

۱۹-۷۱ اردیبهشت ۱۳۷۶

پنجمین کنفرانس مهندسی برق ایران



مجموعه مقالات - ۵

مخابرات (الف)

دانشگاه صنعتی شریف

دانشکده مهندسی برق

ICEE - 97



جداسازی دو سیگنال صحبت درهم

مسعود باباییزاده و محمود تیبیانی

دانشکده برق دانشگاه صنعتی شریف

چکیده: در این مقاله روش جدیدی برای جداکردن دو سیگنال صحبت مخلوط ارائه شده است. بر خلاف روش‌های قبلی موجود، که دو صحبت را در حوزه فرکانس از هم جدا می‌کردند، کلیه محاسبات این روش در حوزه زمان انجام می‌گردد. این روش بر مبنای قضیه جالب و ساده‌ای قرار دارد، که آن هم برای نخستین بار در این مقاله بیان می‌شود. برای آنالیز و سنتز صحبت نیز، از مدل سینوسی صحبت استفاده شده است.

کلمات کلیدی: سیگنال صحبت، جداسازی، مدل سینوسی صحبت، حداقل مربعات.

۱ - مقدمه

مسئله جداکردن دو سیگنال صحبت مخلوط، با وجود بیش از بیست سال تحقیق، هنوز به جواب مطلوبی متوجه نشده است. شکل موج پیچیده سیگنال صحبت، و طبیعت غیرایستان آن، باعث عدم موفقیت کلیه تلاشهای انجام شده برای حل این مسئله گردیده است. نخستین بار شیلدز و اپنهایم^۱ به این مسئله پرداختند و استفاده از فیلتر شانه‌ای را برای حل این مسئله بررسی نمودند [۱]. ایده انتخاب دامنه هارمونیکها برای حل این مسئله، نخستین بار توسط پارسونز^۲ مطرح گردید [۲] و بعد

¹ V.C. Shields and A.V. Oppenheim

² T.W. Parsons

توسط دیگران کاملتر شد [۳ و ۴ و ۵]. کواتیری و دانیسویچ^۳ استفاده از مدل سینوسی صحبت را در حل این مسأله آزمودند [۶] و برخی کار آنها را دنبال کردند [۷ و ۸]. ویژگی همه این روشها آنست که عمل جداسازی، در حوزه فرکانس انجام می‌شود و محدود بودن طول فریمها (ناشی از طبیعت غیرایستان صحبت)، باعث کاهش قدرت تفکیک در حوزه فرکانس و همپوشانی پیکها و بالاخره دشواری عمل جداسازی می‌گردد.

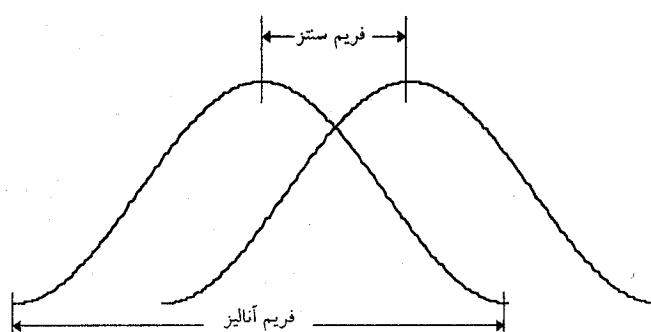
روشن معرفی شده در این مقاله، عمل جداسازی را در حوزه زمان انجام می‌دهد و در نتیجه مشکل قدرت تفکیک کم در حوزه فرکانس، تا حد زیادی کاهش می‌یابد. همچنین، قضیه‌ای مطرح خواهیم کرد که با استفاده از آن و پذیرفتن درصدی خطأ، می‌توان حجم محاسبات را به مقدار زیادی کاهش داد، نتایج بدست آمده نیز حاکی از موفقیت این روش در عمل هستند.

۲ - مدل سینوسی صحبت

در این مدل، سینگنال صحبت در هر لحظه، بصورت جمع تعدادی سینوسی با دامنه، فاز و فرکانس‌های مختلف مدل می‌شود [۹]^۴، یعنی:

$$x(t) = \sum_{k=1}^M a_k \cos(\omega_k t + \varphi_k) \quad (1)$$

یکی از مزایای این مدل، مستقل بودن طول فریم‌های ستز و آنالیز از یکدیگر است (شکل ۱). هنگام تجزیه صحبت، پارامترهای مدل در طول یک فریم آنالیز محاسبه شده و به نقطه مرکزی فریم نسبت داده می‌شود. سپس در هنگام ستز، با توجه به معلوم بودن پارامترها در دو انتهای فریم ستز، مقادیر آنها در نقاط میانی درونیابی می‌گردد. نشان داده شده است [۹]^۵ که برای درونیابی مقادیر دامنه، می‌توان از درونیابی خطی استفاده کرد، در حالیکه برای محاسبه فاز و فرکانس در نقاط میانی، باید از یک چندجمله‌ای درجه سه بهره برد.



شکل (۱): فریم‌های ستز و آنالیز در مدل سینوسی صحبت

توجه شود که برای نواحی واکدرا صحبت، فرکانس‌های این مدل، هارمونیکهای فرکانس اصلی (گام) صحبت هستند.

³ T.F. Quatieri and R.G. Danisewics

مدل فوق را می‌توان به سادگی برای دو صحبت نیز تعمیم داد^[۶]. در اینحالت داریم:

$$x[n] = \sum_{k=1}^{M_a} a_k \cos(\omega_{a,k} n + \phi_{a,k}) + \sum_{k=1}^{M_b} b_k \cos(\omega_{b,k} n + \phi_{b,k}) \quad (2)$$

استخراج فرکانسها از روی صحبت مخلوط، عملی دشوار آست و در این مقاله (همچون بیشتر مقاله‌های قبلی)، بمنظور شبیه‌سازی روش ارائه شده، آنها را از قبل معلوم فرض می‌نماییم.

۳- جداسازی دو صحبت مخلوط

برای جدا کردن دو صحبت از یکدیگر، قضیه زیر را بکار می‌گیریم^[۱۰]:

قضیه: فرض کنید سیگنال $x[n]$ جمع تعدادی سینوسی با فرکانس‌های متفاوت باشد، یعنی:

$$x[n] = \sum_{k=1}^{M_a} a_k \cos(\omega_{a,k} n + \phi_{a,k}) + \sum_{k=1}^{M_b} b_k \cos(\omega_{b,k} n + \phi_{b,k})$$

علاوه بر آن فرض کنید فرکانس تعدادی از سینوسی‌های تشکیل دهنده سیگنال فوق، مثلاً $\omega_{a,k}$ را می‌دانیم و می‌خواهیم دامنه و فازهای آنها را بدست آوریم. در این صورت اگر سیگنال زیر را با دامنه و فازهای مجهول تشکیل دهیم:

$$y[n] = \sum_{k=1}^{M_a} a'_k \cos(\omega_{a,k} n + \phi'_{a,k})$$

و مقادیر این دامنه و فازهای مجهول را بگونه‌ای تعیین کنیم که میانگین $|x[n] - y[n]|^2$ حداقل شود، آنگاه همان مقادیر دامنه و فاز واقعی را بدست خواهیم آورد، یعنی:

$$a'_k = a_k, \quad \phi'_{a,k} = \phi_{a,k}, \quad k = 1, \dots, M_a$$

با توجه به قضیه بالا، برای یافتن یکی از صحبت‌ها، کافی است یک ترکیب خطی از فرکانس‌های تشکیل دهنده آن صحبت را، با دامنه و فازهای مجهول، تشکیل داده و مقادیر این دامنه و فازها را بگونه‌ای تعیین کنیم که میانگین مربعات خطای سیگنال حاصل با سیگنال مخلوط حداقل شود. در اینصورت طبق قضیه بالا، سیگنال بدست آمده، همان صحبت مورد نظر خواهد بود.

برای محاسبه این دامنه و فازها، از فرم تربیعی^۴ سیگنال سینوسی استفاده کرده و ابتدا سعی می‌کنیم خطای خطا را صفر نماییم.

در اینصورت به دستگاه معادلات زیر خواهیم رسید:

⁴ Quadrature Form

$$\mathbf{H} \cdot \mathbf{c} = \mathbf{s}, \quad (3)$$

که در آن:

$$\mathbf{H} = \begin{bmatrix} 1 & 1 & 1 & \cdots & 0 & 0 & \cdots \\ 1 & \cos(\omega_{a,1} \cdot 1) & \cos(\omega_{a,2} \cdot 1) & \cdots & \sin(\omega_{a,1} \cdot 1) & \sin(\omega_{a,2} \cdot 1) & \cdots \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots \\ 1 & \cos(\omega_{a,1} \cdot (N-1)) & \cos(\omega_{a,2} \cdot (N-1)) & \cdots & \sin(\omega_{a,1} \cdot (N-1)) & \sin(\omega_{a,2} \cdot (N-1)) & \cdots \end{bmatrix} \quad (4)$$

و:

$$\mathbf{c} = \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \beta_1 \\ \beta_2 \\ \vdots \end{bmatrix}, \quad \mathbf{s} = \begin{bmatrix} x[0] \\ x[1] \\ \vdots \\ x[N-1] \end{bmatrix} \quad (5)$$

دستگاه بالا را باید به مفهوم میانگین مربعات حل کنیم، یعنی \mathbf{c} را طوری بدست آوریم که $\|\mathbf{H} \cdot \mathbf{c} - \mathbf{s}\|^2$ حداقل شود. می‌توان ثابت کرد [11] که در اینصورت \mathbf{c} از رابطه زیر بدست می‌آید:

$$\mathbf{c} = (\mathbf{H}^* \mathbf{H})^{-1} \mathbf{H}^* \cdot \mathbf{s} \quad (6)$$

پس از محاسبه \mathbf{c} داریم:

$$\begin{aligned} \alpha_k &= \sqrt{\alpha_k^2 + \beta_k^2} \\ \phi_{a,k} &= \tan^{-1}(\beta_k / \alpha_k) \end{aligned} \quad (7)$$

و در نتیجه صحبت اویل بازسازی می‌شود.

۴ - درونیابی چندفریمی

گاهی اوقات برخی از فرکانس‌های صحبت دوم، بیش از اندازه به فرکانس‌های صحبت اویل نزدیک می‌شوند و این پدیده باعث ایجاد خطأ در محاسبه دامنه و فاز متناظر می‌گردد. برای رفع این مشکل، فاصله فرکانس‌های دو نفر را همواره تحت مراقبت قرار می‌دهیم و در صورت وقوع پدیده فوق، فرکانس مربوطه را به نشانه غیرقابل اعتماد بودن دامنه علامت‌گذاری می‌کنیم. در نهایت هنگام بازسازی صحبت، وقتی به چنین بلوکهایی رسیدیم، بجای آنکه تنها یک فریم سنتز را در نظر

بگیریم، فریمهای قبلی و بعدی را نیز تا جاییکه به دامنه قابل اعتمادی برسیم با هم به عنوان یک فریم سنتز طولانی‌تر در نظر گرفته و درونیابی پارامترها را در این فریم طولانی انجام می‌دهیم. به این عمل درونیابی چندفریمی می‌گوییم. استفاده از این روش باعث افزایش کیفیت صدایها می‌گردد.

۵- نتایج

با استفاده از روش مطرح شده، سیستمی برای جداکردن دو صحبت پیاده‌سازی گردید. برای این منظور از صحبتها بطور جداگانه و با فرکانس 10 KHz نمونه‌برداری کردیم. سپس فرکانسهای مدل سینوسی آنها محاسبه گردیده و در فایلهای جداگانه‌ای ذخیره شدند. همچنین گام صحبتها را نیز بطور جداگانه محاسبه نمودیم.

در مرحله اول با استفاده از فرکانسهای مدل سینوسی هرکدام از صحبتها، یکبار بدون استفاده از روش درونیابی چندفریمی و بار دیگر با استفاده از آن، مخلوط آنها را جداکردیم. سپس چندین نفر، به عنوان داور، به این صحبتها گوش کرده و دو نمره، یکی برای میزان جداسازی صحبتها، و دیگری برای کیفیت صحبتهاست ثبت کردند. همگی افراد به میزان جداسازی نمره کامل (۴) دادند. میانگین نمره داده شده به کیفیت صحبتها، در حالت استفاده از درونیابی چندفریمی، ۲/۹ و در حالت استفاده نکردن از آن، ۲/۱ بود. این نکته، کارآیی درونیابی چند فریمی را در بهبود کیفیت، نشان می‌دهد. در مرحله بعد بجای معلوم بودن همه فرکانسهای مدل سینوسی، تنها فرکانس اصلی (گام) آنها معلوم فرض شد و بقیه فرکانسهای مدل، هارمونیکهای آن فرض گردید. نتیجه حاصل از بررسی این صحبتها نشان داد که میزان جداسازی از ۴ به ۲/۳ افت پیدا کرده است.

در مرحله سوم، بجای استفاده از قضیه مطرح شده، ترکیب خطی از کلیه فرکانسها بکار برده شد (حجم محاسبات در اینحالت حدود ۸ برابر بیشتر است). هیچکدام از داوران تفاوتی بین کیفیت صحبتهاست بازسازی شده با صحبتهاست مرحله اول تشخیص ندادند و این، کارآیی قضیه مطرح شده را در کاهش حجم محاسبات نشان می‌دهد.

۶- خاتمه

در این مقاله پس از معرفی مدل سینوسی، روشی برای جداسازی دو صحبت درهم معرفی گردید. ویژگی این روش، انجام همه محاسبات در حوزه زمان است. همچنین قضیه‌ای برای افزایش سرعت محاسبه بیان شد. در نهایت یک مطالعه subjective برای بررسی کارآیی روش انجام گردید که این مطالعه، کارآیی روش معرفی شده را بخوبی نشان داد.

مراجع

- [1] V.C. Shields, "Separation of Added Speech Signals by Digital Comb Filtering," M.S. Thesis, MIT, 1970.
- [2] P.W. Parsons, "Separation of Simultaneous Vocalic Utterances of Two Talkers," Ph.D. Thesis, Department of Elec. Eng., Polytech. Inst. of New York, 1975.
- [3] B.A. Hanson and D.Y. Wong, "The Harmonic Magnitude Supression (HMS) Technique for Intelligibility Enhanc 1984, 18A.5.1-18A.5.4.
- [4] D.G. Childers and C.K. Lee, "Co-Channel Speech Separation," ICASSP 1987, 6.4.1-6.4.4.
- [5] J.A. Naylor and C. Cahnnel Speech," ICASSP 1987, 6.12.1-6.12.4.
- [6] T.F. Quatieri and R.G. Danisewics, "An Approach to Co-Channel Talker Interference Supression Using a Sinusoidal Model for Speech," IEEE Trans. on ASSP, Vol. 38, pp.56-69, January 1990.
- [7] F.M. Silva and L.B. Almeida, "Speech Separation by Means of Stationary Least Squares Harmonic Estimation," ICASSP 1990, pp. 809-812.
- [8] J.A. Naylor and J. Porter, "An Effective Speech Separation System which Requires No Priori Information," ICASSP 1991, pp. 937-940.
- [9] R.J. McAulay and T.F. Quatieri, "Speech Analysis/Synthesis Based on A Sinusoidal Representation," IEEE trans. on ASSP, vol. 34, pp. 744-754, Aug. 1986.
- [10] باباییزاده، مسعود، "جهازاسازی دو سیگنال صحبت مخلوط"، رساله کارشناسی ارشد، دیماه ۱۳۷۵، دانشکده برق دانشگاه صنعتی شریف.
- [11] Kay, S.M., *Modern Spectral Estimation*, Prentice Hall, 1988.