

۱۲ ماهه

جای‌های مختلف، چه در مقاله‌های انتقادی و چه در کتاب‌های ادبی و زبان شناختی، کم و بیش سخن گفته شده است؛ برخی با وسعت نظر، این کار را امری بسیار بایسته و مهم تلقی کرده‌اند، و بعضی دیگر هم از سر ناگاهی - یا شاید کم التفاتی - آن را کاری کاملاً عبث و ماشینی شمرده‌اند.


به طور مختصر و ساده باید گفت که ضرورت تهیه چنین فرهنگ‌هایی، مانند ضرورت آمارگیری‌های عمومی نظیر سرشماری نفوس و مسکن است؛ یعنی مثلاً اگر دولت از جمعیت کشورمان، نرخ باسادی، میزان تحصیلات باسادان، میانگین سنی افراد، میانگین شمار فرزندان هر خانوار، عده پناهندگان و اتباع خارجی، فراوانی مهاجرت‌های داخلی، و چندین فقره دیگر آگاهی دقیق و صحیح نداشته باشد، قطعاً قادر به برنامه‌ریزی درست و اصولی فرهنگی، اجتماعی، اقتصادی، و سیاسی نخواهد بود.

به همین قیاس، اگر ما از محدوده واژگان (vocabulary) زبان فارسی، پرسامدترین لغات آن (واژگان پایه)، دامنه طبقات دستوری کلمات، فراوانی لغات بسيط و مشتق و مرکب بومی و غربی‌بومی، چگونگی ترکیب‌سازی، و نظایر اینها اطلاع کافی نداشته باشیم، چگونه می‌توانیم آن‌گونه که شایسته است، فرهنگ لغت و کتاب درسی تألیف کنیم؟ تاکنون تقریباً همه مواد فرهنگ‌های تالیف شده برای زبان فارسی، براساس شم زبانی مؤلف یا مؤلفان، و یا به تقلید از

«بسامد» مرکب از دو کلمه «بس» و «آمد» و برابر نهاده لفظ فرانسوی frequency (انگلیسی) است، که خود فرانس (ke) تلفظ فرانسوی آن است) نیز در فارسی به کار رفته و می‌رود. رایج ترین متراوف این لغت، «فراآنی» است، که به ویژه در دانش آمار کاربرد دارد. «بسامدی» نیز منسوب یا مربوط به «بسامد» است. بنابراین، «فرهنگ بسامدی» یعنی فرهنگی که بر مبنای بسامد لغات تهیه شده است؛ به عبارت دیگر، یعنی فرهنگی که همه لغات یک پیکره زبانی (corpus) مشخص و تعریف شده را دربرداشته و بسامد تک لغات در آن ذکر شده باشد.

تاکنون چندین فرهنگ بسامدی فارسی - هم در ایران و هم در کشورهای دیگر - تدوین و منتشر شده است، که با رجوع به کتاب‌شناسی‌ها و فهرست‌های منتشر شده می‌توان به سادگی به نام و نشان آنها دست یافت. گرچه فعلاً شمار این گونه فرهنگ‌ها در برابر تعداد فرهنگ‌های عمومی (مانند فرهنگ‌های تک‌زبانه و دوزبانه و چند‌زبانه و نیز واژه‌نامه‌های تخصصی و نیمه تخصصی) اندک است، اما به ویژه در یکی دو دهه اخیر، چند فرهنگ واژه‌نما و بسامدی منتشر شده که هر چند در بعضی از آنها به اصول علمی تدوین چنین فرهنگ‌هایی عنایت کافی نشده، اما کوشش پدیدآورندگان آنها در خور تقدیر و اجرشان مشکور است.

دریاره تهیه انواع فرهنگ‌های بسامدی برای زبان فارسی نیز در



این مشکل برای شخصی چون فرهنگنویس، دوچندان است: زیرا او علاوه بر نام‌های اشیا، لغاتی را که بر مقامی انتزاعی دلالت می‌کنند نیز باید ثبت کند. او چگونه می‌تواند از «آرامش»، «انتظار»، «بخت»، «اپرسیش»، «تصمیم»، و هزاران لغت دیگر، که همه روزه در روزنامه‌ها و سایر رسانه‌ها به کار برده می‌شوند و اهل زبان نیز در طول زندگی خود، بارها و بارها آنها را می‌شنوند و می‌گویند، چشم پوشد؟ حتی اگر به جای پنج هزار لغت، پنجاه هزار یا صد هزار لغت را فهرست کند، باز هم نمی‌تواند با اطمینان ادعا کند که کار او دقیق و کم‌نقص است.

در فرهنگ فارسی، تأثیف شادروان استاد دکتر محمد معین، بسیاری از عنوان‌های اصلی، صرفاً از متون قدیم استخراج شده‌اند و امروزه دیگر کاربردی ندارند، ولی همین انتخاب به شکلی بسیار ناقص و حتی غیرعلمی صورت گرفته است؛ چه لغات و ترکیب‌های فراوانی در آثار معروف گذشتگان (مانند کلبله و دمنه، گلستان، تاریخ جهانگشای، دیوان صائب، و بسیاری از کتاب‌های دیگر) می‌توان یافت که در فرهنگ یاد شده ثبت نشده‌اند. حتی در اثر عظیم امام‌ناتمام لغت‌نامه فارسی، که در «سازمان لغت نامه دهخدا» تدوین می‌شود نیز چنین کاستی‌هایی را - به خصوص در بخش ترکیب‌های آن - می‌توان مشاهده کرد.

فرهنگ‌های پیشین گردآوری و ثبت شده‌اند. حتی در محدودی فرهنگ‌ها، که با تکیه بر شواهد استخراج شده از متون (معاصر یا قدیم و یا هر دو) تأثیف شده‌اند، رگه‌های تقلید و پیروی از قاموس‌های کهن را به وضوح می‌توان دید.

حال به طرح یک پرسش می‌پردازیم: اگر از دوستی خواهش کنیم که فهرستی از نام‌های پنج هزار شئ را که بارها آنها را دیده است و می‌بیند، برای ما تهیه کند، چگونه واز کجا باید آغاز کند؟ طبیعی است که انتظار می‌رود در چنین فهرستی، لغات «آب» و «آینه» و «ابر» و «اشک» و «باران» و «برف» ثبت شده باشد، ولی دشواری کار گزینش، آن جا ظاهر می‌گردد که او به انتهای فهرست نزدیک شده باشد و مثلاً تنها پانصد لغت دیگر به اتمام آن مانده باشد. کافی است دقایقی به اطراف خود بنگردد، یا لحظه‌ای چند تأمل کند؛ از لوازم منزل، کدام‌هارا بزرگ‌بیند و از کدام‌ها صرف نظر نماید؟ از آلات و ادوات موسیقی، کدام‌ها را انتخاب کند؟ نام چند گیاه و پرنده و حشره را بنگارد؟ آیا اگر فهرست پنج هزار لغتی به پایان برسد و لغاتی مثل «آسیاب»، «اکسیژن»، «بازو»، «بنبه»، «تسیبیح»، «اثروت»، «سبب»، «چتر»، «حلقه»، «خرطوم»، «دست‌مال» و چند لغت دیگر نانوشته مانده باشد، کدام لغت یا لغات ثبت شده را می‌تواند حذف کند تا لغات یاد شده را تک‌تک به جای آنها بگذارد؟ اصلاً معیار و ضابطه حذف و افزودن لغات چیست؟

نحوه دار محدوده تاریخی متن های هزارگانه



صورت گزارشی مختصر ارائه کند. تهیه این فهرست در دی ماه ۱۳۷۹ به اتمام رسید.

فهرست تهیه شده، براساس نمونه‌گیری از هزار متن فارسی معاصر (کتاب، مجله، و روزنامه، شامل حدود ۹۰۲۰۰ نفث، به علاوه تکمله‌ای ۱۰۰۰۰ لغتی) با موضوعات گوناگون تهیه شده است. مراحل و روش کار به این ترتیب بوده است:

نگارنده از سال‌ها پیش، این آرزو را در سر داشت که بتواند با استقصا و بسامدگیری دقیق از متون مختلف فارسی در موضوعات گوناگون، فهرستی از لغات پایه این زبان فراهم آورد. سرانجام در اسفندماه ۱۳۷۸، به طور جدی تصمیم گرفت که به عنوان مقدمه‌ای بر طرح اصلی، یک پیکره صدهزار لغتی تهیه کند و نتیجه آن را به

شدن (۱۵۳۶)	(%) ۱۵۴
این/اینها (اسم اشاره و ضمیر اشاره)	(۱۵۰۹) (%) ۵۱
در میان نام‌های خاص، این ده نام در صدر هستند:	
ایران/ایران زمین (۱۳۱ بار)	(۵۶)
آمریکا/امریکا/ایالات متحده آمریکا	(۴۸)
روسیه/روسیه شوروی/شوروی/اتحاد شوروی/اتحاد جماهیر شوروی	(۴۰)
انگلستان/انگلیس/بریتانیا	(۳۹)
تهران/طهران (۳۹)	
چین (۲۲)	
محمد/پیغمبر/پیامبر اسلام/پیغمبر/رسول/رسول اکرم/رسول خدا	(۳۰)
ژاپن (۲۵)	
استرالیا (۲۳)	
اروپا (۲۲)	

آمارهایی دیگر:

پرکاربردترین لغات عربی:	
اما (۲۲۴ بار)	
قرار (۱۶۵)	
ولی (۱۵۸)	
وجود (۱۳۱)	
نظر (۱۱۲)	
کتاب (۱۱)	
انسان (۹۸)	
استفاده (۹۶)	
حروف (۸۶)	
صد (۸۳)	

پرکاربردترین لغات معرفی:	
موسیقی (۵۵ بار)	
فلسفه (۳۳)	
قالب (۲۷)	
کلیسا (۲۰)	
آدم (۱۹)	
الف (۱۸)	
قدن (۱۰)	
اقیانوس (۷)	
قهرمان (۷)	

پرکاربردترین لغات اروپایی:	
فیلم (۷۲ بار)	
سینما (۶۵)	
دکتر (۳۹)	
پلیس (۳۰)	
دلار (۲۹)	
سیستم (۲۸)	
اتومبیل (۲۵)	
متر (۲۵)	
تیم (و تیم ملی) (۲۴)	

۱. انتخاب ده سطر اول نخستین بند صفحه صد از کتاب‌ها، و ده سطر اول نخستین بند صفحه ده از نشریات، و سپرده آنها به حافظه کامپیوتر (محدوده تاریخی متن‌ها از ۱۳۰۱ تا ۱۳۷۹ ه. ش است).

۲. استخراج لغات

۳. جدا کردن اعلام (اسم‌های خاص)

۴. جدا کردن لغاتی که در عبارت‌های عربی (مانند آیات و احادیث) به کار رفته‌اند.

۵. جدا کردن لغات و عبارتی که در متن‌ها با حروف لاتین یا یونانی ثبت شده‌اند.

۶. لماتیزه کردن (لما بتندی) (lemmatize/lemmatiser) مواد، یعنی مرتب کردن آنها به صورتی که هر یک به عنوان یک «واحد واژگانی» (lexical unit) قابل ثبت در فرهنگ باشد (به استثنای انواع فعل‌های مرکب).

چنان که گفتیم، ده هزار سطر انتخاب شده جمیعاً حدود ۹۰۲۰۰ لما (عنوان مستقل) را تشکیل می‌دهند. اما برای رساندن شمار لاما به ۱۰۰۰۰، از قسمتی از متن یکی از روزنامه‌های پرتریاز کشور (۱۷ شماره از روزنامه همشهری، ستون «گشته در دنیا خبرها» شامل نزدیک به ۱۰۰۰۰ لما) نیز استفاده شد، و به این ترتیب تعداد لاما از رقم صدهزار گذشت.

قابل ذکر است که بسیاری از مشکلات فنی کار، به لطف ویاری آقایان دکتر حسن انوری، دکتر محمد شادرلوی منش، و بهروز صفرزاده برطرف شد؛ آقای صفرزاده در بازنخوانی نمونه‌ها نیز به من کمک کردند. مادرم نیز در مقابله بخشی از متن‌ها مرا باری کردند. از همگی سپاسگزارم.

دوستان و همکاران عزیزی نیز با در اختیار گذاشتن منابع، با بنده همکاری کرده‌اند، که هر گاه متن کامل فهرست به چاپ برسد، نامشان به رسم امتحان ذکر خواهد شد.

چنان که در نمودار ملاحظه می‌شود، از میان ۱۰۰۰ متن مورد استفاده‌ما، تنها ۲ متن از دهه نخست سده چهاردهم ه. ش برگزیده شده است، یعنی ۰٪۰۲ از کل ۱۰۰۰ متن. از دهه دوم نیز فقط ۸ متن انتخاب شده است (۰٪۰۸ از ۱۰۰۰ متن)، از دهه بیست (دهه سوم) ۳۰ متن (۰٪۲۰)، از دهه سی ۴۰ متن (۰٪۴۰)، از دهه چهل ۵۳ متن (۰٪۵۳)، از دهه پنجاه ۱۴۶ متن (۰٪۱۴۶)، از دهه شصت ۳۴۸ متن (۰٪۳۴۸)، و سرانجام از دهه هفتاد (کمتر از نه سال) ۳۷۳ متن (۰٪۳۷۳) اختیار شده است.

پس بیش از ۷۲٪ از متون مورد استفاده متعلق به سال‌های ۱۳۶۱ و بعد از آن است، در حالی که تنها ۸٪ از منابع ما را متون چهار دهه نخستین سده (۱۳۰۱ - ۱۳۴۰) تشکیل می‌دهند.

ده لغتی که از لحاظ بسامد در صدر فهرست قرار دارند، عبارت‌اند از:

و (۵۲۱۰ بار) (۱۱) از ۱۰۰۰۰	(%) ۵٪۲۱
بودن (۲۸۵۱) (۲۸۵)	(%) ۲٪۸۵
در (حرف اضافه) (۲۴۸۳) (۲۴۸۳)	(%) ۲٪۴۸۳
که (حرف ربط و موصول) (۲۴۸۲) (۲۴۸۲)	(%) ۲٪۴۸۲
به (۲۶۶۲) (۲۶۶۲)	(%) ۲٪۶۶۲
از (۲۱۳۷) (۲۱۳۷)	(%) ۲٪۱۳۷
را (۲۱۲۷) (۲۱۲۷)	(%) ۲٪۱۲۷
کردن (۱۸۴۰) (۱۸۴۰)	(%) ۱٪۸۴

مدل (۲۳)

پرکاربردترین لغات فارسی:
اتاق/اطاق (۴۰ بار)
کمک (۳۸)

جلو (اسم، صفت، و قید) (۲۶)
توب (۱۸)
تومان (۱۲)
قابل (۱۲)
اردو (۸)
پرچم (۸)

پرکاربردترین لغات مطلول:
آقا (۸۲ بار)
خانم (۳۹)
خان (۲۴)
میز (۱۰)

پرکاربردترین لغات ادبی:
سیگار (۱۱ بار)
ریال (۷)

پرکاربردترین لغات آرامی - سیریانی:
کشیش (۱۰ بار)

عبارت انداز:
پول (۳۴ بار)، دلار (۲۹ بار)، چاپ (۲۴ بار) و چای/چایی (۱۸ بار)

اینک آمارهای دیگر، که به لحاظ دستوری قابل اهمیت اند:

پرکاربردترین اسم‌ها (شامل اسم، اسم مصدر، و حاصل مصدر):
سال (۳۵۵ بار)
کار (۲۶۸)
دست (۲۰۳)
کشور (۱۸۹)
قرار (۱۶۵)
زبان (۱۳۱)
وجود (۱۳۱)
شهر (۱۲۶)
زنده (۱۱۷)
مرد (۱۱۷)

جدید (۷۴)
کوچک (۶۸)
همین (۶۶)
ممکن (۶۲)

قیدها:
وقتی (۸۰)
منوز (۵۹)
چرا (۵۴)
 فقط (۵۴)
آیا (۵۱)
البته (۴۷)
کاملاً (۴۰)
سپس (۳۳)
چه گونه (۳۲)
هنگامی که (۳۱)

قسمات:
او (۵۳۹)
ما (۲۱۹)
تو (۱۳۵)
شما (۱۱۷)
کس (۹۵)
وی (۵۵)
یک دیگر (۳۶)
ایشان (۳۰)
هر چه (۲۱)
هر یک (۱۹)

حروف آفتاب:
در (۲۴۹۸)
به (۲۲۶۲)
از (۲۱۳۷)
با (۱۰۰۴)
برای (۶۱۹)
بر (۲۵۳)
پس از (۱۴۴)
روی (۱۲۸)
درباره (۹۴)
مانند (۶۶)

حروف از بطه:
یا (۳۷۶)
هم (۳۶۹)
اما (۲۴۴)
اگر (۱۹۴)
نیز (۱۸۴)
ولی (۱۵۸)
يعنی (۶۸)
حتی (۶۴)

حروف ها:
چند (۱۶۰)
هر (۱۴۱)
بزرگ (۱۳۷)
چنین (۸۳)
تمام (۸۲)
همان (۸۰)

بلکه (۵۸)
زیرا (۵۷)

حروف مقطعه
و (۵۲۱)

حروف ندا
ای (۲۴)

حروف شاهد
را (۲۱۷)
و [= را] (۱۵)
رو [= را] (۷)

۳

مصدرهای بسطه، تمکن کردها، و فعلهای ویژه.
بودن (۲۸۵۱)
کردن (۱۸۴۰)
شدن (۱۵۳۶)
داشتن (۸۵۸)
دادن (۵۳۴)
گفتن (۴۹۲)
توانستن (۳۴۷)
خواستن (۳۱۸)
گرفتن (۳۱۰)
رفتن (۷۷۹)

مصدرهای پیشوندی:
برداشتن (۴۶)
درآوردن (۳۵)
برگشتن (۳۱)
درآمدن (۳۰)
بازگشتن (۲۱)
برخاستن (۱۴)
دریافت (۱۱)
فروختن (۱۱)
برگرداندن/برگردانیدن (۸)
فراگرفتن (۸)

صفت‌های شمارشی:
یک (۸۸۵ بار)
دو (۲۸۰)
سه (۸۷)
چهار (۶۲)
ده (۵۳)
پنج (۵۲)
شش (۴۰)
هفت (۳۵)
بیست (۳۰)
صد (۲۸)

صفت‌های ترتیبی:
اول (۵۸)
دوم (۴۲)
نخستین (۴۰)
اولین (۳۷)
سوم (۲۶)
چهارم (۱۸)
دومین (۱۴)
پنجم (۱۳)
هشتم (۸)
ششم (۸)

اینکتاب هرستی مقایسه‌ای میان لغات مربوط به مردان و زنان:
مرد (۱۱۷) بار، زن (۱۱۴)
پدر (۹۶)، مادر (۶۲)
بابا (۱۴)، ماما/مامان (۴)
آقا (۸۲)، خانم (۳۹)
پسر (۴۴)، دختر (۵۱)
پسریجه (۵)، دختر بچه (۰)
پسرک (۳)، دخترک (۵)
برادر (۳۷)، خواهر (۱۳)
عمو (۴)، عمه (۵)
دایی (۴)، خاله (۳)
پدر بزرگ/باپا بزرگ (۶)، مادر بزرگ (۴)
پدر شوهر (۰)، پدر زن (۱)
مادر شوهر (۲)، مادر زن (۱)
داماد (۰)، عروس (۲)

و آنها از لیان زنگ‌ها، اینها پرگار برداشت از همه‌اند:

سیاه/سیه (۲۸ بار)
سبز (۱۶)
سفید/سپید (۱۶)
قرمز/سرخ (۱۴)

پانوشتها:

۱- خوب است اشاره شود که آخرین ویرایش یکی از فرهنگ‌های یک جلدی بسیار معروف و معتبر داشتگاه آکسفورد، بر مبنای پیکره‌ای زبانی با رقم شگفت‌انگیز یک صد و چهل میلیون لغت (یک صد میلیون لغت از متون بریتانیایی و چهل میلیون لغت از متون آمریکایی) تألیف شده است:

Oxford Advanced Learner's Dictionary of Current English, Great Britain, Oxford University Press, 5th Edition, 1995 (11th impression, with corrections, 1999)

- ۲- ده لغت اول، جمیعاً ۲۴۴۳۷ بار به کار رفته‌اند، که بر روی هم خود، ۸٪ از کل متن‌های را تشکیل می‌دهند.
۳- شامل لغاتی که طبقه دستوری آنها لغزان است، نمی‌شود (یعنی لغاتی که ممکن است هم اسم باشد و هم صفت یا قید، و یا دارای سایر هویت‌های دستوری).
۴- شامل «ازوجه» نیز هست.