

## محاسبه عدد کوهرت برای فهرست کلمات دوهجایی پربسامد زبان فارسی

سهیلا شایان مهر<sup>۱</sup>، جمیله فتاحی<sup>۱</sup>، سید علی اکبر طاهایی<sup>۲</sup>، شهره جلایی<sup>۳</sup>

<sup>۱</sup>- گروه شنوایی‌شناسی، دانشکده توانبخشی، دانشگاه علوم پزشکی تهران، ایران

<sup>۲</sup>- گروه شنوایی‌شناسی، دانشکده علوم توانبخشی، دانشگاه علوم پزشکی ایران، تهران، ایران

<sup>۳</sup>- آمار زیستی، دانشکده توانبخشی، دانشگاه علوم پزشکی تهران، ایران

### چکیده

**زمینه و هدف:** تعداد رقیب‌های ممکن برای هر کلمه که ابتدای آنها با هم مشابه است «عدد کوهرت» نام دارد. علی‌رغم اهمیت تعداد و ویژگی‌های رقیب‌ها در شناسایی کلمه، در هیچ یک از آزمون‌های ساخته شده برای زبان فارسی عامل عدد کوهرت در انتخاب کلمه در نظر گرفته نشده است. هدف مطالعه کنونی، معرفی نقش عدد کوهرت در شناخت کلمه و سپس محاسبه عدد کوهرت برای کلمات دوهجایی پربسامد زبان فارسی بود.

**روش بررسی:** پس از تهیه پیکره و اژدهای پربسامد زبان فارسی و استخراج کلمات دوهجایی آنها، عدد کوهرت هر یک از کلمه‌های دوهجایی از فرهنگ فارسی عمید محسوبه شد. به این ترتیب یک فهرست کامل از کلمات دوهجایی پربسامد مشتمل بر ۴۲۱ واژه به همراه مقدار کوهرت برای هر یک از کلمات به دست آمد.

**یافته‌ها:** مقادیر کوهرت کلمات محدوده‌ای از صفر تا ۸۷ را شامل شدند. نیمی از کلمات مورد بررسی عدد کوهرت بالای ۱۴ و نیمی عدد کوهرت زیر ۱۴ داشتند.

**نتیجه‌گیری:** عدد کوهرت بر سرعت و دقت تصمیم‌گیری درکی کلمه تأثیر دارد. کلمات فارسی از نظر متغیر کوهرت وزن یکسانی ندارند. از این رو برای طراحی مواد آزمونی کنترل شده‌تر در ساخت انواع مختلف آزمون‌های شنوایی، می‌توان عامل عدد کوهرت را نیز در کنار سایر عوامل مؤثر در نظر داشت.

**واژگان کلیدی:** درک گفتار، شناخت کلمه، مدل کوهرت شناخت کلمه، عدد کوهرت، زبان فارسی

(دریافت مقاله: ۱۷/۶/۹۲، پذیرش: ۲۶/۶/۹۲)

### مقدمه

(the neighborhood) یا تراکم هم‌جواران (Cohort size) نامیده می‌شود)

در نظریه کوهرت دو مرحله برای تشخیص کلمه گفتاری به این شرح پیشنهاد می‌شود مرحله مستقل و دیگری مرحله تعاملی. در مرحله اول (مستقل) اطلاعات فیزیکی‌آوایی مربوط به ابتدای کلمه درون‌داد برای تمام کلماتی که اطلاعات ابتدای آنها با هم یکسان هستند در حافظه برانگیخته می‌شوند. کلمات برانگیخته شده بر مبنای اطلاعات مربوط به آغاز کلمه، یک گروه یا اصطلاحاً کوهرت تشکیل می‌دهند. برای مثال، اگر گوینده کلمه‌ای که با هجای «سر» شروع می‌شود به کار ببرد در حافظه شونده کلماتی که با هجای «سر» شروع می‌شوند برانگیخته

گفتار یک سیگنال پیچیده و متغیر است که به صورت توالی‌ای از واحدهای معنی‌دار زبانی درک می‌شود. به منظور درک یک جمله شنونده باید کلمات منفرد را شناسایی کند و به معنی هر یک از کلمات دست یابد و آنها را برای ایجاد معنی درست با هم ترکیب کند(۱ و ۲). با شنیدن بخش ابتدایی کلمه تعدادی جایگزین لغوی رقیب برای فعل شدن با هم به رقابت می‌پردازند و در نهایت با پردازش‌های بالا به پایین صورت گرفته یکی از رقیب‌ها به طور همزمان برنده می‌شود(۳ و ۴).

یکی از مدل‌های نظری درک گفتار، مدل کوهرت است. در این مدل، برای هر کلمه هدف می‌توان تعداد رقیب‌های ممکن برای آن کلمه را محاسبه کرد و آن مقدار، عدد کوهرت

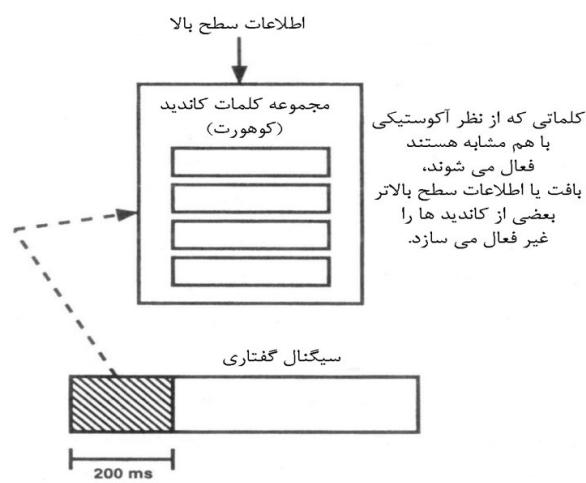
**نویسنده مسئول:** تهران، خیابان انقلاب، بعد از پیچ شمیران، دانشگاه علوم پزشکی تهران، گروه شنوایی‌شناسی، کد پستی: ۱۱۴۸۹۶۵۱۴۱، تلفن:

E-mail: jfatahi@tums.ac.ir ، ۰۲۱-۷۷۵۳۰۶۳۶

آنها آن را تراکم هم‌جواران نامیدند بر تصمیم‌گیری اثر می‌گزارد. کلماتی با هم‌جواران بیشتر دیرتر شناسایی می‌شوند و بهدلیل رقابت، خطاهای بیشتری تولید می‌کنند<sup>(۵)</sup>.

Theunissen و همکاران (۲۰۰۹) در مروری نظاممند به اثر متغیرهای مختلف بر طراحی و تفسیر آزمون‌های جمله در نویز، اشاره می‌کند که نوع و بافت مواد آزمون بر عملکرد افراد اثرگذار است. در این مرور جامع به اهمیت نقش بسامد کلمه، تعداد کلمات مشابه از نظر آوازی (تراکم هم‌جواران یا عدد کوهورت) و بسامد رقیب‌های کلمه در شناخت کلمه اشاره شده است. همچنین در مطالعات نشان داده شده است که افراد کم‌شنوا برای اینکه بتوانند درصد یکسانی از کلمات دشوار از نظر لغوی (کلمات کم‌بسامد و با تعداد هم‌جواران زیاد و پر‌بسامد) و کلمات ساده از نظر لغوی (کلمات پر‌بسامد و با تعداد هم‌جواران کم و کم‌بسامد) را تشخیص دهند به شدت ۵/۸-۳/۱ دسی‌بل بیشتری نیاز دارند<sup>(۶)</sup>.

درک گفتار با واحدهای زبانی مختلفی از جمله واج‌ها، هجاهای، کلمات یا جملات ارزیابی می‌شود. مواد آزمونی گوناگونی برای اندازه‌گیری درک گفتار با این واحدها طراحی شده‌اند<sup>(۷)</sup>. تاکنون مواد کلمه‌ای مختلفی برای آزمون‌های گوناگون در فارسی طراحی شده است، ولی در هیچ یک از آنها عامل عدد کوهورت برای انتخاب کلمات درنظر گرفته نشده است. همواره امتیاز درک بعضی کلمات پایین‌تر از برخی دیگر است. از دلایل آن می‌توان به عدم کنترل میزان آشنازی، بسامد و عدد کوهورت کلمه اشاره کرد. می‌توان گفت هرچه عدد کوهورت کلمه‌ای بیشتر باشد، یا به عبارتی تعداد کلمات مشابه بیشتری برای فعال شدن با هم رقابت کنند، آن کلمه غیرقابل پیش‌بینی‌تر می‌شود و با شنیدن ابتدای کلمه به راحتی نمی‌توان کل کلمه را حدس زد. هنگام انتخاب کلمات برای اهداف مختلف در نظر گرفتن قابلیت پیش‌بینی و حدس کلمه مهم است. برای مثال، اگر در آزمون بازشناسی گفتار (speech recognition threshold) فهرست کلمات از این نظر متوازن و معادل نشده باشد و فهرست صرفاً از کلمات کم‌کوهورت تشکیل شده باشد احتمالاً امتیاز حاصل از این فهرست با فهرست دیگری که از کلمات پر‌کوهورت تشکیل شده است



شکل ۱- مدل کوهورت تشخیص کلمه<sup>(۱۳)</sup>

می‌شوند مانند سرباز، سرما، سردی، سرشیر، سرداد، سرور، سرریز، سردرد، و سرگرم. هنگامی که یک گروه برانگیخته می‌شود کلمات نامناسب از طریق اطلاعات بالا به پایین از قبیل قواعد نحوی یا معنایی غیرفعال می‌شوند (به صورت داوطلب‌هایی از گروه حذف می‌شوند). تمامی منابع احتمالی اطلاعات شامل منابع اطلاعاتی می‌شوند. در فرایند انتخاب کلمه مناسب از گروه دخالت دارند. برای مثال، اگر کلمه «سرباز» برای آن بافت گفتار مناسب نباشد از گروه حذف خواهد شد. این همان مرحله دوم تشخیص کلمه یعنی مرحله تعاملی است. شکل ۱ نمایی طرح‌واره‌ای از مدل کوهورت را نشان می‌دهد.

Marslen-Wilson (۱۹۹۰) اثر بسامد رقیب‌ها بر شناخت کلمات را بررسی کرد و دریافت که افزایش فعال‌سازی برای یک کلمه پر‌بسامد بیشتر از آن برای یک کلمه کم‌بسامد است<sup>(۵)</sup>. نتایج مطالعات Luce و همکاران (۱۹۸۹ و ۱۹۹۰) حاکی از آن است که عدد کوهورت (تعداد رقیب‌ها) بر دوره زمانی شناخت کلمه اثر می‌گذارد. تعداد رقیب‌ها (عدد کوهورت) و ویژگی‌های رقیب‌ها (مانند بسامد) در تشخیص کلمه مهم است. برای مثال، ما کمتر می‌توانیم کلمات کم‌بسامدی را که هم‌جواران زیاد و پر‌بسامد دارند نسبت به کلمات دارای هم‌جواران کمتر و کم‌بسامدتر شناسایی کنیم. Luce و همکاران (۱۹۹۰) عقیده داشتند عدد کوهورت که

تهیه شد. پس از تهیه و بررسی فهرست ۱۴۰۰۰ واژه‌ای کلمات پرپسامد، تمام کلمات دوهجایی، به‌جز اسمی خاص، قیدها و حروف ندا، از بین آنها استخراج شدند. در این مرحله یک فهرست کلمات دوهجایی پرپسامد مشتمل بر ۴۱۲۱ واژه به‌دست آمد. گام بعدی محاسبه عدد کوهرت یا تراکم هم‌جواران برای فهرست کلمات دوهجایی بود. با توجه به اینکه هجای اول در تولید کوهرت اهمیت بسیاری دارد محاسبه عدد کوهرت از روی هجای اول کلمات صورت گرفت؛ به این صورت که با استفاده از فرهنگ فارسی دو جلدی عمید، تمام کلماتی که هجای اول مشابه با کلمه هدف داشتند شمارش و به‌عنوان عدد کوهرت آن کلمه در نظر گرفته شد. به‌منظور شمارش عدد کوهرت، کلمات بیگانه و غیرفارسی و نیز کلمات قدیمی و مستعمل که در فارسی معاصر شناخته شده نیستند و به کار نمی‌روند در محاسبه منظور نشدنند. برای مثال، برای کلمه «دفتر» که یکی از کلمات فهرست ۴۱۲۱ واژه دوهجایی است در فرهنگ فارسی فقط کلمه «دفعه» دارای هجای اول «دف» است. بنابراین عدد کوهرت کلمه «دفتر» یک در نظر گرفته می‌شود. جدول ۱ مثالی از نحوه محاسبه عدد کوهرت برای چند کلمه را نشان می‌دهد. این روند برای تمام ۴۱۲۱ کلمه ده‌جایی انجام شد و مقادیر کوهرت هر یک از کلمات به‌دست آمد.

### یافته‌ها

با محاسبه مقادیر کوهرت، کلمات دوهجایی محدوده وسیعی از مقادیر کوهرت را نشان دادند. کمترین مقدار عدد کوهرت برای کلمات دوهجایی پرپسامد زبان فارسی، یعنی صفر، به‌معنی فاقد رقیب بودن کلمات فوق و بیشترین میزان آن، یعنی ۸۷، به‌معنی وجود ۸۷ کلمه با هجای اول مشابه به‌دست آمد؛ یعنی برای کلمات بررسی شده عدد کوهرت در محدوده بین صفر تا ۸۷ بود. نمودار ۱ کلمات با مقادیر کوهرت مختلف را نشان می‌دهد. نتایج نشان می‌دهد که از بین ۴۱۲۱ کلمه دوهجایی بررسی شده، ۵۰ درصد کلمات عدد کوهرتی پایین‌تر از ۱۴ و ۵۰ درصد دیگر عدد کوهرت بالاتر از ۱۴ داشتند. همچنین عدد

متفاوت خواهد بود و این اختلاف امتیاز به اشتباہ به‌عنوان تفاوت عملکرد افراد تلقی خواهد شد.

با توجه به اینکه تاکنون چنین محاسبه‌ای برای کلمات زبان فارسی صورت نگرفته است این فهرست در طراحی مواد آزمونی دقیق‌تر و کنترل شده‌تر می‌تواند مفید باشد. از این رو این مطالعه با هدف محاسبه تعداد رقیب‌های با هجای اول مشابه در کلمات دوهجایی پرپسامد زبان فارسی انجام شد.

### روش بررسی

در مطالعه حاضر که از نوع توصیفی-اکتشافی بود، پس از تهیه پیکره واژه‌های پرپسامد زبان فارسی، کلمات دوهجایی آنها استخراج و عدد کوهرت هریک از کلمه‌های دوهجایی از فرهنگ فارسی عمید محاسبه شد. به این منظور از پیکره زبانی گردآوری شده توسط عاصی (۱۹۹۷) در پژوهشگاه علوم انسانی و مطالعات فرهنگی استفاده شد. وی از سال ۱۳۷۲ با جمع‌آوری اطلاعات از منابع زیر به ساخت پایگاه داده‌ای زبان فارسی در اینترنت پرداخته‌اند. نمونه‌های وارد شده که به‌عنوان داده‌ها در حافظه رایانه ذخیره شده‌اند شامل متون زبانی و متون مهم نظم و نثر ادبیات معاصر ایران، کتب و مقالات تخصصی، گفتار پیوسته ضبط شده، متن روزنامه‌ها و غیره است که به پایگاه درون داد شده‌اند. مجموع متن‌های گردآوری شده نزدیک به یکصد میلیون واژه است که تاکنون تنها ۶۰ میلیون واژه از آن به درون پایگاه داده وارد شده است. قابل ذکر است که این کار به صورت فعالیتی همیشگی و با افزودن منابع تازه دنبال خواهد شد. در این پایگاه داده‌ها به شکل‌ها و قالب‌های گوناگون نظری فهرست‌های واژه‌نما و بسامدی ذخیره شده‌اند. پایگاه داده‌های زبان فارسی مجموعه‌ای است از متون مختلف فارسی که بخشی از آن دارای نشانه‌گذاری‌هایی از جمله شناسنامه متن، برچسب‌های دستوری، آوایی، ریشه‌ای و معنایی است<sup>(۹)</sup>. بنابراین امکان تهیه فهرست‌های بسامدی واژه‌ها از این پایگاه داده وجود داشت. به این ترتیب فهرست بسامدی واژه‌ها که شامل ۱۴۰۰۰ واژه مختلف بود و واژه‌ها به دو صورت الفبایی و بسامدی در فهرست مرتب شده بودند برای این مطالعه

جدول ۱- مثالی از محاسبه عدد کوهورت برای کلمات

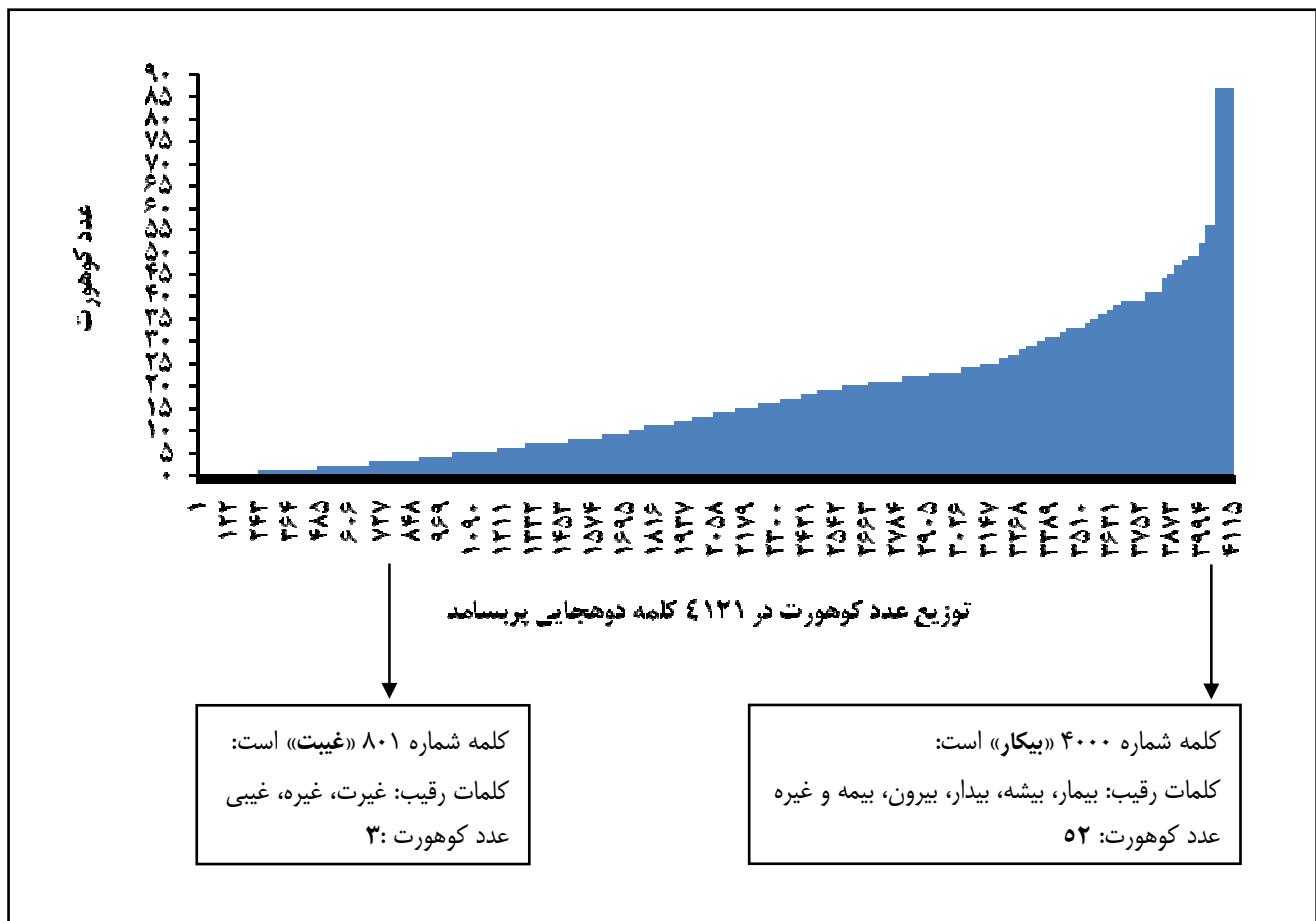
کلمه دوهجایی	بسامد کلمه	کلمات رقیب	عدد کوهورت
آفتاب	۲۳۰۱	-	.
صحراء	۸۱۶	صحنه	۱
دکمه	۳۰۳	دکتر - دکان	۲
خروس	۲۶۰	خنک - خدا - خصوص - خروش - خروج - خطوط - خلود - خمار - خطور - خلوص	۱۰
پاییز	۱۴۳۴	پابند - پابوس - پاپی - پاییچ - پاتوق - پاچه - پاچید - پادرار - پاداش - پادرد - پادو - پاراف - پاریس - پارو - پاره - پاساز - پاسور - پاشید - پاکی - پاکت - پاگیر - پالان - پالش - پالیز - پایان - پایین - پاسخ - پاست	۳۰

## بحث

در مطالعه انجام شده، پس از استخراج واژگان دوهجایی از فهرست کلمات پربسامد زبان فارسی، عدد کوهورت برای واژگان دوهجایی پربسامد محاسبه شده است. علت انتخاب واژگان پربسامد این است که برای اهداف بسیاری، از جمله در ساخت آزمون‌های مختلف، از کلمات رایج و پرکاربرد آن زبان استفاده کلمه در اینجا برجسته می‌شود. در مدل کوهورت، در مرحله اولیه دستیابی لغوی، بسامد کلمه بر شدت فعال‌سازی کلمات داوطلب اثر می‌گذارد؛ به این صورت که برای کلمات پربسامدتر میزان بهره فعال‌سازی بیشتر است (کلمات داوطلب پربسامدتر با بهره بیشتری فعال می‌شوند). بسامد تنها یکی از عوامل تأثیرگذار بر شناخت کلمه است. عامل مهم دیگر میزان آشنایی کلمه است. هرچه کلمه برای شنونده آشناتر باشد راحت‌تر و سریع‌تر شناسایی می‌شود(۵). از دیگر عوامل مهم که کمتر مورد توجه واقع می‌شود تراکم هم‌جواران یا عدد کوهورت کلمه است. با داشتن مقادیر کوهورت کلمات، می‌توان کلمات غیر قابل پیش‌بینی‌تر را انتخاب و جدا کرد و به مقاصد گوناگون از آنها بهره برد. البته بسامد رقیب‌ها نیز بر شناخت کلمه هدف اثرگذار است و کلمه پربسامدی که تنها

کوهورت یک بیشترین تعداد کلمات را به خود اختصاص می‌داد. به عبارتی دیگر، ۲۳۹ کلمه، معادل ۵/۷۹ درصد، دارای عدد کوهورت یک بودند. پس از آن، عدد کوهورت صفر رتبه دوم را داشت که شامل ۲۳۷ کلمه، معادل ۵/۷۵ درصد بود. یعنی در بین ۴۱۲۱ کلمه دوهجایی پربسامد بررسی شده، در ۵/۷۵ درصد آنها با شنیدن هجای اول هیچ کلمه دیگری با آنها رقابت نمی‌کند و بنابراین به راحتی حدس زده می‌شوند. همچنین کلمات پربسامدی وجود داشتند که دارای عدد کوهورت بسیار پایین بودند و عکس آن. برای مثال، در کلمه پرکاربرد «بچه» با بسامد ۸۹۶۲، عدد کوهورت صفر بود. مثال دیگر کلمه کمکاربرد «آژیر» با بسامد پایین ۸۴ و با بیشترین مقدار عدد کوهورت، یعنی ۸۷، بود. جدول ۲ نمونه‌ای از کلماتی است که ارتباط عکس بین بسامد و عدد کوهورت آنها وجود دارد.

یافته کاربردی دیگر این است که بیشترین مقدار کوهورت (۸۷) متعلق به هجای اول «آ» بود. به عبارت دیگر، برای هجای اول «آ» ۸۷ کلمه رقیب وجود دارد که با شنیدن این هجای اول همه این ۸۷ کلمه برای فعال شدن با هم به رقابت می‌پردازن. در کلمات بررسی شده ۷۰ کلمه عدد کوهورت ۸۷ داشتند. ارتباط بین تعداد کلمات دوهجایی با عدد کوهورت متناظر آن را در نمودار ۲ به خوبی می‌توانید مشاهده کنید.



نمودار ۱- روند تغییرات عدد کوهورت

کوهورت بالاتر باشند) تا با کاهش علائم بافتی توجه فرد به کلمه‌ای که واقعاً در حضور نویز شنیده است متتمرکز شود نه آن چیزی که با شنیدن ابتدای کلمه حدس زده است. همان‌طور که در بالا اشاره شد و در نمودارهای ۱ و ۲ نیز دیده می‌شود ۵۰ درصد کلمات دوهجایی پرسامد زبان فارسی عدد کوهورت پایین‌تر از ۱۴ دارند. همچنین بیشترین تعداد کلمات مورد بررسی دارای عدد کوهورت به ترتیب یک و صفر هستند. در ۴۱۲۱ کلمه دوهجایی پرسامد مورد بررسی در مجموع حدود ۱۱/۶ درصد کلمات، کمترین مقادیر کوهورت یعنی اعداد یک و صفر را به خود اختصاص داده‌اند. اگر این یافته را به کل کلمات فارسی تعمیم دهیم می‌توانیم نتیجه بگیریم اکثر کلمات فارسی دارای عدد کوهورت پایین هستند و تعداد کلمات با عدد کوهورت بالا یا به

رقیب‌های کم‌پسامد دارد سریع‌تر شناسایی می‌شود و عکس آن. اهمیت و نقش پیش‌بینی کلمه با شنیدن ابتدای کلمه، کمک به درک گفatar در شرایط شنیداری دشوار، که به طور روزمره رخ می‌دهد، است(۱۰-۱۲). وقتی سیگنال گفتاری با نویز زمینه تخریب می‌شود علائم بافتی اهمیت ویژه‌ای می‌یابند. هرچه علائم بافتی در گفتار بیشتر باشد شنونده کمتر به ویژگی‌های آکوستیکی دقیق صدا اتنکا می‌کند. مفهوم کاربردی مدل کوهورت این است که در ساخت آزمون‌های مختلف، به ویژه آزمون‌های جمله در حضور نویز، دشواری لغوی کلمه مورد استفاده بر دشواری و دقت آزمون اثر خواهد گذاشت(۶). پیش‌بینی کلمه در درک موفق زبان، حیاتی و مهم است. برای ارزیابی درک گفتار در نویز بهتر است کلمات مورد استفاده غیر قابل پیش‌بینی تر باشند (دارای عدد

وجود دارد که کلمات رایج و پر تکرار راحت‌تر شناسایی می‌شوند ولی در این پژوهش یافت شد که بسامد کلمه‌ای ارتباطی به قابلیت شناسایی کلمه ندارد و ممکن است کلمه‌ای بسیار رایج و پر بسامد باشد ولی به دلیل وجود رقیب‌های فراوان و داشتن عدد کوهروت بالا، دیرتر و سخت‌تر شناخته شود. علت احتمالی این یافته مربوط به ساختار کلمه است. کلمات مرکب که هجای اول آنها به تنهایی یک کلمه معنی‌دار است، صرف نظر از میزان بسامدشان، مقادیر کوهروت بالایی دارند. برای مثال، کلمه «دست‌خط»، بسامد بسیار کم (۳۰) و عدد کوهروت بالا (۲۱) دارد یا مثلاً کلمه «پرپشت» بسامد ۹۴ ولی عدد کوهروت ۳۱ دارد. علاوه بر این، همان‌طور که قبل از اشاره شد، کلماتی که هجای آغازین آنها «آ» است بیشترین مقدار کوهروت را دارند گرچه برخی از این کلمات بسامد بسیار کمی دارند.

محاسبه کوهروت در مطالعه کنونی براساس هجای اول کلمات دوهجایی بود. مطالعات فراوانی از این فرضیه حمایت می‌کنند که ابتدای کلمه (۱۵۰ میلی‌ثانیه اولیه)، بهویژه هجای اول، در تولید و محاسبه کوهروت بسیار مهم است. شواهد رفتاری نشان داده است بخش‌های ابتدایی کلمه در شناخت کلمه شنیده شده اهمیت دارند. شواهد حاصل از پتانسیلهای دیررس شناوی (Event Related Potentials: ERP) نیز نشان داده‌اند افراد به طور ترجیحی ابتدای کلمه را در مراحل درکی اولیه پردازش می‌کنند. در گفتار طبیعی، هجای ابتدایی کلمه در مقایسه با هجای میانی کلمه که از نظر آکوستیکی با آن تطبیق داده شده باشد موج word-n (اولین قله منفی) بزرگتری می‌دهد که این حالت شناخت شنیداری آن مهم است. از آنجا که میزان توجه انتخابی، ابزاری برای تعیین میزان اطلاعات است، افراد باید به بخش‌های حاوی بیشترین اطلاعات در گفتار توجه بیشتر و مستقیم‌تری کنند. ابتدای کلمه نسبتاً غیرقابل‌پیش‌بینی است و بنابراین بهشت حاوی اطلاعات است و این فرضیه را که افراد به اجزای غیرقابل‌پیش‌بینی در گفتار توجه مستقیم می‌کنند مطرح می‌کند (۱۳). مطالعات ERP نشان می‌دهند کلماتی که از نظر

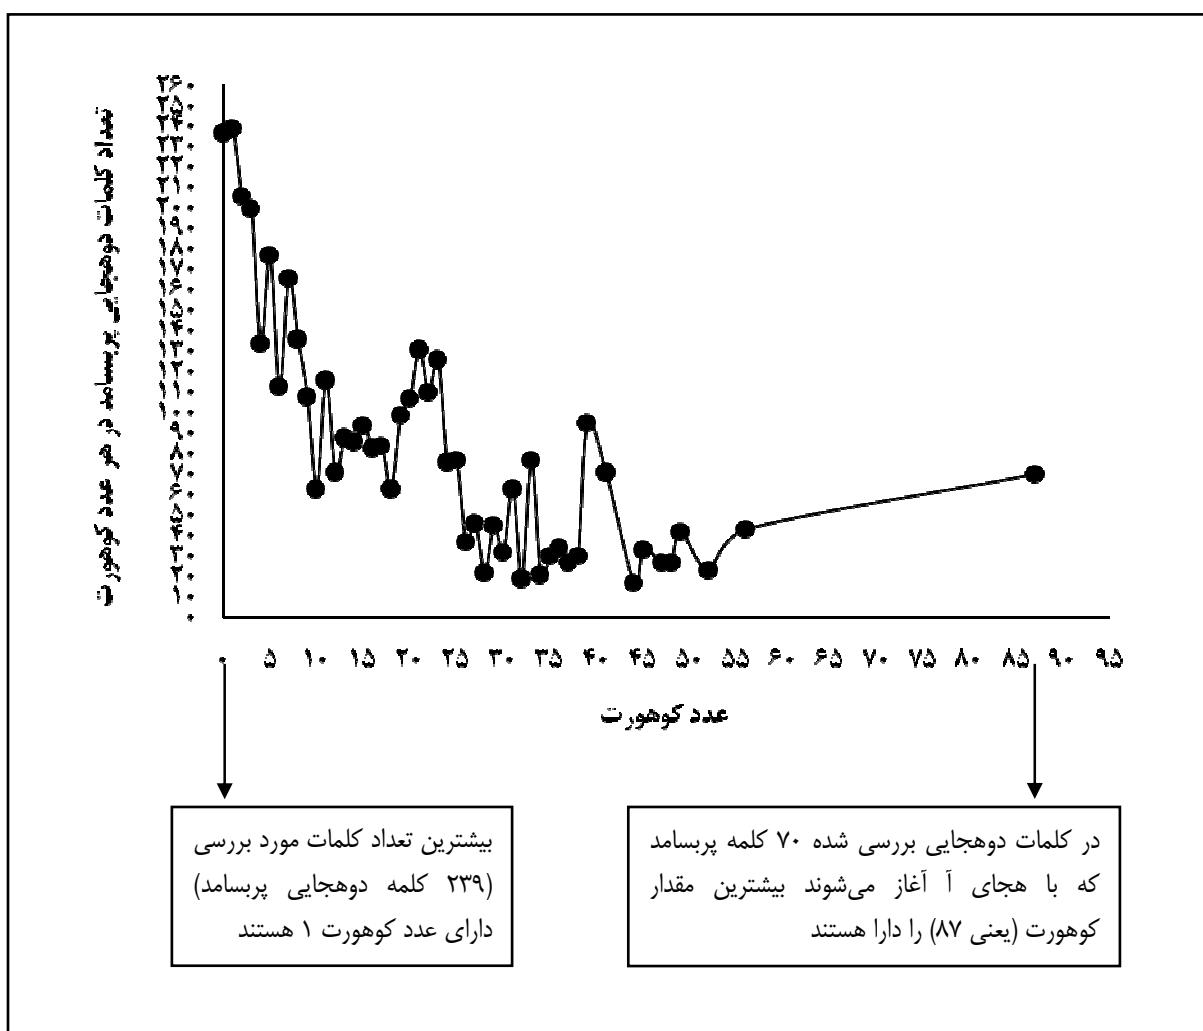
**جدول ۲- نمونه‌ای از کلمات نشان‌دهنده عدم ارتباط بین بسامد و مقدار کوهروت**

کلمه	عنوان	کلمات پر بسامد و کم کوهروت		کلمات کم بسامد و پر کوهروت	
		کلمه	کوهروت	کلمه	کوهروت
فعال	۷۶۴۸	پرپشت	۰	۷۶۴۸	۱
دختر	۸۴۴۰	واله	۰	۸۴۴۰	۱
فوتبال	۱۶۱۵۳	عيان	۱	۱۶۱۵۳	۱۴۱
بسیار	۲۹۱۸۷	ناقص	۰	۲۹۱۸۷	۱۳۲
عنوان	۴۷۱۷۱	آژیر	۱	۴۷۱۷۱	۸۴

عبارتی کلمات غیر قابل پیش‌بینی‌تر محدودتر است. بنابراین برای انتخاب کلماتی که قابلیت حدس آنها کمتر باشد باید دقت نظر بیشتری به خروج داد.

در کلمات مورد بررسی بیشترین مقدار کوهروت ۸۷ بود که متعلق به هجای اول «آ» است. از این یافته می‌توان چنین استنباط کرد که کلمات دارای هجای اول «آ» به دلیل رقابت فراوان موجود به سختی قابل حدس زدن هستند. مفهوم عدد کوهروت ۸۷ این است که در فرهنگ فارسی عمید ۸۷ کلمه دوهجایی وجود دارد که با هجای «آ» شروع می‌شوند و به نوعی رقیب هم محسوب می‌شوند. از طرف دیگر در کلمات دوهجایی پر بسامد بررسی شده ۷۰ کلمه دارای عدد کوهروت ۸۷ هستند که با هجای «آ» شروع می‌شوند. می‌توان نتیجه گرفت که از بین ۸۷ کلمه دوهجایی که هجای آغازین «آ» دارند ۷۰ کلمه آنها پر بسامد بوده و در فهرست واژگان پر بسامد زبان فارسی قرار می‌گیرند. پس از هجای اول «آ»، هجاهای اول «نا، بی، عَ، آ، وَ، بَ، دَ، سَر وَ غَيْرِه» به ترتیب بیشترین مقادیر کوهروت را به خود اختصاص داده‌اند. بنابراین کلماتی که هجای اول آنها از هجاهای مذکور باشد نسبت به سایر کلمات کم کوهروت رقابت بیشتری ایجاد کرده و قابلیت پیشگویی کمتری خواهد داشت.

یافته قابل تأمل دیگر این است که بین بسامد کلمه و عدد کوهروت آن ارتباط مثبتی وجود ندارد. اغلب این باور در اذهان



نمودار ۲ – تعداد کلمات دوهجایی پرسامد موجود به ازای هر مجموعه از اعداد کوهورت یکسان

کوهورت پایین یا صفر) افراد با شنیدن ابتدای کلمه بدون هیچ توجهی می‌توانند کل کلمه را حس بزنند. می‌توان گفت افراد به اجزای غیرقابل پیش‌بینی در گفتار توجه مستقیم می‌کنند (۱۳).

### نتیجه‌گیری

عدد کوهورت کلمات دوهجایی پرسامد فارسی محاسبه شد. محدوده وسیع عدد کوهورت در کلمات مورد بررسی نشان می‌دهد کلمات از نظر عدد کوهورت ارزش متفاوتی دارند. آگاهی از مقادیر کوهورت هنگام گزینش کلمات برای ساخت آزمون‌هایی

بافتی منسجم (coherent) هستند ولی قابل پیش‌بینی نیستند، در مقایسه با کلمات قابل پیش‌بینی،  $n=400$  بزرگتری استخراج می‌کنند. نتایج مطالعات Sanders و Astheimer (۲۰۱۱) نشان داده است که افراد به طور انتخابی به ابتدای کلماتی که نمی‌توانند آنها را از روی بافت پیش‌بینی کنند توجه می‌کنند ولی در پاسخ به کلماتی که کاملاً قابل پیش‌بینی هستند (معادل با عدد کوهورت پایین یا صفر برای کلمه) افراد هیچ اثر توجهی نشان نمی‌دهند و حتی در بعضی موارد شناخت کلمه شنیده شده بدون هیچ توجهی صورت می‌گیرد. یعنی برای کلماتی که رقیبی ندارند (عدد

این مقاله بخشی از پایان‌نامه مصوب دانشگاه علوم پزشکی تهران به شماره قرارداد ۹۱/۲۶۰/۱۹۷۶ مورخ ۹۱/۶/۲۰ است. از جانب آقای دکتر مدرسی، آقای دکتر عاصی و همکاران زبان‌شناس در پژوهشگاه علوم انسانی و مطالعات فرهنگی برای کمک به انجام این پژوهش سپاسگزاری می‌شود.

مانند آزمون بازشناسی گفتار، انواع آزمون‌های ارزیابی درک گفتار در نویز، ERPs و آزمون‌های ارزیابی سیستم شنوایی مرکزی باعث افزایش اعتبار و صحت این آزمون‌ها می‌شود.

### سپاسگزاری

## REFERENCES

1. Davis MH, Johnsrude IS. Hearing speech sounds: top-down influences on the interface between audition and speech perception. *Hear Res*. 2007;229(1-2):132-47.
2. Dumay N, Content A. Searching for syllabic coding units in speech perception. *J Mem Lang*. 2012;66(4):680-94.
3. Lecumberri MLG, Cooke M, Cutler A. Non-native speech perception in adverse conditions: A review. *Speech Commun*. 2010;52(11-12):864-86.
4. Calabrese A. Auditory representations and phonological illusions: a linguist's perspective on the neuropsychological bases of speech perception. *J Neurolinguistics*. 2012;25(5):355-81.
5. Harley TA. The psychology of language: from data to theory. 3<sup>rd</sup> ed. New York: Psychology Press; 2008.
6. Theunissen M, Swanepoel de W, Hanekom J. Sentence recognition in noise: variables in compilation and interpretation of tests. *Int J Audiol*. 2009;48(11):743-57.
7. Thibodeau LM. Speech audiometry. In: Roeser RJ, Valente M, Hosford-Dunn H, editors. *Audiology Diagnosis*. 2<sup>nd</sup> ed. New Yourk: Theime Medical Publishers, Inc; 2007.p. 288-311.
8. McArdle R, Hnath-Chisolm T. Speech audiometry. In: Katz J, Medwetsky L, Burkard R, Hood L, editors. *Handbook of clinical audiology*. 6<sup>th</sup> ed. Baltimore: Lippincot Williams & Wilkins; 2009.p.64-79.
9. Assi SM. "Farsi Linguistic Database (FLDB)". *International Journal of Lexicography*. 1997;10(3):5.
10. Conway CM, Bauernschmidt A, Huang SS, Pisoni DB. Implicit statistical learning in language processing: word predictability is the key. *Cognition*. 2010;114(3):356-71.
11. Gahl S, Yao Y, Johnson K. Why reduce? Phonological neighborhood density and phonetic reduction in spontaneous speech. *J Mem Lang*. 2012;66(4):789-806.
12. Kim D, Stephens JD, Pitt MA. How does context play a part in splitting words apart? Production and perception of word boundaries in casual speech. *J Mem Lang*. 2012;66(4):509-29.
13. Astheimer LB, Sanders LD. Predictability affects early perceptual processing of word onsets in continuous speech. *Neuropsychologia*. 2011;49(12):3512-6.

**Research Article**

# **Calculation of Cohort size for the list of Persian high-frequency spondee words**

**Soheila Shayanmehr<sup>1</sup>, Jamileh Fatahi<sup>1</sup>, Seyed Aliakbar Tahaie<sup>2</sup>, Shohreh Jalaie<sup>3</sup>**

<sup>1</sup>- Department of Audiology, School of Rehabilitation, Tehran University of Medical Sciences, Iran

<sup>2</sup>- Department of Audiology, Faculty of Rehabilitation Sciences, Iran University of Medical Sciences, Tehran, Iran

<sup>3</sup>- Biostatistics, School of Rehabilitation, Tehran University of Medical Sciences, Iran

Received: 7 May 2013, accepted: 17 September 2013

## **Abstract**

**Background and Aim:** Setting of candidates for a word with similar beginnings is known as the Cohort size. Despite the importance of the number and properties of candidates in word recognition, so far, in none of the tests made for Persian language, the Cohort size is considered. The purpose of current study was the introduction of importance of Cohort size in word recognition and calculation of Cohort size for the list of Persian high-frequency spondee words.

**Methods:** The spondee words extracted from high-frequency Persian word store. Then, total spondee words with same first syllable in Amid Persian dictionary recorded and Cohort size calculated for each spondee word. Thus, the list of high-frequency spondee words with their Cohort size composed of 4121 words obtained.

**Results:** The Cohort sizes of word had a wide range from 0 to 87. In the half of the words, the Cohort sizes were less than 14 and in the rest were more than it.

**Conclusion:** The Cohort size affects the time course and precision of decision making about words. Persian words are not equal in Cohort size. For having more controlled test materials to develop and design different types of auditory tests, it is possible to consider the Cohort size of words along other effective factors.

**Keywords:** Speech perception, word recognition, Cohort model of word recognition, Cohort size, Persian language

**Please cite this paper as:** Shayanmehr S, Fatahi J, Tahaie SA, Jalaie S. Calculation of Cohort size for the list of Persian high-frequency spondee words. *Audiol.* 2014;23(3):30-8. Persian.

---

**Corresponding author:** Department of Audiology, School of Rehabilitation, Tehran University of Medical Sciences, Pich-e-Shemiran, Enghelab Ave., Tehran, 1148965141, Iran. Tel: 009821-77530636, E-mail: jfatahi@tums.ac.ir