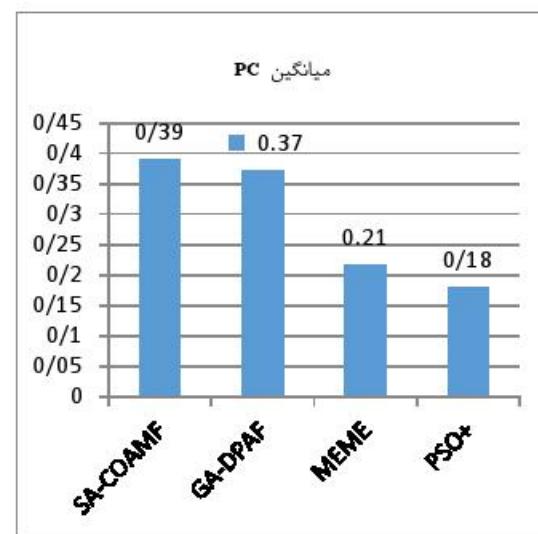
عوامل الگوبرداری	PSO+	GA-DPAF	SA-COAMF
BAS1	۱۷۵	۱۴۷	۲۰۳
CPF1	۵۲	۲۳۰	۶۶
GCR1	۱۳۵	۶۰۹	۱۶۹
HAP2	۹۰	۸۳۲	۱۳۵
MCB	۱۷۵	۹۹۴	۱۶۴
PDR3	۱۹۱	۲۴۷	۱۷۶
PHO2	۶۴	۱۷۶	۳۵
SCB	۸۸	۶۵	۸۲
SSF	۵۹	۶۲	۱۰۱

با توجه به نتایج اعلام شده در جدول ۶، الگوریتم **SA-COAMF** در بیشتر موارد دارای دقت بالاتری نسبت به الگوریتم **GA-DPAF** است. در حالی که با توجه به نتایج جدول ۸ در تمام موارد زمان پردازش الگوریتم پیشنهادی از الگوریتم **GA-DPAF** کمتر است و دارای سرعت بالاتری نسبت به **GA-DPAF** است. ولی با توجه به جدول ۸، الگوریتم **PSO+** در برخی موارد سرعت پردازش پایین تری نسبت به الگوریتم **SA-COAMF** دارد که در مقابل با توجه به جدول ۶ در تمامی موارد دارای دقت پایین تری است. بنابراین، الگوریتم پیشنهادی با کاهش زمان نسبت به **GA-DPAF** و میزان افزایش نسبت به **PSO+** قادر به کشف جواب های بهینه تری است.

در شکل ۴، میانگین زمان اجرای هر الگوریتم بر روی تمامی عوامل الگوبرداری قابل مشاهده است. با مقایسه شکل های ۳ و ۴ می توان پی برد که **SA-COAMF** در زمانی معقول نسبت به دو الگوریتم **PSO+** و **GA-DPAF** به جواب های بهینه دسترسی پیدا می کند.



شکل ۴: میانگین زمان پردازش سه الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+** بر روی عوامل الگوبرداری پایگاه داده **SCPD**



شکل ۳: میانگین نتایج چهار الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+** و **MEME** بر روی عوامل الگوبرداری پایگاه داده **SCPD**

۳-۵- تحلیل زمان پردازش الگوریتم پیشنهادی

به دلیل اینکه الگوریتم پیشنهادی جزء دسته الگوریتم های تکاملی به حساب می آید، سرعت پردازش و پیچیدگی زمانی **SA-COAMF** با دو الگوریتم تکاملی **PSO+** و **GA-DPAF** که جزء الگوریتم های تکاملی هستند، در شرایط یکسان مورد مقایسه و بررسی قرار می گیرد. الگوریتم ها را به زبان برنامه نویسی پل پیاده سازی کردیم.

حداکثر تعداد افراد برای هر سه الگوریتم بر اساس $\sum_{i=1}^t n_i$

تعاریف می شود به طوری که t طول موتیف در هر عامل الگوبرداری از جدول ۵ است. بیشترین تعداد نسل تعریف شده در این شبیه سازی برای هر سه الگوریتم ۱۰ در نظر گرفته شده است که اگر در ۱۰ نسل جواب بهینه عوض نگردد الگوریتم متوقف می شود، در غیر این صورت مادامی که الگوریتم می تواند جواب بهینه ای پیدا کند به کار خود ادامه می دهد.

پیچیدگی زمانی سه الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+** در جدول ۷ بیان شده است.

جدول ۷: پیچیدگی زمانی سه الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+**

	PSO+	GA-DPAF	SA-COAMF
پیچیدگی زمانی	$O(nt^2\ell)$	$O(n^2t^2d\ell)$	$O(nt^2\ell \log_2 \ell)$

* در الگوریتم **GA-DPAF** پارامتر d تعداد گپ را مشخص می کند.

جدول ۸: زمان پردازش سه الگوریتم **GA-DPAF**, **SA-COAMF** و **PSO+** را بر روی تمامی عوامل الگوبرداری جدول ۵ نشان می دهد.

۶- نتیجه‌گیری

- یک مجموعه از زیرتوالی‌های حفاظت شده در توالی‌های زیستی را موتیف می‌گویند به طوری که این زیرتوالی‌ها دارای ساختار و عملکردهای مشابهی هستند. غالباً به دلیل نقش مهم موتیف‌ها در تعیین ساختار و عملکرد یک مولکول، مسئله کشف موتیف یکی از مسئله‌های مهم و با اهمیت در زمینه زیست‌شناسی مولکولی است. در مسئله کشف موتیف هیچ اطلاعاتی درباره موتیف و مصادق‌های آن وجود ندارد و تنها تعدادی توالی زیستی داده می‌شود و هدف یافتن موتیف ناشناخته با رخدادهای تقریبی در موقعیت‌های ناشناخته است. در این مقاله الگوریتم بهینه‌سازی فاخته به عنوان روشی برای حل مسئله کشف موتیف پیشنهاد شده است که این الگوریتم از سبک زندگی یک نوع پرندۀ بنام فاخته الهام گرفته است. یکی از مزایای الگوریتم بهینه‌سازی فاخته سرعت بالای آن در همگرایی به جواب بهینه است. همچنین در روش پیشنهادی از تکنیک‌های مختلفی جهت گریز از بهینه‌های محلی و رسیدن به جواب بهینه سراسری استفاده شده است. برای کارهای آتی می‌توان این الگوریتم را برای کشف موتیف‌های گپدار توسعه داد.

مراجع

- [1] B. Brejová, C. DiMarco, T. Vinar, S. R. Hidalgo, G. Holguin, and C. Patten, *Finding patterns in biological sequences*, Unpublished project report for CS798G, University of Waterloo, Fall, 2000.
- [2] <http://www.hindawi.com/journals/ijad/2011/154325/>. Available: <http://www.hindawi.com/journals/ijad/2011/154325/>
- [3] L. Shao, Y. Chen and A. Abraham, "Motif discovery using evolutionary algorithms," in *Soft Computing and Pattern Recognition, (SOCPAR'09)*, pp. 420-425, 2009.
- [4] C. Reyes-Rico, "Finding DNA motifs using genetic algorithms," in *Fifth Mexican International Conference on Artificial Intelligence*, pp. 331-339, 2006.
- [5] C. E. Lawrence, S. F. Altschul, M. S. Boguski, J. S. Liu, A. F. Neuwald and J. C. Wootton, "Detecting subtle sequence signals: a Gibbs sampling strategy for multiple alignment," *Science*, vol. 262, no. 5131, pp. 208-214, 1993.
- [6] J. van Helden, B. André and J. Collado-Vides, "Extracting regulatory sites from the upstream region of yeast genes by computational analysis of oligonucleotide frequencies," *Journal of molecular biology*, vol. 281, no. 4, pp. 827-842, 1998.
- [7] M. Tompa, "An exact method for finding short motifs in sequences, with application to the ribosome binding site problem," *ISMB*, pp. 262-271, 1999.
- [8] T. F. Smith and M. S. Waterman, "Identification of common molecular subsequences," *Journal of molecular biology*, vol. 147, no. 1, pp. 195-197, 1981.

زیرنویس‌ها

^۱ Transcription Factor^۲ Consensus Sequence^۳ Position Frequency Matrix^۴ Cuckoo Optimization Algorithm^۵ Simulated Annealing^۶ Expected Maximization^۷ Simulated Annealing–Cuckoo Optimization^۸ Motif Finding^۹ Information Content^{۱۰} Egg Laying Radius^{۱۱} Strong Motifs^{۱۲} Weak Motifs^{۱۳} Performance Coefficient^{۱۴} False negative^{۱۵} True Positive^{۱۶} False Positive^{۱۷} Zhu^{۱۸} Zhung

algorithm for finding consensus sequences," *Bioinformatics*, vol. 18, no. 11, pp. 1494-1499, 2002.

[24] T. L. Bailey and C. Elkan, "The value of prior knowledge in discovering motifs with MEME," *ISMB*, pp. 21-29, 1995.

[25] F. Zare-Mirakabad, H. Ahramian, M. Sadeghi, S. Hashemifar, A. Nowzari-Dalini and B. Golaei, "Genetic algorithm for dyad pattern finding in DNA sequences," *Genes & Genetic Systems*, vol. 84, no. 1, pp. 81-93, 2009.

[26] W. Liu ,H. Chen and L. Chen, "An ant colony optimization based algorithm for identifying gene regulatory elements," *Computers in Biology and Medicine*, vol. 43, no. 7, pp. 922-932, 2013.

[27] R. Rajabioun, "Cuckoo optimization algorithm," *Applied Soft Computing*, vol. 11, no. 8, pp. 5508-5518, 2011.

[28] M. Sarkar, B. Yegnanarayana and D. Khemani, "A clustering algorithm using an evolutionary programming-based approach," *Pattern Recognition Letters*, vol. 18, no. 10, pp. 975-986, 1997.

[29] J. Zhu and M. Q. Zhang, "SCPD: a promoter database of the yeast *Saccharomyces cerevisiae*," *Bioinformatics*, vol. 15, no. 7-8, pp. 607-611, 1999.

[30] S. Sinha and M. Tompa, "Performance comparison of algorithms for finding transcription factor binding sites," in *Bioinformatics and Bioengineering*, pp. 214-220, 2003.