

یک چارچوب مبتنی بر آتاماتای یادگیر توزیع شده توسعه یافته برای حل مسئله یافتن زیرگراف بهینه تصادفی

محمد رضا ملاخیلی مبیدی و محمدرضا مبیدی

روش تاکنون توانسته مسایل مختلف مرتبط با گرافهای تصادفی نظریه یافتن کوتاهترین مسیر تصادفی [۷] و [۶] یا حل مسئله فروشنده دوره‌گرد و یافتن مجموعه مستقل ماکریمال [۸] و [۹] را حل کند. علاوه بر آن در موارد دیگری مثل دسته‌بندی اسناد وب [۱۰]، محاسبه رتبه استاد [۱۱]، پیش‌بینی حرکت کاربران در وب [۱۲] و مدل‌سازی کاربران در محیط‌های فرآپوندی نظری وب [۱۳] و کاوش در نحوه استفاده از وب [۱۴] نیز مورد استفاده قرار گرفته است. اما عملاً نحوه فعالیت آتاماتاهای در DLA، سیستم eDLA چند‌عامله توزیع شده مبتنی بر آتاماتای یادگیر را با محدودیت‌هایی مواجه کرده است. در این مقاله به معنی eDLA که توسعه‌ای بر نحوه فعال‌شدن آتاماتاهای در DLA است، پرداخته‌ایم.

در بخش ۲ به بررسی پیش‌نیازهای لازم برای ادامه مقاله پرداخته‌ایم و در بخش ۳ را بررسی کرده و سپس الگوریتم پیشنهادی مبتنی بر eDLA برای حل مسئله یافتن زیرگراف بهینه را ارائه کرده‌ایم. بخش ۴ به بررسی ویژگی‌های ریاضی الگوریتم پیشنهادی اختصاص یافته و در بخش ۵ نتیجه‌گیری و پیشنهادهایی برای کارهای بعدی ارائه شده است.

۲- مبانی ریاضی و مفاهیم مقدماتی ۱-۲ برخی تعاریف ریاضی

برای بررسی عملکرد الگوریتم یافتن زیرگراف بهینه پاره‌ای از مفاهیم را در این قسمت بازتعریف می‌کنیم. برخی از تعاریف برای کارگیری در این مقاله ارائه شده و برخی دیگر تعاریف عمومی مفاهیم هستند.

تعریف ۱: گراف با سه‌تایی $(G, E(G), I_G)$ تعریف می‌شود که در آن $V(G) \neq \emptyset$ ، $V(G) \cap E(G) = \emptyset$ و I_G یک نگاشت وقوع است که به هر عضو $E(G)$ یک زوج نامرتب (بیکسان یا متمایز) از $V(G)$ نظیر می‌کند. عناصر $V(G)$ را رئوس گراف G و عناصر $E(G)$ را یال‌های G می‌نامند. اگر برای یال e از G داشته باشیم $e = I_G(e) = uv$ می‌نویسیم و u و v را پایان‌های e می‌نامیم. در ادامه این مقاله وجود I_G تصریح نمی‌شود.

تعریف ۲: گراف H را زیرگراف G می‌نامیم اگر $V(H) \subseteq V(G)$ و $E(H) \subseteq E(G)$ و I_H برابر تحدید I_G به $E(H)$ باشد.

تعریف ۳: فرض کنید $G = (V, E)$ یک گراف باشد. اگر به هر یال $e \in E$ یک عدد نامنفی $w(e)$ که وزن یال e نامیده می‌شود نظیر کنیم، گراف حاصل را گراف با یال‌های وزن‌دار گوییم. اگر H یک زیرگراف از G باشد، $w(H)$ وزن زیرگراف H و برابر با مجموع وزن یال‌های H است.

تعریف ۴: یک گراف با یال‌های دارای وزن تصادفی، توسط سه‌تایی $G_R = (V, E, W)$ تعریف می‌شود که $V = \{v_1, v_2, \dots, v_n\}$ مجموعه $E = \{e_1, e_2, \dots, e_m\} \subset V \times V$ و $W = \{w_1, w_2, \dots, w_n\}$ وزن‌های مناسب به یال‌ها را نشان می‌دهد به گونه‌ای که متغیر تصادفی w_i نشان‌دهنده وزن یال $e_i \in E$ است.

چکیده: در این مقاله، یک ساختار جدید شبکه‌ای از آتاماتاهای یادگیر موسوم به آتاماتای یادگیر توزیع شده توسعه یافته معرفی شده و سپس الگوریتمی مبتنی بر این ساختار شبکه‌ای برای حل مسئله زیرگراف بهینه در گراف‌های تصادفی با یال‌های وزن‌دار از طریق نمونه‌گیری ارائه می‌شود. نشان داده شده که ساختار شبکه‌ای جدید پیشنهادی قادر به حل مسایل بهینه‌سازی روی گراف‌های تصادفی از طریق نمونه‌گیری با تعداد نمونه کمتر نسبت به روش نمونه‌گیری استاندارد است. علاوه بر این، اثباتی برای همگرازی آن به جواب بهینه ارائه شده و نشان داده می‌شود که ساختار شبکه‌ای پیشنهادی همواره با احتمال ۱ به جواب بهینه همگرا می‌گردد.

کلید واژه: آتاماتای یادگیر، آتاماتای یادگیر توزیع شده توسعه یافته، شبکه آتاماتاهای یادگیر، زیرگراف، گراف تصادفی، نمونه‌گیری.

۱- مقدمه

مدل‌های آتاماتایی برای سیستم‌های یادگیر در دهه ۶۰ میلادی معرفی شدند و با نام آتاماتای یادگیر در [۱] معرفی شده و به محبوبت رسیدند. از آن زمان تاکنون توسعه‌های مختلفی چه در زمینه تئوری و چه در حوزه کاربرد آتاماتای یادگیر رخ داده است. در [۲] و [۳] نویسنده‌گان به تفصیل به بررسی این تحولات پرداخته‌اند.

آتاماتایی یادگیر، اساساً عاملی ساده برای انجام کارهای ساده است [۳]. قابلیت کامل یک آتاماتای یادگیر، در یک شبکه از آتاماتاهای و در تعامل آنها با یکدیگر ظهرور بیدا می‌کند. یکی از ساختارهای مشکل از آتاماتاهای یادگیر متصل به هم، آتاماتای یادگیر توزیع شده است که برای نخستین بار در [۴] معرفی و به کار گرفته شد.

DLA به عنوان شبکه‌ای متصل از آتاماتاهای یادگیر همکار که برای حل یک مسئله خاص با یکدیگر همکاری دارند، بارها و بارها در حل مسایل مختلف، خصوصاً مسایل مربوط به گراف‌های تصادفی با یال‌های وزن‌دار و یا رئوس وزن‌دار مورد استفاده قرار گرفته است [۴] تا [۶].

یکی از اشکالات مشهود DLA به عنوان یک سیستم مبتنی در توزیع شده، وابسته کردن انتخاب عامل فعلی بعدی (که می‌بایستی در محیط اقدامی انجام دهد) به اقدام انجام‌شده توسط آتاماتای فعلی است. به بیان ساده‌تر در DLA علاوه بر این که در هر زمان تنها یک عامل (آتاماتای یادگیر) فعلی بوده و قادر به انجام کشی در محیط است، انتخاب عامل فعلی بعدی به نوع کنش عامل فعلی وابسته است. این

این مقاله در تاریخ ۱۲ خرداد ماه ۱۳۹۲ دریافت و در تاریخ ۱۷ آذر ماه ۱۳۹۲ بازنگری شد.

محمد رضا ملاخیلی مبیدی، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی، واحد میبدی، میبد، (email: m.meybodi@srbiau.ac.ir).

محمد رضا مبیدی، آزمایشگاه محاسبات نرم، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی امیرکبیر، تهران، (email: mmeybodi@aut.ac.ir).

اقداماتی α عمل (k) را انتخاب کرده باشد. همچنین فرض کنید بردار احتمال انتخاب اقداماتی آتاماتا را با $p(k)$ نمایش داده‌ایم. اگر a و b پارامترهایی باشند که به ترتیب میزان افزایش یا کاهش احتمالات اقدامات را مشخص می‌کنند و r تعداد اقداماتی قابل انجام توسط آتاماتاتی یادگیر باشد، بردار (k) توسط الگوریتم یادگیری خطی ارائه شده در روابط زیر به روز رسانی می‌شود. مقدار a را پارامتر پاداش و b را پارامتر جریمه می‌نامند

$$p_j(k+1) = \begin{cases} ((1-a)p_j(k) + a), & j = i \\ ((1-a)p_j(k)), & \forall j \neq i \end{cases} \quad (2)$$

$$p_j(k+1) = \begin{cases} ((1-b)p_j(k)), & j = i \\ ((1-b)p_j(k) + \frac{b}{r-1}), & \forall j \neq i \end{cases} \quad (3)$$

رابطه (۲) زمانی مورد استفاده قرار می‌گیرد که عمل $\alpha_i(k)$ منجر به دریافت پاداش از محیط شده باشد و (۳) زمانی مورد استفاده قرار می‌گیرد که این عمل به دریافت جریمه از محیط منجر شده باشد. در (۲) و (۳) اگر $a = b$ باشد روابط یادگیری خطی را الگوریتم L_{R-P} ، اگر $a \gg b$ باشد آن را L_{R-I} و اگر $b = 0$ باشد آن را L_{R-EP} می‌نامند.

۱-۳-۲ معیارهای کارایی آتاماتاتی یادگیر

گرچه یادگیری اصولاً رهیافتی کیفی است، اما معیارهایی عددی وجود دارند که فرایند یادگیری را توصیف می‌کنند [۱۷]. برای اندازه‌گیری کارایی آتاماتاتی یادگیر تصادفی، معیارهای معینی تعریف شده‌اند که تأثیر آتاماتاتی را مشخص کرده و امکان مقایسه روش‌های روش‌های مختلف یادگیری را فراهم می‌آورند. یکی از این معیارها متوسط پاداش دریافتی توسط آتاماتاتی است. فرض کنید آتاماتاتی یادگیر دارای r اقدام قابل انجام است. متوسط پاداش دریافتی توسط آتاماتاتی یادگیر در زمان n طبق (۴) تعریف می‌شود

$$M(n) = E[\beta | p(n)] = \sum_{j=1}^r p_j(n) d_j = \sum_{j=1}^r p_j(n) = 1 | \alpha(n) = \alpha_j \rangle p(\alpha(n) = \alpha_j) \quad (4)$$

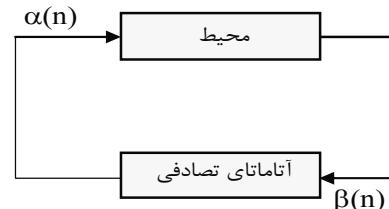
اگر انتخاب اقداماتی آتاماتاتی به شکل کاملاً تصادفی انجام شود (آتاماتاتی شناسی محض) داریم $M(n) = M = \sum_{j=1}^r d_j / r$. زمانی که آتاماتاتی در حال یادگیری است، انتظار آن است که متوسط پاداشی بهتر از این مقدار داشته باشد.

تعریف ۶: آتاماتاتی یادگیر يا Expedient نامیده می‌شود اگر $E[M(n)] > M$. در حقیقت Expedient بودن حداقل انتظار از آتاماتاتی یادگیر است. رفتار بهتری که از آتاماتاتی یادگیر می‌توانیم انتظار داشته باشیم را به صورت زیر تعریف می‌کنیم:

تعریف ۷: آتاماتاتی یادگیر را بهینه يا optimal می‌گوییم اگر $d_m = \max_i \{d_i\}$ که $\lim_{n \rightarrow \infty} E[M(n)] = d_m$ می‌باشد. تعریف معادل دیگری برای بهینگی (۱) (with probability ۱) است. $\lim_{n \rightarrow \infty} p_m(n) = 1$

تعریف ۸: آتاماتاتی یادگیر يا ϵ -optimal نامیده می‌شود اگر $\lim_{n \rightarrow \infty} E[M(n)] > d_m - \epsilon$ به ازای هر مقدار $\epsilon > 0$ با انتخاب مناسب پارامترهای آتاماتاتی یادگیر قابل حصول باشد.

تعریف ۹: یک آتاماتاتی یادگیر يا absolutely-expedient نامیده می‌شود هرگاه $E[M(n+1)] \geq M(n) | P(n) \geq M(n)$ باشد (به ازای هر مقدار $p_i(n) \in (0, 1, 2, \dots, r)$) و تمام مجموعه‌های ممکن $\{d_i\} (i=1, 2, \dots, r)$ به جز حالتی که تمام d_i ها مقادیر برابر داشته باشند) [۱۸].



شکل ۱: آتاماتاتی یادگیر تصادفی.

تعريف ۵: دوگان خنثی یک گراف تصادفی، گرافی است همراه با آن گراف که در آن یال‌ها وزن قطعی ۱ دارند (یا فاقد وزن هستند). به عبارت دیگر اگر $G_R = (V, E, W)$ یک گراف تصادفی باشد، گراف $G'_R = (V, E')$ که در آن $E' = E$ و $V' = V$ است را دوگان خنثی G_R می‌نامند.

۲-۲ کاربرد گراف تصادفی و زیرگراف بهینه تصادفی

گرافهای وزن‌دار، ابزار بی‌نظیری برای مدل‌کردن بسیاری از ساختارها در دنیای علوم کامپیوتر هستند. شبکه‌های کامپیوتری، اینترنت، وب و شبکه‌های اجتماعی نمونه‌هایی هستند که می‌توان بر حسب کاربرد آنها را توسعه گرفته‌ای وزن‌دار مدل کرد. مثلاً یک شبکه کامپیوتری را در نظر بگیرید. وزن یال‌ها می‌تواند تأخیر لینک‌های یک شبکه را نمایش دهد. بدینهی است که در این مثال، وزن یال یا همان تأخیر، یک متغیر تصادفی است که از یکتابع توزیع احتمال نامعلوم تبعیت می‌کند. یافتن مسیری با کمترین تأخیر در این شبکه می‌تواند به یافتن یک کوتاهترین مسیر تصادفی نگاشت شود [۱۴]، [۱۵] و [۱۶].

۳-۲ آتاماتاتی یادگیر

آتاماتاتی یادگیر تصادفی یک واحد تصمیم‌گیرنده تطبیقی است که فرایند یادگیری در آن از طریق تعاملش با محیط مجموعه‌ای از اقداماتی قابل انجام دارد که این اقدامات را به تصادف یادگیر، مجموعه‌ای از اقداماتی که تأثیر آتاماتاتی را می‌براسند، انتخاب شده و به عنوان ورودی به مجموعه اعمال می‌شوند. محیط، اقدام انجام‌شده را به کمک یک سیگنال تقویتی بازخوردی حاصل، بردار توزیع احتمال انتخاب اقدامات را به روز رسانی می‌کند. هدف آتاماتاتی، پیداکردن اقدام بهینه در میان مجموعه اقداماتی قابل انجام است، اقدامی که بیشترین پاداش را از محیط تقویتی بازخوردی، مورد ارزیابی قرار می‌دهد. آتاماتاتی یادگیر بر اساس سیگنال بازخوردی، نشان داده شده است. از

این مجموعه به همراه الگوریتم یادگیری تحت عنوان آتاماتاتی یادگیر تصادفی نام برده می‌شود و به این ترتیب آتاماتاتی یادگیر تصادفی را می‌توان با چهارتایی (۱) تعریف کرد:

$$SLA \equiv \{\alpha, \beta, p, T, c\} \quad (1)$$

به طوری که $\alpha \equiv \{\alpha_1, \alpha_2, \dots, \alpha_r\}$ مجموعه اقداماتی آتاماتاتی / مجموعه ورودی‌های محیط، $\beta \equiv \{\beta_1, \beta_2, \dots, \beta_m\}$ مجموعه ورودی‌های آتاماتاتی / مجموعه خروجی‌های محیط، $p \equiv \{p_1, p_2, \dots, p_r\}$ بردار احتمال اقداماتی آتاماتاتی، $T \equiv \varphi \rightarrow \alpha$ الگوریتم یادگیری و $c \equiv \{c_1, c_2, \dots, c_r\}$ مجموعه احتمالات جریمه که معرف محیط می‌باشند، است.

الگوریتم یادگیری یک رابطه بازگشتی است که برای انجام تقویتات و به روز رسانی در بردار احتمال اقداماتی آتاماتاتی در یک آتاماتاتی یادگیر تصادفی با ساختار متغیر مورد استفاده قرار می‌گیرد. فرض کنید یک آتاماتاتی یادگیر تصادفی ساختار متغیر در زمان k از میان مجموعه

در این شبکه از آناتماتاهای همکار در هر زمان تنها یک آناتماتا فعال است و تعداد اعمال قابل انجام توسط یک آناتماتا در DLA برابر است با تعداد آناتماتاهایی که به این آناتماتا متصل شده‌اند. انتخاب یک عمل توسط آناتماتا در این شبکه، باعث فعال شدن آناتماتای متصل شده به این آناتماتا و منتظر با این عمل می‌گردد. به عبارت معادل، انتخاب یک عمل توسط یک آناتماتا در این شبکه منتظر است با فعال شدن یک آناتماتای دیگر در این شبکه.

وجود یال (LA_i, LA_j) در این گراف به آن معناست که انتخاب عمل α^i توسط LA_i باعث فعال شدن LA_j می‌گردد. تعداد اعمال قابل انتخاب توسط LA_k برابر است با درجه خروجی این رأس. بردار احتمالات مربوط به عمل‌های قابل انجام توسط آناتماتای LA_k به صورت $p_m^k = \{p_1^k, p_2^k, \dots, p_n^k\}$ نشان‌دهنده احتمال مربوط به عمل α_m^k است، انتخاب عمل α_m^k توسط باعث فعال شدن LA_m می‌شود و r_k تعداد اعمال قابل انجام توسط آناتماتای LA_k را نشان می‌دهد.

۳- ساختار والگوریتم پیشنهادی جدید

آناتماتای یادگیر توزیع شده توسعه یافته شبکه‌ای است از آناتماتاهای یادگیر مرتبط با هم که تحت نظارت مجموعه‌ای از قواعد ارتباطی که ناظر بر ترتیب و نحوه فعالیت آنهاست، برای حل یک مسئله خاص با یکدیگر همکاری دارند. در آناتماتای یادگیر توزیع شده توسعه یافته، هر آناتماتا دارای یک سطح فعال بودن است و زمان و نحوه تغییر سطح فعالیت آناتماتاها به تبعیت از شرایط مسئله، تغییر می‌کند. در این آناتماتا در هر زمان تنها یک آناتماتا در سطحی قرار می‌گیرد که قادر به انجام اقدام و اعمال آن بر محیط است. به صورت فرمال می‌توان یک آناتماتای یادگیر توزیع شده توسعه یافته را به صورت زیر تعریف کرد:

تعریف ۱۰: یک آناتماتای یادگیر توزیع شده توسعه یافته توسط چندتایی $eDLA = \{A, E, S, P, S^*, F, C\}$ تعریف می‌شود و در آن:

$A = \{1, 2, \dots, n\}$: مجموعه‌ای از آناتماتاهای یادگیر است که در آن

$E \subseteq A \times A$ مجموعه ارتباطات سلسله مراتبی میان اعضای A

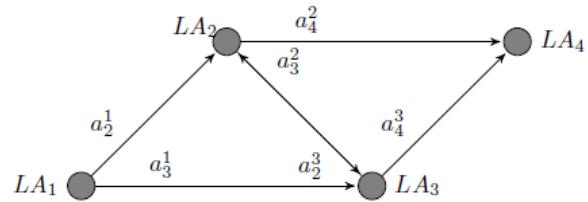
است و $G = (A, E)$ یک گراف ارتباطی نامیده می‌شود.

(۲) $S = \{s_1, s_2, \dots, s_n\}$: مجموعه‌ای از مقادیر موسوم به سطح فعالیت است که سطح فعال بودن هر آناتماتای متعلق به A را مشخص می‌کند. هر یک از s_i ‌ها می‌توانند یکی از مقادیر Passive, Active, Off, Fire و Fi باشند که آنها را به ترتیب با Pa, Ac, Off, Fire, Active و Off نمایش می‌دهیم. Fire, بالاترین سطح فعالیت و Passive, Off پایین‌ترین سطح فعالیت هستند با این تفاوت که اگر آناتماتا به سطح فعالیت off برسد، دیگر هرگز تغییر وضعیت نمی‌دهد اما در حالت Passive امکان تغییر وضعیت وجود دارد.

(۳) P : مجموعه‌ای محدود از قواعد حاکم بر سطح فعالیت آناتماتاها است. این قواعد تابعی از سطح فعالیت فعلی هر آناتماتا و سطح فعالیت آناتماتاهای مجاور است و بسته به مسئله‌ای که برای eDLA

حل آن به کار گرفته می‌شود، می‌تواند متغیر باشد.

(۴) $S^* = \{s_1^*, s_2^*, \dots, s_n^*\}$: وضعیت آغازین سیستم نامیده می‌شود. $F = \{S^F | S^F = (s_1^F, s_2^F, \dots, s_n^F)\}$ مجموعه شرایط پایانی نامیده می‌شود. مجموعه F شرایطی را بر حسب سطح فعالیت آناتماتاها مشخص می‌کند که در صورت تحقق حداقل یکی از آنها سیستم به وضعیت پایانی منتقل می‌شود. F حداقل یک عضو بدیهی دارد که در آن سطح فعالیت تمام آناتماتاها off است.



شکل ۲: آناتماتای یادگیر توزیع شده.

واضح است که برقراری رابطه $E[M(n+1)|P(n)] \geq M(n)$ ایجاب می‌کند که $M(n)$ یک زیرمارتینگل باشد.

۲-۳-۲ آناتماتای یادگیر با مجموعه اقدام‌های متغیر

یک آناتماتای یادگیر با مجموعه اقدام متغیر، آناتماتایی است که در آن تعداد اقدام‌های موجود هر آناتماتا در طول زمان تغییر می‌کند [۱۹]. فرض کنید مجموعه اقدام‌های آناتماتا را با $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$ و مجموعه اقدام‌های قابل انجام توسط آناتماتا در زمان n را با $A(k) \subseteq \alpha$ نشان دهیم $(A(k) \in \{A_1, A_2, \dots, A_m\}, m = 2^{n-1})$.

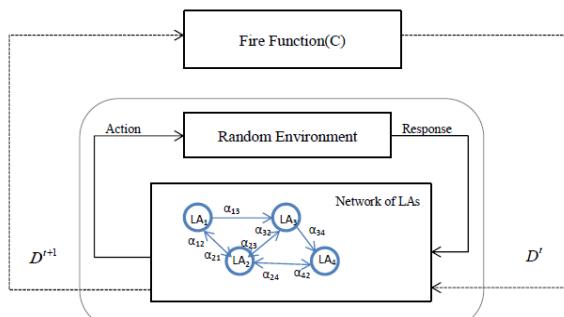
انتخاب زیرمجموعه $A(k)$ از میان مجموعه اقدام‌های قابل انجام توسط آناتماتا، غالباً توسط شرایط بیرونی تحمیل می‌شود. می‌توان این گونه فرض کرد که این زیرمجموعه از اقدام‌های آناتماتا که از این به بعد مجموعه اقدام‌های فعال آناتماتا نامیده می‌شود، توسط یک عامل بیرونی و با توزیع احتمال $\psi_i(k) = \{\psi_1(k), \psi_2(k), \dots, \psi_m(k)\}$ انتخاب می‌شود. اگر تعریف کنیم $\hat{p}_i(k) = Prob[\alpha(k) = \alpha_i | A(k)], \alpha_i \in A(k)$ ، (احتمال انتخاب عمل α_i از میان مجموعه اقدام‌های فعال به شرط آن که مجموعه اقدام‌های فعال آناتماتا برابر با $A(k)$ باشد) در این صورت

$$\hat{p}_i(k) = \frac{p_i(k)}{K(k)} \quad (5)$$

که $K(k)$ مجموع احتمالات تمام اقدام‌های فعال (اقدام‌های عضو $A(k)$) بوده و $p_i(k) = Prob[\alpha(k) = \alpha_i]$ که $K(k) = \sum_{\alpha_i \in A(k)} p_i(k)$ اختلال انتخاب اقدام α_i در میان تمام اقدام‌های آناتماتا (اعم از این که فعال باشد یا نباشد) است. بدین ترتیب نحوه انتخاب اقدام توسط آناتماتا یا مجموعه اقدام متغیر بدین صورت است که فرض کنید آناتماتا مجموعه اقدام‌های فعال $A(k)$ را داشته باشد. ضریب نرمال‌کننده $K(k) = \sum_{\alpha_i \in A(k)} p_i(k)$ برای این مجموعه از اقدام‌های فعال محاسبه شده و بردار احتمال انتخاب اقدام‌های آناتماتا مطابق با رابطه بالا نرمال‌سازی می‌شود (به گونه‌ای که مجموع احتمال اقدام‌های فعال همچنان ۱ باشد). پس از این، آناتماتا بر اساس بردار جدید $\hat{p}_i(k)$ یکی از اقدام‌های (فعال) خود را انتخاب کرده و به محیط اعمال می‌کند. در مرحله به روز رسانی نیز بردار $(\hat{p}_i(k))$ مطابق با الگوریتم یادگیری مورد استفاده مجدد از رابطه بالا بردار $p_i(k) = \hat{p}_i(k) \cdot K(k)$ به دست می‌آید. نشان داده شده [۱۹] در صورتی که الگوریتم یادگیری مورد استفاده L_{R-J} باشد، این روش ویژگی‌های absolute expediency و ϵ -optimality را دارد.

۲-۳-۳ آناتماتای یادگیر توزیع شده

آناتماتای یادگیر توزیع شده شبکه‌ای است از آناتماتاهای یادگیر که برای حل یک مسئله خاص با یکدیگر همکاری دارند. یک DLA در قالب یک گراف ارائه شده و با چندتایی (V, E, T, v) تعریف می‌شود که در آن V مجموعه رئوس گراف، E مجموعه یال‌ها، T مجموعه‌ای از الگوریتم‌های یادگیر مورد استفاده توسط آناتماتاها در DLA و v گره ریشه DLA است [۳].



شکل ۴: ساختار کلی eDLA.

ه) آتاماتایی که Fire شده پس از انجام عمل تصادفی انتخابی، به وضعیت Off تغییر وضعیت می‌دهد.

تعريف ۱۲ (توصیف لحظه‌ای): یک اجرا یا Run را می‌توان با توصیف‌های لحظه‌ای وضعیت آتاماتاهای نشان داد. توصیف لحظه‌ای عبارت است از یک چهارتایی مرتب که با $D^t = (D_{Of}^t, D_{Fi}^t, D_{Ac}^t, D_{Pa}^t)$ نشان داده می‌شود که در آن $D_i^t \subseteq A$ ($i = \{Of, Fi, Ac, Pa\}$), $\bigcup_i D_i^t = A$ داده می‌شود که در آن $D_i^t \cap D_j^t = \emptyset$, $(i \neq j, i, j \in \{Of, Fi, Ac, Pa\})$. هر بار که آتاماتا یکی از اقدام‌های خودش را انجام می‌دهد توصیف لحظه‌ای بر اساس قواعد P تغییر می‌کند. در حالت دیگر هرگاهتابع Fire یکی از آتاماتاهای Fire می‌کند، توصیف لحظه‌ای تغییر می‌کند. علاوه بر این داریم $D^t = (D_{Of}^t, D_{Fi}^t, D_{Ac}^t, D_{Pa}^t) = (\phi, \phi, \{A\}, A - A)$ که توصیف لحظه شروع eDLA و $D^{final} = (D_{Of}^{final}, D_{Fi}^{final}, D_{Ac}^{final}, D_{Pa}^{final}) = (A, \phi, \phi, \phi)$ است. وضعیت پایانی بدیهی یک Run است. بدین ترتیب یک Run را به شکل زیر و به صورت دنباله‌ای از توصیف‌های لحظه‌ای تعریف می‌کنیم

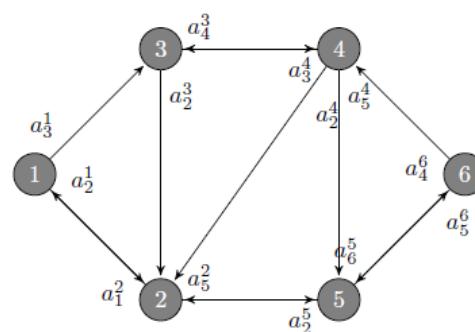
$$Run = D^t \vdash_{fire} D^t \vdash_{action} D^t \vdash_{fire} \dots D^{final} = D^t \vdash^* D^{final}$$

برای فهم بهتر تعاریف، به نمونه‌ای از یک اجرا در eDLA شکل ۳ دقت کنید

$$\begin{aligned} &(\phi, \phi, \{\}, \{2, 3, 4, 5, 6\}) \vdash_{fire} (\phi, \{\}, \{2, 3\}, \{4, 5, 6\}) \vdash^{a_1} \\ &(\{\}, \phi, \{2, 3\}, \{4, 5, 6\}) \vdash_{fire} (\{\}, \{3\}, \{2, 4\}, \{5, 6\}) \vdash^{a_2} \\ &(\{\}, \phi, \{2, 4\}, \{5, 6\}) \vdash_{fire} (\{\}, \{3\}, \{4\}, \{2, 5, 6\}, \phi) \vdash^{a_3} \\ &(\{\}, \{3\}, \phi, \{2, 5, 6\}, \phi) \vdash_{fire} (\{\}, \{3, 4\}, \{2\}, \{5, 6\}, \phi) \vdash^{a_4} \\ &(\{\}, \{3, 4\}, \phi, \{5, 6\}, \phi) \vdash_{fire} (\{\}, \{3, 4, 2\}, \{8\}, \{5\}, \phi) \vdash^{a_5} \\ &(\{\}, \{3, 4, 2\}, \phi, \{5\}, \phi) \vdash_{fire} (\{\}, \{3, 4, 2, 6\}, \{5\}, \phi, \phi) \vdash^{a_6} \\ &\vdash^{no action} (\{\}, \{3, 4, 2, 6, 5\}, \phi, \phi, \phi) \end{aligned}$$

به این ترتیب، آتاماتایی یادگیر توزیع شده توسعه یافته یک ساختار دوبخشی است، متشکل از یک تابع تصمیم‌گیرنده و یک شبکه از آتاماتاهای یادگیر که برای حل یک مسئله خاص به شکل گروهی با یکدیگر همکاری دارند. بسته به نوع مسئله، فرایند تصمیم‌گیرنده متفاوت می‌باشد اما به صورت کلی، وظیفه بخش تصمیم‌گیرنده، تعیین آتاماتایی است که می‌بایستی عملی را در محیط تصادفی انجام دهد. شکل ۴ ساختار کلی eDLA نشان می‌دهد.

در شکل ۵ الگوریتم پیشنهادی مبتنی بر eDLA برای حل مسئله زیرگراف بهینه ارائه شده است. نحوه عملکرد این الگوریتم بسیار ساده می‌باشد، تابع fire مسئله را روی یک گراف قطعی فاقد وزن (همان گراف دوگان خنثی) حل می‌کند. بدین صورت که یک گره را مشخص می‌کند تا از میان یال‌های متصل به آن گره، آتاماتایی یادگیر متناظر، یالی را انتخاب کند.



شکل ۳: گراف ارتباطی یک eDLA نمونه.

۶) C : یک تابع خاص است که بر اساس سطح فعلی فعالیت آتاماتاهای eDLA و مسئله‌ای که برای حل آن طراحی شده است، آتاماتایی را از میان مجموعه آتاماتاهای موجود در eDLA انتخاب می‌کند. C را تابع آتش یا Fire Function می‌نامیم. در ادامه بحث در این خصوص بیشتر توضیح خواهیم داد.

هر آتاماتایی یادگیر در eDLA متناسب با درجه‌اش در گراف ارتباطی G قادر جهت باشد) و یا درجه خروجی اش در گراف ارتباطی (در حالی که گراف ارتباطی G جهت‌دار باشد) اقدام برای انجام دارد.

نحوه انجام کار بین صورت است که بر اساس eDLA از وضعیت S آغاز کرده و بر اساس مجموعه قواعد P نسبت به تغییر سطح فعلی بودن آتاماتاهای اقدام می‌کند. تغییر سطح فعلی بودن آتاماتاهای تا زمان حل کامل مسئله ادامه پیدا می‌کند. در هر زمان آتاماتایی که در سطح فعلی Fire قرار دارد، اقدامی را انتخاب کرده و آن را به محیط اعمال می‌کند. ضمن این که بر اساس قواعد ارتباطی مجموعه‌ای از آتاماتاهای مجاور با آتاماتای Fire که در پایین ترین سطح فعلی بودن (Passive) قرار دارند، ارتقای سطح می‌یابند (به سطح Active). هر آتاماتا پس از Fire شدن و انجام اقدام به وضعیت Off تغییر وضعیت می‌دهد. انتخاب آتاماتای Fire از میان مجموعه آتاماتاهای Active صورت می‌گیرد و غالباً به صورت تصادفی انجام می‌شود.

تعريف ۱۱: یک دور اجرا یا run عبارت است از Off شدن وضعیت تمام آتاماتاهای موجود در eDLA از طریق طی کردن زیست چرخ حیات آتاماتا به شکل $Passive \rightarrow Active \rightarrow Fire \rightarrow Off$. در آغاز هر اجرا بر اساس S آتاماتایی در eDLA وجود دارد که در وضعیت Active قرار دارد. این آتاماتا را آتاماتای ریشه نیز می‌نامیم و با A نمایش می‌دهیم. هر آتاماتا در eDLA یک چرخه زیستی مختص به خود را طی می‌کند. تغییر وضعیت آتاماتاهای در eDLA بر اساس قوانین P و تغییراتی که توسط تابع Fire اعمال می‌شوند، است:

(الف) تمامی آتاماتها- به غیر از آتاماتای متناظر با ریشه- در آغاز کار در وضعیت Passive قرار دارند.

(ب) تابع Fire مشخص می‌کند که کدام آتاماتا از مجموعه آتاماتاهای Active به وضعیت Fire تبدیل شود.

(ج) با Fire شدن وضعیت یک آتاماتا، کلیه آتاماتاهای مجاور آن که Passive هستند به حالت Active تغییر وضعیت می‌دهند (فعال‌سازی به شیوه همسایگی محلی بر اساس قوانین P).

(د) آتاماتایی که شده از میان مجموعه اقدام‌های قابل انجام خود، به تصادف اقدامی را انجام می‌دهد که توسط محیط به شکل منفرد و پس از انجام عمل، یا به صورت گروهی و در پایان یک دور اجرا مورد ارزیابی قرار می‌گیرد.

اما برای این که پیچیدگی محاسباتی این روش کاهش یابد، ناچاریم اولاً از تخمین‌های ساده نظری تخمین‌های stochastic gradient استفاده کنیم و ثانیاً هر فرضی مبنی بر اطلاع داشتن گره‌های میانی از وزن یال نمونه‌گیری شده را کنار بگذاریم. به این ترتیب، گراف تصادفی همانند یک جبهه سیاه تصویر می‌شود که الگوریتم ما تنها به وزن زیرگراف حاصل از نمونه‌گیری روی این گراف تصادفی و یک تقریب نزدیک به واقعیت از واریانس وزن زیرگراف‌های به دست آمده اطلاع دارد. به این ترتیب، هیچ فرض اضافه‌ای در خصوص شبکه تصادفی پویا اعمال نشده [۱۶] و سادگی محاسباتی آتاماتاهای یادگیر نیز نقض نشده است.

برای به دست آوردن معیار جدید به این صورت عمل کردایم:

(۱) تفاوت وزن زیرگراف‌های به دست آمده (W_{k+1}) در هر مرحله با میانگین وزن زیرگراف‌های به دست آمده تا قبل از آن مرحله (WTH_k) محاسبه می‌گردد و این مقدار Err نامیده می‌شود

$$(Err_{k+1} = W_{k+1} - WTH_k)$$

(۲) از مقدار Err برای به روز رسانی مقدار آستانه پویا استفاده می‌شود

$$(WTH_{k+1} = WTH_k + \alpha Err_{k+1})$$

(۳) از یک متغیر نظری V به عنوان تخمینی از واریانس استفاده می‌کنیم. مقدار این متغیر در هر مرحله از طریق یک تخمین گر خطی به صورت ($V_{k+1} = V_k + \beta(\text{abs}(Err_{k+1}) - V_k)$) محاسبه می‌شود. کاملاً واضح است که این تخمین گر، انحراف از میانگین را محاسبه می‌کند (mdev) نه انحراف معیار (sdev). اما می‌دانیم که

$$mdev^r = (\sum |W - W_{TH}|)^r \geq \sum |W - W_{TH}|^r = \delta^r = sdev^r \quad (6)$$

رابطه (۶) نشان می‌دهد که انحراف از میانگین بزرگ‌تر از انحراف معیار و لذا محافظه کارانه‌تر از آن است، ضمن این که محاسبه آن فوق العاده ساده‌تر از واریانس است.

(۴) برای مقایسه و تعیین پاداش یا جریمه آتاماتاهای از کران بالای $WTH_k / 2 + 2 \times V_k$ استفاده می‌کنیم.

به این ترتیب الگوریتم ۱ شکل ۵ قادر به حل مسئله یافتن زیرگراف بهینه تصادفی روی گراف‌های تصادفی است. کافی است که با توجه به مسئله، قواعد مناسب اتخاذ شود. نمونه‌ای از این قواعد را برای دو مسئله مورد بررسی این مقاله در جدول ۱ مشاهده می‌کنید.

۴- تحلیل رفتار الگوریتم پیشنهادی

در این قسمت به بررسی ریاضی رفتار eDLA در حل مسئله یافتن زیرگراف در گراف‌های تصادفی می‌پردازیم. روشی که در این قسمت استفاده می‌کنیم، همان روشی است که در [۱] برای بررسی همگرایی پیشنهاد شده و در [۴] برای بررسی رفتار مجانبی DLA مورد استفاده قرار گرفته است.

اساساً دو نوع مختلف از همگرایی برای الگوریتم‌های یادگیری مورد استفاده در LA وجود دارد. مورد اول برای الگوریتم‌های یادگیری L_{R-P} نظری expedient موردن بررسی قرار می‌گیرد. در این نوع همگرایی توابع توزیع دنباله احتمالات اقدام‌ها به یک تابع توزیع همگرا می‌شود. مثلاً نشان داده شده زمانی که از الگوریتم یادگیری L_{R-P} استفاده می‌شود، $p(n)$ بردار احتمال انتخاب اقدام‌های آتاماتا، به یک متغیر تصادفی پیوسته همگرا می‌شود که میانگین و واریانس آن قابل محاسبه بوده و مقدار واریانس را می‌توان با انتخاب مقادیر مناسب برای پارامترهای الگوریتم یادگیری، به اندازه مورد نیاز کوچک کرد. در این نوع همگرایی، مقادیر اولیه احتمالات تأثیری در رفتار مجانبی الگوریتم ندارند [۱].

Algorithm1: eDLA-based algorithm for finding optimal stochastic sub-graph

Input: Stochastic Graph $G = (V, E, W)$; $v \in V$ Special node (root); K_T ; P_T
Output: Induced Graph
1: $K = 0$;
2: Let S denotes the constructed Graph and W_S denotes its weight
3: **Begin**
4: Assign an automaton to each node of graph and construct eDLA
5: Initialize all LA in eDLA (set activity state of v to active and others to passive);
6: **Repeat**
7: $S = \phi$; $W_S = 0$; $P = 1$;
8: **Repeat**
9: $A_i = \text{Fire (eDLA)}$;
10: $\alpha = \text{selectaction } (A_i)$;
11: $S = S + \text{edge}(A_i, \alpha)$;
12: $W_S = W_S + \text{weight}(A_i, \alpha)$;
13: **Until** $(A_i \neq 0)$
14: $K = K + 1$;
15: evaluate (eDLA, Threshold, K);
16: Threshold = Update (Threshold, K);
17: $\prod p(A_m, \alpha_n) = \prod p(m, n) \quad \forall \text{edge}(m, n) \in S$
18: **Until** $K < K_T$ or $P < P_T$
19: **End**

شکل ۵: الگوریتم پیشنهادی مبتنی بر eDLA برای یافتن زیرگراف تصادفی بهینه.

آتاماتا با انتخاب یک یال از میان یال‌های موجود گره‌ای که تابع fire انتخاب کرده، سعی می‌کند یالی را انتخاب کند که احتمال بهینه‌شدن جواب نهایی مسئله توسط آن بیشتر است (از طریق اقدام متناظری با احتمال انتخاب بیشتر). مجموعه یال‌های انتخاب شده توسط آتاماتاهای در eDLA یک زیرگراف را تشکیل می‌دهد که توسط محیط ارزیابی می‌شود. ارزیابی محیط توسط سیگنال‌های تقویتی پاداش یا جریمه به همه آتاماتاهای دخیل در ساخت زیرگراف مجبور بازخورد می‌شود. آتاماتاهای از الگوریتم یادگیری L_{R-I} برای ارزیابی اقدام خود استفاده می‌کنند و در بخش ۴ و در آنالیز ریاضی eDLA خاصیت absolutely-expediency این رهیافت اثبات می‌شود.

بدین ترتیب ترکیب fire و selectaction که یکی از آنها روی گراف دوگان خشی و دیگری روی گراف تصادفی انجام می‌شود، منجر به حل مسئله می‌شود.

در الگوریتم ۱ شکل ۵ از مقداری موسوم به مقدار آستانه^۱ پویا برای ارزیابی اقدام‌های آتاماتا در eDLA استفاده می‌شود. (خط ۱۵) بر اساس قضیه حد مرکزی در [۴] روشی برای به روز رسانی این مقدار ارائه داده است. در روش پیشنهادی، این مقدار به صورت میانگین تمام مقادیر وزن زیرگراف‌های قبلی محاسبه شده است. این روش محاسبه تقریباً در تمام الگوریتم‌های که بعداً مبتنی بر DLA یا شبکه‌ای از آتاماتاهای ارائه شده دیده می‌شود [۶، [۷] و [۲۰]. بررسی‌ها نشان می‌دهد به دلیل نزدیک شدن مقدار آستانه پویا در الگوریتم به وزن زیرگراف بهینه، از مرحله‌ای به بعد قدرت یادگیری eDLA کاهش می‌یابد. برای حل این مشکل به جای مقدار آستانه پویا که یک میانگین گیری روی وزن زیرگراف‌های قبلی است، از معیار دیگری استفاده می‌کنیم که علاوه بر وزن، واریانس وزن زیرگراف‌های قبلی به دست آمده را نیز در محاسبات لحاظ کند.

1. Threshold

جدول ۱: نحوه به کارگیری EDLA برای حل برخی مسائل بهینه‌سازی روی گراف تصادفی.

مسئله	دراخت پوشای کمینه تصادفی	کوتاهترین مسیر تصادفی بین s و t
انتخاب ROOT	تصادفی: از میان آنماتاها بر اساس توزیع یکنواخت قطعی: آنماتایی با کمترین مقدار آتروپی بردار احتمال اقدامها	قطعی: مبدأ
Fire شدن	تصادفی: از میان آنماتاها Active بر اساس توزیع یکنواخت قطعی: آنماتایی با کمترین مقدار آتروپی بردار احتمال انتخاب اقدامها در میان آنماتاها Fire فعلی	قطعی: اقدام انجام شده توسط آنماتای Fire فعلی تعیین کننده Fire بعدی است بر اساس مجاورت با آنماتای Fire فعلی
Active شدن	بر اساس مجاورت با آنماتای Fire فعلی	شدن آنماتای Fire
خاتمه	شدن تمام آنماتاها Off	شدن آنماتای d

تمام زیرگراف‌های مورد نظر مسئله r باشد و در مرحله k ، زیرگراف s_i که یکی از جواب‌ها است k_i بار انتخاب شده باشد و $i=1,2,\dots,r$. علاوه بر آن $\sum_{i=1}^r k_i = k$. حال فرض کنید زیرگراف s_i در مرحله k انتخاب شده و نیز W_{s_i} وزن زیرگراف s_i باشد. مقدار وزن زیرگراف به دست آمده در j امین اجرای الگوریتم را با $(j) W_{s_i}$ نشان می‌دهیم $j=1,2,\dots,k_i$ و نیز فرض کنید \bar{W}_{s_i} مقدار میانگین وزن زیرگراف s_i است $(i=1,2,\dots,r)$. مقادیر d و c را به صورت زیر تعریف می‌کنیم

$$d_i(k) = \text{Prob}(W_{s_i}(k+1) \leq T(k))$$

$$c_i(k) = \text{Prob}(W_{s_i}(k+1) > T(k)) = 1 - d_i(k)$$

مقادیر d و c به ترتیب احتمال دریافت پاداش یا جریمه توسط محیط زمانی که زیرگراف s_i در مرحله k انتخاب شده را نشان می‌دهند. مقدار آستانه $T(k)$ برای $k > 1$ به صورت زیر تعریف می‌شود

$$T(k) = \frac{1}{k} \sum_{i=1}^r T_i(k_i)$$

در این رابطه k_i تعداد دفعاتی که زیرگراف s_i انتخاب شده را نشان می‌دهد و مقدار $T_i(k_i)$ برابر است با

$$T_i(k_i) = \frac{1}{k_i} \sum_{j=1}^{k_i} W_{s_i}(j)$$

شرط توقف الگوریتم آن است که حاصل ضرب احتمال انتخاب یال‌های زیرگراف s_i که آن را احتمال زیرگراف s_i نامیده و با q_i نشان می‌دهیم از یک مقدار آستانه از پیش تعیین شده بیشتر بوده و یا تعداد تکرارهای الگوریتم از مقدار آستانه‌ای بیشتر باشد.

قضیه ۱: فرض کنید $q_i(k)$ احتمال متناظر با زیرگراف بهینه s_i در گراف تصادفی مفروض در مرحله k ام را نشان دهد. اگر بردار صورت $\underline{q}(k) = [q_i(k)]_{i=1,\dots,r}$ مطابق با الگوریتم شکل ۵ تغییر کند، در این صورت $\lim_{n \rightarrow \infty} q_i(n) = 1$.

اثبات: اثبات این قضیه در چند مرحله صورت می‌گیرد.

لم ۱: اگر در الگوریتم ارائه شده شکل ۵، زیرگراف s_i با احتمال $c_i(k)$ در مرحله k جریمه شود و $\lim_{k \rightarrow \infty} c_i(k) = c^*$ باشد، در این صورت برای هر $(\epsilon, 1) \in \mathbb{R}^2$ و $K(\epsilon) > k$ داریم

$$\text{Prob}(|c^* - c_i(k)| > \epsilon) < \epsilon$$

اثبات: مطابق با نمادگذاری قبلی، c_i احتمال جریمه‌شدن زیرگراف s_i را در گام k نشان می‌دهد. مطابق با قانون قوی اعداد بزرگ اگر $\lim_{k \rightarrow \infty} c_i(k) = c^*$ برای مقادیر بزرگ k باشد آن گاه

$$\lim_{k \rightarrow \infty} \text{Prob}(|c^* - c_i(k)| > \epsilon) \rightarrow 0.$$

لم ۲: اگر $(k, d_i(k))$ احتمالات مربوط به جریمه و تنبیه شدن

حال دوم همگرایی برای الگوریتم‌های یادگیری ε -optimal L_{R-I} اتفاق می‌افتد. در این حالت از تئوری همگرایی مارتینگل استفاده می‌شود که به موجب آن دنباله‌ای از احتمالات اقدامها به یک متغیر تصادفی محدود با احتمال ۱ همگرا می‌شود. تفاوت این دو نوع همگرایی در آن است که در حالت اول زنجیره مارکوفی تولید می‌شود که ارجو دیک است اما حالت جاذب ندارد ولی در روش دوم، زنجیره مارکوف تولیدشده بیش از یک حالت جاذب دارد. برخلاف روش اول، مقادیر اولیه بردار احتمالات نقش مؤثری در همگرایی روش دوم دارند.

به این ترتیب در مورد الگوریتم‌های یادگیری ε -optimal L_{R-I} تنها چیزی که قابل بیان می‌باشد این است که $p(n)$ با یک احتمال مثبت به یک حالت دلخواه همگرا می‌شود و آنچه که اهمیت دارد، میزان عددی این احتمال است. برای حصول اطمینان از همگرایی، احتمال همگرایی به حالت مدنظر به صورت تابعی از احتمال اولیه تعیین می‌شود اما نکته اصلی یافتن چنین تابعی است.

اگر فرض کنیم $(n) p_i$ احتمال انتخاب اقدام i در یک آنماتای L_{R-I} یادگیر باشد که تحت الگوریتم L_{R-I} فرایند یادگیری را انجام می‌دهد، با استی تابعی مثل $[p] = pr[p_i(\infty) = p] = 1|p_i(0) = p$ بازیستی $\Gamma_i(p) = UT_i(p) = \Gamma_i(p)$ را برای کمی‌سازی احتمال همگرایی حالت i تعریف کرد. در [۲۱] نشان داده است تابع Γ با استی معادله تابعی $UT_i(p) = \Gamma_i(p)$ را ارضا کند (با شرایط مزی متناسب برای $p = 0$ و $p = 1$) که در آن U عملگری است که به صورت $UT_i(p) = E[\Gamma_i(p_i(n+1))|p_i(n) = p]$ می‌شود. حل این معادله تابعی کار ساده‌ای نیست.

به جای حل این معادله از دو تابع با شرایط مزی مناسب برای یافتن حدود بالا و پایین تابع Γ استفاده می‌شود. این دو تابع که آنها را $\varphi_+(p)$ و $\varphi_-(p)$ می‌نامیم، با استی برای تمام مقادیر $p \in [0, 1]$ دارای شرایط (۷) باشند

$$\begin{aligned} U\varphi_+(p) &\geq \varphi_+(p) \\ U\varphi_-(p) &\leq \varphi_-(p) \end{aligned} \quad (7)$$

برقراری نابرابری (۷) ایجاب می‌کند که $\varphi_+(p) \leq \Gamma_i(p) \leq \varphi_-(p)$. توابع φ_+ و φ_- به ترتیب ابرمنظمه و زیرمنظمه نامیده می‌شوند و یافتن آنها کار ساده‌تری است. در [۲۱] و [۲۲] نشان داده شده که این توابع به شکل (۸) هستند

$$\varphi_i(p) = \frac{\exp(x_i p) - 1}{\exp(x_i) - 1}, \quad i = 1, 2 \quad (8)$$

در ادامه بحث، این نمادگذاری‌ها را در نظر بگیرید: فرض کنید تعداد

1. Super-Regular
2. Sub-Regular

جدول ۲: بررسی تغییرات در احتمال انتخاب زیرگراف بهینه در یک گراف نمونه.

احتمال انتخاب	تغییرات
s_1	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_2	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_3	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\downarrow}(k)$
s_4	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_5	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_6	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_7	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$
s_8	$q_i(k)$
	$c_i(k)q_i(k)$
	$d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)$

$$E[q_i(k+1)|q(k)] = \\ q_i(k) \times [c_i(k)q_i(k) + d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\downarrow}(k)] + \\ q_i(k) \times [c_i(k)q_i(k) + d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\downarrow}(k)] + \\ q_i(k) \times [c_i(k)q_i(k) + d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \uparrow)p_i^{\uparrow}(k \downarrow)p_i^{\downarrow}(k)] + \\ q_i(k) \times [c_i(k)q_i(k) + d_i(k)p_i^{\downarrow}(k \uparrow)p_i^{\uparrow}(k \uparrow)p_i^{\uparrow}(k \uparrow)p_i^{\downarrow}(k)] + \\ q_i(k) \times [c_i(k)q_i(k) + d_i(k)p_i^{\downarrow}(k \downarrow)p_i^{\uparrow}(k)p_i^{\uparrow}(k)p_i^{\downarrow}(k)] = \\ \sum_{j=1}^8 q_j(k) [c_j(k)q_j(k) + d_j(k) \prod_{e(m,n) \in s_j} \delta_n^m(k)]$$

که در آن

$$\delta_n^m(k) = \begin{cases} p_n^m(k \uparrow) = p_n^m(k)(1-a) + a & , e(m,n) \in s_j \\ p_n^m(k \downarrow) = p_n^m(k)(1-a) & , e(m,n) \notin s_j \end{cases}$$

با توجه به این مثال، به صورت کلی می‌توانیم چنین بنویسیم

$$E[q_i(k+1)|q(k)] = \sum_{j=1}^r E[q_i(k+1)|q(k), \alpha_j] \cdot p(\alpha_j | q(k)) \quad (10)$$

در (۱۰) منظور از α_j مجموعه اقدام‌هایی از eDLA است که منجر به انتخاب زیرگراف s_j گردیده است

$$E[q_i(k+1)|q(k)] = \sum_{j=1}^r E[q_i(k+1)|q(k), \alpha_j] \cdot q_j(k)$$

اما

$$E[q_i(k+1)|q(k), \alpha_j] = (1-d_j)q_i(k) + \\ d_j \prod_{e(m,n) \in s_i \cap s_j} (p_n^m(k) \uparrow) \prod_{e(m,n) \in s_i - s_j} (p_n^m(k) \downarrow)$$

زیرگراف s_i حاصل شده در مرحله k امین مرحله را نشان دهدن (روابط بالا) و بردار $q(k)$ بر اساس الگوریتم شکل ۵ تغییر کند، در این صورت امید ریاضی شرطی $E[q_i(k+1)|q(k)]$ مطابق با روابط می‌شود

$$E[q_i(k+1)|q(k)] = \sum_{j=1}^r q_j(k) [c_j(k)q_i(k) + d_j(k) \prod_{e(m,n) \in s_j} \delta_n^m(k)] \quad (9)$$

که در (۹)

$$\delta_n^m(k) = \begin{cases} p_n^m(k+1) = p_n^m(k)(1-a) + a & , e(m,n) \in s_j \\ p_n^m(k+1) = p_n^m(k)(1-a) & , e(m,n) \notin s_j \end{cases}$$

اثبات: الگوریتم پیشنهادی (الگوریتم ۱ شکل ۵) از روش یادگیری L_R-I برای پاداش یا جریمه آناتماتا استفاده می‌کند، لذا در مرحله k اجرای الگوریتم، احتمال انتخاب زیرگراف s_i (عنی $q_i(k)$) با احتمال $c_i(k)$ بدون تغییر باقی می‌ماند، اگر زیرگراف s_i توسط محیط ارزیابی شده و جریمه شود. اما اگر زیرگراف s_i توسط محیط پاداش داده شود، در این صورت احتمال انتخاب یال‌های تشکیل‌دهنده زیرگراف s_i افزایش می‌یابد و در این حالت برای سایر زیرگراف‌ها نظریه j دو حالت قابل تصور است:

- (الف) j هیچ یال مشترکی با s_i ندارد که در این صورت تمام یال‌های تشکیل‌دهنده j در مرحله k جریمه شده‌اند و در این صورت $q_j(k+1) < q_j(k)$.

- (ب) s_j تعدادی یال مشترک با s_i دارد و این بدان معناست که برخی یال‌ها جریمه و برخی دیگر پاداش گرفته‌اند.

برای فهم ادامه اثبات فرض کنید گرافی داریم که در آن ۸ زیرگراف به شرح زیر جواب‌های ممکن مسئله هستند

$$s_1 = \{(1, 2), (2, 5)\}, \quad s_2 = \{(1, 2), (2, 4), (4, 5)\} \\ s_3 = \{(1, 2), (2, 3), (3, 5)\}, \quad s_4 = \{(1, 2), (2, 3), (3, 4), (4, 5)\} \\ s_5 = \{(1, 5)\}, \quad s_6 = \{(1, 4), (4, 5)\} \\ s_7 = \{(1, 3), (3, 5)\}, \quad s_8 = \{(1, 3), (3, 4), (4, 5)\}$$

ضمناً فرض کنید s_i از اضکاننده محدودیت‌های مورد نیاز مسئله روی گراف تصادفی باشد. برای هر یک از این زیرگراف‌ها، مقدار $q(k)$ متناظر با برابر است با

$$q_1(k) = p_1^{\downarrow}(k)p_1^{\uparrow}(k), \quad q_2(k) = p_2^{\downarrow}(k)p_2^{\uparrow}(k)p_2^{\downarrow}(k) \\ q_3(k) = p_3^{\downarrow}(k)p_3^{\uparrow}(k)p_3^{\downarrow}(k) \\ q_4(k) = p_4^{\downarrow}(k)p_4^{\uparrow}(k)p_4^{\downarrow}(k)p_4^{\uparrow}(k) \\ q_5(k) = p_5^{\downarrow}(k), \quad q_6(k) = p_6^{\downarrow}(k)p_6^{\uparrow}(k) \\ q_7(k) = p_7^{\downarrow}(k)p_7^{\uparrow}(k), \quad q_8(k) = p_8^{\downarrow}(k)p_8^{\uparrow}(k)p_8^{\downarrow}(k)$$

در این روابط $p_j^i(k)$ احتمال انتخاب یال (i, j) یا همان انتخاب اقدام α_j توسط آناتماتای fire شده i در مرحله k است. از آنجا که ۸ جواب بیشتر متصور نیست، بسته به این که در مرحله $k+1$ کدام یک از زیرگراف‌های s_i تا s_8 انتخاب شده باشند، تغییرات حاصل در $q_i(k)$ مطابق با مجموع مقادیر در جدول ۲ است. منظور از $p_j^i(k \downarrow)$ کاهش در مقدار $p_j^i(k)$ و منظور از $p_j^i(k \uparrow)$ افزایش در مقدار $p_j^i(k)$ از طریق روابط است L_R-I

$$p_j^i(k \downarrow) = p_j^i(k) \times (1-a)$$

$$p_j^i(k \uparrow) = p_j^i(k) \times (1-a) + a$$

با جمع مقادیر حاصل در جدول ۲ خواهیم داشت

جاذب فرایند $\{q\}$ باشد و $q^* \in V_r$ حالتی را نشان دهد که $q(k)$ به آن همگرا می‌شود. تعریف می‌کنیم $\underline{q} = \Pr[q^* = e_i | q(\cdot)]$. فرض کنید $C(S_r) : S_r \rightarrow R$ فضای حالت تمام توابع مشتق‌پذیر R پیوسته حقیقی مقدار با مشتق محدود تعریف شده روی S_r باشد که R یک خط حقیقی است. اگر $g[q] \in C(S_r)$ باشد، یک الگوریتم یادگیری نظیر یک عملگر U با میانگین $Ug[\underline{q}] = E[g(q+k)]|q(k) = \underline{q}$ عمل می‌کند که در این رابطه $E[\cdot]$ نشان‌دهنده امید ریاضی است. نشان داده شده که U عملگری خطی است و توابع نامنفی را نامنفی نگه می‌دارد یعنی $Ug[\underline{q}] \geq 0$ $\forall \underline{q} \in S_r$. if $g[\underline{q}] \geq 0$ $Ug[\underline{q}] \geq 0$ نسبت به عملگر U می‌توان دو گروه از توابع را تعریف کرد. اگر $Ug[q] \leq g[q]$ تابع $Ug[q]$ را زیرمنظم و اگر $Ug[q] \geq g[q]$ تابع $g[q]$ را ابرمنظم گویند.

نشان داده شده که $\Gamma_i[\underline{q}]$ تنها جواب پیوسته معادله $UT_i[\underline{q}] = \Gamma_i[\underline{q}]$ با شرایط مرزی زیر است

$$\Gamma_i[e_j] = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (13)$$

اما حل معادله تابعی $UT_i[\underline{q}] = \Gamma_i[\underline{q}]$ برای تعیین احتمال انتخاب زیرگراف بهینه بر حسب احتمال اولیه، کار سختی است. برای این کار از یک کران پایین برای این تابع استفاده می‌کنیم. از گزاره قبلی می‌دانیم که احتمال انتخاب زیرگراف بهینه $\{q_i^*, \dots, q_1^*\}$ است. تعریف می‌کنیم

$$\Phi_i[x, \underline{q}] = \frac{\exp(-xq_i)}{\exp(-x)} - 1 \quad (14)$$

که در آن $x > 0$ بایستی انتخاب شود. واضح است که تابع تعریف شده در (۱۴) شرایط مرزی تعریف شده در (۱۳) را ارضا می‌کند. نشان خواهیم داد که $\Phi_i[x, \underline{q}]$ یک تابع زیرمنظم بوده و لذا قادر است که یک کران پایین برای $\Gamma_i[\underline{q}]$ تعریف کند. می‌توان نشان داد که $\Phi_i[x, \underline{q}]$ وقتی زیرمنظم است که $\theta_i[x, \underline{q}] = \exp(-xq_i/a)$ ابرمنظم باشد.

لهم: اگر δ_i زیرگراف بهینه و $\theta_i[x, \underline{q}] = \exp(-xq_i/a)$ باشد که در آن $q_i = \prod_{e(m,n) \in S_i} p_n^m$ احتمال انتخاب زیرگراف δ_i و a نرخ یادگیری است، در این صورت یک x وجود دارد که $\theta_i[x, \underline{q}]$ ابرمنظم خواهد بود.

اثبات: برای تعیین شرایطی که تحت آن شرایط، تابع $\theta_i[x, \underline{q}]$ یک تابع ابرمنظم است، از تعریف ابرمنظم و محاسبه مقدار امید ریاضی استفاده می‌کنیم. فرض کنید زیرگراف δ_i جواب بهینه باشد، در این صورت

$$U\theta_i[x, \underline{q}] = E[\exp(-xq_i(k+1))|q(k) = \underline{q}] \quad (15)$$

برای محاسبه مقدار امید ریاضی در (۱۵) به این ترتیب عمل می‌کنیم

$$\begin{aligned} E[\exp(-xq_i(k+1))|q(k) = \underline{q}] &= \\ \sum_{j=1}^r E[\exp(-xq_i(k+1))|q(k) = \underline{q}, s_j] q_j &= \\ \sum_{j=1}^r \exp(-xq_i(k+1)) \times q_j \times d_j &+ \\ \sum_{j=1}^r \exp(-xq_i(k)) \times q_j \times (1-d_j) & \end{aligned} \quad (16)$$

با ساده‌سازی (۱۶) به (۱۷) و (۱۸) می‌رسیم. در (۱۷) داریم

در این روابط p_j^i احتمال انتخاب یال (i, j) یا همان انتخاب اقدام α توسط آناتماتی fire شده A_i در مرحله k است. منظور از \downarrow $p_j^i(k)$ کاهش در مقدار p_j^i و منظور از \uparrow $p_j^i(k)$ افزایش در مقدار p_j^i از طریق روابط L_{R-I} است

$$\begin{aligned} p_j^i(k) \downarrow &= p_j^i(k) \times (1-a) \\ p_j^i(k) \uparrow &= p_j^i(k) \times (1-a) + a \end{aligned}$$

به این ترتیب لم ۲ اثبات می‌گردد. ■

لم ۳: اگر زیرگراف بهینه s_i جواب مسئله یافتن زیرگراف بهینه تصادفی باشد، در این صورت مقدار $E[q_i(k+1)|q(k) = q_i(k)]$ همواره مثبت است.

اثبات: الگوریتم یافتن زیرگراف بهینه تشریح شده در شکل ۵ همواره حداقل $n-1$ یال را از میان یال‌های گراف انتخاب می‌کند تا یکی از r جواب ممکن را بسازد. به این ترتیب متوسط مقدار $(q_i(k))$ برای زیرگراف s_i که از ضرب مقادیر احتمال اقدام‌های متناظر با یال‌های تشکیل دهنده s_i تشکیل می‌شود برابر است با

$$\begin{aligned} \Delta q_i(k) &= E[q_i(k+1) - q_i(k)|q(k)] = \\ \prod_{e(m,n) \in S_i} E[p_n^m(k+1)|p_n^m(k)] - \prod_{e(m,n) \in S_i} p_n^m(k) &\geq \\ \prod_{e(m,n) \in S_i} (E[p_n^m(k+1)|p_n^m(k)] - p_n^m(k)) &= \\ \prod_{e(m,n) \in S_i} \Delta p_n^m(k) & \end{aligned} \quad (11)$$

$p^m(k)$ بردار احتمال انتخاب اقدام‌های آناتماتی A_m متناظر با گره k در مرحله m است و برای محاسبه $\Delta q_i(k)$ به بررسی وضعیت تک‌تک آناتماتاهایی می‌پردازیم که تشکیل‌دهنده زیرگراف δ_i هستند. فرض کنید که آناتماتی A_i در حین اجرای الگوریتم fire شده باشد. در این صورت میزان تغییرات احتمال انتخاب عمل u از A_i که منجر به اضافه‌شدن یال (t, u) به مجموعه یال‌های s_i می‌شود، پس از مرحله ارزیابی عبارت است از

$$\Delta p_u^t(k)_{e(t,u) \in \tau_i} = ap_u^t(k) \sum_{s \neq u}^r p_s^t(k)(c_s^t(k) - c_u^t(k)) \quad (12)$$

مطابق با (۱۲)، اولاً $p_u^s(k)$ و $p_s^t(k)$ مقادیری مثبت در بازه $(0, 1)$ هستند و ثانیاً از آنجا که $e(t, u) \in S_i$ یالی است که متعلق به زیرگراف بهینه است، توسط آناتماتی A_i انتخاب می‌شود. اما از لم ۲ می‌دانیم که برای مقادیر بزرگ k داریم $c_s^t(k) - c_u^t(k) > 0$, $\forall s \neq u$. بنابراین برای مقادیر بزرگ k طرف راست (۱۲) مقداری مثبت است و در نتیجه $\Delta q_i(k) \geq 0$.

گزاره: $\{\}$ $\in \{+, 0, -\}$ با احتمال ۱ وجود دارد.

لم ۳ بیان کننده آن است که $\{q(k)\}$ یک زیرمارتبنگل است. با استفاده از قضایای حدی مارتینگل و در نظر گرفتن این واقعیت که $\{q(k)\}$ نامنفی و یکنوا محدود است، نتیجه می‌شود که $\lim_{k \rightarrow \infty} q_i(k) = q_i^*$ با احتمال ۱ وجود دارد. علاوه بر این اگر فرض کنیم $q_i(k) \neq q_i^*$ در این صورت با یک احتمال ناصرف به ازای تمام مقادیر k

■. $q_i^* \in \{+, 0, -\}$. بنابراین الزاماً

گزاره قبلی نشان می‌دهد که الگوریتم ممکن است به جواب بهینه همگرا نشود. سعی می‌کنیم حدودی برای تابع احتمال انتخاب زیرگراف بهینه ارائه دهیم و برای این کار از روش [۲۱] استفاده می‌کنیم. فرض کنید مجموعه بردارهای یکه $V_r = \{e_r, e_{r-1}, \dots, e_1\}$ مجموعه حالت‌های

$$\theta_i[x, \underline{q}] \sum_{j=1}^r q_j d_j = q_i d_i \theta_i[x, \underline{q}] + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \theta_i[x, \underline{q}]$$

فلذا (۲۳) به دست می‌آید و تعریف می‌کنیم

$$V[x] = \begin{cases} \frac{\exp(x) - 1}{x}, & x \neq 0 \\ 1, & x = 0. \end{cases}$$

لذا

$$U\theta_i[x, \underline{q}] - \theta_i[x, \underline{q}] \leq -x q_i \theta_i[x, \underline{q}] ((1 - q_i) d_i V[-x(1 - q_i)] - \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j V[x q_i]) \quad (۲۴)$$

شرط لازم برای ابرمنظم بودن $\theta_i[x, \underline{q}]$ آن است که رابطه زیر برقرار باشد

$$(1 - q_i) d_i V[-x(1 - q_i)] - \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j V[x q_i] \geq 0.$$

لذا

$$(1 - q_i) d_i V[-x(1 - q_i)] \geq \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j V[x q_i]$$

یا

$$\frac{V[-x(1 - q_i)]}{V[x q_i]} \geq \frac{\sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j}{(1 - q_i) d_i} \quad (۲۵)$$

در (۲۵) داریم

$$\frac{\sum_{j=1, j \neq i}^r q_j \times d_j}{(1 - q_i) d_i} = \frac{\sum_{j=1, j \neq i}^r q_j \times d_j}{\sum_{j=1, j \neq i}^r q_j \times d_i} = \frac{\sum_{j=1, j \neq i}^r q_j \times \frac{d_j}{d_i}}{\sum_{j=1, j \neq i}^r q_j}$$

لذا

$$\begin{aligned} \prod_{e(m,n) \in S_i - S_j} \{P_n^m(1-a)\} &= \\ \frac{\prod_{e(m,n) \in S_i - S_j} \{P_n^m(1-a)\} \prod_{e(m,n) \in S_i \cap S_j} \{P_n^m(1-a)\}}{\prod_{e(m,n) \in S_i} \{P_n^m(1-a)\}} &= \\ \frac{\prod_{e(m,n) \in S_i} \{P_n^m(1-a)\}}{\prod_{e(m,n) \in S_i \cap S_j} \{P_n^m(1-a)\}} \end{aligned} \quad (۱۹)$$

با توجه به این که $q_i = \prod_{e(m,n) \in T_i} P_n^m$ و (۱۶) تا (۱۹) خواهیم داشت

$$\begin{aligned} U\theta_i[x, \underline{q}] &= q_i d_i \times \exp\left\{-\frac{x}{a}(q_i + a(1 - q_i))\right\} + \\ &\quad \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \exp\left\{-\frac{x q_j (1-a)}{a} D(P_n^m)\right\} + \\ &\quad \theta_i[x, \underline{q}] - \theta_i[x, \underline{q}] \sum_{j=1}^r q_j \times d_j \end{aligned} \quad (۲۰)$$

اما روشن است که

$$D(P_n^m) = \frac{\prod_{\substack{j=1 \\ e(m,n) \in S_i \cap S_j}} \{P_n^m + a(1 - P_n^m)\}}{\prod_{e(m,n) \in S_i \cap S_j} \{P_n^m(1-a)\}} \geq 1$$

با توجه به نزولی بودن تابع e^{-x} داریم

$$\exp\left\{-\frac{x}{a} q_i (1-a)\right\} \frac{\prod_{\substack{j=1 \\ e(m,n) \in S_i \cap S_j}} \{P_n^m + a(1 - P_n^m)\}}{\prod_{e(m,n) \in S_i \cap S_j} \{P_n^m(1-a)\}} \leq \quad (۲۱)$$

$$\exp\left\{-\frac{x}{a} q_i (1-a)\right\}$$

از (۲۰) و (۲۱) به (۲۲) می‌رسیم

$$\begin{aligned} U\theta_i[x, \underline{q}] - \theta_i[x, \underline{q}] &\leq q_i d_i \times \exp\left\{-\frac{x}{a}(q_i + a(1 - q_i))\right\} + \\ &\quad \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j \times \exp\left\{-\frac{x}{a} q_j (1-a)\right\} - \theta_i[x, \underline{q}] \sum_{j=1}^r q_j d_j \end{aligned} \quad (۲۲)$$

اما

$$\begin{aligned} \sum_{j=1}^r \exp\left(\frac{-x q_j (k+1)}{a}\right) q_j d_j &= q_i d_i \exp\left(\frac{-x \prod_{e(m,n) \in S_i} \{P_n^m + a(1 - P_n^m)\}}{a}\right) \\ &+ \sum_{j=1, j \neq i}^r q_j d_j \exp\left(\frac{-x \prod_{\substack{e(m,n) \in S_i \cap S_j} \{P_n^m + a(1 - P_n^m)\}} \prod_{e(m,n) \in S_i - S_j} \{P_n^m(1-a)\}}{a}\right) \end{aligned} \quad (۲۴)$$

$$\sum_{j=1}^r \exp\left(\frac{-x q_j (k)}{a}\right) \times q_j \times (1 - d_j) = \theta_i[x, \underline{q}] \sum_{j=1}^r q_j \times (1 - d_j) = \theta_i[x, \underline{q}] - \theta_i[x, \underline{q}] \sum_{j=1}^r q_j \times d_j \quad (۲۵)$$

$$U\theta_i[x, \underline{q}] - \theta_i[x, \underline{q}] \leq q_i d_i (\exp\left\{-\frac{x}{a}(q_i + a(1 - q_i))\right\} - \theta_i[x, \underline{q}]) + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j (\exp\left\{-\frac{x}{a} q_j (1-a)\right\} - \theta_i[x, \underline{q}]) =$$

$$\theta_i[x, \underline{q}] (q_i d_i \exp\left\{-x(1 - q_i)\right\} - 1 + \sum_{\substack{j=1 \\ j \neq i}}^r q_j d_j (\exp\left\{x q_j\right\} - 1)) =$$

$$-x q_i \theta_i[x, \underline{q}] ((1 - q_i) d_i \frac{\exp\left\{-x(1 - q_i)\right\} - 1}{-x(1 - q_i)} - \sum_{\substack{j=1 \\ j \neq i}}^r q_j \times d_j \frac{\exp\left\{x q_j\right\} - 1}{x q_j})$$

لازم از یال i است لذا

$$\frac{z_{\alpha}}{\tau} \times \frac{\delta_i}{\sqrt{n_i}} = t_{\alpha/\tau, k-1} \times \frac{S}{(|V|-1)\sqrt{k}} \quad (30)$$

و با حل (۳۰) خواهیم داشت

$$n_i = \left(\frac{z_{\alpha}}{\tau} \right)^{\tau} \times \frac{k(|V|-1)^{\tau}}{S^{\tau}} \times \delta_i^{\tau} \quad (31)$$

و نتیجه نهایی در (۳۱) از مجموعگیری تعداد نمونه‌ها روی یال‌ها در (۳۱) به دست می‌آید

$$n = \sum_{i=1}^{|E|} n_i = \left(\frac{z_{\alpha}}{\tau} \right)^{\tau} \times \frac{k(|V|-1)^{\tau}}{S^{\tau}} \times \sum_{i=1}^{|E|} \delta_i^{\tau} \quad (32)$$

■

قضیه ۲: اگر n تعداد نمونه‌های مورد نیاز در روش نمونه‌گیری استاندارد و m تعداد نمونه‌های مورد نیاز در روش مبتنی بر eDLA برای تضمین یک بازه اطمینان مشخص و یکسان، بالای ۹۰٪، باشد، در این صورت یک کران پایین برای نسبت n/m برابر است با

$$\frac{n}{m} \geq |E| \times \frac{\min_i \delta_i^{\tau}}{\max_i \delta_i^{\tau}}$$

که در آن $|E|$ تعداد یال‌های گراف تصادفی است.

اثبات: مطابق لم قبل اگر k تعداد نمونه‌گیری از زیرگراف تصادفی به کمک eDLA و n تعداد نمونه‌های لازم در نمونه‌گیری استاندارد باشد، یک کران پایین برای n به منظور تضمین بازه اطمینان و دقتی معادل با روش eDLA از (۳۲) به دست می‌آید. اما هر نمونه از زیرگراف ایجادشده توسط eDLA حداکثر شامل $|V|-1$ نمونه‌گیری از یال‌های گراف تصادفی است و اگر m تعداد کل نمونه‌های گرفته شده از یال‌ها در روش مبتنی بر eDLA باشد، داریم $(|V|-1) \leq m \leq k \times (|V|-1)$ و لذا

$$\frac{n}{m} \geq \left(\frac{z_{\alpha}}{\tau} \right)^{\tau} \times \frac{|V|-1}{S^{\tau}} \times \sum_{i=1}^{|E|} \delta_i^{\tau} \quad (33)$$

با فرض $1-\alpha \geq 90\%$ به عنوان بازه اطمینان مشترک، $k \geq 120$ و $|V|-1 \geq 5$ داریم

$$t_{\alpha/\tau, k-1} = 1.645 \cong z_{\alpha}$$

با قراردادن این مقادیر در (۳۳) به (۳۴) می‌رسیم

$$\frac{n}{m} \geq (|V|-1) \times \sum_{i=1}^{|E|} \delta_i^{\tau} \quad (34)$$

الگوریتم مبتنی بر eDLA در هر مرحله حداکثر $|V|-1$ یال را از میان مجموعه یال‌های گراف برای ساخت زیرگراف انتخاب می‌کند. اگر طول زیرگراف را با متغیر تصادفی X و طول هر یک از یال‌های گراف نظری یال i را با متغیر تصادفی Y_i نشان دهیم، داریم

$$X = \sum_i Y_i \quad , \quad i \in M \quad , \quad |M| \leq |V|-1 \quad , \quad M \subset E \quad (35)$$

که M نشان‌دهنده زیرگراف تشکیل شده در هر مرحله توسط eDLA است و از (۳۵) و بر اساس قضایای محاسبه واریانس (۳۶) نتیجه می‌شود

$$\min_{j \neq i} \frac{d_j}{d_i} \leq \frac{\sum_{j=1, j \neq i}^r q_j \times \frac{d_j}{d_i}}{\sum_{j=1, j \neq i}^r q_j} \leq \max_{j \neq i} \frac{d_j}{d_i} \quad (26)$$

با جایگذاری (۲۶) در (۲۵) شرط ابرمنظم بودن به (۲۷) تقلیل می‌یابد

$$\frac{V[-x(1-q_i)]}{V[xq_i]} \geq \min_{j \neq i} \frac{d_j}{d_i} \quad (27)$$

تعریف می‌کنیم $H[x] = \ln V[x]$. با توجه به محدب بودن $H[x]$ می‌توان نشان داد [۲۱]

$$\frac{1}{V[x]} \leq \frac{V[-x(1-q_i)]}{V[xq_i]} \leq V[-x] \quad (28)$$

از آنجا که $V[-x]$ تابعی پیوسته و یکنوا کاهشی با $V[+]=1$ است مقدار $x=x^*$ وجود دارد که برای تمام مقادیر در بازه $x \in (0, x^*)$ داریم $\min_{j \neq i} (d_j/d_i) = V[-x^*] \leq V[-x]$ نابرایری (۲۵)

ارضا خواهد شد که در این صورت $\theta_i[x, q] = \Phi_i[x, q]$ ابرمنظم خواهد بود.

با توجه به لم ۴ و تعریف تابع $\Phi_i[x, q]$ با انتخاب $x=x^*$ نابرایری هر $\varepsilon > 0$ مفروض، ثابت مثبت $1 - \varepsilon \leq \Phi_i[x, q] \leq \Gamma_i[q]$ با فقرار است که نابرایری $\Phi_i[x, q]$ کامل می‌شود. ■

لم ۵: اگر مجموعه زیرگراف‌های حاصل از به کارگیری eDLA برای حل مسئله زیرگراف بهینه تصادفی مجموعه $\{s_1, s_2, \dots, s_k\}$ با وزن‌های $\{w_1, w_2, \dots, w_k\}$ باشد و نیز با فرض

$$S^{\tau} = \frac{\sum_{i=1}^k w_i^{\tau}}{k}$$

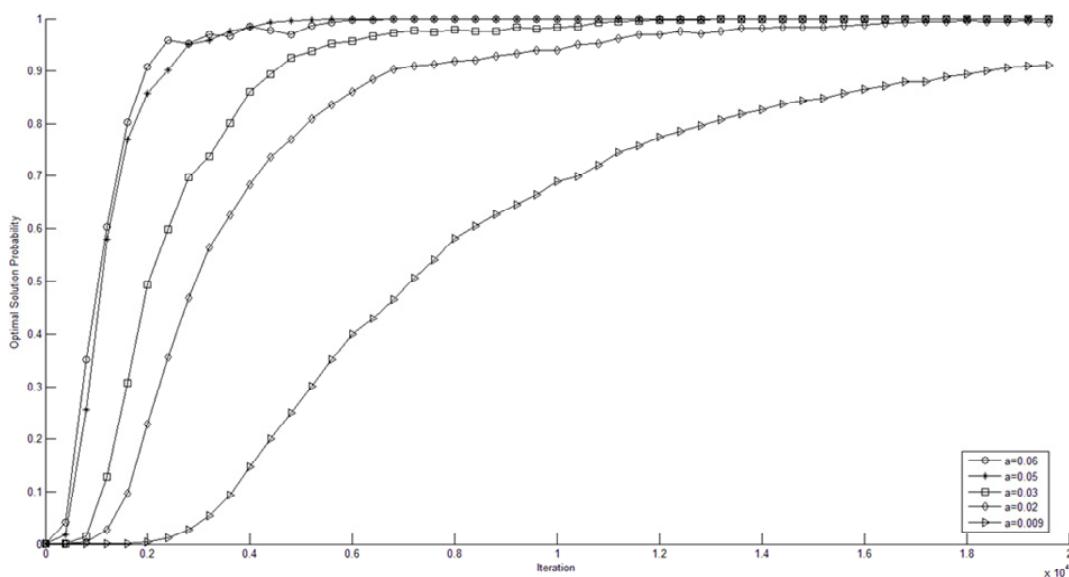
در این صورت تعداد کل نمونه‌های لازم از یال‌ها در روش نمونه‌گیری استاندارد برابر است با

$$n = \left(\frac{z_{\alpha}}{\tau} \right)^{\tau} \times \left(\frac{k(|V|-1)^{\tau}}{S^{\tau}} \right) \times \sum_{i=1}^{|E|} \delta_i^{\tau} \quad (29)$$

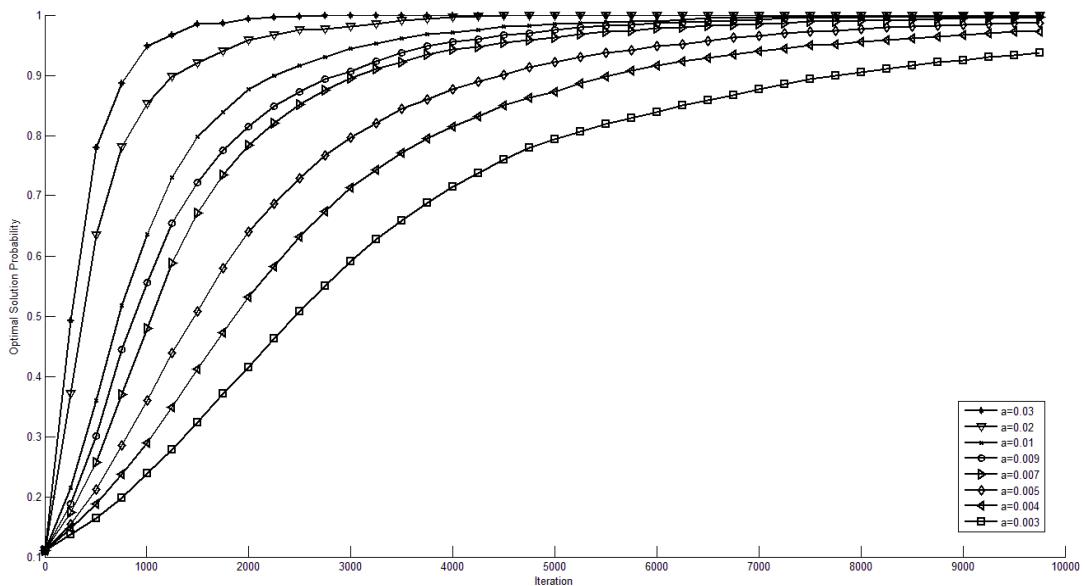
که k تعداد نمونه‌های حاصل از الگوریتم ۱ مبتنی بر δ_i^{τ} eDLA واریانس یال i و S^{τ} و توزیع‌های نرمال و t-student هستند.

اثبات: با توجه به نامشخص بودن واریانس جامعه اصلی (وزن زیرگراف‌های بهینه) و بر اساس قضایای مربوط به نمونه‌گیری، می‌توان متغیر تصادفی وزن مجموعه زیرگراف‌های نمونه‌گیری کرد شده توسط eDLA را با یک توزیع t با $k-1$ درجه آزادی تخمین زد [۲۲] و [۲۳]. در این صورت حدود اطمینان بازه $(1-\alpha) \pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ مبتنی بر این توزیع برابر است با $\pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$. اما اگر فرض کنیم با استفاده از نمونه‌گیری تصادفی از یال‌های گراف تصادفی نمونه‌گیری کرده باشیم و با استناد به قضیه تصحیح Bonferroni و با توجه به این که بیشترین طول یک زیرگراف $-1 \leq |V| \leq 1$ است، اگر حدود اطمینان برای هر یک از یال‌ها $(1-\alpha) \pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ در بازه $(1-\alpha) \pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ باشد در این صورت مطابق حدود اطمینان $\pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ برای زیرگراف‌ها با $(1-\alpha) \pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ تضمین شده است.

اما حدود اطمینان بازه $(1-\alpha) \pm t_{\alpha/\tau, k-1} \times S/\sqrt{k}$ برای هر یک از یال‌ها مثل یال i تعداد نمونه‌های n_i برابر است با $\pm z_{\alpha/\tau} \times \delta_i / \sqrt{n_i}$ که در این رابطه n_i تعداد نمونه‌های



شکل ۶: نحوه تغییر احتمال درخت پوشای کمینه بهینه (جواب مسأله) در حین تکرار الگوریتم در شبکه alex1-b به ازای مقادیر مختلف نرخ یادگیری.



شکل ۷: نحوه تغییر احتمال مسیر بهینه (جواب مسأله) در حین تکرار الگوریتم در گراف Net4 به ازای مقادیر مختلف نرخ یادگیری.

از [۲۴] مورد بررسی قرار داده ایم. هدف از این آزمایش، بررسی نحوه همگرایی الگوریتم مبتنی بر eDLA به جواب بهینه بوده است. در آزمایش اول از eDLA برای یافتن درخت پوشای کمینه استفاده شده و به ازای هر نرخ یادگیری، الگوریتم دقیقاً ۲۰۰۰۰ دور اجرا شده ۲۰۰۰۰ درخت پوشای انتخاب گردیده و الگوریتم یادگیری مورد استفاده توسط آناتماتاها الگوریتم خطی L_{R-I} بوده است. این کار ۱۰۰ بار تکرار شده و متوسط احتمال انتخاب مسیر بهینه محاسبه شده که نتایج مقایسه ای را در شکل ۶ مشاهده می کنید.

در آزمایش دوم از eDLA برای یافتن کوتاهترین مسیر در گراف تصادفی میان یک مبدأ و مقصد مشخص استفاده شده است. در این آزمایش نیز به ازای هر نرخ یادگیری، الگوریتم دقیقاً ۱۰۰۰۰ دور اجرا شده است (۱۰۰۰۰ مسیر). برای محاسبه مقادیر احتمالات مربوط به مسیر بهینه این کار ۱۰۰ دور انجام شده و نتایج متوسط محاسبه شده است. مقادیر احتمال انتخاب مسیر بهینه به ازای مقادیر مختلف نرخ یادگیری را در شکل ۷ مشاهده می کنید. در اینجا نیز الگوریتم یادگیری مورد استفاده توسط آناتماتاها، الگوریتم خطی L_{R-I} بوده است.

$$s^r = \text{Var}(X) = \sum_i \text{Var}(Y_i) \quad , \quad i \in M, |M| \leq |V|-1, M \subset E \quad (36)$$

$$\text{اما داریم } s^r \leq (|V|-1) \times \max_i \delta_i^r \quad \text{و} \quad \sum_{i=1}^{|E|} \delta_i^r \geq |E| \times \min_i \delta_i^r \quad \text{و لذا} \\ \frac{\sum_{i=1}^{|E|} \delta_i^r}{s^r} \geq \frac{|E|}{|V|-1} \times \frac{\min_i \delta_i^r}{\max_i \delta_i^r} \quad (37)$$

به این ترتیب از (۳۶) و (۳۷) نتیجه (۳۸) به دست می آید

$$\frac{n}{m} \geq |E| \times \frac{\min_i \delta_i^r}{\max_i \delta_i^r} \quad (38)$$

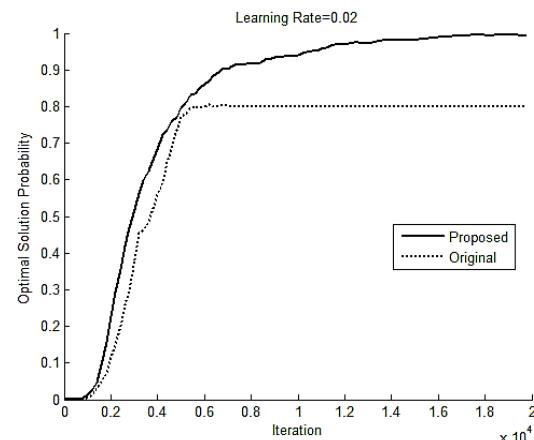
۵- بررسی تجربی

برای بررسی قضیه ۱ در روش پیشنهادی، بر اساس جدول ۱ و الگوریتم ۱ ارائه شده در این مقاله، مسایل یافتن کوتاهترین مسیر تصادفی و درخت پوشای کمینه تصادفی را به ترتیب در گراف های Net4 از [۴] و

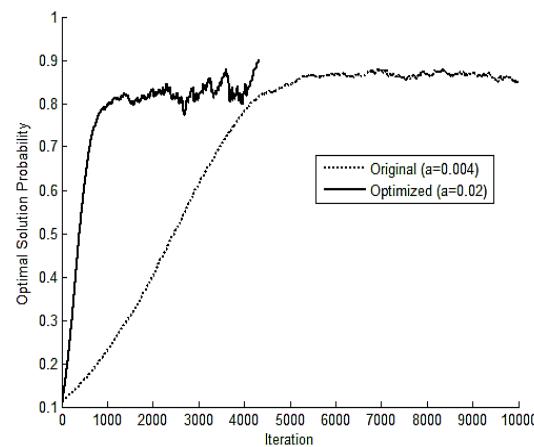
مختلف فعال بودن، محدودیت DLA در نحوه فعال سازی آناتماتاها را مرتفع کرده و از این شبکه از آناتماتاها به عنوان چارچوبی یک دست برای حل مسائل مختلف بهینه سازی روی گراف های تصادفی استفاده کند. بررسی های ریاضی نشان داد که در صورت وجود زیر گراف بهینه، الگوریتم مبتنی بر eDLA با احتمال ۱ به جواب بهینه همگرا می شود. علاوه بر این یک کران پایین برای نسبت تعداد نمونه های لازم در روش استاندارد به روش مبتنی بر eDLA برای یافتن جواب (با دقت یکسان) ارائه شد. به کارگیری eDLA برای حل مسائل بهینه سازی جایگشت تصادفی در دست بررسی است.

مراجع

- [1] K. S. Narendra and M. A. L. Thathachar, "Learning automata: a survey," *IEEE Trans. Syst. Man, Cybernetics*, vol. 14, no. 4, pp. 323-334, 1974.
- [2] M. L. Thathachar and P. S. Sastry, "Varieties of learning automata: an overview," *IEEE Trans. Syst. Man. Cybern. B. Cybern.*, vol. 32, no. 6, pp. 711-722, Jan. 2002.
- [3] H. Beigy and M. Meybodi, Intelligent Channel Assignment in Cellular Networks: A Learning Automata Approach, Amirkabir University of Technology, 2004.
- [4] H. Beigy and M. R. Meybodi, "Utilizing distributed learning automata to solve stochastic shortest path problems," *Int. J. Uncertainty, Fuzziness Knowledge-Based Syst.*, vol. 14, no. 5, pp. 591-615, Oct. 2006.
- [5] M. R. Meybodi and H. Beigy, "A sampling method based on distributed learning automata," in *Proc. the 10th Iranian Conf. on Electrical Engineering*, vol. 1, pp. 618-626, May 2002.
- [6] M. R. Mollakhalil Meybodi and M. R. Meybodi, "A new distributed learning automata based algorithm for solving stochastic shortest path," presented at *6th Conf. on Intelligent Systems*, 2004.
- [7] M. R. Meybodi and H. Beigy, "Solving stochastic shortest path problem using Monte Carlo sampling method: a distributed learning automata approach," *Neural Networks and Soft Computing*, Physica-Verlag HD, pp. 626-632, 2003.
- [8] A. Motevalian and M. R. Meybodi, "Solving maximal independent set problem using distributed learning automata," in *Proc. 14th Iranian Electrical Engineering Conf., ICEEE2006*, Tehran, Iran, 16-18 May, 2006.
- [9] A. Alipour and M. R. Meybodi, "Solving traveling salesman problem using distributed learning automata," in *Proc. 10th Annual CSI Computer Conf.*, pp. 759-761, Tehran, Iran, Feb. 2005.
- [10] S. Saati and M. Meybodi, "A self organizing model for document structure using distributed learning automata," in *Proc. 2nd Int. Conf. on Information and Knowledge Technology, IKT2005*, Tehran, Iran, 24-26 May, 2005.
- [11] Z. Anari, M. R. Meybodi, and B. Anari, "Web page ranking based on fuzzy and learning automata," in *Proc. Int. Conf. Manag. Emergent Digit. Ecosyst., MEDES'09*, pp. 162-166, Lion, France, 27-31 Oct. 2009.
- [12] M. R. Mollakhalil Meybodi and M. R. Meybodi, "Link prediction in adaptive web sites using distributed learning automata," in *Proc. 13th Annual CSI Computer Conf. of Iran*, Kish Island, Iran, 9-11, Mar. 2008.
- [13] M. R. Mollakhalil Meybodi and M. R. Meybodi, "A distributed learning automata based approach for user modeling in adaptive hypermedia," in *Proc. Congress on Electrical, Computer, and Information Technology*, 2012.
- [14] A. Baradaran Hashemi and M. R. Meybodi, "Web usage mining using distributed learning automata," in *Proc. 12th Annual CSI Computer Conf. of Iran*, pp. 553-560, 2007.
- [15] S. Misra and B. J. Oommen, "Dynamic algorithms for the shortest path routing problem: learning automata - based solutions," *IEEE Trans. Syst. Man. Cybern. B. Cybern.*, vol. 35, no. 6, pp. 1179-1192, Dec. 2005.
- [16] K. Liu, Stochastic Online Learning for Network Optimization under Random Unknown Weights, 18 pp. 1-18.
- [17] K. S. Narendra and M. A. L. Thathachar, *Learning Automata: An Introduction*, Prentice Hall, p. 476, 1989.
- [18] S. Lakshminarahan and M. A. L. Thathachar, "Absolutely expedient learning algorithms for stochastic automata," *IEEE Trans. Syst. Man Cybern.*, vol. 6, pp. 281-286, 1973.



شکل ۸: مقایسه تغییرات احتمال درخت پوشای بهینه در الگوریتم پیشنهادی (Proposed) و الگوریتم ارائه شده در [۲۵] (Original) در نزد یادگیری ۰.۰۲ در گراف .alex)-b



شکل ۹: مقایسه سرعت همگرایی الگوریتم پیشنهادی مقاله (Optimal) در برابر الگوریتم مبتنی بر DLA [۴] (Original) (در حالت حداقل های لازم برای همگرایی٪۱۰۰).

مقادیر آستانه مقایسه برای تنبیه یا پاداش به زیر گراف انتخاب شده توسط eDLA نیز در هر دو الگوریتم بر اساس پیشنهاد ارائه شده در این مقاله و با دخالت دادن واریانس محاسبه شده است.

شکل های ۶ و ۷ صحت قضیه ۱ را نشان می دهند. علاوه بر این نشان می دهند روش فعلی ارائه شده بر خلاف روش های قبلی برای حل این مسائل در [۴] و [۲۰] تقریباً مستقل از نزد یادگیری، سرعت همگرایی بالاتری دارد.

مقایسه الگوریتم پیشنهادی برای حل مسائل درخت پوشای کمینه تصادفی و کوتاه ترین مسیر تصادفی که به ترتیب در [۲۵] و [۴] ارائه شده اند حاکی از عملکرد بهتر روش پیشنهادی است. در آزمایش انجام شده در مورد درخت پوشای کمینه تصادفی این بهبود می تواند هم ناشی از ساختار پیشنهادی و هم ناشی از معیار جدید مقایسه ای باشد (شکل ۸) در حالی که در مورد کوتاه ترین مسیر تصادفی به دلیل این که DLA و eDLA یکسان عمل می کنند، بهبود نتایج قطعاً ناشی از معیار مقایسه ای جدید است (شکل ۹).

۶- نتیجه گیری

در این مقاله، چارچوبی جدید مبتنی بر آناتماتاها یادگیر موسوم به eDLA برای حل مسئله یافتن زیر گراف بهینه در گراف های تصادفی ارائه گردید. نشان داده شد که این ساختار می تواند از طریق تعریف سطوح

محمد رضا ملاخلیلی مبیدی تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی کامپیوتر به ترتیب در سال های ۱۳۸۰ و ۱۳۸۲ از دانشگاه های شهید بهشتی و صنعتی امیرکبیر تهران و دکترای مهندسی کامپیوتر را در سال ۱۳۹۳ در واحد علوم و تحقیقات دانشگاه آزاد به پایان رسانده است. وی هم‌اکنون عضو هیأت علمی دانشگاه آزاد اسلامی واحد مبید است. زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: شبکه های کامپیوتری و وب، شبکه های مبتنی بر نرم افزار، محاسبات نرم و کاربردهای آن، یادگیری والگوریتم ها، گراف های تصادفی و شبکه های پیچیده.

محمد رضا میبدی تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد اقتصاد به ترتیب در سال های ۱۳۵۲ و ۱۳۵۶ از دانشگاه شهید بهشتی و در مقاطع کارشناسی ارشد و دکتری علوم کامپیوتر به ترتیب در سال های ۱۳۵۹ و ۱۳۶۲ از دانشگاه اوکلاهما آمریکا به پایان رسانده است و هم‌اکنون استاد دانشکده مهندسی کامپیوتر دانشگاه صنعتی امیرکبیر می باشد. نامبرده قبل از پیوستش به دانشگاه صنعتی امیرکبیر در سال های ۱۳۶۴ الی ۱۳۶۲ استادیار دانشگاه میشیگان غربی و در سال های ۱۳۶۴ الی ۱۳۷۰ دانشیار دانشگاه اوهايو در ایالات متحده آمریکا بوده است. زمینه های تحقیقاتی مورد علاقه ایشان عبارتند از: الگوریتم های موازی، پردازش موازی، محاسبات نرم و کاربردهای آن، شبکه های کامپیوتری و مهندسی نرم افزار.

- [19] M. A. L.Thathachar and B. Harita, "Learning automata with changing number of actions," *IEEE Trans. Syst. Man, Cybern.-Part A Syst. Humans*, vol. 17, no. 6, pp. 1095-1100, Dec. 1987.
- [20] J. Akbari Torkestani and M. R. Meybodi, "A learning automata-based heuristic algorithm for solving the minimum spanning tree problem in stochastic graphs," *J. Supercomput.*, vol. 59, no. 2, pp. 1035-1054, Oct. 2012.
- [21] F. Norman, "On the linear model with two absorbing," *J. Math. Psychol.*, vol. 5, pp. 225-241, Jun. 1968.
- [22] A. Papoulis, *Probability, Random Variables, and Stochastic Processes*, 3rd ed. New York, USA: McGrawHill, 1991.
- [23] S. M. Ross, *Introduction to Probability and Statistics for Engineers and Scientists*, 3rd Ed., Elsevier Academic Press, 2004.
- [24] K. R. Hutson and D. R. Shier, *Online Supplement to 'Bounding Distributions for the Weight of a Minimum Spanning Tree in Stochastic Networks'*, 12 pp.
- [25] J. Akbari Torkestani and M. R. Meybodi, "Learning automata - based algorithms for solving stochastic minimum spanning tree problem," *Appl. Soft Comput.*, vol. 11, no. 6, pp. 4064-4077, Sep. 2011.