مقايسة اتوماتون يادگير و روشهاي استاندارد و پيشرفتة مبتني بر سردكردن فلزات براي آموزش سراسري مدل پنهان ماركف

جهانشاه كبوديان[۱]، محمدرضا ميبدي[۲]، محمدمهدي همايون‌پور[۳]

۱ و۳- آزمايشگاه پردازش هوشمند سيگنالهاي صوتي و گفتاري،
۲- آزمايشگاه محاسبات نرم،
دانشكدة مهندسي كامپيوتر و فناوري اطلاعات، دانشگاه صنعتي اميركبير(پلي‌تكنيك تهران)، تهران.
{kabudian, meybodi, homayoun}@ce.aut.ac.ir

چكيده

مشهورترين روش آموزش مدل پنهان ماركف روش BW[1] مي‌باشد كه يك روش آموزش محلي است و در دام بهينه‌هاي محلي گرفتار مي‌شود. در اين مقاله روش مبتني بر اتوماتون يادگير تقويتي با عمل پيوسته(CARLA[2]) براي اولين بار براي آموزش سراسري مدل پنهان ماركف استفاده شده و همچنين با روشهاي استاندارد و پيشرفتة مبتني بر سرد كردن فلزات(SA[3]) مقايسه شده است. آزمايشهاي انجام شده نشان مي‌دهند كه روش CARLA نسبت به روش استاندارد سردكردن فلزات يعني BA[4] داراي راندمان بالاتري است ولي روشهاي سريع و بسيار سريع مبتني بر سردكردن فلزات يعني FA[5] و VFA[6] بهتر از CARLA هستند.

كلمات كليدي: مدل پنهان ماركف، سردكردن فلزات، سردكردن سريع، سردكردن بسيار سريع، اتوماتون يادگير تقويتي با عمل پيوسته، جستجوي سراسري، بهينه‌سازي سراسري.

۱- مقدمه

مدل پنهان ماركف يكي از ابزارهاي بسيار قوي در پردازش فرآيندهاي اتفاقي و دنباله‌هاي تصادفي است. مشهورترين و پركاربردترين روش آموزش مدل پنهان ماركف روش بام- ولش است كه در واقع يك روش جستجوي محلي است و مانند روشهاي ديگر جستجوي محلي در دام بهينه‌هاي محلي گرفتار مي‌آيد. براي رفع اين ايراد، از روشهاي جستجو و بهينه‌سازي سراسري براي آموزش بهينه مدل ماركف استفاده شده است كه مي‌توانند به راحتي از بهينه‌هاي محلي بگريزند. هدف از اين كار تحقيقي، مقايسه دو دسته از روشهاي جستجو و بهينه سازي سراسري براي آموزش مدل پنهان ماركف مي‌باشد.

---

[1] Baum-Welch
[2] Continuous Action Reinforcement Learning Automata
[3] Simulated Annealing
[4] Boltzmann Annealing
[5] Fast Annealing (Cauchy Annealing)
[6] Very Fast Annealing

در بخش دوم به معرفي مدل پنهان ماركف پيوسته خواهيم پرداخت. در بخش سوم روش بام-ولش را به اختصار توضيح مي‌دهيم. در بخش چهارم روشهاي جستجوي سراسري مبتني بر SA و اتوماتون يادگير(CARLA) را تشريح خواهيم كرد و در پايان نيز به ارائه نتايج آزمايشهاي انجام شده و نتيجه‌گيري مي‌پردازيم.

۲- مدل پنهان ماركف

يكي از ابزارهاي بسيار قدرتمند در مدل كردن فرآيندهاي اتفاقي و دنباله‌هاي تصادفي، مدل پنهان ماركف مي‌باشد. مدل پنهان ماركف، خود داراي دو نوع پيوسته و گسسته است كه نوع گسسته آن در حال حاضر براي مشاهدات پيوسته به ندرت استفاده مي‌گردد. مدل ماركف داراي تعدادي حالت (N) است كه بطور احتمالي و با احتمال گذر بين حالات، تغيير حالت مي‌دهد. فرض كنيد دنباله‌اي از مشاهدات را كه طول دنباله T مي‌باشد، توسط اين مدل مي‌خواهيم توليد كنيم. دنباله مشاهدات چنين تعريف مي‌گردد:

$$O = \{o_1 o_2 ... o_t ... o_T\} \qquad (۱)$$

هر كدام از بردارهاي مشاهده o_t يك بردار D بعدي مي‌باشد كه t انديس زمان است. مدل با شروع زمان و بازاي t=1 با احتمال π_i در حالت i قرار مي‌گيرد و با احتمال a_{ij} از حالت i به حالت j تغيير حالت مي‌دهد و در حالت i يك بردار تصادفي o را با توجه به تابع چگالي احتمال $b_i(o)$ توليد مي‌كند. تابع چگالي احتمال $b_i(o)$ در مدل پنهان ماركف پيوسته معمولاً يك مخلوط از توابع گاوسي يا نرمال چند بعدي به شكل زير است:

$$b_i(o) = \sum_{m=1}^{M} c_{im} N(o, \mu_{im}, C_{im}) \qquad (۲)$$

منظور از $N(o, \mu, C)$ يك تابع چگالي احتمال گاوسي D بعدي با بردار ميانگين μ و ماتريس كوواريانس C به شكل زير است:

$$N(o, \mu, C) = \frac{1}{\sqrt{(2\pi)^D . |\det(C)|}} . \exp(-\frac{1}{2}(o-\mu)^T C^{-1} (o-\mu)) \qquad (۳)$$

فرض بر اين است كه مشاهدات o_t هر كدام يك بردار ستوني D×1 باشند. واضح است كه براي برقراري شرط يك شدن سطح زير منحني تابع چگالي احتمال بايد داشته باشيم:

$$\sum_{m=1}^{M} c_{im} = 1 \qquad (۴)$$

M تعداد توابع گاوسي در يك مخلوط گاوسي در هر حالت است. همچنين بايد داشته باشيم:

$$\sum_{i=1}^{N} \pi_i = 1 \quad و \quad \sum_{j=1}^{N} a_{ij} = 1 \qquad (۵)$$

C^{-1} معكوس ماتريس C و $|\det(C)|$ قدرمطلق دترمينان ماتريس C مي‌باشد. مدل پنهان ماركف λ با پارامترهاي $b(), A, \pi$ چنين نمايش داده ميشود:

$$\lambda = (\pi, A, b()) \qquad (۶)$$

كه منظور از b() در واقع وزنهاي توابع گاوسي (c_{im})، بردارهاي ميانگين (μ_{im}) و ماتريس‌هاي كوواريانس (C_{im}) است.

۳- آموزش مدل پنهان ماركف با الگوريتم **BW**

در بكارگيري مدل پنهان ماركف، يك يا چند نمونه از دنباله‌هاي مشاهدات توسط يك مدل ناشناخته λ توليد شده است و هدف پيدا كردن پارامترهاي مدل λ يعني پارامترهاي $b(), A, \pi$ است و نتيجتاً مدل پنهان ماركف λ مشخص خواهد شد.

مشهورترين و پراستفاده ترين روش براي آموزش مدل پنهان ماركف، الگوريتم BW است. هدف الگوريتم BW پيدا كردن مدل λ^* است، طوري كه احتمال توليد رشته مشاهدات O توسط اين مدل بيشينه باشد:

$$\lambda^* = \arg \max_{\lambda} P(O|\lambda) \qquad (۷)$$

روش بام- ولش به اين صورت عمل مي‌كند كه ابتدائاً يك حدس اوليه بصورت اتفاقي و يا با استفاده از روشهاي ابتكاري براي مدل توليد مي‌شود. آنگاه در هر مرحله، يك تخمين از پارامترهاي مدل در مرحله قبل و با توجه به رشته مشاهدات بدست مي‌آيد و اين تكرار و تخمين آنقدر ادامه مي‌يابد تا مدل همگرا شود. نكته بسيار مهمي كه در مورد الگوريتم BW وجود دارد اين است كه بر حسب اينكه نقطه شروع اوليه چه باشد، اين الگوريتم به بهينه‌هاي محلي مختلف همگرا خواهد شد. براي فرار از به دام افتادن در بهينه‌هاي محلي بايد از روشهاي جستجوي سراسري يا بهينه‌سازي سراسري استفاده كرد. براي جلوگيري از اطالة كلام از جزئيات الگوريتم BW خودداري خواهيم كرد و مرجع بسيار خوب [1] را پيشنهاد مي‌كنيم.

٤- روشهاي جستجو و بهينه‌سازي سراسري

براي حل مسائل بصورت نزديك به بهينة سراسري از روشهاي جستجوي سراسري يا بهينه‌سازي سراسري استفاده مي‌شود. از جمله اين روشها ميتوان به روش سرد كردن فلزات(SA)، روش الگوريتمهاي ژنتيكي(GA)[2] ، روش استراتژي تكاملي(ES)[2] و روش برنامه‌ريزي تكاملي(EP)[2] اشاره كرد. براي بهينه‌سازي سراسري روشهاي ديگري نيز وجود دارد[9]. به تازگي نيز يك روش اتوماتون يادگير تقويتي با مقدار عمل پيوسته(CARLA) براي بهينه‌سازي سراسري در محيطهاي پيوسته ابداع شده است[7,8]. در اين تحقيق تصميم گرفته شد از ميان روشهاي فوق، روشهاي مبتني بر SA و روش CARLA براي آموزش HMM استفاده شود.

٤-١ روش سردكردن فلزات

يكي از روشهاي جستجو و بهينه‌سازي سراسري كه بر اصول ترموديناميك مبتني است و از ديد آماري تضمين مي‌كند كه در صورت رعايت كردن روند كاهش دما(Temperature Schedule) بهينه سراسري را پيدا خواهد كرد، روش آب‌دادن فلزات يا روش سردكردن فلزات(SA) است[3]. اين روش كاربرد بسيار زيادي هم در مسائل گسسته و هم در مسائل پيوسته دارد[4,5]. طرز كار SA به اين صورت است كه در هر تكرار با استفاده از يك تابع چگالي احتمال توليد[۷] g(x) ، يك نقطه تصادفي را در حول و حوش نقطه جواب قبلي، توليد مي‌كند، تابع هزينه E(x) را بازاي اين نقطه محاسبه مي‌نمايد و با استفاده از يك تابع احتمال پذيرش[۸] h(x) نقطه جديد را بطور احتمالي قبول يا رد مي‌نمايد. اگر نقطه جديد داراي راندمان بهتري نسبت به نقطه قبلي باشد، احتمال قبول آن بيشتر است. البته در ابتداي جستجو كه مقدار دما زياد مي‌باشد و محدوده جستجو وسيع است، احتمال قبول و رد نقطه جديد يكسان است(1/2). با كاهش دما و نزديك شدن به نقاط بهينة پيدا شده، محدوده جستجو براي بالا بردن دقت و رزولوشن، كمتر مي‌گردد. در بخشهاي بعدي، روشهاي SA را شرح خواهيم داد.

٤-١-١ روش **SA** استاندارد يا **BA**

روش BA به اين صورت عمل مي‌كند[4,5] :

١- مقدار اوليه براي دما (T_1) و يك نقطة اوليه (x_1) انتخاب مي‌شود.

---

[7] Generating Function
[8] Acceptance Function

۲- $x^* = x_1 \quad , \quad k = 1$

۳- با استفاده از تابع چگالي احتمال توليد g(x) ، يك نقطة جديد x بطور تصادفي در همسايگي x^* انتخاب مي‌شود.

$$g(x, x^*) = (2\pi.T_k)^{\frac{-D}{2}}.\exp\left(-\frac{\| x - x^* \|^2}{2T_k}\right) \qquad (۸)$$

٤- تابع هزينه به ازاي نقطه x محاسبه مي‌شود E(x) .

۵- نقطه جديد x با احتمال h(x) پذيرفته مي‌شود (در صورت پذيرش $x^* = x$ است و در غير اينصورت x^* تغيير نمي‌كند).

$$\Delta E = E(x) - E(x^*) \qquad (۹)$$

$$h(x) = \frac{1}{1 + \exp\left(\frac{\Delta E}{T_k}\right)} \qquad (۱۰)$$

٦- $k = k + 1$

۷- دما كاهش مي‌يابد. $T_k = \frac{T_1}{\ln k}$

۸- اگر شرط خاتمه برقرار است، الگوريتم خاتمه مي‌يابد وگرنه قدم ۳ اجراء مي‌شود.

در الگوريتم فوق D تعداد پارامترهاي تابع هزينه است و منظور از $\|x - x^*\|$ فاصله اقليدسي دو بردار D بعدي x^*, x مي‌باشد. در الگوريتم SA استاندارد، تابع چگالي احتمال توليد نقطه جديد از نوع گاوسي يا نرمال است و الگوريتم متناظر با چنين تابع چگالي احتمالي الگوريتم BA ناميده مي‌شود. اگر روند كاهش دما (قدم ۷ از الگوريتم) از روند ذكر شده سريعتر نباشد، اين روش تضمين مي‌كند كه از ديد آماري حتماً بهينه سراسري را پيدا خواهد كرد. همانطور كه ديده مي‌شود، روش BA با روند كاهش دماي متناظر با آن (قدم ۷) بسيار كُند است و روند رسيدن به جواب بسيار آهسته مي‌باشد و به تكرارهاي بسيار زيادي نياز دارد. اگر بخواهيم از روش SA براي بهينه‌سازي سراسري مدل پنهان ماركف استفاده كنيم، مي‌توان تابع هزينه را چنين تعريف كرد:

$$E = -Log\ P(O|\lambda) \qquad (۱۱)$$

در حالتي كه چندين رشتة مشاهدات وجود دارد، احتمال كل برابر است با حاصلضرب تك تك احتمالات.

۴-۱-۲ روش SA سريع يا FA

همانطور كه در قسمت قبلي ذكر شد، روند كاهش دما در الگوريتم SA استاندارد يا BA بسيار كند است و رسيدن به رزولوشن زياد و دقت زياد و دماهاي كم براي حل مسائل پيوسته بسيار زمان بر خواهد بود. براي حل اين مشكل يك الگوريتم سردكردن سريع يا FA پيشنهاد شده است[4,5] كه براي توليد نقاط تصادفي جديد در حول و حوش جواب قبلي از توزيع كوشي استفاده مي‌كند. يك تابع چگالي احتمال در فضاي D بعدي از نوع كوشي براي توليد بردارهاي تصادفي D بعدي بدين شكل مي‌باشد:

$$g(x, x^*) = \frac{\Gamma\left(\frac{D+1}{2}\right)}{\pi^{\left(\frac{D+1}{2}\right)}} \cdot \frac{T}{\left(\| x - x^* \|^2 + T^2\right)^{\left(\frac{D+1}{2}\right)}} \qquad (۱۲)$$

براي تضمين شرط رسيدن به نقطه بهينه سراسري لازم است كه روند كاهش دما از روند زير سريعتر نباشد:

$$T(k) = \frac{T_0}{k} \qquad (۱۳)$$

همانطور كه ملاحظه مي‌گردد، روند كاهش دما در FA بسيار سريعتر از BA مي باشد. در عمل چون الگوريتم سريعي براي توليد يك بردار تصادفي D بعدي با توزيع كوشي وجود ندارد و نيز به اين دليل كه نياز داريم دماهاي بعدهاي مختلف از پارامترها متفاوت باشند، لذا در هر بعد از فضاي D بعدي بطور مستقل از يك توزيع كوشي يك بعدي استفاده مي‌شود كه بصورت زير است:

$$g_i(x_i, x_i^*) = \frac{1}{\pi}.\frac{T_{ik}}{\left(x_i - x_i^*\right)^2 + T_{ik}^2} \qquad (۱۴)$$

براي تضمين شرط رسيدن به بهينه سراسري، بايد روند زير براي كاهش دما رعايت گردد.

$$T_i(k) = \frac{T_{i0}}{k^{\frac{1}{D}}} \qquad (۱۵)$$

٤-١-٣ روش SA بسيار سريع يا VFA

در اين روش[4,5] باز هم سعي خواهد شد كه روند كاهش دما نسبت به روشهاي قبلي تسريع گردد. اگر فرض كنيم كه x_{ik}^* (مقدار قبلي پارامتر بعد i ام در تكرار k ام) در فاصله $[A_i, B_i]$ قرار گيرد، مقدار جديد اين پارامتر را در تكرار k+1 ام اينچنين توليد مي‌كنيم:

$$x_{i(k+1)} = x_{ik}^* + y_i(B_i - A_i) \qquad (۱۶)$$

متغير y_i يك متغير تصادفي است كه محدود و در فاصله $[-1,+1]$ مي‌باشد و با تابع چگالي احتمال زير توليد مي‌شود:

$$g_i(y_i) = \frac{1}{2\left(|y_i| + T_{ik}\right).\ln\left(1 + \frac{1}{T_{ik}}\right)} \qquad (۱۷)$$

براي تضمين شرط رسيدن به بهينه سراسري، بايد روند كاهش دما از روند زير سريعتر نباشد:

$$T_i(k) = \frac{T_{i0}}{\exp\left(c_i k^{\frac{1}{D}}\right)} \qquad (۱۸)$$

پارامتر c_i كه يك عدد مثبت است، براي كاركردِ بهينه سيستم تنظيم مي‌شود. همانطور كه ملاحظه مي‌گردد، روند كاهش دما در VFA بسيار سريعتر از BA , FA است و رسيدن به دقت و رزولوشن بالا در تعداد تكرار كمتري نسبت به روشهاي قبلي ميسر مي‌گردد(البته با تضمين شرط رسيدن به بهينه سراسري).

٤-٢ اتوماتون يادگير تقويتي با مقدار عمل پيوسته

يكي از روشهايي كه در بهينه‌سازي و كنترل بكار مي‌رود، اتوماتون يادگير يا LA ميباشد[6]. اتوماتون يادگير مدلي است كه با يك محيط در ارتباط است و با توجه به ورودیهايي كه از محيط يا سيستم دريافت مي‌كند، عمل خود را با يك سيگنال تقويتي تصحيح نموده و عمل جديد را به محيط يا سيستم اعمال مي‌نمايد. اين كار مجدداً توسط محيط و سيستم ارزيابي مي‌گردد و باز هم اتوماتون با دريافت ورودي از محيط يا سيستم عمل خود را تصحيح مي‌كند. در مدلهايي كه تا چندي قبل از اتوماتون‌هاي يادگير پيشنهاد شده بودند، مقدار عمل اتوماتون يك مقدار گسسته بوده است. اخيراً يك روش اتوماتون يادگير تقويتي با مقدار عمل پيوسته يا CARLA ارائه شده كه مي‌تواند براي بهينه‌سازي و كنترل در محيط‌هايي با پارامترهاي پيوسته بكار رود[7,8]. CARLA در واقع يك مدل يادگيري تقويتي در محيط‌هاي با پارامتر پيوسته مي‌باشد. اساس روش CARLA اينگونه است كه اين روش مقدار عمل جديد را با استفاده از يك تابع چگالي احتمال عمل توليد مي‌كند. اگر تعداد پارامترهاي سيستم بيشتر از يك پارامتر باشد، تعدادي از اتوماتونهاي يادگير از نوع CARLA بطور موازي با سيستم در ارتباط خواهند بود و هر اتوماتون

وظيفة بهينه‌سازي يك پارامتر از پارامترهاي سيستم را به عهده خواهد داشت. اين اتوماتونها با يكديگر ارتباطي ندارند و فقط با محيط ارتباط دارند و در واقع ارتباط نسبي آنها از طريق محيط است. هر اتوماتون با استفاده از تابع چگالي احتمال عمل خود يك مقدار عمل جديد را توليد مي‌كند، سيستم يا محيط مقدار عمل جديد را ارزيابي مي‌كند و اتوماتون CARLA با استفاده از يك سيگنال تقويتي، تابع چگالي احتمال خود را تصحيح مي نمايد و اين عمل تا رسيدن به نتيجه مطلوب ادامه مي‌يابد. متأسفانه ابداع كنندگان اين روش، اثباتي براي تضمين آماري پيدا كردن بهينة سراسري در كاربردهاي بهينه‌سازي ارائه نداده‌اند. از جمله مزيت‌هاي اين روش مي‌توان به حافظه‌دار بودن اين روش اشاره كرد كه به نحوي اطلاعات نقاط قبلي جستجو را با در نظر گرفتن درجه اهميت نسبي آنها، بعنوان حافظة سيستم نگهداري مي‌كند. روش CARLA به صورت كلي چنين عمل مي‌كند:

١- ابتدائاً تابع چگالي احتمال عمل با يك تابع چگالي احتمال يكنواخت در محدوده پارامترهاي سيستم مقدار دهي اوليه مي‌شود.

٢- با توجه به تابع چگالي احتمال عمل، يك نقطة(عمل) جديد r را توليد ميكند.

٣- پاسخ محيط(يا راندمان سيستم در كاربردهاي بهينه‌سازي) را بدست مي‌آورد.

٤- يك سيگنال تقويتي با توجه به مطلوبيت پاسخ سيستم محاسبه مي‌شود.

٥- تابع چگالي احتمال عمل با توجه به اين سيگنال تقويتي تصحيح مي‌گردد.

٦- اگر شرط خاتمه برقرار نيست، قدم ٢ اجراء شده وگرنه الگوريتم خاتمه مي‌يابد.

فرض كنيد متغير x در محدوده $[x_{\min}, x_{\max}]$ باشد. ابتدائاً تابع چگالي احتمال عمل بدين شكل و بصورت يك توزيع يكنواخت مي‌باشد:

$$f(x,1) = \frac{1}{x_{\max} - x_{\min}} \qquad (١٩)$$

اگر در تكرار n ام باشيم، با استفاده از تابع چگالي احتمال عمل f(x , n) ، عمل r را چنين انتخاب مي‌كنيم:

$$F(r,n) = \int_{x_{\min}}^{r} f(x,n)\,dx = z(n) \qquad (٢٠)$$

يعني ابتدائاً يك عدد تصادفي z(n) با توزيع يكنواخت بين [0,1] انتخاب مي‌كنيم. آنگاه عمل r طوري انتخاب مي شود كه تابع احتمال تجمعي F(r,n) برابر z(n) گردد. تابع تجمعي F(r,n) با استفاده از انتگرال‌گيري عددي در فاصله $[x_{\min}, r]$ انجام مي‌شود. مقدار f(x,n) را در نقاطي كه نداريم، از طريق درونيابي خطي بدست مي‌آوريم. با توليد عمل r به طريق فوق، اين عمل را به محيط اعمال نموده و پاسخ محيط(هزينه) را J(n) مي‌ناميم. يك سيگنال تقويتي β براي تصحيح تابع چگالي احتمال عمل از رابطه زير بدست مي‌آيد:

$$\beta(n) = \min\left(\max\left(0, \frac{J_{med} - J(n)}{J_{med} - J_{\min}} \right), 1 \right) \qquad (٢١)$$

سيگنال تقويتي β بايد در فاصله [0,1] باشد. $J_{\min}, J_{med}$ به ترتيب ميانه و ميانگين هزينه بازاي R نقطه از نقاط قبلي است(بعنوان مثال R=500). اگر تابع چگالي احتمال عمل در تكرار n اُم f(x,n) باشد، آنگاه تابع چگالي احتمال عمل براي تكرار بعدي (n+١ اُم) به اين صورت تصحيح مي‌گردد:

$$f(x,n+1) = \begin{cases} \alpha[\, f(x,n) + \beta(n) H(x,r)] & if \quad x \in [x_{\min}, x_{\max}] \\ 0 & else \end{cases} \qquad (٢٢)$$

كه در آن H(x , r) يك تابع گاوسي با ميانگين r و به شكل زير است:

$$H(x,r)=\frac{g_h}{(x_{\max}-x_{\min})}.\exp\left(-\frac{1}{2}.\frac{(x-r)^2}{(g_w(x_{\max}-x_{\min}))^2}\right) \qquad (۲۳)$$

که در آن پارامترهاي g_w, g_h به ترتيب سرعت و رزولوشن(دقت) يادگيري را تعيين مي‌كنند. مقدار بهينه براي پارامترهاي g_w, g_h به ترتيب 0.3 , 0.02 قرار داده شده‌اند[7,8].

۵- آزمايشها

در اين بخش به ارائه نتايج بدست آمده در آزمايشهاي انجام شده خواهيم پرداخت. هدف از اين آزمايشها آموزش مدل پنهان مارکف با معيار بيشترين شباهت (ML) و توسط دو روش سراسري SA و CARLA مي‌باشد. مدل مارکفي كه قرار است آموزش داده شود، يك مدل پنهان مارکف پيوسته با سه حالت و سه تابع گاوسي در هر حالت با ماتريسهاي كوواريانس قطري مي‌باشد. اگر تعداد پارامترهاي سيستم با فرض قطري بودن ماتريس كوواريانس P باشد، داريم:

$$P=N(1+N+M(2D+1)) \qquad (۲۴)$$

كه به ازاي N=3 , M=3 , D=2 تعداد پارامترهاي مدل برابر ۵۷ پارامتر خواهد شد. آموزش اين مدل در حالت رشته‌هاي مشاهدات چندتايي(Multiple Observation) بوده[1] و براي آموزش آن از K=10 رشتة مشاهده با طول T=20 استفاده شده است. هدف، بيشينه كردن $P(O|\lambda)$ است كه O مجموعه ۱۰ رشتة مشاهده و λ پارامترهاي مدل پنهان مارکف مي‌باشد. همانطور كه مي‌دانيم آموزش مدل پنهان مارکف يك مسالة بهينه‌سازي مقيد است، زيرا بايد شروط زير برقرار باشد:

$$\sum_{j=1}^{N} a_{ij}=1 \qquad \text{و} \qquad \sum_{m=1}^{N} c_{im}=1 \qquad \text{و} \qquad v_{ii}>0 \qquad (۲۵)$$

v_{ii} برابر با عنصر قطري ماتريس كوواريانس و متناظر با واريانس در بعد i ام است. براي تبديل مسأله مقيد HMM به يك مسأله نامقيد براي بهينه‌سازي از نگاشتهاي ابتكاري زير استفاده كرده‌ايم:

$$a_{ij}=\frac{\exp(a'_{ij})}{\sum_{j=1}^{N}\exp(a'_{ij})} \qquad (۲۶)$$

$$c_{im}=\frac{\exp(c'_{im})}{\sum_{m=1}^{M}\exp(c'_{im})} \qquad (۲۷)$$

$$v_{ii}=\exp(v'_{ii}) \qquad (۲۸)$$

اين روابط بدان معني است كه روشهاي بهينه‌سازي سراسري نامقيد همچون SA، پارامترهاي سيستم را در فضاي $v'_{ii}, c'_{im}, a'_{ij}, \pi'_i$ بصورت نامقيد تغيير مي‌دهند، ولي تبديل شدة اين پارامترها توسط روابط بالا قيود و شروط مدل مارکف را اقناع ميكنند. حال به شرح آزمايشها خواهيم پرداخت.

۵-۱ روشهاي مبتني بر سرد كردن فلزات

از روشهاي مبتني بر SA در اين قسمت از سه روش BA , FA , VFA استفاده كرديم. مقادير Max , Min بعضي پارامترها(در جاهايي مثل VFA كه نياز داريم) و همچنين دماهاي اوليه در ابعاد مختلف را با استفاده از اطلاعاتي چون كمترين و بيشترين مقدار پارامترها در بعدهاي مختلف، ميانگين كل داده‌ها و واريانس كل داده‌ها در بعدهاي مختلف بدست آورده‌ايم و مقدار دهي اوليه كرده‌ايم. شكل (۱) نمونه‌اي از عملكرد هر يك از سه روش BA , FA , VFA را نشان مي‌دهد. همانطور كه ديده مي‌شود تغييرات لگاريتم احتمال در انتهاي جستجو در FA , VFA كم است و اين به آن دليل است كه در اين روشها در انتهاي جستجو محدوده جستجو بسيار كوچك شده (رزولوشن و دقتِ جستجو زياد شده) و تغييرات تابع هزينه كم مي‌شود، ولي در

روشي مثل BA بدليل اينكه روند كاهش دما بسيار كند است، حتي در ۱۰۰۰۰ تكرار هم واريانس توزيع و دماي آن هنوز هم زياد بوده و محدوده تغييرات پارامترهاي سيستم زياد است و تغييرات تابع هزينه هنوز هم زياد مي‌باشد

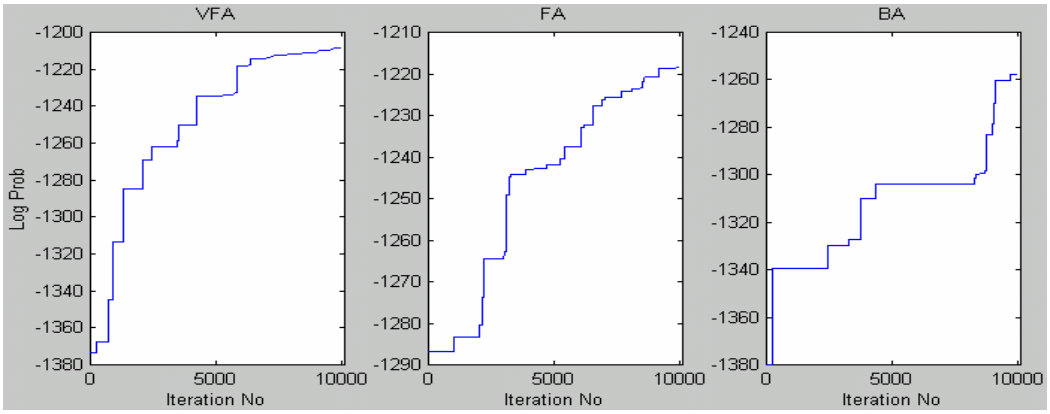

شكل ۱- نمونه‌اي از عملكرد روشهاي مبتني بر **SA**

۲-۵ روش **CARLA**

همانطور كه قبلاً ذكر شد در روش CARLA، هر اتوماتون يكي از پارامترهاي مدل پنهان ماركف را بهينه مي‌كند و جمعيتي از اتوماتونهاي CARLA (به تعداد پارامترهاي مدل ماركف) بصورت موازي و مستقل از همديگر پارامترهاي سيستم را بهينه مي‌كنند. مقادير مي‌نيمم و ماكزيمم پارامترهاي مدل پنهان ماركف از روي داده‌هاي آموزشي بدست مي‌آيند. هر يك از اتوماتونهاي CARLA در هر تكرار از آموزش(جستجو) سعي مي‌كند تابع چگالي احتمال عمل خود را تصحيح كند.

در اين آزمايش از CARLA براي بهينه‌سازي يك پنهان ماركف با N=3 ، M=3 و D=2 استفاده شده است. داده‌هاي آموزشي همان داده‌هاي آموزشي استفاده شده در روشهاي SA است. تعداد پارامترهاي سيستم 57 پارامتر مي‌باشد كه نسبتاً زياد است. شكل (۲) شكل تابع چگالي احتمال عمل را در تكرارهاي مختلف نشان مي‌دهد. همانگونه كه ديده مي‌شود، تابع چگالي احتمال عمل حتي در تكرارهاي زياد هم به خوبي همگرا نشده است و آشفته مي‌باشد.

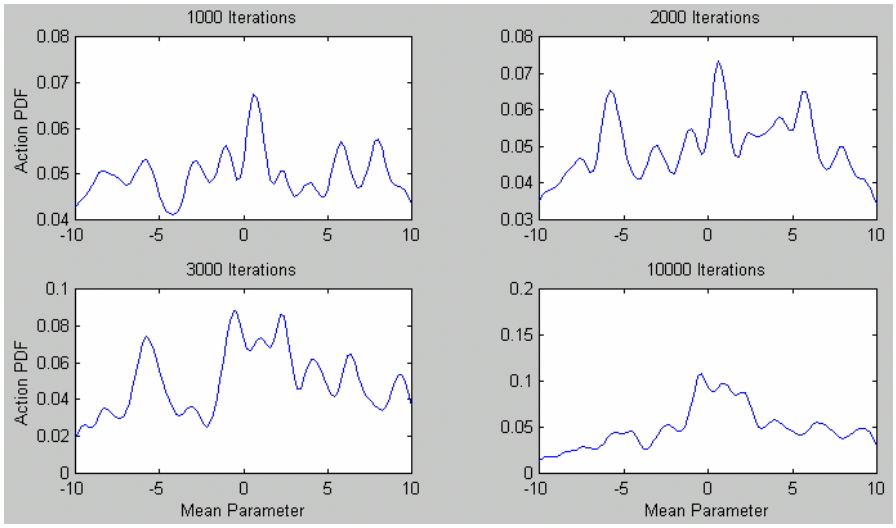

شكل ۲- شكل تابع چگالي احتمال عمل بازاي پارامتر بعد اول از يك مدل ماركف با ۵۷ پارامتر

CARLA براي بهينه‌سازي مسائل با تعداد پارامترهاي ۲ و ۳ و با تعداد مي‌نيمم‌هاي محلي كم(۲ مي‌نيمم محلي) كارآيي خوبي

داشته است[7,8] (همانطور كه در [10] نيز گزارش شده است)، ولي كارآيي آن براي مسائل با تعداد پارامترهاي متوسط يا زياد پايين بوده و روند بهبود آن كند است. شكل (۳) نمونه‌اي از عملكرد CARLA را در آموزش مدل ماركف با ۵۷ پارامتر نشان مي‌دهد.

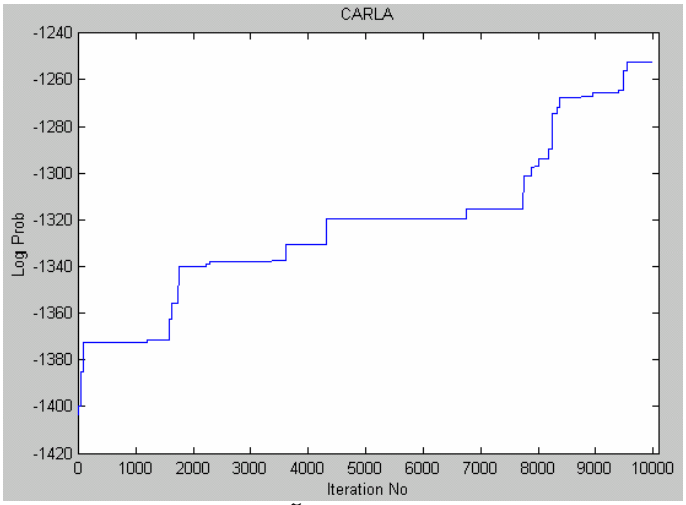

شكل ۳- نمونه‌اي از عملكرد **CARLA** در آموزش مدل ماركف با ۵۷ پارامتر

۳-۵ مقايسه‌اي بين روشهاي سراسري

در اين بخش هدف ما مقايسه روشهاي سراسري در بهينه‌سازي و آموزش مدل پنهان ماركف است. در هر كدام از آزمايشها، تعداد تكرارها ۱۰۰۰۰ تكرار بوده است. براي آنكه نتايج مقايسه، يك نتيجة قابل تعميم و سازگار(Consistent) باشد، هر كدام از روشها به دفعات انجام شده‌اند و شرايط آزمايش براي روشهاي مختلف يكسان بوده است. به اين منظور براي هر روش، آموزش سيستم ۵۰ بار انجام شد. يعني ۵۰ نقطة تصادفي براي شروع اوليه و ۵۰ مجموعه آموزشي مختلف، طوري كه ۵۰ نقطة شروع اوليه و نيز ۵۰ مجموعة آموزشي مختلف براي تمام روشها يكسان باشد. پس از اين مرحله نيز در توليد اعداد تصادفي، بذر اوليه(Seed) براي تمام روشها يكسان قرار داده شد تا شرايط آزمايش كاملاً مساوي باشد. هر آزمايش تا تعداد تكرار برابر با ۱۰۰۰۰ تكرار انجام شد. پس از اتمام آزمايشها، ميانگين لگاريتم احتمال بر روي ۵۰ آزمايش را بعنوان ميانگين كارآيي روش معيار قرار داديم. جدول (۱) متوسط راندمان كارآيي(متوسط لگاريتم احتمال) را به ازاي دو دسته روش را نشان مي‌دهد.

جدول ۱- مقايسه راندمان متوسط روشهاي جستجوي سراسري **SA** و **CARLA** در ۵۰ آزمايش مختلف

VFA	FA	CARLA	BA
-1210.3	-1215.7	-1250.4	-1259.1

همانطور كه ملاحظه مي‌شود، راندمان روشهاي FA و VFA بيش از روش CARLA است و اين بدان دليل است كه اولاً رسيدن به نقطة بهينه در اين روشها بطور آماري تضمين شده است و ثانياً دقت و رزولوشن در اين روشها بسيار بيشتر از روشي مثل CARLA است و روش CARLA نسبت به FA و VFA كندتر است. راندمان BA از راندمان CARLA كمتر است. اين مي‌تواند به دليل حافظه‌دار بودن روش CARLA و نيز كم بودن دقت روش BA در ۱۰۰۰۰ تكرار باشد، زيرا روند كاهش دما در BA بسيار كند است و در ۱۰۰۰۰ تكرار نمي‌تواند به دقت و رزولوشن بالايي برسد(به دماهاي پايين برسد). به همين دليل راندمان روش BA پايين‌تر از روشهاي FA ، VFA و CARLA است. در روشهاي FA و VFA تابع چگالي احتمال توليد در

نقطه فعلي تيز است و داراي دقت بالايي است. در VFA شكل تابع چگالي احتمال توليد در نقطه فعلي تيزتر از شكل تابع در روش FA است و دقت آن بيشتر است. اصطلاحاً اين نوع از توابع چگالي احتمال برخلاف تابع چگالي احتمال نرمال داراي يك قلة تيز و در عين حال حواشي سنگين يا دُم سنگين هستند(Heavy-Tailed). قلة تيز باعث بالا رفتن دقت جستجو مي‌شود و حواشي سنگين باعث فرار راحت تر از بهينه‌هاي محلي مي‌گردد.

٦- نتيجه‌گيري

در اين مقاله روش مبتني بر اتوماتون يادگير(CARLA) و نيز روشهاي استاندارد(BA) و پيشرفتة مبتني بر سردكردن فلزات(FA و VFA) براي آموزش سراسري مدل پنهان ماركف استفاده شدند. آزمايشهاي انجام شده نشان دادند كه روش CARLA نسبت به روش BA داراي راندمان بالاتري است. اين بدان دليل است كه اولاً دقت و رزولوشن CARLA بيشتر از BA است(در تعداد تكرارهاي متوسط) و ثانياً CARLA بر خلاف BA يك روش حافظه دار است. از طرفي آزمايشها نشان دادند كه روشهاي سريع مبتني بر SA يعني FA و VFA داراي راندمان بالاتري نسبت به CARLA هستند. توجيه اين امر آن است كه اولاً پيداكردن بهينة سراسري در روشهاي مبتني بر FA و VFA تضمين شده است(از ديد آماري) و ثانياً رزولوشن FA و VFA بيشتر از CARLA است.

مراجع

[1] Rabiner, L.R., Juang, B.-H., Fundamentals of Speech Recognition, Prentice-Hall, 1993.

[2] Bäck, T., Evolutionary Algorithms in Theory and Practice, Oxford University Press, 1996.

[3] Kirkpatrick, S., Gelatt, C.D., Vecchi, M.P., “Optimization by Simulated Annealing”, Science, Vol. 220, No. 4598, pp. 671-680, May 1983.

[4] Ingber, L., Rosen, B., “Genetic Algorithms and Very Fast Simulated Reannealing: A Comparison”, Mathematical and Computer Modelling, Vol. 16, No. 11, 1992.

[5] Ingber, L., “Simulated Annealing: Practice versus Theory”, Mathematical and Computer Modelling, Vol. 18, No. 11, 1993.

[6] Narendra, K.S., Thathatchar, M.A.L., Learning Automata: An Introduction, Prentice-Hall, 1989.

[7] Howell, M.N., Gordon, T.J., Best, M.C., “The Application of Continuous Action Reinforcement Learning Automata to Adaptive PID Tuning”, Proceedings of IEE Control Seminar on Learning Systems for Control, pp. 1-10, Birmingham, UK, May 2000.

[8] Howell, M.N., Gordon, T.J., “Continuous Learning Automata and Adaptive Digital Filter Design”, UKACC International Conference on Control, Sep. 1998.

[9] Stuckman, B.E., Easom, E.E., “A Comparison of Bayesian/Sampling Global Optimization Techniques”, IEEE Trans. on SMC, Vol. 22, No. 5, Sep. 1992.

[10] ج. كبوديان، م.ر. ميبدي، م.م. همايون‌پور، "استفاده از اتوماتون يادگير با عمل پيوسته براي آموزش سراسري مدل پنهان ماركف"، اولين كنفرانس بين‌المللي فناوري اطلاعات و دانش، صص. ٥٢٩-٥٣٩، دانشگاه صنعتي اميركبير، دي ١٣٨٢.