



به دست آوردن پارامترهای مدل مخفی مارکوف به روش تکاملی

مریم تجویدی
دانشگاه صنعتی خواجه نصیر الدین طوسی
دانشکده مهندسی برق
EMail:M_Tajvidi@yahoo.com

رسانا اخباری
دانشگاه صنعتی خواجه نصیر الدین طوسی
دانشکده مهندسی برق
EMail:Fiora@safineh.net

امیر مسعود فرهمند
دانشکاه صنعتی خواجه نصیر الدین طوسی
دانشکده مهندسی برق
EMail:SoloGen@ieee.org

چکیده: HMM به عنوان مدلی احتمالی کاربردهای بسیار گسترده‌ای چون استفاده در تشخیص صوت دارد. اما روش متداول تعلیم آن (روش Baum-Welch) چون بسیاری از روش‌های جستجوی محلی دیگر، در اکسترم‌های محلی گیر می‌افتد. از طرف دیگر روش‌های تکاملی تا حد زیادی از این مشکل به دور نند. لذا در این مقاله چندین روش مختلف برای تکامل HMM پیشنهاد شده است که با روش متداول B-W مقایسه شده‌اند. نتایج حاصل بیان گر برتری مطلق روش‌های تکاملی است.

کلمات کلیدی: روش‌های تکاملی، مدل مخفی مارکوف (HMM)

۱- مقدمه

HMM به عنوان ابزاری برای مدل کردن فرآیندهای اتفاقی کاربرد بسیار گسترده‌ای دارد. این مدل احتمالی به دلیل قابلیت‌های بالای خود در مسائلی چون تشخیص گفتار-که ذاتاً فرآیندی تصادفی است- بسیار به کار می‌رود، به طوری که اکنون به عنوان یکی از روش‌های مناسب تشخیص گفتار و همچنین مسائلی شبیه به آن، چون تشخیص هویت گوینده می‌باشد.^[1] علاوه بر این، امروزه کاربردهای دیگری چون مدل کردن کانال‌های مخابراتی ناشناخته و تشخیص بافت در تصویر نیز پیدا کرده است.^[2] همان‌طور که در بخش‌های بعدی خواهد دید، مساله اساسی در استفاده از HMM، در کاربردی چون تشخیص گفتار، بدست آوردن مدلی است که به خوبی بتواند نسبت به داده‌های اتفاقی ورودی، واکنش نشان بدهد و در صورتی که داده‌ها از همان منبعی باشند (که در اینجا، منبع می‌تواند چیزی مثل سیستم صوتی انسان در هنگام ادای حرف یا کلمه‌ای خاص باشد) باشند که با آن آموزش دیده است، این امر را مشخص کند. روش‌های مختلفی برای به دست آوردن پارامترهای مدل وجود دارد، که بدون شک الگوریتم تکراری Baum-Welch (کارکرد بر اساس Maximum-Likelihood) معروف ترین آنهاست. از دیگر روش‌ها می‌توان به روش‌های عمومی مبتنی بر گرادیان اشاره کرد.^[3] اما بزرگترین عیب این دو روش این است که تنها یک جواب محلی را پیدا می‌کند و هیچ تضمینی برای ساختن مدل اکسترم وجود ندارد. (و اغلب موقع نیز به آن نمی‌رسد). برای حل این مشکل می‌توان از روش‌های تکاملی استفاده کرد، که روش‌هایی هستند که در حل مسائل بهینه سازی به خوبی جواب داده اند.^[4] هدف ما در این مقاله بررسی تاثیر بکارگیری روش‌هایی روش‌های تکاملی برای حل مساله بدست آوردن پارامترهای HMM است. در اینجا چندین روش مختلف برای تکامل مدل، پیشهاد شده است. ساختار این مقاله از این پس به این صورت می‌باشد:



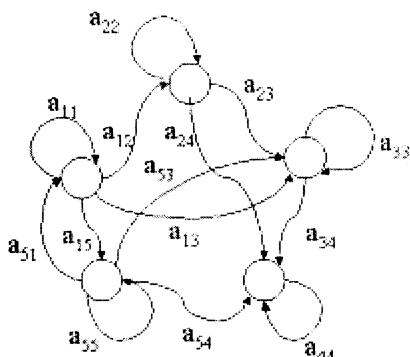
ابتدا در بخش (۲)، مفهوم مختصری بر HMM می‌کنیم، ایده آن، را بیان نموده و فرمول بندی مورد استفاده در این مقاله را بیان می‌کنیم. سپس در بخش (۳)، به طور خلاصه درباره روش‌های تکاملی خواهیم نوشت. در بخش (۴) که قسمت اصلی این مقاله است، چندین روش مختلف برای بکارگیری روش‌های تکاملی در بدست آوردن پارامترهای مدل، پیشنهاد می‌کنیم و پس از آن در بخش (۵) این روش‌ها را با هم و همچنین با روش کلاسیک Baum-Welch مقایسه می‌کنیم. در نهایت نتایج پیشنهاداتمان را در بخش (۶) خواهید دید.

Hidden Markov Model-۲

هدف مدل سازی، پیش‌بینی خروجی فرآیندهای طبیعی می‌باشد. خروجی یک فرآیند طبیعی، ممکن است پیوسته یا گسسته باشد. منبع این سیگنال ممکن است، ایستا (Stationary) یا ناایستا (Non-Stationary) باشد و همچنین سیگنال مشاهده شده، ممکن است ناشی از یک منبع تنها یا چند منبع هم زمان باشد. در هر حال، هدف ما بدست آوردن مدلی است که خروجی این فرآیند طبیعی را مدل کند و تا حد ممکن شبیه آن باشد.

مدل‌های مختلفی می‌توان پیشنهاد داد. می‌توان مدل Deterministic برای فرآیند ایجاد کرد و یا اینکه از مدل‌های اتفاقی (Stochastic) برای این کار استفاده کرد. هدف این مقاله، بررسی مدلی اتفاقی است به نام HMM، که گسترشی از Markov Chain یا Markov Model محسوب می‌شود.

از دیگر مدل‌های اتفاقی می‌توان به مدل گاووسی، پواسون و همچنین تلفیق گاووسی (Gaussian Mixture) اشاره کرد.



Markov Chain - ۱

۲-۱- فرآیند مارکوفی و HMM :

در دیاگرام حالت شکل (۱)، هر State (State) بیانگر یک خروجی سیستم می‌باشد و انتقال (Transition) بین این state‌ها، که با احتمال مشخص شده روی یال متصل کننده دو state مشخص می‌شود، باعث تولید خروجی‌های جدید می‌شود. به این مدل، Markov Chain یا Markov Model نسبتاً گسترده‌ای مخصوصاً در مخابرات دارد. اگر q_t را state در زمان t بدانیم و S_i را بیانگر state i ام:

$$(1) \quad a_{ij} = P[q_t=S_j | q_{t-1}=S_i, q_{t-2}=S_k, \dots] = P[q_t=S_j | q_{t-1}=S_i]$$

که a_{ij} بیانگر انتقال بین state i و j است. از این فرمول بندی مشخص می‌شود که در مدل مارکوف، به state قبلی اش مربوط است.

حال فرض کنید، به جای اینکه هر state خود به تنها یک بیانگر خروجی سیستم باشد (به عبارت دیگر باعث تولید Observation شود)، بیانگر توزیع احتمالی فرآیند دیگری باشد که آن مشخص کننده خروجی سیستم است. یعنی اتصال بین دو state تنها توزیع احتمالی به وجود آمدن خروجی‌ها را تغییر بدهد. به این مدل HMM می‌گویند. [۱]

۲-۲- فرمول بندی HMM :

در این قسمت به فرمول بندی HMM می‌پردازیم، فرض کنید، مدلی دارای N مختلف state دارد و در هر state یکی از سمبول موجود به طور تصادفی انتخاب می‌شود. (در اینجا HMM گستته است) تعریف می‌کنیم:

$$(2) \quad A_{ij} = P[q_{t+1}=S_j | q_t=S_i] \quad 1 \leq i, j \leq N$$

که این احتمال انتقال بین دو state را مشخص می‌کند.

$$(3) \quad b_j(k) = P[V_k \text{ at } t | q_t=S_j] \quad 1 \leq j \leq N, 1 \leq k \leq M$$

که V_k سمبول انتخابی می‌باشد که از مجموعه M تابی انتخاب شده است.

$$(4) \quad \pi_i = P[q_i=S_i] \quad 1 \leq i \leq N$$

که بیانگر احتمالات آغازین است.



همچنین باید داشته باشیم :

$$\sum_j a_{ij} = 1 \quad (5)$$

$$\sum_k b(k) = 1 \quad (6)$$

$$\sum_i \pi_i = 1 \quad (7)$$

با دانستن $\lambda = (A, B, \Pi)$ می توان خروجی مدل یعنی $O = O_1 O_2 \dots O_T$ را به صورت زیر به دست آورد:

۱) با توجه به توزیع احتمال Π , یکی از state ها را انتخاب می کنیم. $q_1 = s_i$.

۲) قرار می دهیم: $t = 1$.

۳) با توجه به توزیع B , یکی از M سمبول را انتخاب می کنیم. $O_t = V_k$.

۴) با احتمال مشخص شده توسط ماتریس A , از i به i state جدید j می رویم و قرار می دهیم: $t = t + 1$.

۵) تا هنگامی که $T = t$, از مرحله ۲ دوباره تکرار می کنیم.

۲-۳- سه مساله اساسی :

برای استفاده از HMM به عنوان مدلی احتمالی، نیاز به حل ۳ مساله زیر داریم:[1]

۱) ورودی های $O = O_1 O_2 \dots O_T$, (هر O_i یک سمبول است) و $(A, B, \pi) = \lambda$ داریم. چگونه $P(O | \lambda)$ را حساب کنیم؟

۲) ورودی های $O = O_1 O_2 \dots O_T$ و $(A, B, \pi) = \lambda$ داریم. چگونه ترکیب $Q = q_1 q_2 \dots q_T$ (دنباله state ها) را به دست بیاوریم به طوری که به بهترین نحو توصیف گر انتقال بین state به ازای این دنباله ورودی باشد؟

۳) با داشتن $O = O_1 O_2 \dots O_T$ به عنوان داده های بدست آمده از منبع، چگونه میتوان پارامترهای مدل $(A, B, \pi) = \lambda$ را طوری انتخاب کرد که مدل بیشترین شباهت را (ماکریم $P(O | \lambda)$) را نسبت به O داشته باشد.

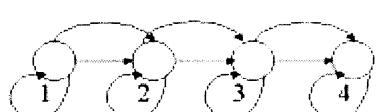
این ۳ مساله اساسی مطرح شونده در HMM می باشد. برای روشن شدن معنی هر کدام از این ها، سیستمی برای تشخیص صوت را در نظر می گیریم :

فرض می کنیم این سیستم قرار است W کلمه مختلف را تشخیص دهد. در نتیجه ما W مدل مختلف نیاز داریم. هر کدام از این مدل ها باید به کلمه ای که برای آن آموزش می بینند بیشترین شباهت (یا ماکریم $P(O | \lambda)$) را نشان دهد. در ابتدا می بایست هر کدام از این مدل ها را با داده های بدست آمده از نمونه گیری صوتی آموزش دهیم.(مساله ۳) سپس برای تشخیص یک کلمه ناشناس، باید آن را به هر کدام از این W مدل مختلف وارد کرد و هر مدلی که $P(O | \lambda)$ بیشتری داشت، به عنوان مدل توصیف گر آن کلمه مشخص می شود.(مساله ۱) از مساله ۲ برای بررسی دقیق تر چگونگی عملکرد مدل و بهبود آ، استفاده می شود

برای حل این مسائل روش های گوناگونی وجود دارد که البته بیشترین اختلاف در هنگام حل مساله ۳ بروز می کند. برای حل مساله ۱ از روشی موسوم به Forward-Bakward استفاده می شود. برای حل مساله ۲، معمولاً از الگوریتم Viterbi استفاده می شود. روش معمول برای حل مساله ۳، استفاده از روشی موسوم به Baum-Welch می باشد که یک روش-EM(Expectation-ML(Maximum Likelihood) بر اساس Modification) است. البته روش های مبتنی بر گرادیان نیز وجود دارد که جواب های قبل مقایسه ای با روش قبلی می دهد. علاوه بر اینها به تازگی از روش های تکاملی نیز استفاده می شود که هدف اصلی این مقاله است.[7] ، [6] ، [5]

۴- دیگر مسائل :

هدف ما در این مقاله ارائه توصیف نسبتاً کاملی از HMM نمی باشد و این بخش، تنها آشنایی دهنده ای با HMM است. برای همین تنها به اشاره ای به بعضی از دیگر صورت بندی ها و مسائل اکتفا می شود.



شکل ۲- Left-Right HMM

در قسمت قبل، فرض بر این بود که خروجی سیستم گسسته باشد. در عمل سیستمی که بیشتر به کار می رود، صورت بندی پیوسته HMM است که به جای $b_i(k)$ گسسته، صورتی پیوسته قرار می گیرد. به علاوه، این مدل می تواند شکل های



مختلفی هم داشته باشد. مدلی که در آن هر state به تمامی state های دیگر متصل باشد، مدل Ergodic نام دارد. شکل متدالو استفاده شونده در تشخیص گفتار و صوت، به صورتی مشابه با شکل(۲) است که به مدل Left-Right(Bakis) معروف است. همچنین از دیگر مسائل مطرح، می توان به اضافه کردن قابلیت تاخیر در مدل اشاره کرد(در این state ضرایب انتقال به خود برای تمامی state ها یعنی همان a_{ii} ها مساوی صفر قرار داده می شوند و چگالی استمرار (Duration Density) به طور صریح مشخص می شود. به این مفهوم که انتقال از یک state به state جدید تنها پس از اینکه سیستم به تعداد دفعات مناسبی در همان state باقی ماند و خروجی تولید کرد، صورت می گیرد). که این نیز باعث بهتر عمل کردن سیستم های تشخیص گفتار می شود.[8] در نهایت، این که می توان مدل های دیگری غیر از ML مانند MMI(Maximum Mutual Information) استفاده کرد که البته باعث صورت بندی متفاوتی برای الگوریتم یادگیری(Baum-Welch) به طور خاص) می شود.[9]

۳- روش های تکاملی :

بسیاری از مسائل طراحی در مهندسی، در اصل مساله ای بهینه سازی هستند. در این مسائل می بایست پارامترهای مساله را طوری تغییر داد تا به پاسخ بهینه-که توسط نوع مساله مشخص می شود- رسید. روش های مختلفی برای این کار وجود دارد که از مهم ترین و عمومی ترین آنها روش های مبتنی بر گرادیان هستند. اما عیب بزرگشان گیر افتادن در اکسترم های محلی است. برای حل این مشکل روش های مختلفی وجود دارد که معروف ترین آنها روش های تکاملی ای هستند که امروز بسیار پر کاربرد گشته اند.[4] البته درباره چرا و چگونگی عملکرد بهینه آنها درینجا صحبتی نمی کنیم. [10],[11],[12] ، [13]

۴- روش پیشنهادی:

در این قسمت چندین روش و صورت بندی برای تکامل HMM پیشنهاد می گردد. تجزیه و تحلیل دقیق این روش ها در اینجا صورت نمی گیرد زیرا در اکثر موارد نمی توان تئوری های توصیف گری چون Schema را که توصیف کننده رفتار تکاملی در GA است_ بکار برد و کاربرد آنها تنها محدود به state های بسیار ساده می باشد و بیشتر جنبه کیفی پیدا می کند تا کمی. در هر صورت فرض بر این است که تکامل HMM نیز چون بسیاری از مسائل مهندسی، مساله گمراه کننده ای(Deceptive) نباشد و یک سری روش های ساده برای Selection و همچنین CrossOver، Mutation جواب های خوبی بدهنند و برتر بودن نسبی یک روش نسبت به بقیه با چند آزمایش تا حدی مشخص شود.

:Fitness و Selection-۱-۴

در این مساله، ما سه پارامتر A,B,Π داریم که به ترتیب برداری N بعدی، ماتریس $N^{\wedge}2$ بعدی و ماتریسی NM بعدی هستند. برای ذخیره سازی آنها، از صورت بندی متدالو در ES (و یا GA) استفاده می کنیم و در نتیجه مجموعه پارامترهایمان، فضای جستجوی $N+NM+N^2$ بعدی ای تشکیل می دهد. تنها نکته ای که لازم به ذکر هست، این است که در اکثر موارد برای اعمال اپراتورهای تکاملی روی هر عنصر جمعیتی (Individual)، هر کدام از این دسته پارامترها را به طور خاص در نظر می گیریم و با عناصر A، مانند عناصر B رفتار نمی کنیم. این نکته بعداً مشخص خواهد شد.

برای ساختن جمعیت اولیه، از توزیع یکنواخت (بین ۰ و ۱) استفاده می کنیم و بعد به توجه به شروط (۵) تا (۷)، آن ها را نرمال می کنیم. سپستابع $(\lambda_i|O)$ را به ازای O_{Train} و λ_i های متعلق به جمعیت حساب می کنیم. بدیهی است که هدف ما، ماقزیم کردن این تابع است. ما در اینجا همانند اکثر پیاده سازی های روش Forward-Backward، از $\text{Log}(P(O|\lambda_i))$ استفاده می کنیم. اما با این وجود تفاوت مقدار $\text{Log}(P(O|\lambda_i))$ های مختلف چندان زیاد نیست. (مثلًا بین -۵۰ و -۵۵- قرار دارند) و برای زیاد کردن این تفاوت و بالاتر بودن تفاوت بین یک عنصر خوب و بد از Ranking زیر برای Fitness استفاده می کنیم:

$$\begin{aligned} P_i &= \text{abs}[P(O_{Train}|\lambda_i)] & 1 \leq i \leq \text{Population Size} \\ P = 1/N * \sum_i P_i & , \quad \sigma_p^2 = 1/N * \sum_i (P_i - P)^2 \\ P_{min} &= \min(P_i) \\ \text{Fitness}(P_i) &= (P - (P_{min} - \sigma_p^2) + K)^{-1} \end{aligned} \quad (8)$$



که با تعیین K می‌توان میزان حداکثر Fitness را به طور تقریبی مشخص کرد. در پیاده سازی های ما $K=0.1$ در نظر گرفته شده است. برای Selection از ترکیبی Deterministic, Stochastic استفاده می‌کنیم. کسری از بهترین اعضا به طور مستقیم به نسل بعد وارد می‌شوند و بقیه با برگزاری یک Selection تورنمنتی برای نسل بعد انتخاب می‌شوند.

۴-۲-۱-اپراتورهای تکاملی

در این مقاله ۷ نوع پارامتر تکاملی پیشنهاد شده است که ۲ تای آنها از نوع CrossOver و بقیه از نوع Mutation هستند. با توجه به اینکه فرم نگهداری زن‌ها در کروموزوم، به صورت حقیقی است، قدرت مانورمان نسبت به فرم متداول در GA بسیار بیشتر می‌شود. می‌توان گفت که پیاده سازی بیش از آنکه شبیه به GA باشد، به ES شباهت دارد.

۴-۲-۱-۱-اپراتور جهش :

به احتمال P_m ، هر کدام از عناصر ماتریس A, B, Π مقدارشان با مقدار اتفاقی (با توزیع یکنواخت) بین 0 و M_{max} عوض می‌شود. به طور ساده می‌توان گفت که این شبیه ترین نوع Mutation ای است که به Mutation متداول در GA داریم و با اینکه صورت بندی حقیقی دارد، به نظر می‌رسد که نحوه عملکردشان تا حد زیادی شبیه به هم باشد. احتمال P_m (که جدا از احتمال انتخاب شدن این نوع Mutation است)، به طور تجربی مساوی ۰.۰۵ انتخاب شده است. مقادیر بیشتر باعث تغییر زیاد در ماتریس می‌شوند و آن به طور ناگهانی کاهش پیدا می‌کند و مقادیر کم هم باعث کند شدن بیش از حد فرآیند می‌شوند. مقدار m_{max} برای هر کدام از ماتریس‌های A, B, Π تفاوت دارد و باید متناسب با N انتخاب شود تا حداکثر معقول یک ضریب را در بر بگیرد. (مثلاً از آنجایی که در یک ماتریس Π با ۵ عنصر وجود دrajه ای با مقدار ۰.۹ معقول نیست (مگر در حالات خاص) این مقدار کوچک تر و در حد ۰.۵ انتخاب می‌شود).

نکته‌ای که لازم به ذکر است، این است که پس از اجرای هر اپراتور تکاملی، ماتریس‌ها بایست نرمال شوند تا در شرایط صدق کنند.

۴-۲-۱-۲-اپراتور جهش :

این اپراتور نیز مشابه با اپراتور قبلی است، با این تفاوت که تغییرات هر درایه ماتریس متناسب با مقدار آن درایه است و در نتیجه تغییرات شدید در درایه ای که باید کوچک باشد به وقوع نمی‌پیوندد. در این روش داریم:

$$\Delta a_{ij} = \alpha a_{ij} \quad (9)$$

می‌توان انتظار داشت که این روش فضای جستجو را نسبت به روش قبلی آرام تر می‌پیماید ولی در عوض احتمال خراب شدن (degrade) یک عنصر کمتر است.

۴-۲-۳-اپراتور Simple Crossover

این روش ساده‌ترین حالت برای انجام عمل Crossover می‌باشد. این نحوه شکل دهی کروموزوم که در [5] و [6] برای مدل Left-Right (Bakis) یا Right (Bakis) جهت تشخیص صوت به کار رفته و نتایج خوبی هم داده است به صورت زیر می‌باشد: فرض می‌کنیم همه سطرهای ماتریس A و B را پشت سر هم به صورت برداری N^2 و NM بعدی مرتب کرده‌ایم. برای انجام عمل Crossover از Simple 1-Point Crossover برای ماتریس A و π و 2 -Points Crossover برای ماتریس B استفاده می‌کنیم.

۴-۲-۴-۱-اپراتور Interpolation Crossover (BLX- α)

در این روش، مکان جدید نقطه‌ای ایجاد شده در فضای جستجو N^2 بعدی برای A و NM بعدی برای B و N بعدی برای π ، مکانی بین دو بردار $V1$ و $V2$ می‌باشد که هر کدام از این‌ها بیان گر پارامترهای A, B, π مدل می‌باشد. برای ایجاد کروموزوم جدید می‌نویسیم:

$$\begin{aligned} A' &= \alpha \cdot A_1 + (1 - \alpha) \cdot A_2 \\ A'' &= (1 - \alpha) \cdot A_1 + \alpha \cdot A_2 \end{aligned} \quad (10)$$

چنین رابطه‌ای برای B و π نیز صادق است. در رابطه‌ی بالا، α عددی است اتفاقی بین 0 تا 1 که البته در این پیاده‌سازی، α را توزیع نرمالی با واریانس کوچک‌تر از 1 و متوسط صفر گرفته‌ایم. دلیل این کار این است که اولاً تغییرات حول کروموزوم اصلی کوچک باشد (کوچک بودن واریانس) و همچنین کروموزم حاصل بتواند بیرون از فضای درون‌یابی شده نیز باشد (با منفی شدن



مقدار α و انجام عمل برونویابی) که این عمل یکی از راههای گسترش قابلیت جستجوی کل فضای پارامتری (exploration) می‌باشد.

ایده‌ی استفاده از این نوع عمل‌گر این است که فرض می‌کنیم مجموعه پارامترهای دو کروموزم در دو سوی قله‌ای از تابع Fitness قرار گرفته‌اند و با این عمل نتیجه‌ی حاصل به سمت قله حرکت می‌کند.

۴-۵-۲-۴- اپراتور Row Replacing Crossover

این اولین نوع Crossover است که به ساختار HMM نیز نظر دارد و بر اساس ساختار ویژه‌ی آن عمل می‌کند. در این روش دو state مختلف از دو کروموزم متفاوت با هم تعویض می‌شوند. یعنی تمام درایه‌هایی از ماتریس انتقال که به یک state خاص وارد می‌شوند، از state‌ای متفاوت از ماتریس دیگری گرفته می‌شود و برعکس.

$$A' = A_1 \& A'' = A_2 \quad (11)$$

except :

$$a'_{ij_{new}} = a_{ik_2}$$

$$a''_{ik} = a_{ij_1}$$

فرض شده است که یک state با ورودی‌های اش می‌تواند بیان‌گر یک Building Block خوب باشد که لازمه رسید به جواب مطلوب است.

۴-۶-۲-۴- اپراتور State Replacing Crossover I

در این شیوه Crossover، تعدادی از state‌های یک کروموزم با state‌های کروموزم دیگر مبادله می‌شود. به این معنا که با انتخاب اتفاقی $1 \leq m \leq N$ ، تمام درایه‌های ماتریس انتقال بین state‌های کوچک‌تر از m و state‌های بزرگ‌تر و مساوی آن از کروموزم اول با معادل‌شان در کروموزم دوم مبادله می‌شوند. می‌توان این را تعمیمی از روش قبلی دانست زیر چندین state را در بر می‌گیرد. اما از طرف دیگر تفاوتی که دارد این است که هم انتقال‌های مشخص شونده با $(j,i)a$ و هم چنین $(i,j)a$ را که شرط مورد نظر را داشته باشند، در بر می‌گیرد در حالی که روش قبلی تنها بر درایه‌های ماتریس انتقال یک جهت تاثیر می‌گذشتند. همچنین در این روش بر ماتریس احتمالات (B) تغییری داده نمی‌شود.

۴-۷-۲-۴- اپراتور State Replacing Crossover II

این شیوه نیز درست مشابه روش قبل است با این تفاوت که دو حد بالا و پایین برای مجموعه state‌هایی که جایه‌جا می‌شوند گذاشته می‌شود.

۵- نتایج آزمایش:

در بخش قبلی روش‌های متفاوتی برای به کارگیری سیستم‌های تکاملی برای تعیین پارامترهای HMM پیشنهاد شد. همان‌طور که گفته شد برای بررسی دقیق و ریاضی تاثیر یک عمل (مانند Crossover، Mutation، Selection) نوع Fitness و همچنین چگونگی اختصاص Cost به تابع Fitness معمولاً بسیار پیچیده و غیرعملی است. لذا بهترین و ساده‌ترین روش مقایسه بین این‌ها، آزمایش روش‌های مختلف روی مساله‌های واقعی است.

ما برای این کار مدل آزمایشی زیر را پیشنهاد داده‌ایم که تا حد خوبی مشخص کننده‌ی کارکرد سیستم است: HMM مدلی است که یک فرآیند مارکوفی (فرآیندی که دارای چندین state مختلف است و هر state تنها به state قبلی وابستگی دارد) را تخمین می‌زند و هر چه مدل به منبع مارکوفی تولید کننده‌ی خروجی نزدیک‌تر باشد، مدل بهترین تقریب‌زده شده است. با وجود این که سیستم‌های طبیعی‌ای چون سیستم تولید گفتار در انسان واقعاً یک مدل مارکوفی نیست ولی در عمل با یک مدل مارکوفی می‌توان تا حد خوبی ساختار داخلی آن‌ها را مدل کرد. در نتیجه اگر سیستمی بتواند هر سیستم مارکوفی ناشناخته را مدل کند، می‌توان نتیجه گرفت که سیستم تعلیم‌دهنده‌ی خوبی برای آن مدل مارکوفی است.

در این مقاله ما تعدادی HMM اتفاقی و ناشناخته (برای سیستم تعلیم‌دهنده) به وجود می‌آوریم و دنباله‌ای از خروجی آن به دست می‌آوریم. هر کدام از این دنباله‌ها را به سیستم تعلیم‌دهنده‌ای که تنها از یکی از روش‌های ذکر شده استفاده می‌کند می‌دهیم و اجازه می‌دهیم تا مدل پیشنهادی خود را تعلیم دهد. سپس این مدل را با داده‌های دیگری که از منبع ناشناخته (برای



مدل تعلیم‌یافته) تولید شده است، مورد آزمایش قرار می‌کنیم. $(\lambda|P)$ را حساب می‌کنیم. نتیجه، مشخص کننده‌ی میزان خوب بودن مدل است. در جدول‌های زیر نتایج ۷ مدل تکاملی مختلف پیشنهاد شده و همچنین مدل به دست آمده از طریق روش تکراری Baum-Welch را می‌بینیم. در این سلسله آزمایش‌ها، پارامترهای زیر انتخاب شده است:

برای هر مجموعه پارامتر N و M که به ترتیب مشخص کننده تعداد state‌ها و تعداد سمبیل‌های مدل اتفاقی‌اند) ۵ آزمایش مختلف با ۵ مدل متفاوت صورت گرفته است. تعداد مجموعه داده‌های تعلیم و همچنین تست از هر مدل منبع، ۱۰ مجموعه بوده که هر کدام شامل ۱۵ سمبیل (به عبارت دیگر، شامل ۱۵ observation) بوده‌اند. جمعیت سیستم تکاملی ۲۰ عضو داشته است و $P(Crossover)=0.6$ (در صورت انتخاب یک اپراتور از نوع Crossover) و $P(Mutation)=0.05$ برای Mutation نوع اول و ۰.۰۸ برای نوع دوم انتخاب شده بود. حداکثر تعداد نسل‌های ممکن ۳۰ نسل بود که شرط هم‌گرایی (تفاوت متوسط cost که همان $(\lambda|P)$ می‌باشد) در دو نسل متوالی کمتر از ۰.۰۱ باشد) برقرار می‌بود، تکامل در طی دو نسل پس از آن وضعیت پایان می‌یافتد. این شرط باعث این می‌شود که در اکثر مواقع تعداد نسل‌های محاسبه شده کمتر از ۲۰ بشود. برای الگوریتم Baum-Welch نیز حداکثر تکرار به ۱۰۰ محدود شده بود که بحث معمولاً در طی ۴۰ تکرار سیستم هم‌گرا می‌شود.

نتایج به دست آمده به خوبی بیان گر برتری روش‌های تکاملی نسبت به روش جستجوی محلی Baum-Welch می‌باشد. این تفاوت هر چقدر مدل پیچیده‌تر می‌شود (افزایش تعداد state‌ها و یا سمبیل‌های قابل تولید) آشکارتر است به طوری که در موردی چون $N=6$ و $M=64$ مقادیر به دست آمده از روش دوم عملاً قابل استفاده نیست.

علاوه بر تفاوت معنادار در $\log(\lambda|P)$ بین دو گروه، ویژگی دیگری که مشخص شده است، تغییرات زیاد آن مقدار در روش Baum-Welch است که به خوبی بیان گر ویژگی جستجوی محلی آن می‌باشد. با توجه به این موارد می‌توان ادعا کرد که روش‌های تکاملی از نظر بهینه‌سازی، مدل بسیار بهتری را ارایه می‌دهند. گرچه عیب بزرگ آن‌ها این است که نسبت به روش‌های دیگر جستجو بسیار زمان بر می‌باشند به طوری که محاسبه نتایجی که می‌بینید چندین ساعت بر روی یک کامپیوتر شخصی طول کشید. (از ارایه اطلاعات کمی به دلیل عدم زمان‌بندی دقیق و بهینه نبودن کد برنامه صرف‌نظر می‌شود).

اما از طرف دیگر مقایسه‌ی بین روش‌های تکاملی آسان نیست و تاویل دقیق آن‌ها نیاز به بررسی‌های سیستماتیک‌تری دارد. همچنین به دلیل این که بعضی از اپراتورهای تکاملی چون State Cut Crossover I,II عمل می‌کنند، در نتیجه هیچ‌گونه جستجویی بر روی فضای B و π انجام نمی‌شود و لذا منطقی است که این روش از حداکثر قابلیت تغییر پارامترها برای به دست آوردن Building Block های مناسب استفاده نمی‌کند. گرچه با این وجود می‌بینیم که این دو روش به طور نسبی خوب کار می‌کنند (خصوصاً در داده‌های تست) و این بیان گر قدرت بالای آن‌هاست که در صورت ترکیب با روش‌های دیگر می‌توانند به عنوان اپراتور بسیار مناسبی برای جستجو درآید.

$N=4$ $M=16$	Simple Cross.	InterPole Cross.	Row Replacing Cross.	State-Cut1 Cross.	State-Cut2 Cross.	Mut.1	Mut.2	Baum- Welch
TR.Mean	-39.347	-39.510	-38.280	-39.461	-39.678	-39.457	-38.063	-47.100
TR.Var	1.096	0.775	0.750	1.034	0.702	0.990	1.5372	6.3927
TE.Mean	-41.147	-42.382	-42.483	-41.597	-41.377	-41.997	-42.097	-52.841
TR.Var	1.160	2.152	2.522	1.233	1.246	1.852	1.556	9.861

$N=4$ $M=32$	Simple Cross.	InterPole Cross.	Row Replacing Cross.	State-Cut1 Cross.	State-Cut2 Cross.	Mut.1	Mut.2	Baum- Welch
TR.Mean	-50.191	-50.551	-48.739	-50.341	-49.878	-49.434	-48.920	-59.061
TR.Var	0.534	0.362	0.512	0.760	0.601	1.175	1.165	9.156
TE.Mean	-53.346	-52.887	-54.468	-52.012	-53.387	-54.746	-52.799	-58.309
TR.Var	1.446	1.089	2.203	1.737	1.838	5.551	2.526	9.592

$N=6$ $M=32$	Simple Cross.	InterPole Cross.	Row Replacing Cross.	State-Cut1 Cross.	State-Cut2 Cross.	Mut.1	Mut.2	Baum- Welch
TR.Mean	-50.366	-50.419	-48.549	-50.173	-50.465	-50.456	-48.910	-103.19
TR.Var	0.261	0.507	0.714	0.418	0.398	0.850	1.181	39.572
TE.Mean	-52.691	-51.810	-54.276	-52.852	-52.631	-53.618	-53.208	-168.67
TR.Var	0.841	0.726	2.296	0.656	1.244	3.216	0.991	48.08



N=4 M=16	Simple Cross.	InterPole Cross.	Row Replacing Cross.	State- Cut1 Cross.	State- Cut2 Cross.	Mut.1	Mut.2	Baum- Welch
TR Mean	-60.975	-60.976	-59.187	-60.612	-60.333	-59.968	-59.959	-191.421
TR Var.	0.372	0.302	0.633	0.266	0.257	1.519	0.735	129.295
TE. Mean	-62.452	-62.986	-62.236	-63.209	-62.618	-67.230	-64.620	-Inf
TE. Var	0.794	1.460	1.387	1.030	1.102	5.158	0.572	NaN

۶-نتیجه‌گیری و پیشنهادها:

در این مقاله ابتدا کمی درباره HMM و ایده‌ی نهفته در آن نوشتیم و سپس با بیان این که روش‌های تکاملی در بسیاری از مسائل بهینه‌سازی به خوبی جواب می‌دهند، چندین اپراتور متفاوت برای عملیات Crossover و Mutation برای HMM ارایه دادیم. در نهایت با مقایسه این روش‌ها با روش متداول Baum-Welch، برتری روش تکاملی را نشان دادیم. مراحل زیر برای ادامه‌ی کار پیشنهاد می‌شود که در حال بررسی و مطالعه درباره‌شان هستیم: بررسی شکل کلیتابع $P(\lambda|O)$ در فضای پارامتری HMM و ارایه روش‌های جدید بر اساس ساختار ویژه‌ی آن‌ها، بررسی میزان کارکرد روش‌های تکاملی بر روی مسائل عملی ای چون تشخیص صوت و مقایسه با دیگر روش‌ها، پیاده‌سازی توزیعی سیستم تکاملی برای گسترش قابلیت exploration و exploitation [14]، پیاده‌سازی سیستمی هایبرید که در آن از روش‌های جستجوی محلی (مانند Baum-Welch) و جستجوی کلی (سیستم‌های تکاملی) با هم استفاده شده باشد. (سیستم‌های تکاملی لامارکی)

۷-مراجع:

- [1]-Rabiner, L. R., "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," in Proceedings of The IEEE, vol. 77, no. 2, February 1989.
- [2]-Li, J., Najmi, A., Gray, R. M., " Image Classification by a Two Dimentional Hidden Markov Model," in Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing, 1999.
- [3]-Galindo, P. L., "The Competitive Forward-Backward Algorithm (CFB)," in IEE Artificial Neural Networks, Conference Publication, 1995.
- [4]-Goldberg, D. E., Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley Publishing, 1989.
- [5]-Chau, C. W., Kwong, S., Diu, C.K., Fahrner, W.R., "Optimization of HMM by a Genetic Algorithm , " in IEEE Inter. Conf. on Acoustics, Speech, and Signal Processing, 1997.
- [6]-Kwong, S., Chau, C. W., "Analysis of Parallel Genetic Algorithms on HMM Based Speech Recognition System," in IEEE Trans. on Consumer Electronics, Nov 1997, Vol 43/4.
- [7]-Kwon, J. Lee, S., Shin, Ch., Jang, Y., Hong, S., "Signal Hybrid HMM-GA-MLP Classifier for Continuous EMG Classifier purpose," Engineering in Medicine Biology Society, 1998, Proceeding of the 20th Annual Inter. Conf. of the IEEE.
- [8]-Russel, M. J., Moore, R. K., "Explicit Modeling of State Occupancy in Hidden Markov Models for Automatic Speech Recognition," 85, 1985
- [9]-Juang, B. H., Levinson, S. E., Sandhi, M. M., "Maximum Likelihood Estimation for Multivariate Mixture Observations of Markov Chains," IEEE Trans. on Information Theory, vol. IT-32, no.2, Mar 1986.
- [10]-Stephens, Ch., Walebroeck, H., "Schemata Evolution and Building Blocks ", MIT Evolutionary Computation, vol 7, no 2, 1999.
- [11]-Goldberg, D.E. , "Real-Coded Genetic Algorithms, Virtual Alphabets, and Blocking," Illinois Genetic Algorithm Lab (IlliGAL) report no. 90001
- [12]-Goldberg, D.E., Deb, K., Clark, J.H., "Genetic Algorithms, Noise, and the Sizing of Population," IlliGAL report no. 91010
- [13]-Goldberg, D.E., Deb, K., Thierens, D., "Toward a Better Understanding of Mixing in Genetic Algorithms ", IlliGAL report no. 92009

۱۴-[فرهمند، ا.م، میرمیرانی، ا.ع، "سیستم‌های الگوریتم ژنتیکی توزیعی،" سومین کنفرانس دانشجویی مهندسی برق ایران، ۱۳۷۹]