

ارائه درون‌یابی KNNGI^۱ و مقایسه آن با درون‌یابی FI^۲ در بازشناسی گفتار

ابوالقاسم صیادیان*، کامبیز بدیع*، محمد شهرام معین** و نصرالله مقدم
دانشکده برق دانشگاه صنعتی امیرکبیر
مرکز تحقیقات مخابرات ایران
دانشکده فنی و مهندسی، دانشگاه تربیت مدرس

(دریافت مقاله: ۸۱/۹/۱۷ – دریافت نسخه نهایی: ۸۳/۳/۲۵)

چکیده – مدل‌سازی آماری HMM رویکردی پرکاربرد در سیستمهای بازشناسی گفتار پیوسته و گسسته است. توزیع احتمال بردارهای مشاهدات هر حالت پنهان مدل، به دو روش پیوسته^۳ یا گسسته^۴ تخمین زده می‌شوند. عملکرد توزیع احتمال پیوسته (با مدل‌سازی GMM^۵) بالاتر از عملکرد توزیع احتمال گسسته (با مدل‌سازی QV^۶) است. ولی چنانچه بخواهیم از رویکرد HMM برای بازشناسی گفتار گسسته با دایره لغات وسیع استفاده کنیم، هزینه محاسباتی مرحله بازشناسی با افزایش تعداد لغات، به نحو چشمگیری افزایش می‌یابد. بدین لحاظ در بازشناسی گفتار گسسته با دایره لغات وسیع، از توزیع احتمال گسسته به منظور کاهش هزینه محاسباتی و امکان پیاده‌سازی بی‌درنگ^۷ استفاده می‌شود. برای جبران کاهش دقت و عملکرد مدل‌سازی DD-HMM، استفاده از درون‌یابی فازی FI مرسوم است. در این تحقیق روش درون‌یابی گوسی که دارای پشتونه نظری قوی‌تر نسبت به FI است ارائه کردۀ‌ایم. کارایی دو روش درون‌یابی FI و KNNGI در بازشناسی ۱۵۰۰ کلمه فارسی مورد تحقیق و بررسی قرار دادیم. نتایج این تحقیق نشان می‌دهد که دقت و انعطاف‌پذیری درون‌یابی KNNGI بیشتر از روش FI است.

واژگان کلیدی : درون‌یابی گوسی، درون‌یابی فازی، مدل مارکف مخفی چگالی گسسته، بازشناسی تلفظ گسسته

Presentation of K Nearest Neighbor Gaussian Interpolation and Comparing it with Fuzzy Interpolation in Speech Recognition

A. Sayadiyan, K. Badi, M. Moin and N. Moghadam

Department of Electrical Engineering, AmirKabir University of Technology

Abstract: Hidden Markov Model is a popular statistical method that is used in continuous and discrete speech recognition. The probability density function of observation vectors in each state is estimated with discrete density or continuous density modeling. The performance (in correct word recognition rate) of continuous density is higher than discrete density HMM, but its computation complexity is very high, especially in very large discrete utterance recognition problems. For real time implementation of very large discrete utterance recognition, we must use discrete density HMM (DDHMM). To increase the performance of DDHMM, one usual solution is fuzzy interpolation. In this study, we present a new method named Gaussian interpolation. We implemented and compared the performance of two types of interpolation methods for 1500 Persian speech command words. Results show that precision and flexibility of Gaussian interpolation is better than those of the fuzzy interpolation.

Keywords: Gaussian Interpolation, Fuzzy Interpolation , Discrete Density HMM, Discrete utterance recognition

* – دانشیار ** – استادیار

فهرست علائم

q	متغیر نماینده حالت	a	متغیر نماینده احتمال وقوع حالات شرطی
t	متغیر نماینده توالی زمانی	b	متغیر نماینده احتمال وقوع هر بردار مرجع در هر حالت
V	متغیر نماینده نام بردار کتاب گذ	c	نام یک کلاس اکوستیکی
W	متغیر نماینده وزن دادن	d	نام تابع فاصله اقلیدس
π	متغیر نماینده احتمال وقوع حالت در شروع	m	متغیر نماینده مقدار فازی بودن
α	متغیر نماینده توابع عضویت نمایش فازی	N	متغیر نماینده توزیع نرمال
σ	متغیر نماینده واریانس توزیع نرمال	o	بردار ویژگی مشاهده شده
p		p	متغیر نماینده مقدار احتمال گوسی

حالت (سه حالت برای تشخیص واجها و $N \geq 5$ حالت برای تشخیص کلمات و عبارات) مدل‌سازی می‌شوند. اطلاعات آماری مربوط به قواعد توالی زمانی تولید حالتها، توسط ماتریس A (با بعد $N \times N$) و بردار حالت اولیه π (با بعد $N \times 1$) بازنمایی می‌شوند. تغییرات آماری ویژگی‌های طیفی در داخل هر حالت هر کلاس توسط یک pdf^{۱۶} پیوسته یا گستته مدل‌سازی می‌شوند. روش‌های تخمین (در فاز آموزش) و روش‌های استفاده (در فاز بازناسی) از ماتریس A و بردار π در هر دو روش CD-HMM و DD-HMM تقریباً یکسان است. وجه تمایز اصلی دو روش در نحوه مدل‌سازی pdf بردارهای طیفی در داخل حالات است. مدل‌سازی پیوسته pdf در سیستمهای بازناسی پیوسته CSR^{۱۷} که تعداد کلاس‌های اکوستیکی کم و محدود است. (منتظر با تعداد واجهای هر زبان) (حدود ۳۰ واج برای فارسی و حدود ۴۴ واج برای زبان انگلیسی)، بسیار مورد توجه است. ولی در سیستمهای بازناسی گفتار گستته با تعداد کلاس‌های اکوستیکی بالا (حدوداً بالای ۱۰۰۰ لغت)، استفاده از pdf پیوسته به ویژه در فاز بازناسی از نظر پیاده‌سازی بسی درنگ مقرن به صرفه و عملی نیست. در این تحقیق تعداد کلاس‌های اکوستیکی بالاتر از ۱۰۰۰ لغت و برابر ۱۵۰۰ کلمه است. در چنین مواردی از بازنمایی گستته pdf (با استفاده از تکنیک VQ) یا از بازنمایی نیمه پیوسته^{۱۸} استفاده می‌کند. چون بازنمایی گستته دارای بالاترین سرعت در هنگام

رویکرد آماری HMM در کاربردهای عملی بازناسی گفتار، رویکردی غالب نسبت به سایر روشها از جمله ANN^{۱۹} و DTW^{۲۰} است. از ویژگی‌های بارز رویکرد HMM استفاده بهینه از اطلاعات ویژگی‌های طیفی و زبانی، در مدل‌سازی مؤثر و تشخیص صحیح واقعی اکوستیکی متفاوت و متمایز است. HMM‌ها هم برای گفتار پیوسته^{۲۱} و هم برای گفتار گستته^{۲۲} مورد استفاده قرار می‌گیرند. در کاربردهای بازناسی گفتار پیوسته، علاوه بر مدل‌سازی اکوستیکی^{۲۳} به مدل‌سازی زبانی^{۲۴} نیز نیازمندیم. با توجه به اینکه در زبان فارسی پایگاه داده گفتاری جامع و پوشای مدل‌سازی ATP^{۲۵} و همچنین پایگاه متنه جامع و پوشای مدل‌سازی SLM^{۲۶} موجود نیست، توجه اصلی این تحقیق به کاربرد HMM‌ها در بازناسی گفتار گستته معطوف شده است. هدف سیستم بازناسی گفتار گستته عبارت است از، تعیین کلاس یک سیگنال اکوستیکی دریافتی (با فرض اینکه محدوده تقریبی ابتدا و انتهای آن با دقت مناسبی مشخص است): همچنین پارامترهای مدل آماری M کلاس اکوستیکی متمایز، از قبل (در فاز آموزش) مشخص است. هر کلاس اکوستیکی می‌تواند یک فرمان یا درخواست صوتی یک تا حداقل پنج کلمه‌ای باشد (در این تحقیق). در مدل‌سازی HMM، به منظور استفاده بهینه از اطلاعات زمانی به منظور متمایزسازی کلاسها، هر کلاس اکوستیکی توسط N

قابل مطالعه است. در فاز بازشناسی با استفاده از الگوریتم برگشتی FP^9 ، نمره (یا احتمال) هر کلاس با دریافت هر دنباله از بردار مشاهدات اکوستیکی $O_1 O_2 \dots O_T$ به شرح زیر محاسبه می‌شود:

قدم اول: محاسبه در لحظه $t=1$

$$a_i(l,i) = \pi_i b_i(l,o_i) \quad 1 \leq i \leq N \quad (4)$$

قدم دوم: مرحله تکراری

$$a_{t+1}(l,j) = \left\{ \sum_{i=1}^N a_t(l,i) a_{ij}(l) \right\} b_j(l, O_{t+1}) \quad 1 \leq t \leq T-1 \quad 1 \leq j \leq N \quad (5)$$

قدم سوم: محاسبه نمره نهایی هر کلاس

$$P(l) = P(O_1, \dots, O_T | C_l) = \sum_{i=1}^N a_t(l,i) \quad (6)$$

$$1 \leq t \leq T-1 \quad 1 \leq j \leq N$$

مراحل فوق برای L تا $1=1$ تکرار می‌شود. کلاسی که بیشترین $P(l)$ را تولید کند به عنوان کلاس برنده اعلام می‌شود. البته از الگوریتم ویتربی [5] نیز برای محاسبه نمره نهایی هر کلاس می‌توان استفاده کرد.

با توجه به محدود بودن رنج دینامیکی پارامترهای A , π , a در مدل‌سازی آماری هر کلاس، بسیاری از محققان اعتقاد دارند که نقش اصلی در بالا بردن عملکرد سیستم بازشناسی به بهبود مدل‌سازی و تخمین دقیق پارامترهای ماتریس B نهفته است. مدل‌سازی پیوسته عناصر ماتریس B توسط مدل GMM به عنوان بهترین راه حل شناخته شده است. اما به دلایلی که در این تحقیق بیان شد، از بازنمایی گستته می‌خواهیم استفاده کنیم.

۳- روشهای طراحی کتاب کد برای مدل‌سازی گستته pdf بردارهای طیفی

در بخش قبل بیان کردیم که برای محاسبه عناصر ماتریس B به تعدادی الگوی مرجع به نام کتاب کد برای هر کلاس اکوستیکی نیازمندیم. فرض می‌کنیم TV_1, \dots, TV_S مجموعه بردارهای آموزشی متعلق به یک حالت از یک کلاس اکوستیکی باشد. با استفاده از مجموعه بردارهای آموزشی و دو الگوریتم کلاسیک LBG^{۱۰} یا EM^{۱۱} می‌توان کتاب کد طراحی کرد [۷] و

پیاده‌سازی است (به علت امکان استفاده از ساختارهای مناسب برای جستجوی سریع در مرحله کدینگ VQ ، مورد توجه و عنایت این تحقیق قرار گرفته است. بنابراین روش پایه در این تحقیق DDHMM است. عملکرد مدل‌سازی DDHMM از نظر دقیق پاییتر از مدل‌سازی DDHMM است. روش کلاسیک برای افزایش نسبی دقت روش بازشناسی DDHMM، استفاده از درون یابی فازی (FI) است. این روش‌ها در بخش (۴) مراجع [۸] و [۹] مورد بررسی قرار گرفته‌اند. در این تحقیق دو نوع درون یابی جدید به نامهای KNNGI (درون یابی گوسی K نزدیکترین همسایه) و KNNFI (درون یابی فازی K نزدیکترین همسایه) در بخش (۵) ارائه کرده و عملکرد آنها را در بخش (۳-۵) و بخش (۶) و (۷) مورد ارزیابی قراردادیم. نتایج ارزیابی نشان می‌دهند که روش جدید درون یابی KNNGI دارای بهترین عملکرد در میان روش‌ها بازشناسی DDHMM است.

۲- بررسی مدل‌سازی DD-HMM در بازشناسی

گفتار گستته

فرض می‌کنیم تعداد L کلاس اکوستیکی (کلمه یا عبارت) داریم. هر کلاس اکوستیکی توسط N حالت مدل‌سازی زمانی می‌شود. اطلاعات زمانی ماندن یا گذر از حالتی به حالتی دیگر برای هر کلاس به صورت زیر توصیف می‌شود:

$$A_l = \{a_{ij}(l)\} \quad \text{that} \quad a_{ij}(l) = P\{q_{t+1}(l) = j | q_t(l) = i\} \quad (1)$$

$$l=1 \quad \quad \quad 1 \leq i, j \leq N$$

$$\pi_l = \{\pi_i(l)\} \quad \text{that} \quad \pi_i(l) = P\{q_{t+1}(l) = i\} \quad (2)$$

$$l=1 \quad \quad \quad 1 \leq i \leq N$$

فرض می‌کنیم بردارهای مشاهدات هر حالت توسط M بردار مرجع کد می‌شوند، در این صورت توزیع احتمال گستته حالات به صورت زیر توصیف می‌شود:

$$B_l = \{b_i(l,k)\} \quad \text{that} \quad b_i(l,k) = P[o_t = v_k(l) / q_t(l) = i] \quad (3)$$

$$l=1 \quad \quad \quad 1 \leq i \leq N \quad 1 \leq k \leq M$$

روشهای تخمین پارامترهای فوق الذکر از روی نمونه‌های آموزشی (در فاز آموزش) در مراجع متعدد از جمله [۱] و [۵]

چندی کردن گستته ویژگیهای طیفی به تعداد معینی سطوح، نویز چندی شده کارایی سیستم را از نظر دقت بازناسی به ویژه برای تلفظها و گویندگانی که در مرحله آموزش شرکت نداشته اند، پایین می‌آورد. کاهش دقت سیستم بازناسی چگالی گستته نسبت به چگالی پیوسته امری مسلم و ثابت شده برای محققان است. تلاش دانشمندان برای افزایش کارایی مدل DD-HMM منجر به ابداع روش‌های FVQ، SCD شد. این روشها در حد قابل قبولی نقطه ضعف DD-HMM را از نظر دقت بازناسی برطرف کردند. در روش SCD ابتدا یک کتاب کد همانند حالت چگالی گستته طراحی می‌شود. سپس با استفاده از مجموعه بردارهای آموزشی نسبت داده شده به هر کلمه کد، یک چگالی پیوسته با تعداد مخلوطهای محدودی (نوعاً یک تاشن) توسط مدل‌سازی GMM طراحی می‌شود. استفاده از مدل‌سازی SCD موجب افزایش دقت سیستم در حد مدل‌سازی پیوسته CD شده است. [۲ و ۴]. اگر چه استفاده از روش SCD بسیار مفید است، ولی چون در عمل مجبوریم تعداد کلمات کد کتاب کد اصلی (DD) را کم انتخاب کنیم، دیگر قادر نیستیم از کارایی مدل DD به صورت کامل (برای ایجاد ساختارهای جستجوی سریع) استفاده کنیم. در نتیجه از هدف اصلی خود در به کارگیری مدل‌سازی گستته pdf دور خواهیم شد. در روش FVQ علاوه بر استفاده از کلمه کد برنده (در مرحله بازناسی) از تعداد I کد با کمترین فاصله نسبت به بردار مشاهده O_t نیز برای بالا بردن دقت سیستم به صورت زیر استفاده می‌کنند [۸ و ۹]. فرض می‌کنیم $V_{i1}, V_{i2}, \dots, V_{il}$ کدهای برنده با کمترین فاصله نسبت به بردار مشاهده O_t باشند یعنی داریم:

$$d(v_{il}, O_t) \leq d(v_{i2}, O_t) \leq \dots \leq d(v_{i1}, O_t) \quad (۸)$$

$$1 \leq j \leq M$$

$$j \neq i, \dots, l$$

در روش کلاسیک DD، مستقل از فواصل O_t نسبت به سایر کدها، نمره نهایی سیستم محاسبه می‌شود. در روش FVQ مقدار $(O_t)_j$ به صورت زیر درونیابی می‌شود:

$$\begin{aligned} \text{در مدل DD کلاسیک:} \\ b_j(O_t) = b_j(V_{il}) \\ \text{در مدل FVQ:} \end{aligned}$$

۱۰ - [۱۳]. فرض می‌کنیم تعداد کلمات کد هر کتاب (یا تعداد بردارهای مرجع) برابر M باشد. همچنین فرض می‌کنیم ویژگیهای طیفی ناهمبسته باشند (در اغلب کاربردهای عملی از ویژگی MFCC و مشتقات مرتبه اول و دوم آن استفاده می‌شود که تقریباً شرایط مطرح شده را دارا هستند). در این صورت خروجی هر دو الگوریتم EM و LBG شامل M بردار (یا $i=1$ تا M) Vi (بردار واریانس i) میانگین VAR_i (یا $i=1$ تا M) (اگر ویژگیها ناهمبسته نباشند به جای بردار واریانس ماتریس M کوواریانس تولید خواهد شد)، و تعداد M اسکالار وزنی w_i (یا $i=1$ تا M) محدودیت $\sum_{i=1}^M w_i = 1$ (خواهند بود. w_i ها در الگوریتم EM به عنوان ضرایب مخلوط و در الگوریتم LBG به عنوان فرکانس نسبی برنده شدن هر کد ذکر می‌شوند. در مدل‌سازی کلاسیک DD-HMM صرفاً از بردارهای متوسط Vi (یا $i=1$ تا M) در مرحله کدینگ و بازناسی استفاده می‌شود. یعنی با دریافت هر بردار O_t آن را به یکی از M بردار Vi طبق منطق زیر نسبت می‌دهند:

$$\text{Code}(O_t) = V_k \quad \text{if} \quad k = \operatorname{argmin} [d(V_1, O_t), d(V_2, O_t), \dots, d(V_M, O_t)] \quad (۹)$$

$d(X, Y)$ تابع فاصله اقلیدسی بین دو بردار X, Y است. بر اصلی هزینه محاسباتی مرحله کدینگ تعیین M تابع فاصله اقلیدسی $d(O_t, Vi)$ (یا $i=1$ تا M) است. نکته بر جسته در استفاده از روش بازناسی با چگالی گستته آن است که، با استفاده از ساختارهای جستجوی سریع می‌توان فرایند تعیین کد برنده MDWC^۳ را به جای M بار محاسبه به $k \log M$ بار محاسبه تابع فاصله کاهش داد (نوعاً بین ۲ تا ۴ قرار دارد). البته کارایی ساختارهای جستجوی سریع موقعی قابل ملاحظه و قابل استفاده است که M باندازه کافی بزرگ باشد. این مزایا وقتی قابل توجه است که بخواهیم سیستم بازناسی با دایره لغات وسیع و به صورت بی درنگ طراحی کنیم.

۴- استفاده از بازنایی SCD^۳ و FVQ^۴ برای جبران کاهش دقت مدل‌سازی DD-HMM

استفاده از چگالی گستته اگرچه دارای مزایای سادگی و سرعت پیاده‌سازی به ویژه در فاز بازناسی است، اما به دلیل

مناسب در فاز آموزش به طور سریع تعیین می شود). فاصله بردار مشاهده o_t را با $v_i, v_{il}, \dots, v_{ik}$ به شرح زیر تعیین می کنیم.

$d(o_t, v_i), d(o_t, v_{il}), \dots, d(o_t, v_{ik})$

با استفاده از فواصل فوق توابع عضویت را به شرح زیر به دست می آوریم:

$$\alpha_j(o_t, v_i) = \frac{[d(o_t, v_{il})]^{\frac{1}{m}}}{\sum_{k=0}^{K+1} [d(o_t, v_{ik})]^{\frac{1}{m}}} \quad (12)$$

$j=0, 1, \dots, k$, $v_{io} \Delta v_i$

تعداد توابع عضویت برابر $k+1$ است. با استفاده از مقادیر $k+1$ تابع عضویت $\alpha_k, \dots, \alpha_1$ مقدار تابع احتمال (o_t) b_j به شرح زیر درون یابی می شود:

$$b_j(o_t) = \sum_{l=0}^k \alpha_l \cdot b_j(v_{il}) \quad (13)$$

$v_{io} \Delta v_i$

ملحوظه می شود که درون یابی صرفاً با استفاده از فاصله بردار مشاهده O_t از کد برنده و k نزدیکترین همسایه آن انجام می پذیرد. یعنی تعیین (o_t) به فواصل O_t از سایر کلمات کد بستگی ندارد. بنابراین در این روش نیز می توان از ساختارهای جستجوی سریع استفاده کرد.

۵- ارائه درون یابی KNNFI

بردارهای مرجع V_1, \dots, V_M (یا کلمات کد) نوعاً توسط الگوریتم EM یا LBG طراحی می شوند. در پایان اجرای الگوریتم LBG (یا EM)، علاوه بر بردارهای مرجع، بردارهای واریانس متناظر نیز محاسبه می شوند (با فرض قطری بودن ماتریس کوواریانس بردارها). در روش درون یابی KNNFI از اطلاعات واریانس هر کلمه کد هیچ گونه استفاده ای نمی شود. اما می دانیم که واریانس هر بردار مرجع، نماینده چگونگی پراکندگی بردارهای آموزشی است که آن بردار مرجع نماینده آنهاست. سؤال اساسی برای محققان این نوشتار این بود که چگونه از این اطلاعات اضافی برای بهبود عملکرد فرایند درون یابی استفاده کنیم. با توجه به کارایی مدل‌های GMM، ایده

$$b_j(o_t) = \sum_{i=1}^I \alpha_i \cdot b_j(o_t = V_i) \quad (9)$$

که در آن v_i ها، کدهای برنده با قواعد ذکر شده‌اند.

ضرایب وزنی درون یابی α_i ها ($i=1$ تا I) به صورت فازی به شرح زیر محاسبه می شوند:

$$\alpha_i = \frac{(d_i)^{\frac{1}{m}}}{\sum_{k=1}^I (d_k)^{\frac{1}{m}}} \quad \text{that} \quad \sum_{k=1}^I \alpha_i = 1 \quad (10)$$

که m مقدار فازی بودن 20 سیستم (عددی بین ۱ تا ۲) و α_i ها توابع عضویت در بازسازی (o_t) به هستند [۹]. کارایی FVQ به مراتب بیشتر از VQ (روش DD کلاسیک) است. همچنان که ملاحظه می شود، در این روش نیز مجبوریم کلیه توابع فاصله بین بردار مشاهده O_t و کلیه اعضای کتاب کد را به دست آورده و سپس آنها را مرتب کرده و کلمه کد برنده با تابع فاصله‌های متناظر را برای محاسبه α_i مورد استفاده دهیم. بنابراین نمی توانیم از ساختارهای جستجوی سریع برای اهداف این تحقیق استفاده کنیم.

۶- ارائه درون یابی KNNGI

در روش KNNFI و KNNGI ساختارهایی به شرح زیر بر روی اعضای کتاب کد (در مرحله آموزش) ایجاد می کنیم. فرض می کنیم (V_1, \dots, V_M) اعضای کتاب کد یک کلاس اکوستیکی باشند.

برای هر بردار مرجع، تعداد k نزدیکترین همسایه بر مبنای کمترین فاصله به شرح زیر به دست می آوریم. فرض می کنیم i_1, i_2, \dots, i_k تعداد k نزدیکترین همسایه کلمه کد v_i باشند یعنی داریم:

$$d(v_i, v_{i_1}) \leq d(v_i, v_{i_2}) \leq \dots \leq d(v_i, v_{i_k}) \quad (11)$$

فرایند تعیین k نزدیکترین همسایه را برای کلیه کلمات کد انجام می دهیم. ایندکس k نزدیکترین همسایه هر کلمه کد به همراه سایر اطلاعات کتاب کد را در فاز آموزش به دست آورده و ذخیره می کنیم. توجه می شود که فرایند تعیین ایندکس k نزدیکترین همسایه هر کلمه کد، صرفاً یکبار در مرحله آموزش محاسبه و ذخیره می شود.

۷- ارائه درون یابی KNNFI

فرض می کنیم O_t یک بردار مشاهده در فاز بازناسی و v_i نزدیکترین بردار مرجع به آن باشد (که با ایجاد ساختارهای

مجموع هزینه محاسباتی متناسب با $10^{24} \times 50$ عمل جمع خواهد شد. البته در تخمین هزینه محاسباتی فوق الذکر، از وارد کردن حجم محاسبات مربوط به تحلیل هر فریم و مقایسه پویا در محاسبه نمرات کلاس‌های اکوستیکی، تشخیص ابتدا و انتهای کلمه و ...، به علت مشترک بودن فرایندهای فوق الذکر در هر دو مدل DDHMM و CDHMM صرف‌نظر شده است. در محاسبات تحلیلی فوق، مشاهده می‌شود که هزینه محاسباتی حدود نصف CDHMM است. این نسبت کاهش محاسباتی، ارزش توجه و به کارگیری مدل DDHMM در مقابل CDHMM را ندارد (با توجه به مقدار افت دقت بازناسی مدل DDHMM در مقابل مدل CDHMM). هزینه محاسباتی تخمین زده شده برای مدل DDHMM با فرض استفاده از ساختار جستجوی کامل است. در سیستمهای کاربردی از ساختارهای جستجوی سریع، مانند ساختار باینری و یا ساختار تلفیقی باینری و جستجوی تصادفی k نزدیکترین همسایه استفاده می‌کنند. در حالت دوم، تعداد عملیات برای محاسبه نمره یک فریم متناسب با $2p \log_2 10^{24}$ می‌شود. (k بین ۲ تا ۴ بوده و در این تحقیق $k=3$ حاصل شده است). بنابراین در مدل‌سازی DDHMM با ساختار تلفیقی جستجوی سریع، هزینه محاسباتی برای تعیین نمره یک فریم متناسب با $10^{24} \times 1/5$ عمل جمع می‌شود. مقایسه هزینه محاسباتی مدل DDHMM با ساختار تلفیقی جستجوی سریع و مدل CDHMM، علت توجه محققان به مدل‌سازی DDHMM را به خوبی آشکار می‌کند (کاهش هزینه محاسباتی به نسبت $\frac{1}{62}$).

دو روش درون‌یابی KNNFI و KNNGI که برای جبران کاهش دقت بازناسی مدل DDHMM در طی این تحقیق ارائه و پیاده سازی شده‌اند، از ساختار تلفیقی جستجوی سریع مدل DDHMM (برای کاهش بار محاسباتی) استفاده می‌کنند. بنابراین هزینه محاسباتی آنها تقریباً معادل روش DDHMM با ساختار تلفیقی جستجوی سریع است. در روشهای ارائه شده (در فاز بازناسی)، ابتدا بردار مرجع برند (از میان 10^{24} بردار مرجع) را به روش جستجوی سریع تعیین می‌کیم. آن‌گاه

زیر را مورد توجه قرار دادیم:

فرض می‌کنیم v_i کد برنده با مشاهده بردار O_i باشد، همچنین v_{ik}, \dots, v_{i1} تعداد k نزدیکترین همسایه بردار مرجع v_i باشد. ضرایب وزنی درون‌یابی را به شرح زیر پیشنهاد و مورد استفاده قرار دادیم:

$$p_j \triangleq N(o_i, v_{ij}, \sigma_{ij}) \quad (14)$$

(-) نمایندهتابع گوسی با بردار میانگین v_{ij} و بردار واریانس σ_{ij} است.

$$\alpha_j \triangleq \frac{p_j}{\sum_{l=0}^K p_l} \quad \text{that} \quad j = 0 \quad \text{تا} \quad k \quad (15)$$

مالحظه می‌شود که در درون‌یابی KNNGI، نیز صرفاً از فاصله گوسی بردار مشاهده O_i و کد برنده O_k و k نزدیکترین همسایه آن استفاده شده است. بنابراین استفاده از درون‌یابی KNNGI به ساختار جستجوی سریع خدشهای وارد نمی‌کند.

۳-۳ بررسی کارایی محاسباتی KNNFI و KNNGI

با توجه به اینکه روشهای ارائه شده در این تحقیق برای سیستمهای بازناسی با دایره لغات وسیع طراحی شده‌اند، در نتیجه پیاده سازی هر دو مدل بازناسی (CDHMM و DDHMM) به صورت گره زدن مخلوط‌ها (TM)^{۲۸} انجام پذیرفته است. در مدل CDHMM از ۵۱۲ مخلوط گوسی و برای مدل DDHMM از 10^{24} بردار VQ برای بازنمایی pdf حالات تمامی کلمات مربوط به تمامی گویندگان استفاده کردیم. برای محاسبه مقدار درست نمائی هر فریم دریافتی در مدل DDHMM، به حداقل $512 \times 3p$ عمل (ضرب و جمع و تقسیم) و 512 محاسبه تابع اکسپننسیل و 512 عمل ضرب نیازمندیم. (p بعد بردار ویژگی است که در این تحقیق برابر ۲۵ است). فرض می‌کنیم هزینه محاسباتی هر عمل ضرب دو برابر عمل جمع و هر عمل تقسیم چهار برابر عمل جمع و محاسبه تابع اکسپننسیل ده برابر عمل جمع باشد. بنابراین مجموع تعداد عملیات محاسباتی برای تعیین نمره یک فریم دریافتی متناسب با 93×10^{24} عمل جمع می‌شود. برای حالت DDHMM

فوق الذکر را نشان می‌دهد. در آزمون مربوط به نمونه‌های آموزشی، $\frac{2}{3}$ گویندگان مرد و زن برای آموزش و $\frac{1}{3}$ گویندگان باقیمانده برای آزمایش مورد استفاده قرار گرفته‌اند. فرایند فوق پنج مرتبه با تغییر گویندگان آموزشی (به صورت تصادفی) انجام پذیرفته است. نتیجه اعلام شده متوسط و انحراف معیار این آزمون است. با مروری به نتایج چهار آزمون انجام پذیرفته به جمع‌بندی زیر می‌رسیم:

- ۱- دقت بازشناسی بر روی نمونه‌های آزمایشی همیشه کمتر از نمونه‌های آموزشی است. اما قدرت سیستم طراحی شده می‌باشد به گونه‌ای باشد که افت دقت در حد قابل قبول باشد (حدود یک تا حداقل دو درصد) افت دقت بر روی نمونه‌های آزمایشی در مدل CD-HMM قابل قبول بوده ولی برای مدل DD-HMM (بدون درون‌یابی) غیرقابل قبول است.
- ۲- قضاویت نهایی برای بررسی عملکرد یک سیستم بازشناسی، بررسی نتایج دقت بازشناسی بر روی نمونه‌های آزمایشی است. بدین لحاظ جدول (۲) نتایج بازشناسی دو روش درون‌یابی KNNGI و KNNFI را بر روی داده‌های آزمایشی نشان می‌دهد. ملاحظه می‌شود، که دقت بازشناسی دو روش درون‌یابی ارائه شده در مقایسه با مدل DD-HMM به شدت بهبود یافته و به دقت سیستم CD-HMM نزدیک شده است.
- ۳- دقت بازشناسی درون‌یابی KNNGI بر روی نمونه‌های آزمایشی به طور متوسط حدود 79% درصد بهتر از دقت بازشناسی درون‌یابی KNNFI است.
- ۴- دقت بازشناسی DD-HMM با درون‌یابی KNNGI در حدود دقت بازشناسی CD-HMM (با حدود 50% درصد افت دقت) است بنابراین با اطمینان کافی می‌توان از آن برای سیستمهای کاربردی استفاده کرد.

در آزمون دیگری، برنامه‌ای به زبان C (در محیط VC++ 6) برای بازشناسی گفتار ۱۵۰۰ کلمه فارسی به دو روش DD-HMM و CD-HMM (با درون‌یابی KNNGI) نوشته شده است. سیستم بازشناسی به روش DD-HMM (با درون‌یابی KNNGI) به طور متوسط حدود 72% ثانیه پس از دریافت

فاصله فازی یا فاصله گوسی بردار فریم دریافتی و k بردار مرجع نزدیکترین همسایه بردار مرجع برنده را محاسبه می‌کنیم. ایندکس k نزدیکترین همسایه هر بردار مرجع در فاز آموزش تعیین می‌شود. بنابراین در فاز بازشناسی به بار محاسباتی اضافی نیازی نداریم. مقدار بهینه k (تعداد همسایه‌ها) بین ۵ تا ۶ گزارش می‌شود. در این تحقیق پس از آزمایش‌های تجربی فراوان k را برابر ۶ در نظر گرفتیم.

۶- نتایج پیاده‌سازی

مدلهای درون‌یابی ارائه شده در بازشناسی ۱۵۰۰ کلمه فارسی ناوابسته به گوینده^{۲۹} مورد استفاده و ارزیابی قرار گرفتند. پایگاه داده گفتاری شامل ۳۰ مرد و ۲۰ زن بوده است. از هر گوینده حدود ۶۰ تلفظ برای هر کلمه ضبط کردیم. (ده تلفظ طی ۶ روز متفاوت). فرکانس نمونه‌برداری ۸ kHz و نمونه‌ها به صورت ۱۶ بیتی ضبط شده‌اند. داده‌های گفتاری توسط میکروفون برای کیفیت خوب در محیط عادی ضبط شده‌اند. تعداد حالات هر کلمه در مدل‌سازی HMM را برابر پنج (N=5) قرار دادیم. ویژگیهای مورد استفاده ۱۲ ضریب MFCC^{۳۰} و مشتق مرتبه اول آن و مشتق لگاریتم گین یعنی مجموعاً ۲۵ ویژگی بوده‌اند. روش تحلیل برای استخراج ویژگیهای طیفی روش PLP^{۳۱} [۵] بوده است. ویژگیهای فوق به ازای هر $6/25$ میلی ثانیه یکبار استخراج شده‌اند. برای هموار کردن کانتور ویژگیها، از یک فیلتر غیرخطی $(3 \times 7) MM$ ^{۳۲} استفاده کردیم. برای تخمین پارامترهای آماری مدل HMM از الگوریتم بام ولش [۵ و ۶] استفاده کردیم. تعداد اعضاء کتاب کد برای DDHMM برابر ۱۰۲۴ بود و برای CDHMM برابر ۵۱۲ مخلوط در نظر گرفته شدند. چندین آزمون به شرح زیر انجام پذیرفته است:

- پیاده‌سازی مدل DD-HMM بدون درون‌یابی
- پیاده‌سازی مدل DD-HMM با درون‌یابی KNNFI
- پیاده‌سازی مدل DD-HMM با درون‌یابی KNNGI
- جداول (۱) و (۲) نتایج بازشناسی برای چهار نوع مدل‌سازی

جدول ۱- نتایج دقت بازشناسی ناوابسته به گوینده مدل DDHMM و CDHMM

نوع مدل	نمونه‌های آموزشی	نمونه‌های آزمایشی
CDHMM	۹۸/۲۱ (۱/۰۵)	۹۷/۶۵ (۱/۸۵)
DDHMM	۹۹/۱۸ (۰/۰۱)	۸۹/۲۷ (۲/۸۲)

جدول ۲- نتایج دقت بازشناسی ناوابسته به گوینده مدل DD-HMM با درون‌یابی KNNFI و KNNGI

نوع درون‌یابی	نمونه‌های آموزشی	نمونه‌های آزمایشی
KNNGI	۹۸/۳۱ (۰/۹۷)	۹۷/۱۶ (۱/۹۲)
KNNFI	۹۸/۴۸ (۰/۹۱)	۹۶/۳۷ (۲/۱۲)

قدرت تعمیم پذیری مدل DDHMM، بازنمایی گستته فضای pdf توسط تعداد محدودی بردار (اعضای کتاب کد) است. در روش CDHMM به علت پیوسته بودن بازنمایی فضای pdf، بردارهایی که در فاز آموزش دیده نشده‌اند نیز دارای مقادیر احتمال مناسبی برای همان کلاس‌اند. این توانمندی به علت گستته شدن فضای pdf در مدل DDHMM در حد مناسبی برقرار نیست. البته مدل DDHMM نسبت به مدل CDHMM دارای دو برتری اساسی است؛ ۱- قدرت متمایز سازی بیشتر بر روی نمونه‌های آموزشی ۲- سرعت اجرای بسیار سریعتر. تنها مشکل آن پایین بودن قدرت تعمیم پذیری است. (یعنی پایین بودن دقت بازشناسی بر روی نمونه‌های آزمایشی که قبلًا در آموزش شرکت نداشته‌اند). روش درون‌یابی فازی FI که قبلاً توسط محققان دیگر [۸ و ۹] ارائه شده است، تا حدودی نقطه ضعف مدل DDHMM را از نظر قدرت تعمیم پذیری برطرف کرده است. روش درون‌یابی فازی کلاسیک، از ساختارهای جستجوی سریع استفاده نمی‌کند. زیرا به ازای هر بردار تست ورودی، فاصله فازی آن با تمام بردارهای مرجع محاسبه شده و سپس تعداد ۵ تا ۶ بردار مرجع که فاصله فازی آن از بقیه اعضای کتاب کد کمتر است، برای درون‌یابی نهایی انتخاب می‌شوند. بنابراین درون‌یابی فازی کلاسیک، قابلیت پیاده‌سازی سریع مدل DDHMM را کم رنگ می‌کند. در روش KNNFI که در این تحقیق ارائه کردیم، ضمن استفاده از خواص درون‌یابی فازی برای افزایش قابلیت تعمیم پذیری

کلمه مورد نظر نتایج بازشناسی را اعلام می‌کند سیستم بازشناسی به روش CD-HMM به طور متوسط حدود دو دقیقه پس از دریافت کلمه مورد نظر نتایج بازشناسی را اعلام می‌دارد. برنامه‌ها بر روی رایانه پتیوم ۴ (۲/۴ GHZ) با حافظه ۵۱۲ mbyte اجرا شدند. بنابراین از نظر اجرای بی‌درنگ، به نظر می‌رسد که روش CD-HMM قابلیت کاربرد چندانی برای دایره لغات وسیع ندارد. ولی روش DD-HMM (با درون‌یابی KNNGI) دارای قابلیت کاربرد در سیستمهای کاربردی با اجرای بی‌درنگ است.

۷- بررسی کارایی درون‌یابی KNNFI و KNNGI

مدل CDHMM، توزیع آماری بردارهای ویژگی داخل هر حالت هر کلاس اکوستیکی را توسط یک pdf پیوسته و پارامتریک، به نام GMM بازنمایی می‌کند. تعداد مخلوطهای توزیع پارامتریک GMM هر حالت، بستگی به تنوع گفتار و تعداد گوینده‌ها، متغیر است. توزیع پیوسته و پارامتریک GMM، توازن مناسبی بین قدرت متمایزسازی و قدرت تعمیم پذیری کلاسهای اکوستیکی ایجاد می‌کند. با افزایش تعداد بردارهای کتاب کد، قادریم قدرت متمایزسازی مدل DDHMM را بیشتر از مدل CDHMM کنیم. این توانمندی مدل DDHMM در اغلب تحقیقات محققان دیگر نیز گزارش شده است. متأسفانه در اغلب کاربردهای عملی، به قدرت متمایزسازی و قدرت تعمیم پذیری به طور همزمان نیازمندیم. علت اصلی پایین بودن

۸- جمع‌بندی و نتیجه‌گیری

هدف این تحقیق بازشناسی گفتار گستته (با دایره لغات وسیع) با امکان پیاده‌سازی بی درنگ (با تأخیری در حدود نیم تا حداثر یک ثانیه) بر روی رایانه‌های PC قابل دسترس بوده است. با توجه به این که مدل‌سازی HMM روش غالب و موفق در سیستمهای بازشناسی گفتار پیوسته و گستته است، از این روش برای کاربرد ذکر شده استفاده کردیم. دو رویکرد چگالی پیوسته CD و چگالی گستته DD، برای بازنمایی pdf بردارهای طیفی مورد استفاده قرار می‌گیرند. رویکرد اول CD دارای دقت بازشناسی مناسب است. متأسفانه به علت حجم بالای محاسبات (برای دایره لغات وسیع) امکان استفاده از آن در بازشناسی بی درنگ با رایانه‌های PC موجود و قابل دسترس وجود ندارد. رویکرد دوم DD اگرچه دارای دقت پایینتری (نسبت به CD) است ولی پیاده‌سازی بی درنگ آن بر روی pc های قابل دسترس امکانپذیر است. روش کلاسیک برای افزایش دقت رویکرد دوم (DD) (با حفظ ساختارهای جستجوی سریع) استفاده از درون‌یابی فازی FI است. در این تحقیق روش درون‌یابی جدیدی به نام KNNGI ارائه و مورد استفاده قراردادیم. درون‌یابی گوسی، ضمن بالا بردن دقت بازشناسی (در حد رویکرد اول CD) به راحتی بر روی رایانه‌های موجود به صورت بی درنگ قابل پیاده‌سازی است. پیاده‌سازی دو مدل درون‌یابی برای بازشناسی ناویسته به گوینده ۱۵۰۰ کلمه مجزای فارسی نشان می‌دهد که عملکرد دقت روش درون‌یابی گوسی بیشتر از درون‌یابی فازی و در حد رویکرد اول یعنی CDHMM است.

مدل DDHMM، به سرعت پیاده‌سازی مدل KNNGI نیز خدشهای وارد نمی‌کند. زیرا در روش KNNGI، از ساختارهای جستجوی سریع می‌توان برای استفاده کرد. بنابراین درون‌یابی KNNGI در مقابل روش FI کلاسیک، دارای قدرت پیاده‌سازی سریعتر است (که یکی از اهداف اصلی این تحقیق بوده است).

درون‌یابی KNNGI که نیز در این تحقیق ارائه و پیاده‌سازی شده است، ضمن حفظ قابلیت پیاده‌سازی سریعتر (همانند درون‌یابی KNNGI) مقدار مناسبی نیز به دقت بازشناسی سیستم افزوده است. این حقیقت در نتایج مندرج در جدول (۲) به خوبی آشکار است. همان طوری که از جدول (۲) مشاهده می‌شود، دقت درون‌یابی KNNGI حدود ۷۹/۰ درصد بیشتر از درون‌یابی KNNGI شده است. این افزایش دقت معادل کاهش ۲۲ درصدی خطای سیستم است. دلیل تحلیلی کاهش خطای استفاده از پارامتر نرم‌افزاری کننده واریانس و تابع تحلیلی گوسی می‌تواند باشد. همان طور که می‌دانیم، واریانس نماینده پراکندگی نمونه‌ها حول مقدار میانگین است. در درون‌یابی فازی، مستقل از واریانس خوش، فاصله بردار دریافتی با مرکز خوش محاسبه شده و از یک فاصله اقلیدسی نیز برای محاسبه فاصله فازی استفاده می‌شود. با مقایسه روابط (۱۲) و (۱۴) می‌توان گفت که علت دوم برتری درون‌یابی KNNGI، استفاده از تابع فاصله گوسی به جای تابع فاصله اقلیدسی است. بنابراین در مجموع می‌توان گفت که مدل DDHMM به همراه درون‌یابی KNNGI جایگزین مناسبی برای دسترسی به دقت بالا و پیاده‌سازی سریع سیستمهای بازشناسی با دایره لغات وسیع است.

واژه نامه

- | | | |
|--|----------------------------------|-------------------------------------|
| 1. K nearest neighbor Gaussian interpolation | 9. dynamic time warpping | 17. continious speech recognition |
| 2. fuzzy interpolation | 10. continious speech | 18. semi continious |
| 3. continious density HMM | 11. discrete (utterance) speech | 19. forward procedure |
| 4. discrete density HMM | 12. acoustic modeling | 20. Linde, Bazo, Gray |
| 5. Gaussian mixture model | 13. language modeling | 21. expectation maximization |
| 6. vector quantization | 14. acoustic to phonetic | 22. minimum distance winer codeword |
| 7. real time | 15. statistical LM | 23. semi continious density |
| 8. artifitial neural net | 16. probability density function | 24. fuzzy vector quantizition |

- | | | |
|---|--|------------------------|
| 25. fuzziness
26. K nearest neighbor fuzzy interpolation
27. KNN Gaussian interpolation
28. TIED mixture | 29. speaker dependent
30. mel frequency cepstrum
coefficient
31. perceptual linear prediction | 32. mean median filter |
|---|--|------------------------|

مراجع

1. Rabiner, L., and Juang, B.H., *Fundamentals of Speech Recognition*, Prentice Hall Inc, 1993.
2. Huang, X. D., "Phoneme Classification Using Semi Continuous Hidden Markov Models," *IEEE Transactions on signal processing*, Vol. 40, No. 5, pp.45 – 56, May 1992.
3. Zhang, Y., Tognoni, R., and Alder, M., "Phoneme Based Vector Quantization in a Discrete HMM Speech Recognizer," *IEEE Transaction on Speech and Audio Processing*, Vol. 5, No.1, January 1997.
4. Furui, S., and Sondhi, M. M, *Advances in Speech Signal Proceesing*, Marcel Dekker, Inc., 1992.
5. Beccetti, C., Ricotti, L. P., *Speech Recognition, Theory and C Implementation*, John wiley & Sons, Ltd, 1999.
6. Jurafsky, D., Martin, J. H., *Speech and Language Processing*, Prentice Hall. Inc., 2000.
7. Linde, Y., Buzo, A., Gray, R. M., "An Algorithm for Vector Quantizer design," *IEEE Transaction on Communication*, Vol. Com 28, pp. 84-95, 1980.
8. Tseng, H. P., Sabin, M., Lee, E., "Fuzzy Vector Quantization applied to Hidden Markov Modeling," *In proc, ICASSP-87*, 1987.
9. Schwartz, R., Kimball, O., kubala, F., Feng, M., Chow, Y., Barry, C., Makhoul, J., "Robust Smothing Methods for Discrete Hidden Markov Models," *In proc, ICASSP-89*, 1989.
10. Dempster, A. P., Laird, N. M., Rubin, D. B., "Maximum Likelihood from Incomplete Data Via the LM Algorithm," *J. Roy. Stat. Soc. Ser. B(methodological)*, Vol. 39, pp. 1-38, 1977.
11. Render, R. A., Walke, H. F. "Mixture Densities, Maximum Likelihood, and the EM Algorihm," *SIAM Rer.*, Vol. 26, pp. 195-239, 1984.
12. Bailey, T. L., Elkan, C., "Fitting a Mixture Model by Expectation Maximization to Discove Motifs in Biopolymers," *proc. of Biology*, pp. 28-30, AAAI PRESS, (1994).
13. Gauvain, J. L., Lee, C. H., "Maximum a Posteriori Estimation Gausian Mixture Observations of Mardov Chain," *IEEE Trans. On speech and Audio processing*, No. 2, pp. 291-298, Apr. 1994.