

آشکارسازی وجود استرس در گفتار با استفاده از ویژگی‌های مبتنی بر مدل غیرخطی تولید گفتار

شهلا ترابی^{۱,۲}، فرشاد الماس گنج^۱، امین محمدیان^۲

۱- دانشگاه صنعتی امیرکبیر، دانشکده‌ی مهندسی پزشکی

۲- پژوهشکده‌ی پردازش هوشمند علائم

نویسنده‌ی عهده‌دار مکاتبات: شهلا ترابی

چکیده

مطالعات نشان می‌دهند که استرس روانی گوینده در نحوه‌ی تولید گفتار او اثر می‌گذارد. آشکارسازی وجود استرس در گفتار دارای کاربردهای متعدد می‌باشد. در کارهای اخیر، ویژگی‌های صوتی مختلف، به صورت جداگانه، توسط طبقه‌بندی‌کننده‌ی HMM مورد ارزیابی قرار گرفته‌اند و از میان آن‌ها، ویژگی غیرخطی TEO-CB-Auto-Env کارآمدترین پارامتر بوده است. در این مقاله، یک ویژگی جدید که آن را (TEO-Pch-LFPC) می‌نامیم، پیشنهاد شده است. دادگان گفتار استرسی (حالات خنثی، عصبانی، بلند و لمبارد) از پایگاه داده‌ی SUSAS برداشته شده و نقطه‌ی قوت کار حاضر این است که در آن، از طبقه‌بندی‌های ساده‌تری نسبت به HMM استفاده شده است، یعنی طبقه‌بندی‌های استاتیک (SVM، LDA و KNN)، و روش ارزیابی نیز RRM می‌باشد. با استفاده از ویژگی TEO-Pch-LFPC و طبقه‌بند SVM در تفکیک دو حالت، درصد صحت ۹۳.۷۸٪ و در طبقه‌بندی چندحالته ۷۰.۲۲٪ می‌باشد.

کلید واژه: آشکارسازی استرس، آشکارسازی احساس، پردازش گفتار

در تعاملات انسان و رایانه طبیعی‌تر است سعی کنیم با رایانه‌ها همان‌گونه که با انسان‌ها رابطه برقرار می‌کنیم، ارتباط برقرار کنیم. برای این منظور رایانه‌ها باید به گونه‌های احساس و استرس انسانی حساسیت داشته باشند. مطالعاتی که در مورد تعاملات انسان و رایانه انجام شده است، نشان می‌دهد که آشکارسازی استرس گوینده، حاوی اطلاعات مهمی می‌باشد [۳]. اگر بتوان به طرقی وجود استرس و انواع آن را تعیین کرد، آن‌گاه این اطلاعات می‌توانند با سیستم‌های بازشناسی گفتار تلفیق شوند و عملکرد این سیستم‌ها را بهبود بخشند. همچنین، آشکارسازی استرس می‌تواند کاربرد پزشکی، نظامی و یا قضایی (دروغ سنجه) داشته باشد [۱].

بهطور کلی، استرس به یکی از حالات‌های زیر یا ترکیبی از آن‌ها اطلاق می‌شود [۴]: "احساسات منفی (عصبانیت، ترس، تأسف)، اجبار برای انجام یک وظیفه در یک زمان محدود و شرایط محیطی نامطلوب (مقدار زیاد نویز پس‌زمینه)". در این میان حالات عصبانی، بلند و اثر لمبارد

۱- مقدمه

یکی از کارکردهای گفتار، انتقال مفاهیم غیرزبانی و حالت روحی شخص است؛ طوری که گاهی نقش احساسات در برقراری ارتباط، فراتر از اطلاعات منطقی منتقل می‌شود [۱]. هنگامی که یک لغت توسط یک فرد تلفظ می‌شود، بسته به این که چگونه ادا شود معانی مختلفی خواهد داشت؛ بهطور مثال، کلمه‌ی «really» در زبان انگلیسی، می‌تواند معانی مختلفی داشته باشد (سؤالی باشد، مفهوم «تحسین‌کردن» را داشته باشد و یا با حالت تعجب بیان گردد). بنابراین فهمیدن مفهوم لغوی یک کلمه به تنها یکی، برای تعبیر معانی آن کافی نیست. برقراری ارتباط را از طریق ارسال و دریافت پیام‌های غیرزبانی، یا به عبارتی «پیام‌های غیروابسته به کلمات»، ارتباط غیرکلامی^۱ (NVC) می‌گویند [۲]. در این زمینه، یکی از مسائلی که در سال‌های اخیر به‌طور تخصصی مورد توجه قرار گرفته، بازشناسی استرس از گفتار شخص است.

^۱ Non-Verbal Communication

مبتنی بر TEO می‌تواند در تفکیک دو حالته (گفتار خنثی و یکی از حالات استرسی) عملکرد مناسبی داشته باشد، اما مشاهده می‌شود که در طبقه‌بندی چندحالته‌ی استرس، درصد صحت طبقه‌بندی، به شدت افت می‌کند.

هنگامی که یک کلمه در حالات مختلف استرسی بیان می‌شود سیگنال، هم در حوزه‌ی زمان و هم در حوزه‌ی فرکانس دستخوش تغییر می‌گردد. یک معیار ممکن برای اندازه‌گیری استرس موجود در گفتار، برسی توزیع انرژی طیفی در باندهای فرکانسی مختلف است. فرض می‌شود سیستم شناوایی انسان یک فرآیند فیلترینگ است که در آن کل محدوده‌ی فرکانسی قابل شنیدن به تعداد زیادی باندهای بحرانی قسمت‌بندی می‌شود [۱]. بنابراین توزیع انرژی در لگاریتم باندهای فرکانسی مختلف می‌تواند یک ویژگی مناسب برای طبقه‌بندی استرس باشد. به‌همین دلیل ویژگی‌های زیرباندی مبتنی بر FFT می‌توانند برای طبقه‌بندی استرس مناسب باشند؛ زیرا تبدیل فوریه (بدون این‌که به زمان وابستگی داشته باشد) خطی بودن در رزولوشن فرکانسی را حفظ می‌کند. ضرایب LFPC^۴ برای این منظور مناسب‌اند [۶,۷].

در مراجع مختلف [۳, ۸]، ویژگی‌های طیفی حاصل از تجزیه‌ی مبتنی بر ویولت، به عنوان نشان‌گرهایی از استرس معرفی شده‌اند. اما، این ویژگی‌ها وابسته به زمان هستند و بیشتر برای کاربرد بازشناسی گفتار مناسب‌اند تا طبقه‌بندی استرس. چراکه در بازشناسی لغات، توالی زمانی آواها در کلمه مهم است اما در یک حالت استرسی (مثلًا عصبانیت)، توالی زمانی خاصی در سیگنال مدنظر نیست. به‌طور مثال، اگر بلندی صدای مرتبط با عصبانیت را در نظر بگیریم هیچ زمان مشخص و ثابتی در کلمه موجود نیست که این بلندی در آن زمان خاص باشد. این رویداد می‌تواند در ابتداء، وسط یا انتهای کلمه رخ دهد. تا زمانی که بلندی صدا هست، حالت عصبانیت توصیف می‌شود [۳].

در مقالات سه روش برای طبقه‌بندی استرس موجود می‌باشد [۹, ۲]:

- ۱- روش مبتنی بر شبکه‌های عصبی مصنوعی (ANNs)
 - ۲- مدل مخفی مارکوف چند کاناله
 - ۳- ترکیب مدل‌های مخفی مارکوف
- واماک و هانسن^۵ [۹] برای طبقه‌بندی استرس از روش شبکه‌ی عصبی استفاده کرده‌اند و این‌گونه گزارش کرده‌اند

^۴ Log-Frequency Power Coefficients

^۵ Womack , Hansen

پرکاربردترین دادگان گفتار استرسی مورد استفاده در مقالات هستند [۱، ۳، ۴، ۵]. اثر لمبارد به شرایطی گفته می‌شود که شخص در یک محیط نویزی قرار دارد و سعی می‌کند حالت تولید گفتارش را به‌گونه‌ای تغییر دهد که صدایش بهتر به گوش شنونده برسد [۵].

محفغان سعی کرده‌اند با بررسی متغیرهای صوتی از قبیل فرکانس پایه، دامنه، شدت، تراکم انرژی طیفی، مکان سازه‌ها^۱ [۳، ۴، ۵] و موارد دیگر، شاخص‌های قابل اعتمادی را برای استرس تعیین نمایند (اکثر پارامترهای نامبرده، مبتنی بر تئوری خطی تولید گفتار هستند). در تئوری خطی فرض می‌شود که جریان هوا از داخل تارهای صوتی به صورت یک موج خطی منتشر می‌شود و انقباض یا حرکت تارهای صوتی، به عنوان منبع تولید گفتار شناخته می‌شوند.

ارزیابی‌ها نشان می‌دهند که ویژگی‌های مبتنی بر مدل خطی تولید گفتار، همواره برای آشکارسازی استرس مناسب نیستند و نشان داده شده است که از بین این ویژگی‌های خطی، ویژگی گام گفتار بهترین عملکرد را دارد. از طرف دیگر، مطالعات تیگر [۱] نشان می‌دهند که در داخل ناحیه‌ی صوتی، جریان هوا به‌طور یکنواخت در تارهای صوتی منتشر نمی‌شود، بلکه به صورت تفکیک شده درمی‌آید و در نزدیکی دیوارهای مرمرکز می‌گردد؛ به این ترتیب گرداب‌هایی در سرتاسر ناحیه‌ی صوتی پدیدار می‌شوند. منبع تولید صوت، تعاملات بین جریان این گرداب‌هاست و ماهیت غیرخطی دارد. از آنجایی که تغییرات فیزیولوژیک ناشی از استرس، روی الگوی تعاملات بین جریان گرداب‌ها تأثیر می‌گذارند، برای تفکیک گفتار خنثی و استرسی، نیاز به ویژگی‌های غیرخطی داریم [۳].

تیگر یک اپراتور انرژی به نام TEO^۲ را به صورت زیر ارائه می‌کند که در آن $(n)^x$ سیگنال گفتار نمونه‌برداری شده است:

$$\Psi[x(n)] = x^2(n) - x(n+1)x(n-1) \quad (1)$$

در مرجع [۱] سه ویژگی غیرخطی که از اپراتور TEO مشتق شده‌اند برای طبقه‌بندی استرس، پیشنهاد شده است که از بین آن‌ها ویژگی TEO-CB-Auto-Env^۳ به عنوان کارآمدترین پارامتر شناخته می‌شود. اگرچه این ویژگی

^۱ Formant

^۲ Teager Energy Operator

^۳ Critical band based TEO autocorrelation envelope area



۲- تعریف استرس

از دیدگاه پردازش گفتار استرسی، استرس به حالتی گفته می‌شود که در آن تولید گفتار یک گوینده از حالت طبیعی خارج شود [۱۳، ۱۲، ۳]. در مقابل، اگر گوینده در یک محیط آرام و بدون هیجان باشد، فشار کاری نداشته باشد و دچار احساسات و یا اضطراب نشده باشد، آنگاه گفتار تولید شده حالت طبیعی خواهد داشت. با این تعریف، دو حوزه‌ی استرسی پیداگار می‌شوند [۱۳]: "ادراکی" و "فیزیولوژیکی". در استرس ادراکی، شخص از طریق مشاهده درمی‌یابد که محیط پیامونش از حالت طبیعی خارج شده و به همین دلیل، "آهنگ" گفتارش نسبت به حالت خنثی تغییر می‌کند. دلایل استرس ادراکی عبارتند از احساسات، نویز محیطی (اثر لمبارد) و استرس کاری.

استرس فیزیولوژیکی نتیجه‌ی تأثیر یک عامل فیزیکی روی بدن شخص است که موجب می‌شود آهنگ تولید گفتار او از حالت خنثی خارج شود. عوامل ایجاد کننده این نوع استرس عبارتند از: لرزش بدن، تعاملات شیمیایی داروها، بیماری، اثر G-Force (تأثیر جاذبه‌ی زمین روی بدن شخص در فرود یا صعود ناگهانی) و یا سنگینی هوا.

همان‌طور که می‌دانیم در علم گفتار، به تأکیدی هم که روی سیالاب‌های یک کلمه می‌شود، استرس گفته می‌شود. برای این‌که این دو نوع استرس، با هم اشتباہ نشوند در تحقیقات از عبارت «گفتار تحت استرس» استفاده می‌شود. مفهوم «تحت استرس» این است که فشاری روی گوینده وجود دارد و این فشار روی فرآیند تولید گفتارش اثر می‌گذارد.

۳- پایگاه داده

در این مطالعه ارزیابی‌های صورت گرفته به منظور طبقه‌بندی استرس، روی پایگاه داده SUSAS^۱ [۱۲] انجام شده‌اند. این پایگاه داده قبلاً توسط هانسن جمع‌آوری شده است. تمام کلمات با یک A/D 16 بیتی با نرخ نمونه‌برداری ۸ کیلو هرتز، نمونه‌برداری شده‌اند. ما ارزیابی‌های خود را روی بخش شبیه‌سازی شده SUSAS انجام می‌دهیم. علت این امر این است که استرس ظاهر شده در شرایط واقعی شدیدتر و آسان‌تر قابل تشخیص می‌باشد [۱]؛ یعنی با همین روند آشکارسازی، در شرایط واقعی به درصد صحت بالاتری دست خواهیم یافت، جزئیات بیشتر در [۱] آمده است.

^۱ Speech under stress

^۲ Speech Under Simulated and Actual Stress

که، عملکرد طبقه‌بندی استرس توسط شبکه‌ی عصبی، از طریق اندازه‌ی فاصله‌ی تفکیک‌پذیری ویژگی‌های است و با تغییر اندازه‌ی لغت و نیز تغییر شخص گوینده، نتیجه‌ی این عملکرد، به طور جدی تغییر می‌کند؛ و با توجه به عملکرد ضعیف این طبقه‌بند در آشکارسازی استرس، لازم است تست‌ها به صورت واپسی به متن و واپسی به گوینده انجام گردد. درنتیجه، روش شبکه‌ی عصبی در این زمینه کارآیی چندانی ندارد؛ و دو روش طبقه‌بندی دیگر هم دینامیک هستند [۳].

در کار حاضر، سعی داریم از طبقه‌بندهای دیگری که تاکنون در این زمینه مورد استفاده قرار نگرفته‌اند (یعنی طبقه‌بندهای استاتیک (KNN، LDA و SVM)) استفاده کنیم. لازم به ذکر است که پیاده‌سازی و کاربرد طبقه‌بندهای استاتیک، ساده‌تر و سریع‌تر است.

در کار جاری، در درجه‌ی اول، تلاش ما در جهت تعیین یک مجموعه ویژگی مفید و کاربردی است که قادر باشد «وجود استرس در گفتار» را تشخیص دهد و در ضمن، ایده‌آل خواهد بود اگر بتوانیم حالات مختلف استرسی را در سیگنال‌های گفتاری از هم تفکیک نماییم. ویژگی پیشنهاد شده، TEO-Pch-LFPC نام دارد و توسط آن عملکرد تأم پارامترهای (۱) گام گفتار، (۲) TEO-CB-Auto-Env و (۳) ضرایب LFPC را در آشکارسازی استرس روانی گوینده بررسی می‌کنیم. اگرچه اکثر مطالعات اخیر از طبقه‌بند مبتنی بر HMM که نسبتاً پیچیده است استفاده کرده‌اند [۱، ۳، ۵، ۱۰]، اما از آن‌جاگی که تمرکز ما روی انتخاب بهترین مجموعه ویژگی کاربردی است، ابتدا از دو طبقه‌بند معمول LDA و KNN که خوش‌رفتار هستند و پیاده‌سازی آن‌ها ساده است، استفاده می‌کنیم [۱۱]؛ سپس، نتایج طبقه‌بندی را، به‌ازای طبقه‌بند SVM که قوی‌تر است، بیان خواهیم کرد.

کار حاضر به صورت زیر سازماندهی شده است:

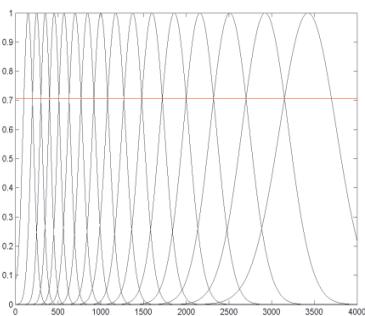
در بخش ۲ مفهوم استرس از دیدگاه پردازش گفتار استرسی تعریف می‌شود. بخش ۳ پایگاه داده مورد استفاده را توضیح می‌دهد. بخش ۴ ویژگی‌های صوتی منفرد را برای طبقه‌بندی استرس توصیف می‌کند. بخش ۵ این ویژگی‌ها را ترکیب می‌کند تا به یک بردار ویژگی کارآمدتر دست یابد. بخش ۶ روی نتایج به دست آمده از بخش ۵ بحث می‌کند و آن‌ها را با بهترین نتایج کارهای قبلی مقایسه می‌کند. در نهایت در بخش ۷، پیشنهادهایی برای کارهای آینده ارائه می‌گردد.

$$\begin{aligned}\alpha_1 &= 266, \alpha_2 = 266, \alpha_3 = 266, \alpha_4 = 294, \alpha_5 = 321, \\ \alpha_6 &= 374, \alpha_7 = 401, \alpha_8 = 427, \alpha_9 = 507, \alpha_{10} = 561, \\ \alpha_{11} &= 641, \alpha_{12} = 747, \alpha_{13} = 854, \alpha_{14} = 1014, \\ \alpha_{15} &= 1201, \alpha_{16} = 1467,\end{aligned}$$

با جایگزینی t توسط nT ، معادله $g(t)$ گسته‌سازی می‌شود (T پریود نمونه‌برداری است). $g(n)$ یک فیلتر FIR متقان در فاصله $n \leq N$ است که با سیگنال گفتار، کانولو می‌شود [۱۴]:

$$g(n) = \begin{cases} \exp(-b^2 n^2) \cos(\Omega_c n), & |n| \leq N \\ 0 & |n| > N \end{cases} \quad (4)$$

در این رابطه، $b = \alpha t$ و $\Omega_c = 2\pi f_c$ است. طوری انتخاب می‌شود که پوش گوسین $g(n)$ در $n = N$ ، لزومناً به صفر برسد. معادله $\exp(-b^2 N^2) \approx 10^{-5}$ یک انتخاب مناسب برای N به دست می‌دهد.



شکل ۱: دامنه نرمالیزه شده پاسخ فرکانسی فیلترهای گابور [۱]

برای استخراج بردار ویژگی TEO-CB-Auto-Env، هر پروفایل TEO به فریم‌هایی به طول ۲۵ میلی‌ثانیه، با هم پوشانی ۱۲.۵ میلی‌ثانیه بین فریم‌های مجاور، بخش‌بندی می‌شود. برای هر فریم زمانی، M تا مساحت نرمالیزه شده زیر پوش بالای خودهمبستگی TEO، استخراج می‌شود (یعنی برای هر باند بحرانی یکی) و M تعداد کل باندهای بحرانی است ($M=16$). در محاسبه این ویژگی نیازی به تخمین F_0 نمی‌باشد. روابط ریاضی مربوط به فرآیند فوق به صورت زیر خلاصه می‌شوند:

$$u_j(n) = s(n) * g_j(n), \quad j = 1, 2, 3, \dots, 16 \quad (5)$$

$s(n)$ سیگنال گفتار، $u_j(n)$ خروجی هر فیلتر گابور میانگذر و "۳۰" اپراتور کانولشن می‌باشد. $(n)_j \Psi$ ، یعنی

دلیل استفاده از پایگاه داده SUSAS این است که در حال حاضر این مجموعه، به عنوان استاندارترین و پرکاربردترین داده‌ی گفتاری استرس‌دار مورد استفاده قرار می‌گیرد. مزیتی که این پایگاه داده دارد این است که اکثر مقالات مرتبط با موضوع «پردازش گفتار استرس‌دار» تحقیقات خود را روی این دادگان انجام داده‌اند و این امر ما را قادر می‌سازد که بتوانیم نتایج خود را با کارهای قبلی مقایسه کنیم.

در حوزه شبیه‌سازی شده هر کلمه توسط هر گوینده دو بار گفته شده است. از آن جایی که عملکرد اپراتور TEO برای واکدارها بهتر از بی‌واک‌ها است در هر مورد فقط از بخش واکدار هر کلمه استفاده می‌شود [۵، ۱۲].

۴- استخراج ویژگی

4-1-4 TEO-CB-Auto-Env :

همان‌طور که اشاره شد، به طور تجربی فرض می‌شود که سیستم شنوایی انسان یک فرآیند فیلترینگ است و کل محدوده فرکانسی قابل شنیدن را به تعداد زیادی باندهای بحرانی قسمت‌بندی می‌کند [۱]. بر پایه این فرضیه، ویژگی TEO-CB-Auto-Env از یک بانک فیلتر با ۱۶ باند بحرانی، برای سیگنال گفتار استفاده می‌کند و سپس پردازش TEO انجام می‌شود [۱]. هر فیلتر موجود در بانک فیلتر، یک فیلتر گابور میان‌گذر است که پهنانی باند RMS مؤثر آن به اندازه‌ی باند بحرانی مربوطه است (شکل ۱). دلیل انتخاب فیلتر گابور این است که این فیلتر هم در حوزه‌ی زمان و هم در حوزه‌ی فرکانس، به صورت بهینه فشرده شده است. شکل گوسین $H(f)$ مانع از تولید لوب‌های کناری (بزرگ) می‌شود [۱۴]. پاسخ ضریبه و پاسخ فرکانسی این فیلتر در حالت پیوسته به صورت زیر تعریف می‌شوند [۱۵]:

$$g(t) = \exp(-\alpha^2 t^2) \cos(2\pi f_c t) \quad (2)$$

$$G(f) = \frac{\sqrt{\pi}}{2\alpha} \left[\exp\left(-\frac{\pi^2(f-f_c)^2}{\alpha^2}\right) + \exp\left(-\frac{\pi^2(f+f_c)^2}{\alpha^2}\right) \right] \quad (3)$$

f_c فرکانس مرکزی فیلتر و α پارامتری است که پهنانی باند را تنظیم می‌کند (۱۶ مقدار دارد):

فرکانسی ۱۰۰ هرتز تا فرکانس نایکوئیست (نصف فرکانس نمونهبرداری)، سیگنال ورودی را به تعداد زیادی خروجی می‌شکند. انرژی در بانک فیلتر Iam از طریق معادله‌ی زیر محاسبه می‌گردد:

$$S_t(m) = \sum_{k=f_m-b_m/2}^{k=f_m+b_m/2} (X_t(k))^2, m=1,2,\dots,12. \quad (9)$$

که در آن $X_t(k)$ ، امین مؤلفه‌ی طیفی سیگنال قطعه‌بندی شده است. t تعداد فریم‌ها و $S_t(m)$ خروجی بانک فیلتر Iam است و f_m و b_m به ترتیب فرکانس مرکزی و پهنه‌ای باند زیرباند Iam می‌باشند. انرژی در خروجی بانک فیلتر Iam به صورت زیر محاسبه می‌شود:

$$\text{LFPC}_t(m) = 10 \frac{\log_{10}(S_t(m))}{N_m} \quad (10)$$

که در آن N_m تعداد مؤلفه‌های طیفی در زیرباند Iam است. برای هر فریم ۱۲ پارامتر LFPC بدست می‌آید.

۵- ارزیابی

ارزیابی‌ها در دو مرحله انجام می‌شوند [۱۸]: در مرحله‌ی اول سیگنال گفتار ورودی به عنوان گفتار خنثی و یا استرس‌دار طبقه‌بندی می‌گردد. بعد از این‌که حالت غیرخنثی آشکارسازی شد، می‌توان روی آن پردازش‌هایی به منظور تفکیک حالات استرسی مختلف انجام داد.

ما در آزمایش‌های خود از بخش واکدار مجموعه لغات زیر که از پایگاهداده SUSAS برداشته شده‌اند، استفاده می‌کنیم: “fix”，“eighty”，“east”，“no”，“nav”，“mark”，“help”，“enter” و “oh”. برای هر حالت استرسی (خنثی، عصبانی، بلند و لمبارد) ۲۰ کلمه (دو ضرب در ۱۰) از ۹ گوینده داریم؛ در مجموع ۷۲۰ کلمه.

بعد از استخراج ویژگی‌های ذکر شده در بالا از بخش واکدار TEO-CB-Auto- هر کلمه، ابتدا پارامترهای آماری ویژگی- Pch (یعنی میانگین و انحراف معیار آن) در آن واکه تخمين زده می‌شوند^۱ و سپس مقدار متوسط گام گفتار به این پارامترهای آماری اضافه می‌گردد (تا اینجا بعد بردار ویژگی ما ۳ است). عملکرد این بردار ویژگی که آن را TEO-Env- می‌نامیم برای طبقه‌بندی دو حالت و چند حالت استرس

^۱ توجه شود که در کارهای قبلی که از ویژگی- Pch به صورت منفرد استفاده می‌شد، بعد این ویژگی به تنها ۱۶ بود. در ضمن عملکرد پارامترهای آماری این ویژگی بهتر است.

پروفایل TEO مربوط به باند بحرانی Iam مطابق تعریف، به صورت زیر است:

$$\Psi_j(n) = \Psi[u_j(n)] = u_j^2(n) - u_j(n-1)u_j(n+1) \quad (6)$$

$$R_{\Psi_j^{(i)}(n)}(k) = \sum_{n=1}^{N-k} \Psi_j^{(i)}(n) \Psi_j^{(i)}(n+k) \quad (7)$$

تابع خودهمبستگی فریم i از $\Psi_j^{(i)}(n)$ می‌باشد. به این ترتیب بردار ویژگی TEO-CB Auto-Env به ازای هر فریم، ۱۶ پارامتر دارد.

۴-۲- مقدار متوسط گام گفتار:

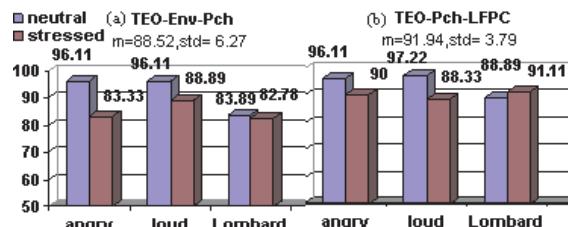
نشان داده شده است [۱] که مقدار متوسط گام گفتار در شرایط غیرخنثی به طور محسوسی تغییر می‌کند. ما از مقدار متوسط گام گفتار به عنوان یک ویژگی در آشکارسازی استرس گوینده، استفاده می‌کنیم. به ازای هر واکه، مقدار متوسط گام گفتار به روش Cross-Correlation محاسبه می‌شود.

۴-۳- مقدار LFPC :

ویژگی‌های LFPC مبتنی بر FFT [۱۶، ۷، ۶]، برای شبیه‌سازی مشخصه‌های فیلترینگ لگاریتمی سیستم شناوری انسان، با استفاده از اندازه‌گیری باندهای طیفی، طراحی شده‌اند. ابتدا سیگنال گفتار به پنجره‌های زمانی زمان کوتاه ۲۵ میلی ثانیه، بخش‌بندی می‌شود. سپس محتوا فرکانسی هر فریم با استفاده از روش FFT محاسبه می‌گردد. این طیف توان به یک بانک فیلتر با فرکانس لگاریتمی داده می‌شود. در [۱۷]، ایده طراحی یک بانک فیلتر ۱۲ بانده ارائه می‌شود که برای شکستن سیگنال گفتار به باندهای شناوری، با گوش انسان مطابقت دارد. فرکانس مرکزی f_i و پهنه‌ای باند b_i به صورت زیر تعریف می‌گردد:

$$\begin{aligned} b_1 &= C \\ b_i &= ab_{i-1}, 2 \leq i \leq 12 \\ f_i &= f_i + \sum_{j=1}^{i-1} b_j + \frac{(b_i - b_j)}{2} \end{aligned} \quad (8)$$

به ازای $F_s = 8000$ (فرکانس نمونه‌برداری پایگاه داده مورد استفاده) مقادیر $C = 100$ ، $\alpha = 1.3$ ، $f_1 = 100$ هستند. این بانک فیلتر از طریق ۱۲ فیلتر میان‌گذر با محدوده‌ی



شکل ۱: طبقه‌بندی دو حالته با استفاده از LDA. در هر مورد std به معنای انحراف معیار و m به معنای مقدار میانگین است.

۵-۲-۵- طبقه‌بندی چندحالته (چهار طبقه)

بعد از آشکارسازی حالات استرسی، هر حالت می‌تواند به صورت جداگانه تفکیک شود [۱۸]. در جدول (۲) درصد صحت‌های طبقه‌بندی چندحالته‌ی استرس، برای ویژگی‌های پیشنهاد شده، بیان می‌شوند و در جدول (۳)، بهترین نتایج TEO-Pch-LFPC (۲) (یعنی نتایج مربوط به ویژگی LFPC) با جزیيات بیشتر آورده شده است. در اینجا RRM به ۷۲۰ کلمه اعمال می‌شود.

جدول ۲: طبقه‌بندی چندحالته‌ی استرس (طبقه)

	LFPC	TEO-Env-Pch	TEO-Pch-LFPC
LDA	۵۵.۱۴	۵۸.۴۷	۶۱.۲۵
KNN	۵۵.۵۶	۵۵.۱۴	۶۵.۸۵

جدول ۳: جزیيات نتایج طبقه‌بندی چندحالته‌ی استرس توسط

TEO-Pch-LFPC ویژگی

KNN	a) Correct Detection Rate (%)		b) Distribution of STRESS Detection Rate (%) across 3 Styles		
	Neutral	Stress	Angry	Loud	Lombard
Neutral	۸۶.۱۱		۰	۴	۹۶
Angry		۹۵ ۹۳.۸۹	۵۵.۵۶ ۸۷.۷۸	۲۵.۱۵ ۲۰.۱۲	۱۹.۳ ۲۷.۲۲
Loud				۵۲.۶۶	
Lombard				۹.۴۳	۸۵.۵۳
Total Rate	Test		Train		
	۶۵.۸۵		۸۶.۱۰		

هدف این ارزیابی این است که ابتدا دریابیم ویژگی پیشنهاد شده تا چه حد می‌تواند گفتار خنثی و استرس‌دار را از هم تفکیک کند و در ضمن تا چه حد قادر است حالات مختلف استرسی را از هم جدا نماید. در جدول (۳) ابتدا نتایج آشکارسازی صحیح خنثی و استرسی گزارش می‌شوند [بخش (a)]. بهمنظور پیاده‌سازی این فرآیند، کل دادگان استرسی به عنوان "گفتار استرسی" در یک گروه قرار می‌گیرد. اگر یک کلمه‌ی خنثی به عنوان داده‌ی تست به طبقه‌بند داده شود، آشکارسازی صحیح زمانی اتفاق می‌افتد.

بررسی می‌شود. سپس بردار ویژگی پیشنهاد شده با اضافه-کردن LFPCC (۱۲ پارامتر) تکمیل می‌گردد (بردار ویژگی نهایی TEO-Pch-LFPC). نامیده می‌شود و بعد آن ۱۵ است. برای تعیین طبقه‌ی هر نمونه، ابتدا از طبقه‌بندی‌های ساده‌ی KNN و LDA استفاده می‌کنیم. به‌ازای هر طبقه‌بند، نتایج ویژگی LFPC هم گزارش شده است. روش ارزیابی RRM^۱ می‌باشد [۵]. به این معنی که، هر بار یک کلمه (از دو تلفظ مربوط به یک سوژه) به عنوان داده‌ی تست کنار گذاشته می‌شود و از بقیه‌ی کلمات برای تعلیم استفاده می‌گردد. این فرآیند به‌ازای تمام داده‌ها تکرار می‌شود و سپس روی نتایج میانگین گرفته می‌شود.

در ادبیات گفتار استرسی، آشکارسازی استرس را «تفکیک دو حالت» و تفکیک حالات مختلف استرسی از هم را «طبقه‌بندی چندحالته» می‌گویند. در ضمن، منظور از تشخیص استرس در این تحقیق، آشکارسازی خودکار وجود استرس ادراکی در یک کلمه است.

در بخش ۱-۵ فقط تفکیک دو حالتی (خنثی/استرسی) را توصیف می‌کنیم. در حالی که در بخش ۲-۵ تلاش می‌کنیم، حالات مختلف استرسی را از هم جدا کنیم.

۵-۱-۵- طبقه‌بندی دو حالت

در این رویکرد برای هر طبقه‌بند سه بار عمل تفکیک را انجام می‌دهیم و هر بار روی دو حالت کار می‌کنیم (حالت خنثی و یکی از حالات استرسی). به این ترتیب، در هر طبقه‌بندی دو حالت، RRM به ۳۶۰ کلمه اعمال می‌شود که نصف آن‌ها دادگان گفتاری خنثی و نصف دیگر مربوط به دادگان گفتاری آن حالت استرسی خاص می‌باشند. جدول (۱) درصد صحت متوسط‌گیری شده‌ی کل را، به‌ازای هر ویژگی، گزارش می‌کند.

جدول ۱: طبقه‌بندی دو حالتی استرس

Accuracy	LFPC	TEO-Env-Pch	TEO-Pch-LFPC
LDA	Mean(%)	۸۶.۵۰	۸۸.۵۲
	std	۳.۸۹	۶.۲۷
KNN	Mean(%)	۸۵.۲۷	۸۸.۱۴
	std	۵.۱۷	۶.۳۱

به منظور مقایسه با کارهای قبلی شکل (۲) بهترین نتایج این جدول (یعنی نتایج طبقه‌بند LDA) را با جزیيات بیشتر نشان می‌دهد.

^۱ Round-Robin Method



در ارزیابی‌های آن‌ها ثابت بوده است. نتایج طبقه‌بندی دو حالتی آن‌ها در جدول (۵) گزارش شده است:

جدول ۵: نتایج تفکیک دو حالت با طبقه‌بند HMM [۱]

	m	std
گام گفتار	۸۱.۸۳	۱۷.۴۶
TEO-CB-Auto-Env	۸۷.۲۳	۸.۷۶

همچنین، برای طبقه‌بندی چندحالته درصد صحت کل و نرخ آشکارسازی صحیح حالت خنثی به ترتیب بصورت زیر هستند [۱]:

جدول ۶: نتایج طبقه‌بندی چهارحالت با طبقه‌بند HMM [۱]

	نرخ آشکارسازی صحیح حالت خنثی	درصد صحت کل
گام گفتار	%۵۸.۵	%۵۲.۲
TEO-CB-Auto-Env	%۵۶.۱۶	%۷۰.۶

به نظر می‌رسد این ویژگی‌ها قادر نیستند، حالات لمبارد و خنثی را به طور مناسبی از هم تفکیک کنند [۱]. دلیل این مسئله این‌گونه توجیه شده است که با بررسی نرخ توزیع آشکارسازی استرس، متوجه می‌شویم حالات مختلف استرسی تا حدودی با هم، همپوشانی دارند. علت این امر این است که شرایط استرسی، بسیار پراکنده هستند و نمی‌توان آن‌ها را در تعداد محدودی داده‌ی تعلیم گنجاند. معمولاً جفت‌های (عصبانی و بلند) با هم و جفت‌های (خنثی و لمبارد) با هم اشتباہ گرفته می‌شوند؛ چرا که به طور مثال، اشخاص اغلب سعی می‌کنند عصیانیت خود را با بلند کردن صدایشان نشان دهند. حال می‌خواهیم با ثابت نگهداشتن ویژگی، طبقه‌بند را از نوع دینامیک به نوع استاتیک تغییر دهیم؛ برای این منظور، ۱۶ پارامتر ویژگی- TEO-CB-Auto- Env را به عنوان ورودی به طبقه‌بند KNN می‌دهیم، نتایج زیر بدست می‌آید (طبقه‌بند LDA در این زمینه بسیار ضعیف عمل می‌کند و نتایج حتی از شانس هم کمتر است):

جدول ۷: جزئیات نتایج طبقه‌بندی ۴ حالت استرس توسط ویژگی TEO-CB-Auto-Env

KNN	a) Correct Detection Rate (%)		b) Distribution of STRESS Detection Rate (%) across 3 Styles		
	Neutral	Stress	Angry	Loud	Lombard
Neutral	۶۸.۳۲				
Angry		۸۷.۲۲	۵۷.۳۲	۳۱.۲۱	۱۱.۴۶
Loud		۷۹.۴۴	۲۱.۸۸	۴۶.۸۸	۳۱.۲۵
Lombard		۸۸.۸۹	۹.۷۹	۳۳.۵۷	۵۶.۶۴
Total Rate	Test		Train		
	۵۱.۲۵		۷۵.۹۷		

که طبقه‌بند برچسب خنثی را آشکار کند (۱۱/۸۶%). در حالی که برای یک کلمه‌ی استرسی اگر برچسب آشکار شده متعلق به هر یک از حالات استرسی باشد، آن‌گاه فرض بر این است که حالت استرسی درست تشخیص داده شده است. (به عنوان مثال ۹۵٪ داده‌های عصبانی به عنوان گفتار استرسی تشخیص داده می‌شوند، نه لزوماً به عنوان داده‌ی عصبانی).

در بخش (b) نتایج تفکیک چندحالته گزارش می‌شود؛ یعنی با این فرض که کلمه به عنوان استرسی تشخیص داده شده باشد، می‌خواهیم بینیم که چند درصد این حالت استرسی، درست همان حالتی که بوده است، تشخیص داده شده است.

برای تست خنثی (بخش (b)) نرخ خطأ را می‌دهد. بخش عمده‌ای از کلمات خنثی که به طور اشتباه استرس دار تشخیص داده شده‌اند، متعلق به حالت لمبارد هستند (۹۶٪؛ جدول ۳).

جدول ۴: جزئیات نتایج طبقه‌بندی ۴ حالت استرس توسط ویژگی SVM و طبقه‌بند TEO-Pch-LFPC

SVM classifier	a) Correct Detection Rate (%)		b) Distribution of STRESS Detection Rate (%) across 3 Styles		
	Neutral	Stress	Angry	Loud	Lombard
Neutral	۹۱.۰۵				
Angry			۹۷.۲۲	۵۳.۳۳	
Loud			۹۷.۵۳		۵۶.۰۱
Lombard			۹۴.۷۵		۸۷.۹۵
Total Rate	Test		Train		
	۷۰.۲۲		۷۷.۰۱		

توضیحات مربوط به جدول (۴) در بخش بعدی آورده شده است.

۶- بحث

مطالعات نشان می‌دهند [۱۸] که طبقه‌بندی چندحالته استرس فقط در حالت وابسته به گوینده عملکرد مناسبی دارد و این عملکرد در کاربردهای مستقل از گوینده افت می‌کند. در مرجع [۱] هر یک از ویژگی‌های TEO-CB-Auto-Env و گام گفتار به طور جداگانه توسط طبقه‌بندی‌های مبتنی بر HMM پنج حالت (۴ مدل HMM) با ۴۳۲ کلمه از SUSAS در مرحله‌ی تعلیم بررسی شده بودند. برای هر حالت استرسی ۲۷۰ کلمه (یه‌جز آن‌هایی که در مرحله‌ی تعلیم بودند) به صورت خودکار برای تست استفاده شده‌اند. بدین ترتیب مجموعه دادگان تست و تعلیم

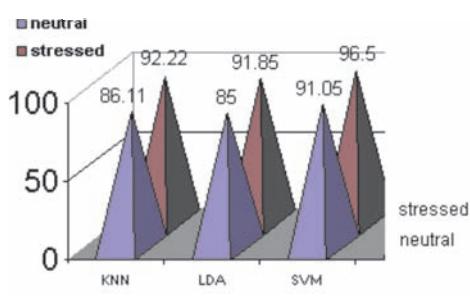
را خلاصه می‌کند. در ضمن، برای مقایسه، نتایج ویژگی TEO-CB-Auto-Env مجموعه‌ی حاضر، در مقایسه با کارهای اخیر، هم ماهیت ویژگی‌ها و هم ماهیت طبقه‌بند (طبقه‌بند HMM از نوع دینامیک است) تغییر کرده‌اند. در شکل(۲)، خلاصه‌ی نتایج آورده شده است.

جدول ۸: خلاصه‌ی نتایج تفکیک دو حالته با ویژگی TEO-Pch- LFPC مخفف N و Neutral S مخفف Stressed می‌باشد.

		Neutral	Angry	Loud	Lombard	نیزه‌اشکارسازی	نیزه‌محض
		N	۸۶.۱۱			۱۱.۸۶	۷۱.۱۷
KNN	S		۵	۹۳	۸۷.۷۷	۲۱.۲۲	۸۹.۱۷
	N	۷۷				۷۸	۷۸.۷۷
LDA	S		۴۴.۴۴	۹۲	۸۸.۳۳	۵۱.۸۱	۸۷.۷۷
	N	۵۰				۵۰	۷۷.۳۳
SVM	S		۹۷.۲۲	۹۷	۹۴.۷۵	۶۶	۷۰.۲۲
	N	۹۱.۰۰				۹۱.۰۰	۷۰.۲۲

جدول ۹: خلاصه‌ی نتایج طبقه‌بندی چهار حالته

	KNN	LDA	SVM
TEO-CB-Auto-Env	۵۱.۲۵	-	۵۶.۶۴
TEO-Pch-LFPC	۶۵.۸۵	۶۱.۲۵	۷۰.۲۲



شکل ۲: خلاصه‌ی نتایج در تفکیک دو حالته (TEO-Pch-LFPC) ویژگی

همان‌طور که مشاهده می‌شود نتایج این ویژگی با طبقه‌بند استاتیک هم، برای تفکیک چند حالتی استرس مناسب نمی‌باشد. مرجع [۱] بحث خود را این‌گونه خاتمه می‌دهد: "کیفیت عملکرد TEO-CB-Auto-Env و گام گفتار با هم متفاوت است، به این ترتیب که TEO-CB-Auto-Env در جاکردن گفتار خنثی از استرسی، عملکرد بهتری دارد؛ در حالی که گام گفتار در آشکارسازی حالات استرسی بهتر عمل می‌کند. به این ترتیب پیشنهاد می‌شود که ترکیب این دو ویژگی، عملکرد طبقه‌بند را بهبود می‌دهد." بر اساس این پیشنهاد، در کار حاضر این دو ویژگی با هم تلفیق شدند. یادآوری این نکته ضروری است که اگرچه ترکیب گام گفتار و TEO-CB-Auto-Env تا حدودی مؤثر بوده است (ستون یکی مانده به آخر جدول‌های ۱ و ۲) اما دلیل اصلی بهبود نتایج، دخیل کردن ضرایب LFPC می‌باشد (ستون آخر جدول‌های ۱ و ۲). توجه شود که این بهبود، بهزاری ساده‌ترین طبقه‌بند است و هنگامی که از طبقه‌بندهای استاتیک دیگر چون SVM استفاده می‌کنیم، نتایج به دست آمده، بسیار بهتر می‌شوند. در کار حاضر از SVM با هسته‌ی RBF استفاده شده است. نتایج مربوط به این طبقه‌بند در جدول ۴، آمده است. در اینجا هم روش ارزیابی، RRM است و افزایش چشمگیر نرخ آشکارسازی حالت خنثی (۹۱.۰۵) و درصد صحت کل (۷۰.۲۲) مشهود می‌باشد. با توجه به این که در هر دو نوع طبقه‌بندی (دو حالته و چند حالته)، عملکرد طبقه‌بند SVM از دو طبقه‌بند استاتیک دیگر بهتر است، برای مقایسه‌ی نهایی نتایج این کار با ویژگی قبلی (TEO-CB-Auto-Env و TEO-Pch-LFPC) از مجموعه (ویژگی) استفاده می‌کنیم (در طبقه‌بند SVM با استفاده از طبقه‌بند SVM، ۱۳.۵۸٪ بهبود مشاهده می‌شود، جدول ۹).

نکته‌ی قابل تأمل این است که در کارهای اخیر، در رویکرد تفکیک دو حالته، هر بار روی دو حالت کار شده است (حالت خنثی و تنها یکی از حالات استرسی). اگرچه، در این تحقیق، نتایج با این شیوه هم گزارش شده‌اند، اما این مسئله قدری اشکال دارد! چرا که هیچگاه، در کاربرد عملی، نمی‌توان یک حالت استرسی خاص داشت و فقط روی آن حالت تمرکز نمود. معقول‌تر این است که بهمنظور پیاده‌سازی این فرآیند، کل دادگان استرسی به عنوان «گفتار استرس‌دار» در یک گروه قرار گیرند. بنابراین، گزارش نهایی نتایج تفکیک دو حالته را بر اساس این معیار ارائه می‌دهیم (جدول ۸)؛ جدول ۹ نتایج مربوط به طبقه‌بندی چهار حالته

انتخاب «مناسب‌ترین مجموعه‌ی ویژگی‌طبقه‌بند» مرکز شدیم و روی بحث استقلال از گوینده مرکز نکردیم؛ چراکه هدف ما نخست، بررسی قابلیت آشکارسازی استرس گوینده و سپس، بهبود نتایج در مقایسه با کارهای قبل بود. از آن جایی که تاکنون، در مبحث تشخیص استرس گفتاری به صورت مستقل از گوینده، کاری انجام نشده است، پیشنهاد می‌شود در کارهای آینده این امر هم مورد توجه قرار گیرد. با به کارگیری رویکردهای مختلف و مقایسه‌ی نتایج آن‌ها با هم، این مهم دست یافتنی به نظر می‌رسد.

برای داشتن یک سیستم بازناسی احساس «مستقل از زبان» باید مجموعه‌ای از گفتارهای احساسی به زبان‌های مختلف گردآوری شوند. اما ابتدا باید به این سؤال پاسخ داد که «آیا می‌توان مستقل از زبان کار کرد یا نه؟!». برای پاسخ به این سوال، اولین مرحله این است که یک واکه‌ی ثابت را، که توسط گویندگان بومی زبان‌های مختلف گفته شده است، مورد پردازش قرار دهیم.

در نهایت، تعیین میزان و سطح استرس گوینده (کم، متوسط و یا زیاد) می‌تواند یک موضوع قابل بررسی برای تحقیقات آینده باشد. روش‌های موجود برای آشکارسازی استرس، فقط از یک رویکرد تضمیم‌گیری دو حالت (وجود یا عدم وجود استرس) بهره می‌گیرند. چون میزان استرس متغیر است، این‌گونه به نظر می‌رسد که برای تشخیص صحیح حالت استرسی گوینده، نیاز است که سطح استرس فرد نیز به درستی تشخیص داده شود.

۸- مراجع

- [1] G. Zhou, J. H. L. Hansen and J. F. Kaiser, "Nonlinear Feature Based Classification of Speech under Stress," IEEE Trans. Speech and Audio Processing, vol. 9, No. 3, March 2001.
- [2] T. Polzin, "Detecting verbal and non-verbal cues in the communication of emotions". Doctoral Dissertation, School of Computer Science, Carnegie Mellon University, 2000.
- [3] D. Ververidis and C. Kotropoulos, "Emotional Speech Recognition: Resources, Features and Methods," Artificial Intelligence and Information Analysis Laboratory, Aristotle University of Thessaloniki, April 2006.
- [4] D. A. Cairns and J. H. L. Hansen, "Nonlinear Analysis and Classification of Speech Under Stressed Conditions," Robust Speech Processing Laboratory, Department of Electrical Engineering, Duke University, July 1994.
- [5] G. Zhou, J. H. L. Hansen and J. F. Kaiser, "A New Nonlinear Feature for Stress Classification," Robust Speech Processing Laboratory, Duke University, 1998.
- [6] T. L. Nwe, Y. Wang, "Automatic Detection of Vocal Segments in Popular Songs," School of Computing National University of Singapore, 2004.

با وجود این که شرایط با کارهای پیشین یکسان نیست، یعنی تعداد دادگان در مرحله‌ی تعلیم افزایش یافته است، اما به نظر می‌رسد رویکرد پیشنهاد شده در این مقاله در مقایسه با تحقیقات اخیر عملکرد بهتر و ساده‌تری دارد.

۷- نتیجه‌گیری و پیشنهادها

یک راه برای ارتقای نرخ آشکارسازی استرس گوینده، تلفیق شیوه‌های قدیمی با روش‌های موجود است. با استفاده از نتایج به دست آمده از طبقه‌بندی ویژگی‌های منفرد، در کار حاضر چند ویژگی خطی و غیرخطی را (که در مطالعات اخیر بهترین عملکرد را داشته‌اند)، با هم ترکیب کرده‌ایم و از طبقه‌بندی‌های استاتیک LDA، KNN و SVM استفاده نموده‌ایم. به عنوان یک پیشنهاد برای کارهای آینده، می‌توان طبقه‌بند مبتنی بر HMM را با این طبقه‌بندی‌های استاتیک ترکیب کرد. همچنین می‌توان قبل از ترکیب ویژگی‌ها، به هر کدام یک وزن مناسب اختصاص داد و یا یکتابع مناسب اعمال کرد تا نرخ طبقه‌بندی در عملکرد تأثیر آن‌ها، بهبود یابد (این کار باید بر اساس نظر فیزیولوژیست‌ها و اشخاص کارشناس در این زمینه انجام گردد). اعمال طبقه‌بندی‌های HMM یا DBN به ویژگی پیشنهاد شده، می‌تواند یک شناسنامه جدید برای مدل‌سازی دینامیک گفتار استرسی را فراهم نماید.

یکی از مشکلات امدهای که در پردازش گفتار استرسی (به خصوص هنگام کاربرد عملی) با آن مواجه می‌شویم مشکل کمبود داده‌ی برچسب‌خورده است. روش‌های طبقه‌بندی سنتی نمی‌توانند از دادگان بدون برچسب استفاده نمایند. از طرف دیگر، برچسب‌زدن داده‌های این حوزه، هزینه‌بر و زمان‌بر است و به نظر افراد متخصص نیاز دارد. روش‌های یادگیری نیمه‌سرپرستی [۱۹، ۲۰] می‌توانند برای حل این مشکل مفید باشد. الگوریتم طبقه‌بندی نیمه‌سرپرستی با استفاده از دادگان بدون برچسب، فرضیات به دست آمده توسط دادگان برچسب‌دار را اصلاح می‌کنند و حتی گاهی فرضیات جدید و قوی‌تری می‌سازند.

در ضمن، از آن‌جایی که اکثر راه‌کارهای بازناسی و طبقه‌بندی استرس گفتاری، وابسته به گوینده هستند [۳، ۲۱]. باید سعی شود این وابستگی تا حد امکان کاهش یابد. به نظر می‌رسد، ساده‌ترین راه برای این منظور، تلفیق روش‌های طبقه‌بندی استرس با الگوریتم‌های بازناسی گوینده باشد [۲۱]. به طور کلی، اگر قرار باشد مقوله‌ی پردازش گفتار استرسی، جنبه‌ی کاربردی پیدا کند، باید مستقل از گوینده و حتی مستقل از زبان باشد. در مجموعه‌ی حاضر، ما روی

^۱ منظور از این برچسب، حالات مختلف استرسی (عصبانی، بلند، خنثی و اثر لمبارد) است و با برچسب مربوط به جداسازی اوج‌ها تفاوت دارد.

- [21] P. Thevenaz, and H. Hugli, "Usefulness of the LPC Residue in Text-independent Speaker Verification," *Speech Communication*, Vol.17, pp. 145-157,1995 .



شهلا ترابی (متولد ۱۲ تیر ۱۳۶۳) در سال ۱۳۸۵، در رشته مهندسی پزشکی، گرایش بالینی (دوره کارشناسی)، از دانشگاه امیرکبیر فارغ التحصیل شده است. سپس دوره کارشناسی ارشد در همین رشته (گرایش بیوالکتریک)، را تا سال ۱۳۸۸، ادامه داده است. زمینه تحقیقاتی مورد علاقه‌ی او، پردازش گفتار و نیز پردازش عالم حیاتی می‌باشد.

نشانی پست الکترونیکی ایشان عبارت است از:
Shahla_t5024@yahoo.com



فرشاد الماس گنج در سال ۱۳۶۳ در رشته برق، گرایش الکترونیک، از دانشگاه امیرکبیر فارغ التحصیل گردیده است. سپس دوره کارشناسی ارشد در همین رشته را تا سال ۱۳۶۷ ادامه داده است. او با یک فاصله ۴ ساله، دوره دکتری برق (گرایش مهندسی پزشکی) را در دانشگاه تربیت مدرس آغاز نموده و از سال ۱۳۷۷ با سمت استادیار در دانشکده مهندسی پزشکی از دانشگاه امیرکبیر مشغول به کار است. زمینه تحقیقاتی اصلی او پیرامون پردازش سیگنال و عمدتاً در زمینه بازناسی گفتار فارسی و بازناسی خصوصیات پژوهشی گفتار می‌باشد.

نشانی پست الکترونیکی ایشان عبارت است از:
almas@aut.ac.ir



امین محمدیان مدرک کارشناسی خود را در رشته مهندسی پزشکی در سال ۱۳۸۱ از دانشگاه صنعتی امیرکبیر و مدرک کارشناسی ارشد در رشته مهندسی برق- بیوالکتریک را در سال ۱۳۸۴ از دانشگاه تربیت مدرس اخذ نمود. او هم اکنون دانشجوی دکتری مهندسی پزشکی- بیوالکتریک در دانشگاه صنعتی امیرکبیر و مدیر گروه پردازش عالم حیاتی پژوهشکده پردازش هوشمند عالم می‌باشد. زمینه‌های تحقیقاتی مورد علاقه‌ی اوی پردازش سیگنال‌های EEG، ERP در حالات ذهنی، پردازش تصاویر حرارتی، پردازش اطلاعات فرا گفتار، شناسایی الگو و محاسبات نرم می‌باشد.

نشانی پست الکترونیکی ایشان عبارت است از:
Mohammadian@Rcisip.ac.ir

- [7] K. H. Hyun, E. H. Kim and Y. K. Kwak, "Robust Speech Emotion Recognition Using Log Frequency Power Ratio," *SICE-ICASE International Joint Conference*, 2006.
- [8] R. Sarikaya, N. Gowdy, "Wavelet Based Analysis of Speech under Stress," *Digital Speech and Audio Processing Laboratory of Clemson University*, 1998.
- [9] B.D. Womack and J.H.L Hansen. N-channel hidden markov models for combined stressed speech. *IEEE Trans Speech Audio Proc*, 7(6):668–677, 1999.
- [10] G. Zhou, J. H. L. Hansen and J. F. Kaiser, "Classification of Speech Under Stress Based on Features Derived from the Nonlinear Teager Energy Operator," *IEEE ICASSP-98*, 1998.
- [11] A. Mohammadian and V. Aboutalebi, "Single Trial Classification of Event-Related Potentials for Detection of Target stimulus" *Journal of Biannual Letter of Research Center of Intelligent Signal Processing*, No. 1, serial.5, pp.3-12, 2006.
- [12] J. H. L. Hansen and S. Bou-Ghazale, "Getting Started with SUSAS: A Speech under Simulated and Actual stress," in proc. *EUROSPEECH '97*, vol. 4, pp. 1743-1746, 1997.
- [13] B. D. Womak and J. H. L. Hansen, "N-Channel Hidden Markov Model for Combined Stressed Speech Classification and Recognition," *IEEE Transactions on Speech and Audio Processing*, vol. 7, NO. 6, November 1999.
- [14] P. Maragos, J. F. Kaiser and T. F. Quatieri, "Energy Separation in Signal Modulations with Application to Speech Analysis," *IEEE Trans. Signal Proc.*, vol. 41, NO. 10, pp. 3025-3051, October 1993.
- [15] A. Potamianos and P. Maragos, "Speech Formant Frequency and Bandwidth Tracking Using Multiband Energy Demodulation," *School of Electrical and Computer Engineering, Georgia of Technology*, June 1994.
- [16] T.L. Nwe, S.W. Foo, and L.C. De Silva. "Detection of stress and emotion in speech using traditional and FFT based log energy features," In *Fourth Pacific Rim Conference on Multimedia, Information, Communications and Signal Processing*, volume 3, pages 1619–1623, December 15-18 2003.
- [17] K. Hyun, E. Kim and Y. Keun Kwak, "robust speech recognition using log frequency power ratio", *SICE-ICACE International Joint Conference*, 2006.
- [18] G. Zhou, J. H. L. Hansen and J. F. Kaiser, "Linear and Nonlinear Speech Feature Analysis for Stress Classification," *Robust Speech Processing Laboratory*, Duke University, 1998.
- [19] W. Du, K. Inoue, and K. Urahama, "Unsupervised and semi-supervised extraction of fuzzy clusters in similarity data," *IEICE Technical Report, PRMU 2005-177*, Jan. 2006.
- [20] B. Krishnapuram, D. Williams, Y. Xue, A. Hartemink, L. Carin, and M. Figueiredo, "On semi-supervised classification," *Proc. NIPS*, pp.721–728, 2005.

