بهسازی گفتار به‌کمک یادگیری واژه‌نامه مبتنی‌بر داده

سمیرا مودّتی[1]* و سید محمد احدی[2]

[1]استادیار، دانشکده فنی و مهندسی، دانشگاه مازندران، بابلسر، ایران

[2]استاد، دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر، تهران، ایران

چکیده

بهسازی گفتار یکی از پرکاربردترین حوزه‌ها در زمینه پردازش گفتار است. در این مقاله، یکی از روش‌های بهسازی گفتار مبتنی‌بر اصول بازنمایی تُنُک بررسی می‌شود. بازنمایی تُنُک این امکان را فراهم می‌سازد که عمده اطلاعات لازم برای بازنمایی سیگنال، براساس بُعد بسیار کمتری از پایه‌های فضایی اصلی قابل مدل‌سازی باشد. روش یادگیری در این مقاله براساس تصحیح الگوریتم تطبیقی حریصانه مبتنی‌بر داده خواهد بود که واژه‌نامه در آن، به‌طور مستقیم از روی سیگنال داده و براساس شاخص تُنُکی مبتنی‌بر نُرم به منظور تطابق بیشتر میان اتم‌ها و ساختار داده آموزش می‌بینند. در این مقاله شاخص تُنُکی جدیدی براساس معیار جینی پیشنهاد می‌شود. همچنین محدوده پارامتر تُنُکی بخش‌های نوفه‌ای با توجه به فریم‌های ابتدایی گفتار تعیین و طی یک روال پیشنهادی در تشکیل واژه‌نامه مورد استفاده قرار می‌گیرد. نتایج بهسازی نشان می‌دهد که عملکرد روش پیشنهادی در انتخاب قاب‌های داده براساس معیار معرفی‌شده در شرایط نوفه‌ای مختلف بهتر از شاخص تُنُکی مبتنی‌بر نُرم و سایر الگوریتم‌های پایه در این راستا است.

واژگان کلیدی: بهسازی گفتار، بازنمایی تُنُک، یادگیری واژه‌نامه، مبتنی‌بر داده، تطبیقی حریصانه، شاخص تُنُکی جینی

Speech Enhancement using Adaptive Data-Based Dictionary Learning

Samira Mavaddati[1*] & Seyyed Mohammad Ahadi[2]

[1]Electrical Department, Faculty of Technology and Engineering, University of Mazandaran, Babolsar, Iran

[2]Electrical Engineering Department, Amirkabir University of Technology, Tehran, Iran

Abstract

In this paper, a speech enhancement method based on sparse representation of data frames has been presented. Speech enhancement is one of the most applicable areas in different signal processing fields. The objective of a speech enhancement system is improvement of either intelligibility or quality of the speech signals. This process is carried out using the speech signal processing techniques to attenuate the background noise without causing any distortion in the speech signal. In this paper, we focus on the single channel speech enhancement corrupted by the additive Gaussian noise. In recent years, there has been an increasing interest in employing sparse representation techniques for speech enhancement. Sparse representation technique makes it possible to show the major information about the speech signal based on a smaller dimension of the original spatial bases. The capability of a sparse decomposition method depends on the learned dictionary and matching between the dictionary atoms and the signal features. An over complete dictionary is yielded based on two main steps: dictionary learning process and sparse coding technique. In dictionary selection step, a pre-defined dictionary such as the Fourier basis, wavelet basis or discrete cosine basis is employed. Also, a redundant dictionary can be constructed after a learning process

* Corresponding author

*نویسندهٔ عهده‌دار مکاتبات

• تاریخ ارسال مقاله: ۱۳۹۶/۸/۱۵ • تاریخ پذیرش: ۱۳۹۸/۱۱/۲ • تاریخ انتشار: ۱۳۹۹/۰۴/۰۱ • نوع مطالعه: پژوهشی

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

that is often based on the alternating optimization strategies. In sparse coding step, the dictionary is fixed and a sparse coefficient matrix with the low approximation error has been earned. The goal of this paper is to investigate the role of data-based dictionary learning technique in the speech enhancement process in the presence of white Gaussian noise. The dictionary learning method in this paper is based on the greedy adaptive algorithm as a data-based technique for dictionary learning. The dictionary atoms are learned using the proposed algorithm according to the data frames taken from the speech signals, so the atoms contain the structure of the input frames. The atoms in this approach are learned directly from the training data using the norm-based sparsity measure to earn more matching between the data frames and the dictionary atoms. The proposed sparsity measure in this paper is based on Gini parameter. We present a new sparsity index using Gini coefficients in the greedy adaptive dictionary learning algorithm. These coefficients are set to find the atoms with more sparsity in the comparison with the other sparsity indices defined based on the norm of speech frames. The proposed learning method iteratively extracts the speech frames with minimum sparsity index according to the mentioned measures and adds the extracted atoms to the dictionary matrix. Also, the range of the sparsity parameter is selected based on the initial silent frames of speech signal in order to make a desired dictionary. It means that a speech frame of input data matrix can add to the first columns of the over complete dictionary when it has not a similar structure with the noise frames. The data-based dictionary learning process makes the algorithm faster than the other dictionary learning methods for example K-singular value decomposition (K-SVD), method of optimal directions (MOD) and other optimization-based strategies. The sparsity of an input frame is measured using Gini-based index that includes smaller measured values for speech frames because of their sparse content. On the other hand, high values of this parameter can be yielded for a frame involved the Gaussian noise structure. The performance of the proposed method is evaluated using different measures such as improvement in signal-to-noise ratio (ISNR), the time-frequency representation of atoms and PESQ scores. The proposed approach results in a significant reduction of the background noise in comparison with other dictionary learning methods such as principal component analysis (PCA) and the norm-based learning method that are traditional procedures in this context. We have found good results about the reconstruction error in the signal approximations for the proposed speech enhancement method. Also, the proposed approach leads to the proper computation time that is a prominent factor in dictionary learning methods.

Keywords: Speech enhancement, Sparse representation, Dictionary learning, Data-Based learning, Greedy adaptive

۱- مقدمه

بحث نمونه‌برداری فشرده[1] و مفاهیم مرتبط با آن مانند بازنمایی تُنُک[2] و یادگیری واژه‌نامه[3] مدت زمان زیادی در دست بررسی بوده و پژوهش‌های گسترده‌ای به‌خصوص در زمینه پردازش سیگنال تصویر بر روی آن انجام گرفته است. این پژوهش‌ها شامل فشرده‌سازی، حذف نوفه، قطعه‌بندی، طبقه‌بندی و بازسازی است [1-4]. مطالعات به‌کمک این روش‌ها به‌منظور بهسازی سیگنال گفتار تنها به سال‌های اخیر باز می‌گردد و پژوهش‌های زیادی در این زمینه انجام نشده است. بحث پردازش گفتار با تکیه بر یادگیری واژه‌نامه و بحث کدگذاری سیگنال گفتار در ابتدا از مرجع [5] آغاز شد. در این مرجع الگوریتمی برای آموزش پایه‌های فراکامل[4] معرفی شد که مشابه با یک مدل احتمالی از داده‌های مشاهده‌ای است. در ادامه نشان داده شد که پایه‌های فراکامل می‌توانند تقریب بهتری از توزیع آماری داده‌های مشاهده‌ای نمایش داده و به کارایی بیشتری در زمینه کدگذاری منجر شوند. در مرجع [6] کاربرد روش سنجش فشرده[5] در زمینه کدگذاری گفتار براساس پیش‌گویی خطی تنک مورد بررسی قرار گرفت. از این روش به‌منظور محاسبه تقریب تُنُک گفتار با استفاده از سیگنال تحریک در پیش‌گویی خطی به کار گرفته شده که دارای نمونه‌های غیرصفر بسیار کمی است. در [7] از روش سنجش فشرده به‌منظور کاهش نوفه سیگنال صوت و گفتار بهره گرفته شده و مسأله کاهش نوفه براساس تئوری سنجش فشرده به‌صورت مسأله کمینه‌سازی نُرم l_1 با ترکیب خطی از قیود و عمل‌گر تبدیل فوریه جزئی تصادفی بیان شد. در ادامه، تُنُکی سیگنال در فضای تبدیل کسینوسی گسسته[6] نیز مورد بررسی قرار گرفته و معیارهایی برای تعیین میزان تنکی سیگنال ارائه شده است [8]. یکی از این معیارها، قید تُنُکی اکید سیگنال[7] است که تُنُکی سیگنال را با شمارش محض تعداد درایه‌های غیرصفر بردار سیگنال در حوزه زمان یا هر حوزه تبدیل دیگر در نظر می‌گیرد [9-10]. در [11]، از نمونه‌برداری فشرده به‌منظور بهسازی سیگنال گفتار[8] در

[1] Compressive sampling
[2] Sparse representation
[3] Dictionary learning
[4] Overcomplete bases

[5] Compressive sensing
[6] Discrete cosine transform
[7] Strict sparsity
[8] Speech enhancement

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

می‌شود. نکته مهمی که در این روش وجود دارد و مورد بررسی قرار نگرفته است، این است که در انتخاب اتم‌ها برای ساخت واژه‌نامه تنها از معیار تُنُکی بهره گرفته می‌شود و هیچ معیار دیگری به‌منظور تعیین مناسب‌بودن قاب انتخابی به‌منظور بازنمایی‌کردن محتوای سیگنال وجود ندارد. از آنجایی‌که هدف در این روش حذف نوفه است و اتم‌های انتهایی واژه‌نامه می‌بایست ساختار نوفه را به‌درستی بازنمایی کنند، بنابراین دخیل‌کردن پارامتر دیگری در انتخاب بهترین اتم‌ها با ماهیت نوفه‌ای مهم به نظر می‌رسد. در روش پیشنهادی، راه‌حلی به‌منظور مرتفع‌کردن این مشکل ارائه می‌شود. همچنین یک معیار جدید تُنُکی معرفی می‌شود که می‌تواند بیان درستی از تُنُکی سیگنال را به‌دست دهد تا روال حذف نوفه با دقت بالاتری حاصل شود.

در این مقاله، روال یادگیری واژه‌نامه توسط الگوریتم تطبیقی حریصانه بیان شده و سپس روش پیشنهادی ارائه می‌شود. در ادامه نتایج به‌دست‌آمده از به‌کارگیری روش پیشنهادی به‌منظور بهسازی گفتار مورد ارزیابی و مقایسه قرار می‌گیرد. در بخش آخر نیز به نتیجه‌گیری در مورد پژوهش انجام‌شده خواهیم پرداخت.

۲- الگوریتم یادگیری واژه‌نامه تطبیقی حریصانه

سیگنال گفتار در مواجهه با نوفه سفید گوسی به‌صورت خطی زیر قابل مدل‌شدن است:

$$\boldsymbol{X(k) = S(k) + N(k)} \quad (۱)$$

که X(k)، S(k) و N(k) به‌ترتیب سیگنال نوفه‌ای، گفتار و نوفه با شماره قاب k هستند. سیگنال نوفه‌ای $X \in \mathbb{R}^N$ می‌تواند به‌صورت خطی با نمایش تُنُک اتم‌ها به‌صورت X=D.C بیان شود که در آن $D \in \mathbb{R}^{N\times P}, P > N$ یک واژه‌نامه فراکامل با P اتم است که اتم‌های آن به وسیله $\{d_p\}_{p=1}^{P}$ با نُرم واحد $\|d_{(:,p)}\|_2 \; \forall p = 1, \dots, P$ و بردار کدگذاری تُنُک $c \in \mathbb{R}^P, P \gg K_0$ که شامل ضرایب تُنُک X است نمایش داده می‌شود [5].

$$c = arg\,\min_{c} \|X - D.c\|^2 \quad (۲)$$
$$, \|c\|_0 \le K_0$$

در این رابطه K_0 تعداد ضرایب غیرصفر در ماتریس ضرایب تُنُک C یا قید تُنُکی را بیان می‌کند.

ایده تُنُکی مضاعف در بحث یادگیری واژه‌نامه در ابتدا به‌منظور بهسازی تصاویر پرتونگاری رایانه‌ای سه‌بعدی مطرح شد [24]. تُنُکی مضاعف به این معنی است که علاوه‌بر نمایش تُنُک سیگنال، خود واژه‌نامه $D = AB$ نیز تُنُک باشد؛ یعنی اتم‌های A بر روی واژه‌نامه ثابت B بازنمایی تُنُک داشته باشند که در آن B می‌تواند هر واژه‌نامه ثابت موجک یا تبدیل کسینوسی گسسته باشد. تبدیل موجک هنگامی که توابع پایه آن به‌خوبی محلی شده باشند، می‌تواند ارتباط مناسبی را میان تُنُکی در تجزیه و تُنُکی در واژه‌نامه به‌منظور آنالیز سیگنال‌های طبیعی مانند صوت، تصویر و سیگنال‌های پزشکی فراهم کند. همچنین در [25] نیز از سیگنال گفتار به‌صورت مستقیم به‌عنوان اتم‌های واژه‌نامه به‌کمک روش کدگذاری تُنُک مبتنی‌بر آنالیز مؤلفه‌های مستقل[1] استفاده شده است؛ بنابراین می‌توان مفهوم تُنُکی را برای نوع خاصی از سیگنال‌ها مانند گفتار یا موسیقی هم در بخش تجزیه و هم در واژه‌نامه استفاده کرد. نوع نوفه در روال بهسازی این روش به‌علت وابستگی کم قاب‌های زمانی به‌منظور تعیین شاخص تُنُکی مناسب قاب‌ها، نوفه گوسی جمع‌شونده در نظر گرفته شده است. در این روش، استفاده از شاخص تُنُکی دقیق که بتواند چینش مناسبی از قاب‌ها را برحسب میزان تُنُکی‌شان در واژه‌نامه مبتنی‌بر داده مورد نظر فراهم آورد، بسیار حائز اهمیت است. کارایی این عملکرد در حضور انواع نوفه دیگر پایین‌تر خواهد بود؛ زیرا هر گونه شباهت میان محتوای سیگنال گفتار و نوفه، موجب مرتب‌سازی نامناسب قاب‌ها در واژه‌نامه شده و ممکن است، قاب‌های نوفه به‌اشتباه در اتم‌های ابتدایی و قاب‌های گفتاری نیز در انتهای واژه‌نامه قرار گرفته و حذف اتم‌های انتهایی واژه‌نامه، اعوجاج سیگنال گفتار را نتیجه دهد. در روال یادگیری واژه‌نامه GAD، این مسأله در نظر گرفته شده است که با توجه به ساختار سیگنال گفتار، بیش‌تر قاب‌های گفتاری تُنُکی مشخص و بالا و قاب‌های نوفه‌ای تُنُکی پایینی دارند؛ بنابراین ستون‌های واژه‌نامه در هنگام طراحی، به‌ترتیب با قاب‌هایی از سیگنال مشاهده‌ای که بیشترین تا کمترین میزان تُنُکی را دارند، جایگزین می‌شوند؛ سپس برای حذف بخش نوفه‌ای سیگنال تنها تعداد مشخص و محدودی از ستون‌های اولیه سیگنال در نظر گرفته و تخمین سیگنال تمیز حاصل می‌شود. واژه‌نامه وابسته به داده در این الگوریتم به‌صورت وفقی و به‌کمک استخراج پی‌درپی ستون‌های ماتریس الگوی ورودی X آموزش می‌بینند. استخراج ستون جدید در هر تکرار منوط به یافتن ستونی از X است که شرط زیر را برآورده کند:

$$\xi = \max_{k} \frac{\|x_k\|_1}{\|x_k\|_2} \quad (۳)$$

[1] Independent component analysis(ICA)

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

بیشینه‌سازی رابطه بالا برطبق روال زیر خواهد بود [۲۳]:

۱- مقداردهی اولیه: تضمین می‌شود که ستون‌های ماتریس X یعنی (x_k) که نُرم l_1 واحد دارند، به‌عنوان ماتریس مانده اولیه در نظر گرفته شود:

$$\widetilde{x_k} = \frac{x_k}{\|x_k\|_1} \rightarrow R^0 = \widetilde{X} \quad (۴)$$

۲- نُرم l_2 هر فریم به‌صورت زیر محاسبه می‌شود:

$$E_k = \|r_k^j\|_2 = \sum_{n=1}^{L} |r_k^j(n)|^2 \quad (۵)$$

در این رابطه $R^j = [r_1^j, \dots, r_k^j]$ و r_k^j بردار ستونی مانده K بعدی متناظر با k امین ستون R^j است.

۳- شاخص $\hat{k}$ متناظر با فریمی از سیگنال با بزرگترین نُرم l_2 به‌دست می‌آید:

$$\hat{k} = arg\max_{k \in \mathbb{k}}(E_k) \quad (۶)$$

۴- ضریب توسعه با حاصل‌ضرب داخلی بردار مانده و اتم به‌دست آمده محاسبه می‌شود:

$$\alpha_k^j = \langle r_k^j, d_j \rangle \quad (۷)$$

۵- مانده جدید با حذف مؤلفه‌های متناظر با اتم انتخاب‌شده برای هر k در r_k^j محاسبه می‌شود:

$$r_k^{j+1} = r_k^j - \frac{\alpha_k^j}{\langle d_j, d_j \rangle} d_j \quad (۸)$$

عبارت $\langle d_j, d_j \rangle$ در مخرج رابطه بالا تضمین می‌کند که ضریب توسعه نرمالیزه‌شده خواهد بود. بنابراین ستون متناظر در ماتریس مانده R^j به صفر مقداردهی شده و در نتیجه موجب متعامدشدن تبدیل می‌شود. تعامد تبدیل ویژگی مهم این الگوریتم است، زیرا با داشتن X=D.C، بردار ضرایب تُنُک از رابطه $C=D^TX$ قابل محاسبه است.

۶- بازگشت به مرحله دوم تا هنگامی‌که تعداد اتم‌های مورد نیاز به‌دست آید [23].

به‌منظور تعیین میزان تُنُکی حاصل از یک الگوریتم یادگیری واژه‌نامه، شاخص تُنُکی مبتنی‌بر نُرم ξ برای ضرایب تبدیل حاصل به‌صورت زیر تعریف می‌شود:

$$\xi = \|C\|_1 / \|C\|_2 \quad (۹)$$

هر چقدر میزان این شاخص تُنُکی کمتر باشد، به معنای آن است که سیگنال تنک‌تر خواهد بود و بالعکس. مقایسه شاخص تُنُکی در الگوریتم‌های GAD، آنالیز مؤلفه‌های اساسی[1] و روش یادگیری واژه‌نامه مبتنی‌بر K-SVD[2] و همچنین نرخ خطای بازسازی این الگوریتم‌ها در شکل (۱) نشان داده شده است [22-19]. نتایج شبیه‌سازی‌ها گزارش‌شده در شکل‌ها و جداول این بخش بر روی یک جمله مربوط به یک گوینده زن از مجموعه دادگان GRID آزمایش شده است [26]. تعداد اتم‌ها و نرخ تُنُکی برای الگوریتم K-SVD به‌ترتیب برابر با چهارصد و ده تنظیم شده است. همچنین تعداد اتم‌های GAD چهارصد و تعداد اتم‌ها در PCA، سیصد در نظر گرفته شده است.

همانطور که مشاهده می‌شود، تُنُکی ξ حاصل از الگوریتم GAD با افزایش تعداد اتم‌ها با شیب ملایمی افزایش می‌یابد. نرخ تُنُکی برای الگوریتم‌های PCA و K-SVD وابستگی زیادی به تعداد اتم‌ها در واژه‌نامه ندارد و در ابتدای گام یادگیری قابل تنظیم و ثابت است. بنابراین می‌توان بیان کرد که با توجه به کم‌بودن شاخص تُنُکی ξ بر طبق رابطه (۱)، سیگنال بازنمایی‌شده توسط الگوریتم GAD نمایش تُنُک‌تری نسبت به حوزه زمان و در مقایسه با سایر الگوریتم‌های بیان‌شده دارد. همچنین خطای بازسازی مطابق با قسمت (b) برای این الگوریتم مقدار مناسبی دارد. خطای تقریب حاصل نیز در جدول (۱) بیان شده که نشان می‌دهد بر طبق انتظار با افزایش تعداد اتم‌ها خطای تقریب کاهش می‌یابد. همان‌طور که بیان شد در این روش اتم‌ها به‌طور مستقیم از روی سیگنال گفتار یادگیری شده و به‌منظور داشتن یک الگوریتم سریع از یک تبدیل متعامد حاصل از مجموعه قاب‌های محلی که از قاب‌بندی سیگنال گفتار به‌دست می‌آیند، استفاده می‌شود. این الگوریتم، تُنُک‌ترین قاب‌های داده ورودی را تشخیص داده و از روش متعامدسازی به‌منظور کاهش پیچیدگی‌های مسأله بهره می‌گیرد [25].

(جدول-۱): خطای تقریب $\varepsilon \times 10^{-3}$ بر حسب دسیبل برای الگوریتم GAD و PCA.

(Table-1): The reconstruction error value ($\varepsilon \times 10^{-3}$) based on decibel for GAD, PCA and K-SVD algorithms.

	تعداد اتم‌ها در واژه‌نامه					
	512	400	300	200	100	50
GAD	0.00	0.35	0.89	1.63	2.45	4.30
PCA	0.00	0.23	0.81	1.52	2.38	4.12
K-SVD	0.00	0.21	0.97	1.71	2.65	4.67

در گام نهایی الگوریتم، دو قانون به‌منظور رسیدن به تعداد اتم‌های موردنظر یا کاهش خطای تقریب از مقدار

[1] Principal component analysis(PCA)
[2] K-Singular value decomposition

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

پیش فرض برای خاتمه الگوریتم در نظر گرفته شده است. در شبیه‌سازی‌های انجام‌شده، نتایج حاصل از این الگوریتم با روش‌های یادگیری واژه‌نامه دیگر مانند PCA و K-SVD مقایسه شده است. شاخص تُنُکی نمونه‌هایی از اتم‌های یادگرفته‌شده از روش‌های مختلف در شکل (۲) نشان داده شده است. همان‌طورکه دیده می‌شود، اتم‌های استخراج‌شده از روش PCA، خصوصیات محلی داده را به تصویر نمی‌کشند؛ یعنی تمامی قاب‌های برگزیده‌شده به‌عنوان اتم‌های مورد استفاده در واژه‌نامه مبتنی‌بر داده از نظر تُنُکی در یک سطح هستند و ویژگی بارزی از سیگنال گفتار را بیان نمی‌کنند.

اتم‌های حاصل از یادگیری با واژه‌نامه K-SVD نیز ساختار مشابه با داده دارند؛ اما در الگوریتم GAD، اتم‌های ابتدایی به‌دست‌آمده برخلاف PCA نسبت به اتم‌های انتهایی به‌طور کامل خصوصیات محلی سیگنال را به تصویر کشیده و دارای بیشترین تُنُکی هستند.

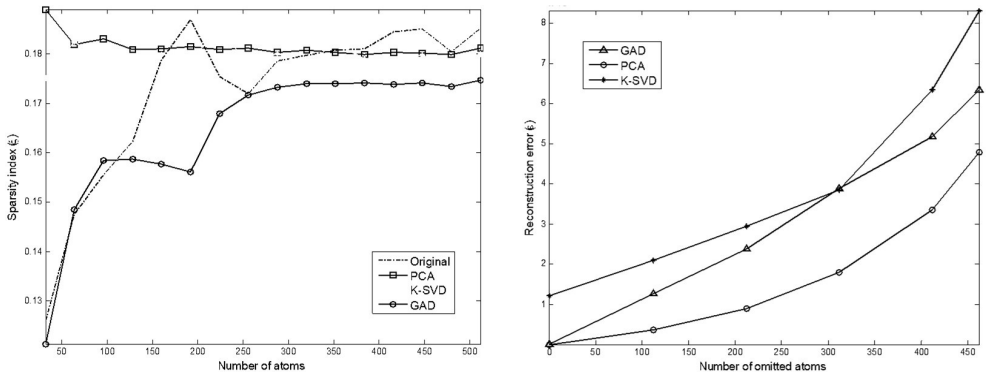

(شکل-۱): a) مقایسه شاخص تُنُکی حاصل از اتم‌های استخراجی از الگوریتم GAD، PCA و K-SVD. b) مقایسه خطای بازسازی در الگوریتم GAD، PCA و K-SVD.

(Figure-1): a) Comparison of sparsity index of speech frames extracted from GAD, PCA and K-SVD algorithms. b) Comparison of reconstruction error for GAD, PCA and K-SVD algorithms.

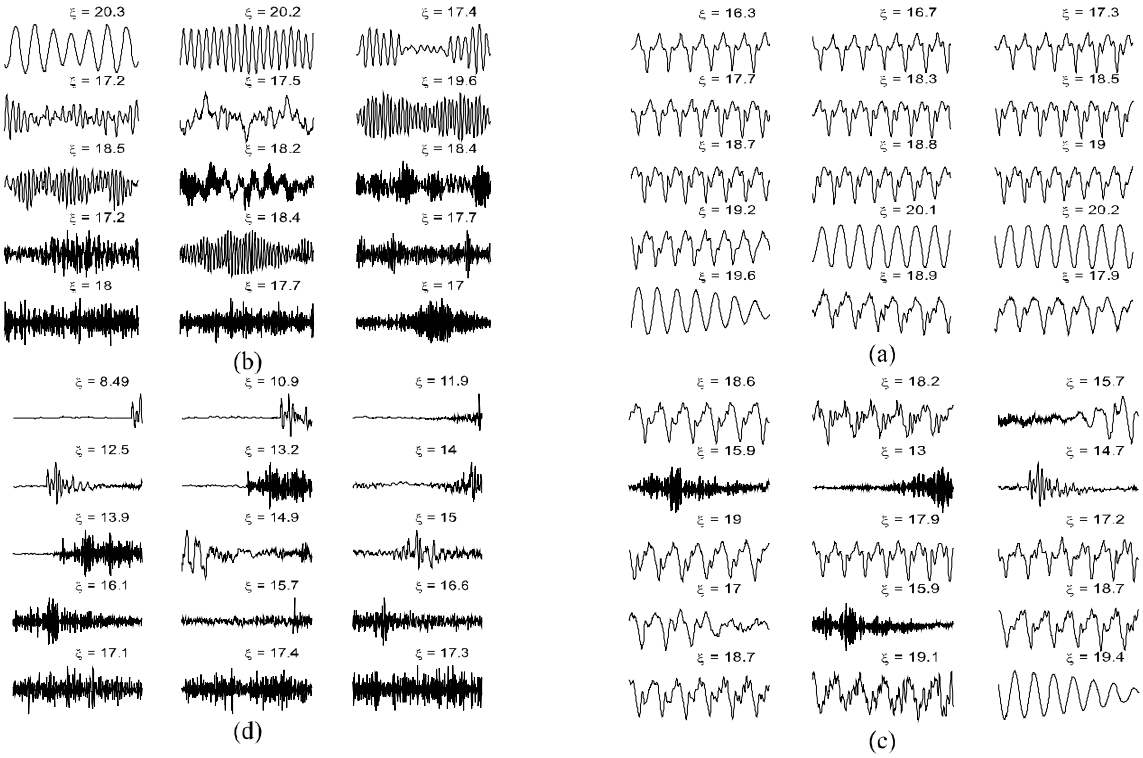

(شکل-۲): a) نمونه‌هایی از قاب‌های سیگنال گفتار. نمونه‌هایی از اتم‌های آموزش دیده با: b) PCA. c) K-SVD. d) GAD.

(Figure-2): a) The selected frames of speech signal. The examples of the learned atoms using: b) PCA. c) K-SVD. d) GAD algorithms.

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

مطابق شکل (۲)، اتم‌های یادگیری‌شده از قاب‌های سیگنال گفتار با الگوریتم GAD، در ابتدا شاخص تُنُکی کمی دارند و با یافتن اتم‌های جدید در هر مرحله مقدار این شاخص افزایش پیدا کرده و اتم‌های با تُنُکی کمتر(نوفه‌گونه) به‌دست می‌آیند. پس با انتخاب تعداد مناسبی از اتم‌های اولیه می‌توان به نتایج بهسازی مناسبی دست یافت. نتایج حاصل برتری الگوریتم مبتنی بر داده GAD نسبت به روش PCA و K-SVD در بهبود نسبت سیگنال به نوفه[1] را نشان می‌دهد.

۳- روش پیشنهادی

در روش بهسازی گفتار به‌کمک واژه‌نامه مبتنی‌بر داده، حذف اتم‌های واژه‌نامه بدون توجه به این مسأله صورت می‌گیرد که ماهیت قاب‌های بی‌واک گفتار می‌تواند بسیار مشابه با قاب‌های نوفه‌ای و با تُنُکی بسیار پایین باشد. این قاب‌ها در فرآیند بهسازی به‌کمک نمایش تُنُک سیگنال گفتار نادیده گرفته شده و حذف می‌شوند؛ بنابراین سیگنال گفتار تخمینی با اعوجاج منبع حاصل می‌شود.

در این صورت می‌بایست از قاب‌های ابتدایی که به‌طور معمول گفتاری نیستند و تنها می‌توانند مربوط به نوفه باشند، محدوده پارامتر تُنُکی قاب‌های نوفه‌ای را به‌دست آورده و در چینش اتم‌های واژه‌نامه مبتنی‌بر داده این مسأله را در نظر گرفت. تنها اتم‌هایی که تُنُکی در محدوده تُنُکی به‌دست‌آمده دارند، در ستون‌های انتهایی واژه‌نامه قرار می‌گیرند تا در تخمین سیگنال تمیز نادیده گرفته شده و حذف شوند؛ همچنین به‌منظور بالابردن دقت در انتخاب اتم‌های واژه‌نامه می‌توان در کنار معیار تُنُکی ξ تعریف‌شده در روش GAD، از معیارهای تُنُکی دیگری نیز بهره برد.

گروه پردازش سیگنال تُنُک[2] یک تیم پژوهشی در دانشگاه دوبلین ایرلند است که در سال ۱۹۹۷ شروع به کار کرده‌اند. این گروه بر روی کاربردهای آنالیز زمان-فرکانس و زمان-مقیاس و نمایش‌های تُنُک سیگنال و جداسازی منابع با استفاده از این نمایش‌های تُنُک تمرکز کرده‌اند و درنهایت به معرفی چند معیار تنکی پرداختند [27-29]. برای بررسی میزان تُنُکی سیگنال گفتار در حوزه‌های مختلف، ابتدا باید به بیان ویژگی‌های لازم برای یک معیار اندازه‌گیری تُنُکی و سپس به معرفی معیارهای مناسب پرداخت. این ویژگی‌ها توسط دالتون در [30] مطرح شده است. نکته قابل توجه آن است که یک معیار تنکی می‌بایست به‌صورت مجموع وزن یافته‌ای از همه ضرایب باشد تا تغییر در یک ضریب، در اندازه تُنُکی تأثیر گذارد. به این منظور باید مؤلفه‌های کوچک نسبت به مؤلفه‌های بزرگ دارای وزن بیشتری باشند. ویژگی دیگری که یک معیار تُنُکی باید داشته باشد، نرمالیزه‌بودن آن است. بدین معنا که یک مجموعه از ضرایب را تنها به این دلیل که تعداد ضرایب بیشتر یا کمتری نسبت به مجموعه دیگر دارد، نباید تُنُک‌تر از دیگری دانست؛ بنابراین دو وضعیت برای نرمالیزه‌کردن می‌بایست وجود داشته باشد: نخست این که یک معیار تنکی بایستی که به مقدار نسبی ضرایب به‌صورت تابعی از مقدار کلی وابسته باشد و دوم این‌که مقدار حاصل از معیار تُنُکی مستقل از تعداد ضرایب باشد تا بتوان تُنُکی مجموعه‌هایی با اندازه‌های مختلف را با هم مقایسه کرد. همچنین نشان داده شده است که تنها دو معیار جینی[3] و هایر[4] این دو خاصیت را برآورده می‌سازند [30].

همچنین تنها معیاری که تمام ویژگی‌های شش‌گانه دالتون را دارد معیار جینی است. برای یک رشته Nتایی از ضرایب $\vec{C} = [C_1 C_2 C_3 \dots C_n]$ این دو معیار به‌صورت زیر بیان می‌شوند [30].

$$C = \left(\sqrt{N} - \frac{\sum_j c_j}{\sqrt{\sum_j c_j^2}} \right) \left(\sqrt{N} - 1 \right)^{-1} \qquad (۱۰)$$

$$Gini = 1 - 2 \sum_{j=1}^{N} \frac{c_j}{\|\vec{C}\|_1} \left(\frac{N - j + \frac{1}{2}}{N} \right) \qquad (۱۱)$$

با استفاده از نتایج گزارش‌شده در [27-28]، استفاده از این معیارها به جای معیار تُنُکی می‌تواند نتایج مطلوبی در یادگیری واژه‌نامه مبتنی‌بر داده به‌دست دهد؛ بنابراین با توجه به ویژگی‌های این روش یادگیری واژه‌نامه، اعم از داشتن سرعت بالا در روال یادگیری و آموزش اتم‌های واژه‌نامه که متناسب با ساختار سیگنال طراحی می‌شوند و همدوسی بالایی با رده داده آموزش دارند، بر آن شدیم تا با انتخاب یک معیار تُنُکی مناسب، کارایی الگوریتم را در حذف نوفه بهبود دهیم.

هر چقدر مقدار شاخص تُنُکی جینی بیشتر باشد به معنای تُنُکی بیشتردر فریم داده خواهد بود و بالعکس. درحالی‌که در رابطه تُنُکی بر مبنای نُرم تعریف‌شده در رابطه (۳)، هرچه میزان این شاخص تُنُکی بیشتر باشد

[1] Signal to noise ratio(SNR)
[2] Sparse signal processing team
[3] Gini
[4] Hoyer

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

به‌معنای سیگنال با تُنُکی کمتر خواهد بود. شاخص تُنُکی پیشنهادشده در این بخش براساس معیار جینی و به‌صورت زیر تعریف می‌شود:

$$\xi_{\text{Gini}} = max \frac{\|x_k\|_1}{Gini(|x_k|)} \qquad (۱۲)$$

k در این رابطه، شماره قاب سیگنال ورودی است. با توجه به شاخص تُنُکی معرفی‌شده، درصورتی‌که قاب داده تُنُکی زیادی داشته باشد، مانند قاب‌های گفتاری، مقادیر کم و درصورتی‌که قاب داده تُنُکی کمی داشته باشد، مانند قاب‌های نوفه‌ای مقادیر بالاتری را اتخاذ می‌کند. نتایج حاصل از این معیار با نام GAD_Gini در نظر گرفته می‌شود؛ همچنین مورد دیگر در روش پیشنهادی این است که با توجه به بازه شاخص تُنُکی به‌دست‌آمده از قاب‌های اولیه سیگنال مشاهده‌ای که مربوط به قاب‌های نوفه‌ای خواهد بود، قاب‌های با شاخص تُنکُی در این محدوده در ستون‌های ابتدایی واژه‌نامه که متناظر با قاب‌های گفتاری است قرار نمی‌گیرند و به انتهای جدول هدایت می‌شوند. نمونه‌هایی از اتم‌های آموزش‌دیده با الگوریتم GAD_Gini در شکل (۳) نشان داده شده است. همچنین، قاب‌های داده انتخاب‌شده با بیشترین و کمترین مقادیر شاخص تُنُکی معرفی‌شده در روابط (۳) و (۹) در شکل (۴) نشان داده شده است.

قابل ذکر است که نتایج حاصل از معیار هایر به‌علت مطلوب‌نبودن سیگنال بهسازی‌شده نتیجه در شکل‌ها و جداول آورده نشده است. با به‌کارگیری این شاخص تُنُکی جدید مبتنی‌بر معیارهای دالتون در روال الگوریتم GAD، نتایج مناسبی در بهسازی گفتار حاصل می‌شود که به‌علت خصوصیات مهم این شاخص است که در ادامه ذکر می‌شود:

۱) شاخص جینی به‌صورت مجموع وزن یافته‌ای از همه ضرایب موجود محاسبه می‌شود تا تغییر در یک ضریب حتی کوچک در اندازه تنکی کل تأثیر بگذارد. بنابراین مؤلفه‌های کوچک در آن نسبت به مؤلفه‌های بزرگ دارای وزن بیشتری هستند.

۲) این شاخص نسبت به تعداد ضرایب نرمالیزه شده است تا یک مجموعه از ضرایب را تنها به این دلیل که تعداد ضرایب بیشتر یا کمتری نسبت به مجموعه دیگر دارد یا ضرایب آن خیلی بلند یا خیلی کوتاه است، تنک‌تر از دیگری تعیین نکنند.

۳) مقدار این شاخص برای بخش‌های نوفه‌ای متمایز از بخش‌های گفتاری است؛ بنابراین درنظرگرفتن شاخص تُنُکی قاب‌هایی اولیه سیگنال مشاهده‌ای که ماهیت نوفه‌ای دارند در انتخاب ستون‌های واژه‌نامه مبتنی‌بر داده بسیار مؤثر خواهد بود. همان‌طورکه دیده می‌شود، قاب‌های استخراج‌شده براساس بیشینه میزان تُنُکی تعیین‌شده از روابط (۳) و (۱۲) به‌ترتیب در شکل (۲-d) و شکل (۳) بسیار مشابه هستند؛ اما در قاب‌های استخراج‌شده براساس کمینه میزان تُنُکی که ستون‌های ابتدایی در واژه‌نامه مبتنی‌بر داده را تعیین می‌کند، اندکی تفاوت دارند.

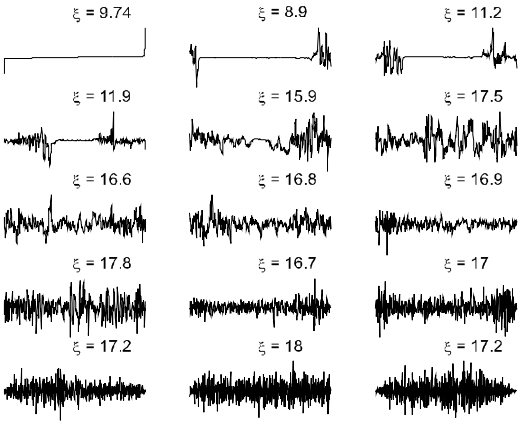

(شکل-۳): نمونه‌هایی از اتم‌های آموزش دیده با الگوریتم GAD_Gini.

(Figure-3): The examples of the learned atoms using GAD_Gini algorithms.

درواقع قاب حاصل از رابطه پیشنهادی که بر مبنای معیار جینی پایه‌ریزی‌شده تُنُک‌تر از قابی خواهد بود که براساس تُنُکی مبتنی‌بر نُرم به‌دست آمده است. این نتیجه‌گیری به‌طور تقریبی در بیش‌تر داده‌های گفتاری متعلق به گویندگان زن و مرد مشاهده شده است.

در مورد نحوه انتخاب اتم‌های ابتدایی ماتریس واژه‌نامه نیز همان‌طورکه بیان شد از اطلاعات حاصل از قاب‌های ابتدایی سیگنال گفتار نوفه‌ای ورودی استفاده می‌شود. به این معنی که تنها قاب‌هایی از داده در ابتدای واژه‌نامه قرار می‌گیرند که دارای بیشترین نرخ تُنُکی براساس رابطه (۱۲) باشند و این مقدار تُنُکی حاصل، خارج از بازه نرخ تُنُکی به‌دست‌آمده از قاب‌های ابتدایی سیگنال گفتار باشد. در هر تکرار الگوریتم برای دست‌یابی به اتم‌های جدید در واژه‌نامه نیز وضعیت بازنمایی تُنُک قاب‌های سیگنال ورودی علاوه‌بر مقدار نرخ تُنُکی محاسبه‌شده بر روی واژه‌نامه بررسی می‌شود و قاب‌هایی در ابتدای واژه‌نامه قرار می‌گیرند که علاوه‌بر داشتن نرخ تُنُکی بالا دارای انرژی

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

بازنمایی تُنُک مناسبی بر روی اتم‌های واژه‌نامه حاصل باشند. روال بهسازی پیشنهادی در ادامه بیان شده است:

ورودی الگوریتم: X، D[.](ماتریس تهی اولیه واژه‌نامه) و محدوده تغییرات نرخ تُنُکی برای قاب‌های سکوت اولیه سیگنال گفتار (ε_N)

خروجی الگوریتم: C و D

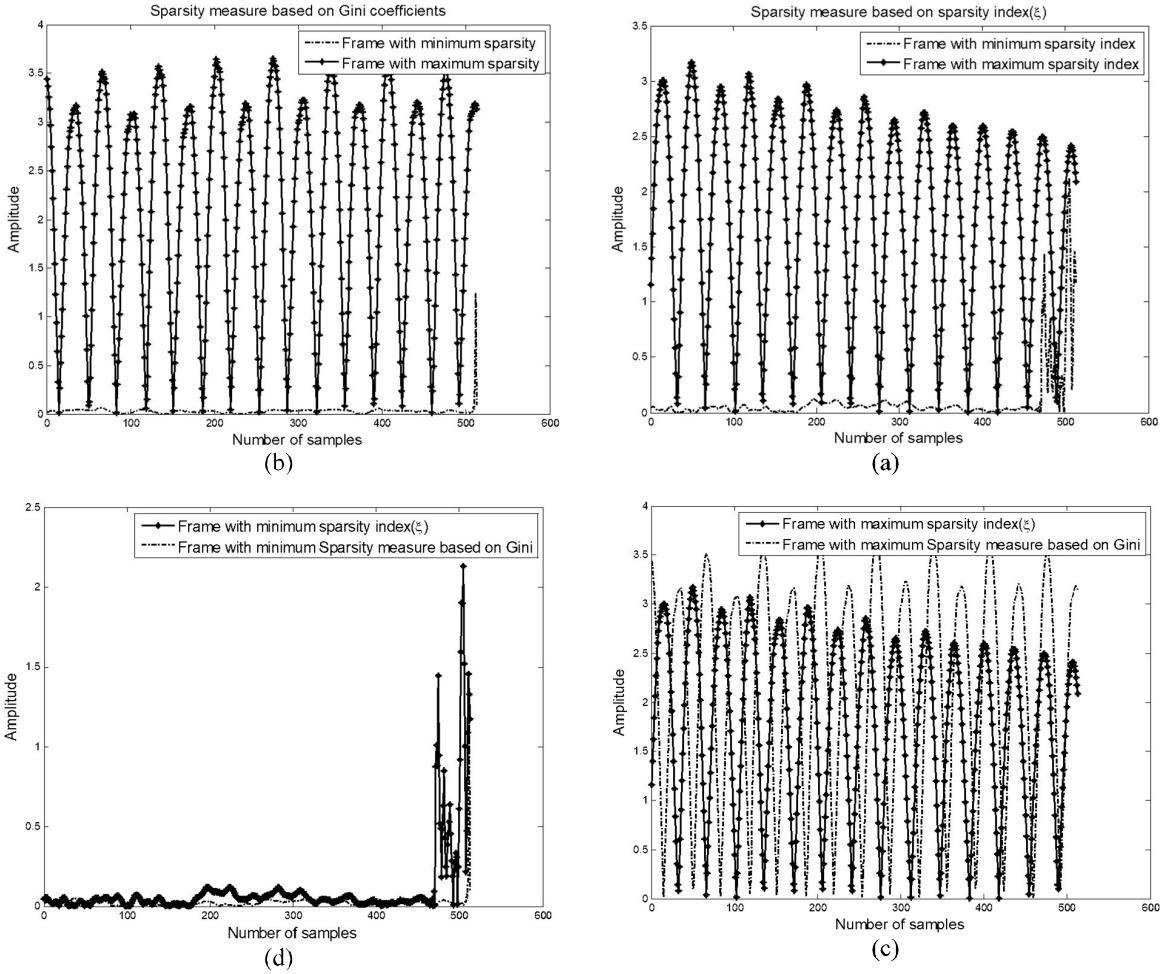

(شکل-۴): a) نمایش قاب‌های با کمینه و بیشینه مقدار تُنُکی انتخاب شده براساس شاخص تُنُکی مبتنی‌بر نُرم. b) نمایش قاب‌های با کمینه و بیشینه مقدار تُنُکی انتخاب شده براساس رابطه پیشنهادی. c) نمایش قاب‌های با بیشینه مقدار تُنُکی انتخاب شده براساس شاخص تُنُکی مبتنی‌بر نُرم و رابطه پیشنهادی. d) نمایش قاب‌های با کمینه مقدار تُنُکی انتخاب شده براساس براساس شاخص تُنُکی مبتنی‌بر نُرم و رابطه پیشنهادی.

(Figure-4): a) The representation of speech frames with minimum and maximum sparsity values selected based on the norm-based sparsity index. b) The representation of speech frames with minimum and maximum sparsity values selected based on the proposed sparsity index. c) The representation of speech frame with maximum sparsity values selected based on the norm-based sparsity index and the proposed sparsity index. d) The representation of speech frame with minimum sparsity values selected based on the norm-based sparsity index and the proposed sparsity index.

* در گام اول t=1

۱) محاسبه نرخ تُنُکی ξ_{Gini} از رابطه (۱۲) برای تمامی K قاب سیگنال گفتار نوفه‌ای $X_k, 1 \le k \le K$

۲) انتخاب قاب با بیشترین تُنُکی ξ_{max} و انتقال آن به نخستین ستون ماتریس واژه‌نامه $D_1 \leftarrow (X_m)_{\xi_{max}}$

** شروع حلقه یادگیری واژه‌نامه مبتنی‌بر داده t≠1

۱) محاسبه ξ_{Gini} برای تمامی K-t قاب سیگنال گفتار نوفه‌ای

۲) انتخاب قاب با بیشترین تُنُکی ξ_{max}

۳) اگر ξ_{max} خارج از محدوده ε_N باشد و انرژی بازنمایی برای قاب انتخاب‌شده بر روی اتم‌های واژه‌نامه که ماهیت گفتاری دارند، به‌اندازهٔ کافی زیاد باشد، یعنی:

$$\|C\|_2 > 0.4\|X\|_2 \leftarrow (X_k)_{\xi_{max}} = D_t.C$$

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

قاب انتخاب‌شده به ستون بعدی ماتریس واژه‌نامه اختصاص می‌یابد: $D_t \leftarrow (X_k)_{\xi_{max}}$

۴) اگر تعداد ستون‌های کافی برای واژه‌نامه حاصل نشده است، حلقه یادگیری تکرار شود و t=t+1.

به این صورت در هر گام یک اتم به ماتریس واژه‌نامه اضافه شده و درنهایت چینش اتم‌ها تکمیل می‌شود. مقدار آستانه به‌منظور بررسی انرژی بازنمایی قاب ورودی بر روی واژه‌نامه و قرارگرفتن آن قاب به‌عنوان ستون جدید واژه‌نامه براساس مقایسه آن با مقدار چهل درصد از نرم دوم ماتریس قاب‌های ورودی X در گام سوم خواهد بود که این میزان به‌صورتی تجربی انتخاب شده است. در گام بهسازی و پس از تکمیل واژه‌نامه، تنها بخشی از اتم‌های چیده‌شده در ستون‌های ابتدایی درنظر گرفته می‌شوند و مابقی اتم‌ها که ساختار نوفه را بازنمایی می‌کنند در روال دست‌یابی به سیگنال بهسازی‌شده نادیده گرفته می‌شوند و ماتریس واژه‌نامه $\widehat{D}$ حاصل می‌شود. به‌صورت تجربی هفتاد درصد ستون‌ها به‌منظور بازسازی سیگنال گفتار مورد استفاده قرار می‌گیرند و از ضرب این درصد اتم‌ها در ماتریس بازنمایی تُنُک مختصرشده $\hat{c}$، سیگنال گفتار حذف نوفه شده $\hat{X}$ حاصل می‌شود.

۴- نتایج شبیه‌سازی

داده گفتاری مورد نیاز از مجموعه دادگان GRID برای گویندگان زن و مرد انتخاب شده است [26]. نرخ نمونه‌برداری این داده برابر با شانزده کیلوهرتز تنظیم شده است. در ابتدا سیگنال گفتار $X(t)$، به قاب‌های با طول L که به‌اندازهٔ G نمونه هم‌پوشانی دارند، تقسیم‌بندی می‌شوند. Kاُمین قاب به‌صورت زیر به‌دست می‌آید:

$$X_k = \left[X\left((k-1)(L-G)+1\right), \dots, X(kl-(k-1)G)\right]^T \quad (۱۳)$$

که در آن $k \in \{1, \dots, K\}$ شماره قاب مورد بررسی است. سپس از قاب‌های ساخته‌شده ماتریس $X \in R^{L \times K}$ تشکیل می‌شود که kاُمین ستون با قاب داده X_k مشخص و (l,k)اُمین ستون به‌صورت زیر خواهد بود:

$$[X]_{l,k} = X(l+(k-1)(L-G)) \quad (۱۴)$$

که در آن $l \in \{1, \dots, L\}$ و $K > L$ است. در این بخش، مقدار L و G به‌ترتیب برابر با ۵۱۲ و ۱۲ در نظر گرفته شده که بیان‌گر قاب‌های ورودی با طول ۳۲ میلی‌ثانیه و با هم‌پوشانی ۰/۷۵ میلی‌ثانیه است.

به‌منظور بررسی شاخص تُنُکی، میانگین مقدار این معیار در الگوریتم‌های مورد بررسی برای اتم‌های واژه‌نامه و ماتریس ضرایب تُنُک C حاصل از روال یادگیری، برای گوینده‌های زن و مرد محاسبه شده و در جدول (۲) نشان شده است. تعداد اتم‌ها در تمامی روش‌ها یکسان و برابر با ۵۱۲ و مقدار پارامتر تُنُکی در الگوریتم K-SVD برابر با ده در نظر گرفته شده است. در این نتایج، نتایج حاصل از الگوریتم GAD ارائه‌شده در [23] با اتم‌های واژه‌نامه مبتنی‌بر داده انتخاب‌شده بر مبنای شاخص تُنُکی پیشنهادی براساس معیار جینی، با نام GAD_Gini بیان شده است. این نتایج حاصل میانگین‌گیری بر روی صد سیگنال گفتاری انتخاب‌شده از مجموعه دادگان GRID است. نتایج به‌دست‌آمده نشان می‌دهد که اتم‌های حاصل از الگوریتم‌های GAD مبتنی‌بر معیار تُنُکی مبتنی‌بر نُرم داده و معیار پیشنهادی، تُنُک‌تر از قاب‌های سیگنال داده اصلی هستند. همچنین اتم‌های حاصل از روش GAD_Gini اندکی تُنُک‌تر از اتم‌های حاصل از روش GAD به‌دست آمده است که این نتایج در مورد ماتریس ضرایب نیز برقرار خواهد بود. گفتنی است که در این بخش از بیان نتایج حاصل از دیگر روش به‌دلیل پایین‌بودن مقادیر حاصل خودداری شده است.

شاخص تُنُکی برای تمامی اتم‌ها در واژه‌نامه یادگیری‌شده به روش‌های مختلف در شکل (۵) نشان داده شده است. نتایج در این شکل در SNR=0 حاصل شده است. همان‌طورکه از پیش بیان شد هر چه شاخص تُنُکی در یک اتم کوچک‌تر باشد، آن اتم تُنُک‌تر خواهد بود و به‌منظور به‌کارگیری از واژه‌نامه یادگیری شده در بهسازی گفتار می‌بایست اتم‌ها در واژه‌نامه مبتنی‌بر داده از قاب‌های شبه‌گفتار با تُنُکی بالا(مقدار شاخص تنکی کم) تا قاب‌های شبه‌نوفه با تُنُکی کم(مقدار شاخص تنکی بالا) مرتب شوند. نتایج حاصل از این شکل نشان می‌دهد که شاخص تُنُکی در بیش‌تر اتم‌های یادگیری‌شده در روش پیشنهادی GAD_Gini پایین‌تر از سایر روش‌ها و داده اصلی به‌دست آمده است که نشان می‌دهد تُنُکی اتم‌های حاصل بیشتر از داده گفتاری خواهد بود. همچنین می‌توان مشاهده کرد که در الگوریتم GAD و GAD_Gini، مقدار تُنُکی به‌ترتیب بعد از تعداد اتم‌های برابر با ۲۰۰ و ۲۵۰ به مقدار تُنُکی بیشینه نزدیک است و بنابراین این مقدار می‌تواند آستانه‌ای برای جداسازی قاب‌ها باشد که آگاهی از این مقدار آستانه در روال بهسازی گفتار بسیار مورد استفاده قرار می‌گیرد. در شکل (۶) شاخص تُنُکی اتم‌ها به‌کمک الگوریتم یادگیری واژه‌نامه پیشنهادی و نیز به‌کارگیری بخش‌های آن شامل اعمال محدوده بر شاخص

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

تُنُکی به‌کمک قاب‌های ابتدایی و نیز به‌کارگیری شاخص Gini نشان داده شده است. الگوریتم پیشنهادی به‌کمک اعمال محدوده بر شاخص تُنُکی با نام GAD_Gini1 و الگوریتم پیشنهادی به‌کمک به‌کارگیری شاخص تُنُکی Gini با نام GAD_Gini2 درنظر گرفته شده است. نتایج به‌دست‌آمده نشان می‌دهد که هر یک از این دو گام سهمی در دقت انتخاب تُنُک‌ترین قاب‌های ورودی داشته‌اند و در کنار یکدیگر توانسته‌اند، نتیجه مطلوبی در این راستا به‌دست دهند. به‌منظور بررسی بیشتر عملکرد، خطای بازسازی به‌ازای حذف تعداد مختلفی از اتم‌های در هر یک از روش‌ها محاسبه شده و در شکل (۷) نمایش داده شده است. نتایج این شکل در SNR=0 به‌دست آمده است. محدوده این تعداد اتم حذف‌شده از صفر تا ۴۶۰ اتم در نظر گرفته شده که به معنی به‌کارگیری ۵۱۲ تا ۵۲ اتم است. همان‌طور که مشاهده می‌شود نرخ تغییر خطای بازسازی تمامی الگوریتم‌ها با بالارفتن تعداد اتم‌های حذف‌شده افزایشی است. همچنین، خطای بازسازی در الگوریتم K-SVD حتی بدون حذف هیچ یک از اتم‌ها غیرصفر است. الگوریتم PCA کمترین نرخ خطای بازسازی را در استفاده از هر تعداد دلخواه اتم به‌دست آورده است؛ زیرا مؤلفه‌های سیگنال در این تبدیل به‌گونه‌ای مرتب می‌شوند که بیشترین انرژی در تعداد بسیار کمی از مؤلفه‌ها متمرکز شود و این مؤلفه‌ها همان اتم‌هایی هستند که زودتر استخراج می‌شوند. همچنین مشاهده می‌شود که نتایج حاصل از الگوریتم GAD_Gini با تعداد اتم‌های حذف‌شده کمتر مناسب‌تر از الگوریتم بر مبنای GAD است و از آنجایی‌که مواردی با تعداد اتم‌های حذف‌شده زیاد به‌طور معمول رخ نمی‌دهد، ابتدای این نمودار اهمیت بیشتری داشته و کارایی روش مبتنی‌بر معیار GAD_Gini مناسب‌تر خواهد بود. نتایج حاصل از خطای بازسازی به‌ازای حذف تعداد مختلفی از اتم‌ها به‌کمک الگوریتم یادگیری واژه‌نامه پیشنهادشده و همچنین به‌کارگیری گام‌های مختلف این روش در شکل (۸) نشان داده شده است. الگوریتم پیشنهادی با به‌کارگیری محدوده شاخص تُنُکی با نام GAD_Gini1 و الگوریتم پیشنهادی با به‌کارگیری شاخص تُنُکی Gini با نام GAD_Gini2 نام‌گذاری شده است. نتایج نشان می‌دهد که اعمال هر یک از این دو گام توانسته است، خطای بازسازی را کاهش دهد و اعمال هم‌زمان این دو گام و در روش پیشنهادی منجر به کاهش خطای بازسازی محسوسی شده است.

نمودار مشخصه زمان-فرکانس اتم‌های آموزش دیده به‌کمک روش‌های مختلف یادگیری واژه‌نامه در شکل (۹) و به‌ازای SNR=0 نمایش داده شده است. همان‌طورکه دیده می‌شود اتم‌های یادگیری‌شده براساس الگوریتم پیشنهادی GAD_Gini به‌خوبی توانسته است، فضای زمان-فرکانس و مشخصات آن را بازنمایی کند.

(جدول-۲): میانگین شاخص تُنُکی در الگوریتم‌های مختلف برای اتم‌ها و ماتریس ضرایب تُنُک گوینده‌های مختلف

(Table-2): The average values of atom sparsity index and sparsity for coefficient matrix of different algorithms

Method	Atom sparsity index		Sparsity of coefficient matrix	
	Female	Male	Female	Male
Speech data	0.1741	0.1673	0.1741	0.1673
PCA	0.1722	0.1731	0.1527	0.1597
K-SVD	0.1643	0.1724	0.1336	0.1387
GAD	0.1531	0.1641	0.1371	0.1357
GAD_Gini	**0.1476**	**0.1431**	**0.1107**	**0.1202**

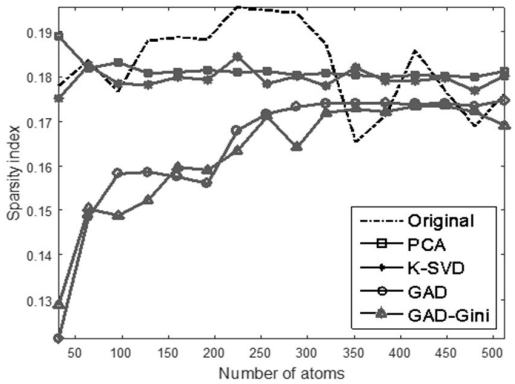

(شکل-۵): بررسی شاخص تُنُکی برای اتم‌ها در واژه‌نامه‌های یادگیری‌شده با روش‌های مختلف

(Figure-5): Plot of sparsity index of atoms in the learned dictionaries of different algorithms

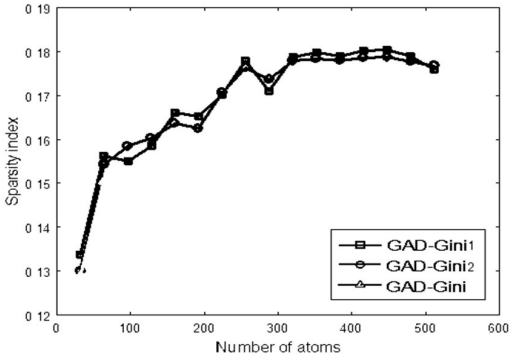

(شکل-۶): بررسی شاخص تُنُکی اتم‌ها در واژه‌نامه‌های یادگیری‌شده با روش پیشنهادی و به‌کارگیری بخش‌های آن

(Figure-6): Plot of sparsity index of atoms based on the proposed dictionary learning algorithm and its different steps

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

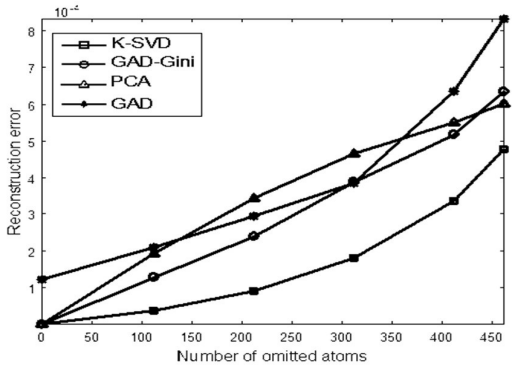

(شکل-۷): مقایسه خطای بازسازی به‌ازای حذف تعداد مختلفی از اتم‌های واژه‌نامه در روش‌های مختلف

(Figure-7): Comparison of the reconstruction error of sparse representation by removing different number of atoms

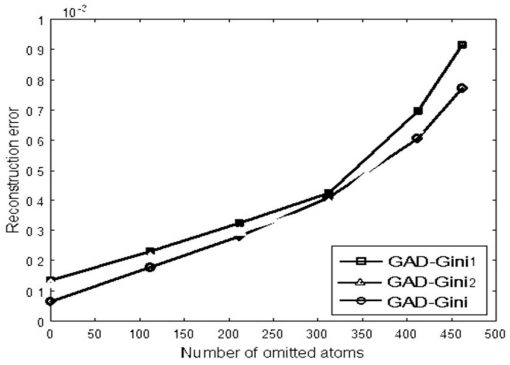

(شکل-۸): مقایسه خطای بازسازی به‌ازای حذف تعداد مختلفی برای واژه‌نامه‌های یادگیری‌شده با روش پیشنهادی و به‌کارگیری بخش‌های آن

(Figure-8): Comparison of the reconstruction error of sparse representation by removing different number of atoms based on the proposed dictionary learning algorithm and its different steps

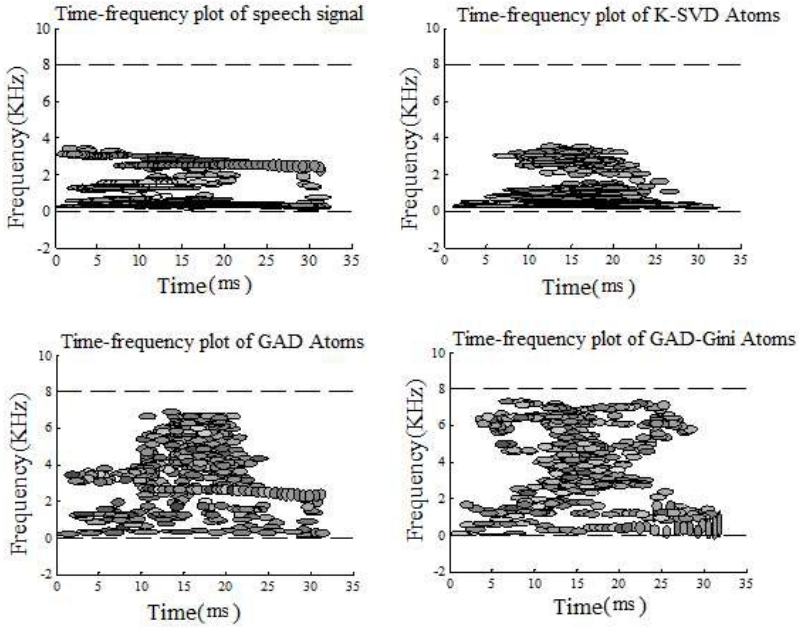

(شکل-۹): نمایش بازنمایی مشخصات زمان-فرکانس توسط اتم‌های واژه‌نامه آموزش دیده به‌کمک الگوریتم‌های مختلف

(Figure-9): Plot of time-frequency structure of the atoms learned using different methods

اتم‌های یادگیری‌شده توسط GAD نیز تا حد مطلوبی قادر به بازنمایی کل فضای زمان-فرکانس خواهد بود. در جدول (۳) نتایج حاصل از بهسازی گفتار در حضور نوفه سفید گوسی برای روش‌های مختلف آورده شده است. نتایج گزارش‌شده حاصل میانگین‌گیری بر روی صد سیگنال گفتاری منتخب از مجموعه دادگان است.

این نتایج به‌کمک معیار عینی بهبود نسبت سیگنال به نوفه[1] در سطوح نوفه ۱۰dB، ۰dB و ۱۰dB- به‌دست آمده است. این معیار به‌صورت زیر بیان می‌شود:

$$ISNR = 10log\frac{E\{(x(t)-y(t))^2\}}{E\{(x(t)-\hat{x}(t))^2\}} \qquad (۱۵)$$

که در آن $x(t)$، $y(t)$ و $\hat{x}(t)$ به‌ترتیب سیگنال داده اصلی، سیگنال نوفه‌ای مشاهده شده و سیگنال بهسازی‌شده هستند. همان‌طور که قابل نتیجه‌گیری است، هرچه سیگنال بهسازی‌شده به سیگنال اصلی شبیه‌تر باشد، مقدار این معیار بزرگ‌تر خواهد بود؛ همچنین مقدار این معیار در تمامی روش‌های مورد بررسی به جز K-SVD، هنگامی‌که از تمامی اتم‌ها در روال بازسازی استفاده شود، مقدار صفر خواهد داشت و بازسازی کامل خواهد بود؛ اما در

[1] Improvement in signal to noise ratio(ISNR)

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

سایر شرایط که تعدادی از اتم‌ها در نظرگرفته نمی‌شوند، K-SVD بهترین نتایج را در همه سطوح نوفه به‌دست آورده است. در تمامی روش‌ها می‌توان نتیجه گرفت که هرچه میزان اتم‌های حذف شده بیشتر باشد، نتایج بهسازی بهتری به‌دست خواهد آمد.

(جدول-۳): نتایج حاصل از معیار ISNR در حضور نوفه سفید گوسی در SNRهای مختلف

(Table-3): The results of ISNR value in the presence of white Gaussian noise in different SNR values

SNR	Method	Number of atoms in dictionary					
		512	**400**	**300**	**200**	**100**	**50**
−10dB	PCA	0	0.48	1.44	2.37	4.69	5.73
	K-SVD	5.41	**6.08**	**6.52**	**6.41**	**5.29**	**4.11**
	GAD	0	1.27	2.94	4.33	4.98	4.07
	GAD_Gini	0	**2.29**	**3.97**	**4.87**	**5.01**	**4.26**
	OMLSA	4.71					
0dB	PCA	0	0.46	1.31	2.71	5.41	8.20
	K-SVD	5.69	**6.91**	**7.18**	**7.57**	**8.53**	**10.05**
	GAD	0	1.31	2.69	5.22	7.24	**9.14**
	GAD_Gini	0	**2.43**	**3.56**	**6.42**	**8.07**	7.18
	OMLSA	7.24					
-10dB	PCA	0	0.51	1.31	2.72	5.48	8.29
	K-SVD	5.82	**6.75**	**7.56**	**9.91**	**12.51**	**13.68**
	GAD	0	1.31	2.84	5.31	7.69	9.28
	GAD_Gini	0	**1.54**	**3.12**	**6.57**	**8.24**	**10.17**
	OMLSA	7.93					

در این جدول، نتایج حاصل از روش OMLSA[1] نیز اضافه شده که یک تخمین‌گر گفتار است. تابع بهره طیفی بهینه در این روش براساس یک میانگین هندسی وزن‌دار مرتبط با عدم حضور گفتار به‌دست می‌آید [31]. این روش به‌منظور حذف نوفه‌های ناایستا ارائه شده است. طیف نوفه در این روش به‌کمک میانگین‌گیری بازگشتی توان طیف با استفاده از یک پارامتر هموارسازی که بر طبق احتمال حضور گفتار تنظیم می‌شود، تخمین زده می‌شود؛ همچنین نتایج بهسازی گفتار حاصل از روش پیشنهادی در حضور نوفه‌های غیرگوسی مانند نوفه صورتی و نوفه قهوه‌ای به‌ترتیب در جداول (۴ و ۵) گزارش شده است. انجام این شبیه‌سازی به‌منظور بررسی کارایی روش پیشنهادی در حضور نوفه‌های غیرگوسی صورت گرفته است. همان‌طورکه نتایج گزارش می‌دهند، می‌توان مشاهده کرد الگوریتم پیشنهادی توانسته است به مقادیر ISNR بالاتری در شرایط نوفه‌ای مختلف نسبت به روش‌های پایه آموزش واژه‌نامه مانند K-SVD و PCA، روش پایه یادگیری واژه‌نامه منطبق بر داده به‌کمک معیار نرم و نیز روش OMLSA که یک تخمین‌گر گفتاری به‌منظور حذف نوفه‌های ناایستا است، دست پیدا کند. برتری روش پیشنهادی می‌تواند به‌علت اصلاحات دقیقی باشد که در روش پایه یادگیری واژه‌نامه مبتنی‌بر داده صورت گرفته است که شامل معرفی یک معیار تعیین تُنُکی قاب‌ها براساس شاخص Gini و بررسی محدوده قاب‌های انتخابی با توجه به محدوده تُنُکی قاب‌های اولیه نوفه‌ای سیگنال مشاهده شده است. همچنین همان‌طورکه انتظار می‌رود تعیین تعداد اتم‌های تشکیل‌دهنده واژه‌نامه و حذف اتم‌های بازنمایی‌کننده ویژگی‌های نوفه‌ای بسیار حائز اهمیت است و به‌همین دلیل با کم‌شدن یا زیادشدن بیش از حد مطلوب تعداد اتم‌ها، نتایج بهسازی به‌شدت مورد تأثیر قرار می‌گیرد. گفتنی است که نتایج بهسازی الگوریتم پیشنهادی در حضور نوفه صورتی اندکی بالاتر از نتایج حاصل از کاهش نوفه در مقابل نوفه قهوه‌ای است.

نتایج گزارش‌شده نشان می‌دهد که بهسازی حاصل از الگوریتم GAD و GAD_Gini نزدیک به هم و مناسب بوده و در بیشتر موارد بالاتر از الگوریتم PCA است که در آن فضای مسأله به دو زیرفضای گفتار و نوفه تجزیه می‌شود. در برخی شرایط بسته به تعداد اتم به‌کارگرفته شده، نتایج حاصل از الگوریتم GAD_Gini بالاتر از GAD به‌دست آمده است. گفتنی است که کارایی الگوریتم GAD_Gini در SNR پایین مناسب‌تر خواهد بود. نتایج حاصل از بهسازی در حضور نوفه‌های صورتی و قهوه‌ای اندکی پایین‌تر از نتایج گزارش‌شده از نوفه سفید گوسی بوده است که می‌تواند به این علت باشد که معیار جینی پیشنهادی بهترین انطباق را به‌منظور اکتساب قاب‌های تُنُک براساس نوفه سفید گوسی به‌دست می‌دهد.

[1] Optimally-modified log-spectral amplitude

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

(جدول-۴): نتایج حاصل از معیار ISNR در حضور نوفه صورتی در SNRهای مختلف

(Table-4): The results of ISNR value in the presence of Pink noise in different SNR values

SNR	Method	Number of atoms in dictionary					
		512	**400**	**300**	**200**	**100**	**50**
−10dB	PCA	0	0.41	1.32	2.21	4.49	5.63
	K-SVD	5.12	**5.82**	**6.21**	**6.03**	**5.10**	**3.96**
	GAD	0	1.14	2.81	4.20	4.82	3.85
	GAD_Gini	0	**2.17**	**3.81**	**4.72**	**4.89**	**4.11**
	OMLSA	4.52					
0dB	PCA	0	0.59	1.22	2.65	5.32	8.04
	K-SVD	5.03	**6.83**	**7.02**	**7.69**	**8.46**	**9.88**
	GAD	0	1.22	2.59	5.14	7.16	**9.01**
	GAD_Gini	0	**2.36**	**3.47**	**6.35**	**7.95**	6.93
	OMLSA	6.84					
-10dB	PCA	0	0.44	1.23	2.65	5.37	8.19
	K-SVD	4.92	**6.68**	**7.47**	**9.85**	**12.39**	**13.41**
	GAD	0	1.22	2.71	5.19	7.52	9.18
	GAD_Gini	0	**1.43**	**2.96**	**6.43**	**8.16**	**9.86**
	OMLSA	7.18					

(جدول-۵): نتایج حاصل از معیار ISNR در حضور نوفه قهوه‌ای در SNRهای مختلف

(Table-5): The results of ISNR value in the presence of Brown noise in different SNR values

SNR	Method	Number of atoms in dictionary					
		512	**400**	**300**	**200**	**100**	**50**
−10dB	PCA	0	0.38	1.29	2.17	4.42	5.55
	K-SVD	5.08	**5.73**	**6.15**	**5.89**	**5.03**	**3.89**
	GAD	0	1.08	2.75	4.15	4.81	3.80
	GAD_Gini	0	**2.14**	**3.76**	**4.65**	**4.81**	**4.05**
	OMLSA	4.42					
0dB	PCA	0	0.52	1.18	2.60	5.31	7.96
	K-SVD	4.95	**6.75**	**6.92**	**7.61**	**8.45**	**9.82**
	GAD	0	1.18	2.51	5.06	7.08	**8.92**
	GAD_Gini	0	**2.29**	**3.41**	**6.28**	**7.91**	6.90
	OMLSA	6.77					
-10dB	PCA	0	0.39	1.14	2.72	5.34	8.16
	K-SVD	4.88	**6.64**	**7.42**	**9.81**	**12.36**	**13.38**
	GAD	0	1.20	2.67	5.12	7.49	9.15
	GAD_Gini	0	**1.38**	**2.91**	**6.59**	**8.11**	**9.81**
	OMLSA	7.14					

همچنین نتایج بهسازی به‌دست‌آمده با استفاده از معیار PESQ[1]، از آنجاییکه همدوسی بالایی با امتیازهای حاصل از معیارهای قابلیت فهم و کیفیت گفتار دارد، محاسبه شده است [32]. در این آزمایش از برنامه‌های آماده در نرم‌افزار متلب[2] که در [32] ارائه شده، استفاده شده است. نتایج حاصل از این معیار به منظور بهسازی سیگنال در حضور نوفه سفید گوسی با SNRهای مختلف در جدول (۶) نشان داده شده که حاصل میانگین‌گیری از نتایج صد سیگنال گفتاری است. همان‌طورکه انتظار می‌رود با کاهش تعداد اتم‌ها در واژه‌نامه، خطای بازسازی بیشتر و معیار PESQ کاهش می‌یابد؛ همچنین نتایج معیار PESQ حاصل از بهسازی گفتار به‌کمک روش پیشنهادی و سایر الگوریتم‌های مورد بررسی در حضور نوفه‌های صورتی و قهوه‌ای به‌ترتیب در جداول (۷ و ۸) گزارش شده است. نتایج حاصل از معیار PESQ به‌منظور بررسی تکمیلی کارایی روش پیشنهادی در حضور نوفه‌های غیرگوسی گزارش شده است. نتایج حاصل از این شبیه‌سازی نیز بر توانایی روش پیشنهادی در حذف نوفه‌های غیرگوسی از سیگنال گفتار تأکید کرده و مؤید نتایج قبلی است. روش پیشنهادی توانسته در شرایط نوفه‌ای مختلف، مقادیر PESQ بالاتری نسبت به روش‌های پایه آموزش واژه‌نامه، روال پایه یادگیری واژه‌نامه منطبق بر داده و نیز روش OMLSA بدست دهد که می‌تواند به‌دلیل تصحیحات صورت‌گرفته در روش پایه یادگیری واژه‌نامه مبتنی‌بر داده باشد که در بخش ۳ به آن‌ها اشاره شد. همان‌طورکه انتظار می‌رود، تعداد اتم‌های انتخابی واژه‌نامه در این روال بهسازی نیز تأثیرگذار بوده و با افزایش تعداد اتم‌ها تا حد مناسب، نتایج بهتری حاصل می‌شود. این نتایج در حضور نوفه صورتی اندکی بالاتر از نتایج حاصل از کاهش نوفه در مقابل نوفه قهوه‌ای حاصل شده است؛ همچنین نتایج الگوریتم پیشنهادی به‌کمک اعمال محدوده بر شاخص تُنُکی با نام GAD_Gini1 و الگوریتم پیشنهادی

[1] Perceptual evaluation of speech quality
[2] MATLAB

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

به‌کمک به‌کارگیری شاخص تُنُکی Gini با نام GAD_Gini2 در این جدول بیان شده است. نتایج حاصل نشان می‌دهد که هر یک از این دو گام به تنهایی قادر است، نتایج بهسازی را افزایش دهد و به‌کارگیری این دو گام در کنار یکدیگر توانایی دست‌یابی به نتایج مناسب در این حوزه پردازشی را فراهم می‌سازد. مقدار PESQ برای سیگنال نوفه‌ای نیز در آخرین سطر این جدول گزارش شده است؛ این افزایش خطای بازنمایی قاب‌های داده با کاهش میزان SNR، تشدید می‌شود؛ همچنین مشاهده می‌شود که نتایج حاصل از الگوریتم پیشنهادی بهتر از سایر روش‌های بیان‌شده به‌منظور حذف نوفه سفید گوسی از سیگنال گفتار است. این نتایج، حاصل میانگین‌گیری بر روی پنجاه داده آزمایش است.

به‌منظور بررسی بهتر عملکرد الگوریتم بهسازی گفتار پیشنهادی، نمایش اسپکتروگرام سیگنال‌های بهسازی‌شده به‌کمک روش پیشنهادی در SNRهای مختلف در شکل (۱۰) نشان داده شده است. همان‌طورکه انتظار می‌رود با افزایش میزان SNR، نتایج بهتری به‌دست می‌آید؛ همچنین در شکل (۱۱)، اسپکتروگرام سیگنال‌های بهسازی‌شده در SNR=+5dB برای الگوریتم‌های K-SVD، PCA، GAD و GAD_Gini به نمایش گذاشته شده است. نتایج بهسازی حاصل از این الگوریتم‌ها در SNR=0dB در شکل (۱۲) نشان داده شده است. نتایج حاصل نشان می‌دهد که الگوریتم بهسازی مبتنی‌بر آموزش واژه‌نامه بر مبنای داده با شاخص تُنُکی متشکل از معیار Gini قادر است، نتایج بهتری را نسبت به سایر الگوریتم‌های نامبرده به‌دست دهد و بر نتایج گزارش‌شده در جداول پیشین مبنی‌بر برتری روش بهسازی پیشنهادی تأکید دارد.

(جدول-۶): نتایج حاصل از معیار PESQ در حضور نوفه سفید گوسی و در SNRهای مختلف برای تعداد متفاوت اتم‌ها

(Table-6): The results of PESQ values in the presence of white Gaussian noise in different SNR values for various numbers of atoms

SNR→ / Methods↓	-10dB			0dB			+10dB		
	512	**300**	**100**	**512**	**300**	**100**	**512**	**300**	**100**
PCA	0.76	0.42	0.23	2.61	1.98	0.93	3.56	2.88	2.04
K-SVD	1.06	0.79	0.73	2.78	2.37	1.12	3.70	2.96	2.26
OMLSA		0.15			0.76			2.53	
GAD	1.59	1.28	0.80	3.03	2.54	1.67	3.75	3.09	2.39
GAD_Gini1	1.61	1.32	0.83	3.09	2.57	1.70	3.77	3.14	2.41
GAD_Gini2	1.63	1.35	0.85	3.12	2.59	1.73	2.81	3.17	2.45
GAD_Gini	**1.65**	**1.39**	**0.87**	**3.17**	**2.61**	**1.78**	**3.84**	**3.21**	**2.48**
Noisy signal		0.18			0.88			1.86	

(جدول-۷): نتایج حاصل از معیار PESQ در حضور نوفه صورتی و در SNRهای مختلف برای تعداد متفاوت اتم‌ها

(Table-7): The results of PESQ values in the presence of Pink noise in different SNR values for various numbers of atoms

SNR→ / Methods↓	-10dB			0dB			+10dB		
	512	**300**	**100**	**512**	**300**	**100**	**512**	**300**	**100**
PCA	0.73	0.40	0.22	2.59	1.95	0.91	3.52	2.81	1.98
K-SVD	1.02	0.78	0.71	2.75	2.38	1.09	3.66	2.93	2.21
OMLSA		0.13			0.73			2.49	
GAD	1.53	1.25	0.77	3.05	2.51	1.70	3.72	3.01	2.34
GAD_Gini1	1.57	1.29	0.79	3.04	2.58	1.73	3.75	3.12	2.38
GAD_Gini2	1.61	1.32	0.80	3.09	2.55	1.71	2.78	3.15	2.39
GAD_Gini	**1.66**	**1.37**	**0.85**	**3.15**	**2.63**	**1.76**	**3.82**	**3.19**	**2.45**
Noisy signal		0.17			0.83			1.85	

(جدول-۸): نتایج حاصل از معیار PESQ در حضور نوفه قهوه‌ای و در SNRهای مختلف برای تعداد متفاوت اتم‌ها

(Table-8): The results of PESQ values in the presence of Brown noise in different SNR values for various numbers of atoms

SNR→ / Methods↓	-10dB			0dB			10dB		
	512	**300**	**100**	**512**	**300**	**100**	**512**	**300**	**100**
PCA	0.68	0.35	0.18	2.50	1.89	0.87	3.46	2.77	1.91
K-SVD	0.96	0.71	0.65	2.71	2.31	0.98	3.59	2.88	2.18
OMLSA		0.11			0.67			2.42	
GAD	1.49	1.21	0.72	2.98	2.47	1.66	3.67	2.94	2.28
GAD_Gini1	1.51	1.23	0.73	2.96	2.49	1.67	3.69	3.04	2.31
GAD_Gini2	1.55	1.27	0.76	3.01	2.49	1.68	2.73	3.07	2.31
GAD_Gini	**1.61**	**1.31**	**0.79**	**3.09**	**2.58**	**1.70**	**3.78**	**3.14**	**2.39**
Noisy signal		0.19			0.81			1.79	

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

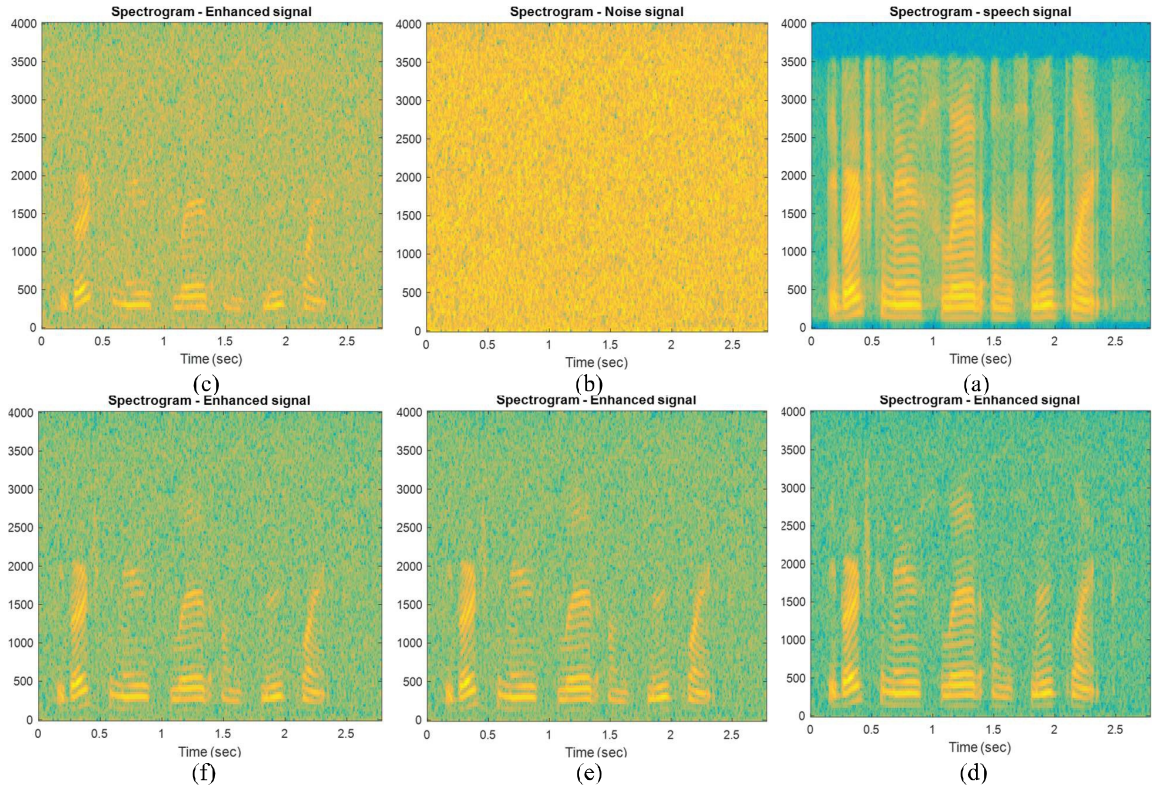

(شکل-۱۰): نمایش اسپکتروگرام برای: a) سیگنال گفتار. b) سیگنال نوفه سفید گوسی. c) سیگنال گفتار نوفه‌ای با SNR=0dB. d) سیگنال بهسازی‌شده در SNR=+5dB. e) سیگنال بهسازی‌شده در SNR=0dB. f) سیگنال بهسازی‌شده در SNR=-5dB.

(Figure-10): Spectrogram representation for: a) Speech signal. b) Gaussian white noise signal. c) Noisy signal. d) Enhanced signal at SNR=+5dB. e) Enhanced signal at SNR=0dB. f) Enhanced signal at SNR=-5dB.

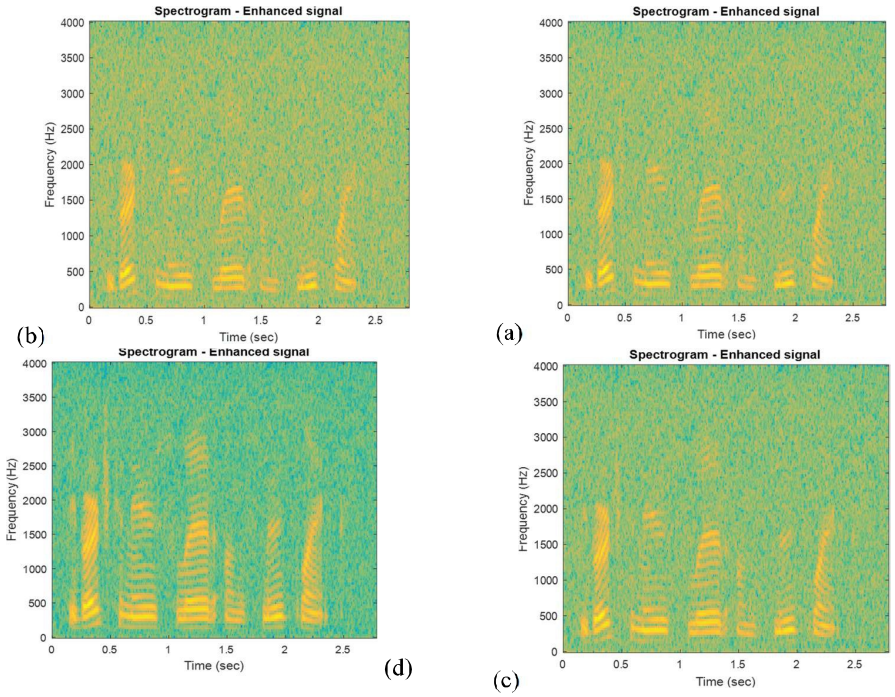

(شکل-۱۱): نمایش اسپکتروگرام برای سیگنال بهسازی‌شده در SNR=+5dB براساس: a) الگوریتم K-SVD. b) الگوریتم PCA. c) الگوریتم GAD. d) الگوریتم GAD_Gini.

(Figure-11): Spectrogram representation for the enhanced signal at SNR=+5dB using: a) K-SVD algorithm. b) PCA algorithm. c) GAD algorithm. d) GAD_Gini algorithm.

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]
[DOI: 10.29252/jsdp.17.1.99]

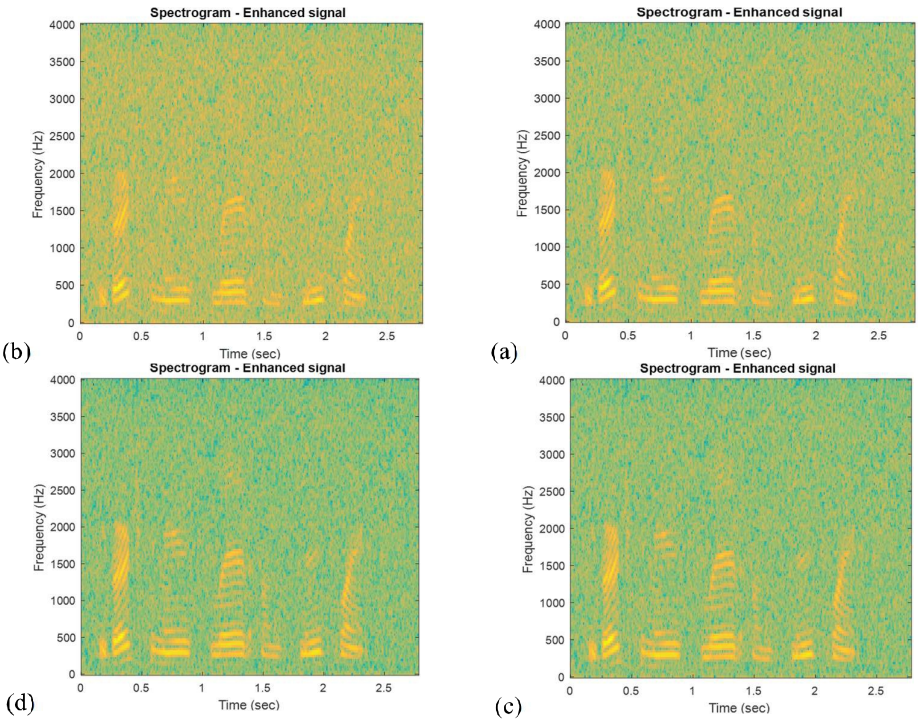

(شکل-۱۲): نمایش اسپکتروگرام برای سیگنال بهسازی‌شده در SNR=0dB براساس: a) الگوریتم K-SVD. b) الگوریتم PCA. c) الگوریتم GAD. d) الگوریتم GAD_Gini.

(Figure-12): Spectrogram representation for the enhanced signal at SNR=0dB using: a) K-SVD algorithm. b) PCA algorithm. c) GAD algorithm. d) GAD_Gini.

همچنین، زمان محاسباتی برای اجرای روش‌های مختلف مورد بررسی با میانگین‌گیری بر روی اجرای هر یک از این الگوریتم‌ها بر روی ده سیگنال ورودی در جدول (۹) گزارش شده است. تمامی برنامه‌ها بر روی نرم‌افزار متلب براساس ویندوز ۶۴ بیتی با مشخصات Core i5 3.2GHz CPU اجرا شده است. همان‌طورکه دیده می‌شود، زمان روال اجرای روش پیشنهادی به‌علت مرتب‌کردن ضرایب و محاسبه معیار جینی اندکی بیشتر از الگوریتم GAD خواهد بود. الگوریتم K-SVD به‌علت به‌کارگیری روال تکرارشونده به‌منظور هم‌گرایی به کمترین خطای تقریب، زمان اجرای طولانی دارد و روش PCA نیز که تبدیل کامل است به‌علت نداشتن روال پیچیده محاسباتی کمترین زمان اجرا را به خود اختصاص می‌دهد.

(جدول-۹): میانگین زمان محاسباتی برای اجرای روش‌های یادگیری واژه‌نامه مختلف

(Table-9): The average of computation time for dictionary learning of different methods

روش	میانگین زمان اجرا (ثانیه)
PCA	10
K-SVD	6744
GAD	173
GAD-Gini	178

۵- نتیجه‌گیری

در این مقاله روش‌های یادگیری واژه‌نامه مبتنی‌بر داده معرفی شد. از این میان روش یادگیری واژه‌نامه تطبیقی حریصانه GAD به‌منظور بهسازی سیگنال گفتار در حضور نوفه سفید گوسی مورد توجه قرار گرفت. واژه‌نامه در این روش به‌طور مستقیم از روی سیگنال گفتار یادگیری می‌شود تا تطابق بیشتری میان اتم‌ها و ساختار سیگنال ایجاد شده و همدوسی اتم‌ها و ردهٔ داده افزایش یابد. انتخاب این اتم‌ها به‌کمک شاخص تُنُکی مبتنی‌بر نُرم از میان قاب‌های سیگنال مشاهده‌ای است. از آنجایی‌که این نحوه انتخاب اتم‌ها، یادگیری را درگیر روال پیچیده نکرده و سرعت هم‌گرایی بالایی به‌دست می‌دهد، بر آن شدیم تا با بررسی این الگوریتم‌ها به نتایج بهتری در زمینه بهسازی گفتار دست پیدا کنیم. بر این اساس ایده تُنُکی مورد بررسی قرار گرفت و بر مبنای معیارهای مطرح‌شده برای یک شاخص تُنُکی مطلوب، شاخص تُنُکی جینی در نظر گرفته شد. با بررسی عملکرد این شاخص در انتخاب قاب‌های داده به این نتیجه رسیدیم که عملکرد این شاخص در برخی جنبه‌ها بهتر از شاخص تُنُکی مبتنی‌بر نُرم

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

معرفی‌شده، خواهد بود. بنابراین این شاخص در روال الگوریتم یادگیری واژه‌نامه تطبیقی حریصانه مورد استفاده قرار گرفت. نتایج حاصل از شبیه‌سازی‌های مختلف نشان می‌دهد که اگرچه شاخص پیشنهادی در تمامی شرایط درنظر گرفته شده بهتر از شاخص مبتنی‌بر نُرم عمل نمی‌کند؛ اما نتایج حاصل از آن مطلوب بوده و می‌تواند با دقت مناسبی در بهسازی گفتار مورد استفاده قرار گیرد.

6- References ۶- مراجع

[1] H. Guo, B. Zhao, G. Zhou, "Image compression based on compressed sensing theory and wavelet packet analysis", Cross Strait Quad-Regional Radio Science and Wireless Technology Conference, vol. 2, pp. 1426-1429, 2011.

[2] J. L. Starck, M. Elad, D. L. Donoho, "Image decomposition via the combination of sparse representation and a variational approach", IEEE Trans. on Image Proces, vol. 14, No. 10, pp. 1570-1582 , 2005.

[3] F. Rodriguez, G. Sapiro, "Sparse representation for image classification: Learning discriminative and reconstructive non-parametric dictionaries", IMA Preprint, 2007.

[4] S. Zhang, J. Huang, D. Metaxas, W. Wang, X. Huang, "Discriminative sparse representations for cervigram image segmentation", IEEE International Symposium on Biomedical Imaging: From Nano to Macro, pp.133-136, 2010.

[5] M. S. Lewiki, T. J. Sejnowski, "Learning overcomplete representations", Neural Computing, vol. 12, No. 2, pp. 337-365, 2000.

[6] D. Giacobello, M. G. Christensen, M. N. Murthi, S. H. Jensen, M. Moonen, "Retrieving sparse patterns using a compressed sensing framework: applications to speech coding based on sparse linear prediction", IEEE Signal Processing Letters, vol. 17, No. 1, pp.103-106, 2010.

[7] D. Wu, Z. Ping, M. N. S. Swamy, "A compressive sensing method for noise reduction of speech and audio signals", IEEE 54th International Midwest Symposium on Circuits and Systems, pp. 1-4, 2011.

[8] D. Wu, Z.W. Ping, M. N. S. Swamy, "On sparsity issues in compressive sensing based speech enhancement", IEEE International Symposium on Circuits and Systems, pp. 285-288, 2012.

[9] E. Candès, J. Romberg, T. Tao, "Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information", IEEE Trans. Inform. Theory, vol. 52, No. 2, pp. 489-509, 2006.

[10] E. J. Candes, T. Tao, "Near-optimal signal recovery from random projections and universal encoding strategies", IEEE Trans. Inform. Theory, vol. 52, No. 12, pp. 5406-5425, 2006.

[11] H. Xu, "Speech enhancement based on compressed sensing technology", Sensors & Transducers Journal, vol. 181, pp. 141-145, 2014.

[12] G. S. Sivaram, S. K. Nemala, M. Elhilali, H. Hermansky, "Sparse coding for speech recognition", IEEE International Conference on Acoustics Speech and Signal Processing (ICASSP), pp. 4346-4349, 2010.

[13] D. D. Lee, H. S. Seung, "Learning the parts of objects by non-negative matrix factorization", Nature 401, 788- 791, 1999.

[14] N. Mohammadiha, P. Smaragdis, A. Leijon, "Supervised and unsupervised speech enhancement using nonnegative matrix factorization", IEEE Transactions on Audio, Speech, and Language Processing, vol. 21, No. 10, pp.2140-2151, 2013.

[15] J. T. Geiger, J. F. Gemmeke, B. Schuller, and G. Rigoll, "Investigating NMF speech enhancement for neural network based acoustic models", Proceedings of the Annual Conference of International Speech Communication Association (INTERSPEECH), 2014.

[16] P. O. Hoyer, "Non-negative matrix factorization with sparseness constraints", J. Mach. Learn. Res., vol. 5, pp. 1457-1469, 2004.

[17] C. D. Sigg, T. Dikk, J. M. Buhmann, "Speech enhancement with sparse coding in learned dictionaries", In Acoustics Speech and Signal Processing (ICASSP), IEEE International Conference on, pp. 4758-4761, 2010.

[18] C. D. Sigg, T. Dikk, J. M. Buhmann, "Speech enhancement using generative dictionary learning", IEEE Transactions on Audio, Speech, and Language Processing, vol. 20, No. 6, pp. 1698-1712, 2012.

[19] M. Aharon, M. Elad, A. Bruckstein, "K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation", IEEE Trans. Signal Process, vol. 54, No. 11, pp. 4311-4322, 2006.

[20] H. Yongjun, J. Han, S. Deng, T. Zheng, G. Zheng, "A solution to residual noise in speech denoising with sparse representation", In Acoustics, Speech and Signal Processing

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]

(ICASSP), IEEE International Conference on, pp. 4653-4656, 2012.

[21] S. Mavaddaty, S. M. Ahadi, S. Seydin, "A novel speech enhancement method by learnable sparse and low-rank decomposition and domain adaptation", Speech Communication, vol. 76, pp. 42-60, 2016.

[22] M. G. Jafari, M. D. Plumbley, "Speech denoising based on a greedy adaptive dictionary algorithm", 17th European Signal Processing Conference (EUSIPCO), pp. 1423-1426, 2009.

[23] M. G. Jafari, M. D. Plumbley, "Fast dictionary learning for sparse representations of speech signals", IEEE Journal of selected topics in signal processing, vol. 5, pp. 1025-1031, 2011.

[24] R. Rubinstein, M. Zibulevsky, M. Elad, "Double sparsity: Learning sparse dictionaries for sparse signal approximation", IEEE Trans. on Signal Processing, Vol. 58, pp. 1553-1564, 2010.

[25] M. G. Jafari, E. Vincent, S. A. Abdallah, M. D. Plumbley, M. E. Davies, "An adaptive stereo basis method for convolutive blind audio source separation", Neuro computing, vol. 71, pp. 2087-2097, 2008.

[26] http://www.dcs.shef.ac.uk/spandh/gridcorpus.

[27] N. Hurley, S. Rickard, "Comparing measures of sparsity", IEEE Trans. on Information Theory, vol. 55, pp. 4723-4741, 2009.

[28] S. Rickard, M. Fallon, "The gini index of speech", In Proc. Of Information Sciences and Systems conference, Princeton, NJ, 2004.

[29] P. J. Wolfe, "Sparse time-frequency representations in audio processing, as studied through a symmetrized lognormal model," In Proc. of the European Signal Processing Conference (EUSIPCO), pp. 355-359, 2007.

[30] H. Dalton, "The measurement of the inequity of incomes", Economic Journal, Vol. 30, pp. 348-361, 1920.

[31] I. Cohen, B. Berdugo, "Speech enhancement for non-stationary noise environments", Signal processing, vol. 81, No. 11, pp. 2403-2418, 2001.

[32] A. Rix, J. Beerends, M. Hollier, A. Hekstra, "Perceptual evaluation of speech quality (PESQ)-a new method for speech quality assessment of telephone networks and codecs", In Proc. IEEE Int. Conf. Acoustics, Speech, Signal Process., pp. 749-752, 2001.

سمیرا مودّتی مدارک کارشناسی و کارشناسی ارشد خود را به‌ترتیب در سال‌های ۱۳۸۶ و ۱۳۸۹ از دانشگاه مازندران در رشته مهندسی-برق- الکترونیک دریافت کرد. ایشان درجه دکترای خود را در سال ۱۳۹۵ از دانشگاه صنعتی امیرکبیر در رشته مهندسی برق- الکترونیک اخذ کرد. وی هم‌اکنون استادیار گروه مهندسی برق دانشکده فنی و مهندسی دانشگاه مازندران است. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: پردازش سیگنال گفتار، پردازش سیگنال تصویر، بهینه‌سازی و هوش مصنوعی.

نشانی رایانامه ایشان عبارت است از:

s.mavaddati@umz.ac.ir

سید محمد احدی مدارک کارشناسی و کارشناسی ارشد خود را به‌ترتیب در سال‌های ۱۳۶۳ و ۱۳۶۶ از دانشگاه صنعتی امیرکبیر در رشته مهندسی- برق- الکترونیک دریافت کرد. ایشان درجه دکترای خود را در سال ۱۳۷۵ از دانشگاه کمبریج در رشته مهندسی برق- الکترونیک اخذ نمود. وی هم‌اکنون استاد گروه مهندسی برق دانشگاه صنعتی امیرکبیر است. زمینه‌های پژوهشی مورد علاقه ایشان عبارت است از: بازشناسی سیگنال گفتار، بهسازی سیگنال تصویر.

نشانی رایانامه ایشان عبارت است از:

sma@aut.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2025-06-13]

[DOI: 10.29252/jsdp.17.1.99]