

است از ساختن مجموعه‌ای از گفتارهای بالقوه نامحدود با استفاده از فهرست محدودی از واحدهای نایپوسته، درست همان طور که از ترکیب ده عدد نظام اعدادمان با یکدیگر می‌توان مجموعه‌ای نامحدود از ارزش‌ها و عبارات ریاضی متفاوت ساخت.

این سازمان‌دهی همانند نظام زبان و اعداد

به راحتی امکان این را فراهم می‌سازد که واحدهای زبانی را به صورت اعداد نمایش دهیم و به گونه‌ای آنها را به کار ببریم که گویی واحدهای ریاضی هستند. جانو نیست. که کامپیوتر واژه‌ای را که از نظر املایی غلط است برایمان پیدا کند: اگر کامپیوتر واژه‌نامه‌ای در اختیار داشته باشد که در آن برای هر واژه یک گُددی تعیین شده باشد، می‌تواند کد عددی واژه‌ای را که می‌نویسیم با ارزش عددی واژه در فهرست واژه‌های نمایش از طریق یک عملیات حسابی ساده مقابله و مقایسه کند. چنان‌چه مابازایی برای آن یافته نشود، واژه مورد نظر در واژه‌نامه کامپیوتر وجود ندارد و بدین ترتیب می‌فهمیم که املای واژه غلط است.

#### کارآیی و حشو

زبان‌ها – از آنجا که در طی قرون و اعصار به طور خودجوش در جوامع رشد و تکامل یافته‌اند – دارای ترکیبی‌های ریاضی‌ای به مراتب پیچیده‌تر از واژگی‌های ریاضی‌تاشی از ساختار سلسه مراتبی واحدهای نایپوسته هستند. زبان‌ها در آن واحد هم کارآیی دارند و هم حشو. این دو خصیصه متناقض به

تصحیح در متن بازحمت بسیار تمام صفحات آن را از نو

حروف‌چینی کنیم. امروزه می‌توانیم مترافات و تعاریف را در واژه‌نامه‌های الکترونیکی جست‌وجو کنیم، یا حتی از کامپیوتر بخواهیم که غلط‌های املایی ما را بساید و

تصحیح کند، و یا دستور زبان و سبک نگارشمان را محک بزنی.

کامپیوترها – که هنوز هم برخی از ما آنها را صرفماشین حساب‌هایی با سرعت برق آسا می‌دانیم –

می‌توانند زبان را رمزگذاری، پردازش، و در سطحی

محدد درک کنند. این امر مدیون ویژگی‌های

چشم‌گیری است که دستگاه‌های زبان طبیعی برای

تحول و تکامل در طول تاریخ طولانی خود یافته‌اند.

زبان ماهیتاً ساختاری سازمان‌یافته از نشانه‌های دارای

سلسله مراتب است، که ما را قادر می‌سازد تا تعداد

بالقوه نامحدودی مفهوم را با استفاده از ابزاری محدود

بیان کنیم. اجزای اصلی این ساختار بسیار محدودند:

مجموعه‌ای از آواهای متقابل – واچ‌های زبان – که

می‌توانیم آنها را به شکل حروف و ترکیبات حروف در

نظام‌های نوشتاری الفبایی خود نشان دهیم. این اجزای

سازنده اولیه به شیوه‌هایی بسیار محدود با یکدیگر

ترکیب می‌شوند و واحدهای معنادار اصلی – واژه‌های

زبان – را می‌سازند. واژه‌ها نیز به توبه خود بر طبق

اصول روش‌مند ترکیب‌سازی زنجیره‌های معناداری را

می‌سازند که بر پایه قواعد نحو قرار دارند و ما آنها را

«جملات» می‌نامیم. بدین ترتیب کل این نظام عبارت

زبان چنان با انسان عجین شده و وسیله‌ای بالقوه بی‌همتا برای بیان تغیلات شاعرانه گشته که بسیاری از ما به دشواری می‌توانیم آن را دارای جنبه‌های غیرتخیلی، کلیشه‌ای و قابل پیش‌بینی، یا حتی ریاضی بدانیم. با این حال، در طی چند دهه گذشته شاهد برداشیم که حجم وسیعی از گفتارها و نوشتارها یمان به بسیله کامپیوترها خبیث، پردازش، و منتقل شده است. کامپیوترها قادرند واژه‌های مکتوب ما را به نشانه‌های الکترونیکی تبدیل کنند، و بدین ترتیب این امکان را برای ما فراهم سازند که در میان واژه‌ها به جست‌جو پردازیم، و آنها را سازمان‌دهی کنیم، و آن‌گاه، در صورت نیاز، آنها را در قالب نشانه‌های الکترونیکی بی‌درنگ به فواصل دور بفرستیم. این کار کامپیوتر – که با کم ذوقی از «ازده پردازی» و «بازتابی اطلاعات» نامیده‌ایم – نه تنها صنعتی چند میلیارد دلاری، بلکه ابزار اطلاع‌رسانی نوینی است که همانند اختراق چناب در پردازش از پانصد سال قبل، اطلاع‌رسانی را از پایه دگرگون سازد.

منو هم مردم بخشی از وقت خود را به تدوین نمی‌سپارم. نوشتن رمان، و سرودن شعر اختصاص می‌دهند. اما دیگر مجبور نیستیم که برای اعمال چند

پژوهشگاه علوم انسانی و مطالعات فرهنگی  
پرستال جامع علوم انسانی

هزاری کوچرا  
متوجه بهروز صفرزاده

ریاضیات زبان

گونه‌ای با یکدیگر توازن یافته‌اند که ارتباطات را سودمند و قابل اعتماد می‌سازند.

نخست حشو را در نظر بگیریم: از میان حدود ۳۳ واژ رسان انگلیسی، تنها زیرمجموعه کوچکی از جای‌گشتهای بالقوه آنها در ساخت واژه‌های بالفعل زبان به کار می‌رود. مثلاً انگلیسی زبانان بزرگ‌سال می‌دانند که *trip*، واژه‌ای انگلیسی است. اما آنها این را هم می‌دانند که *trip* واژه‌ای انگلیسی نیست، و لزومی هم ندارد که برای اطیبان از این مسئله به واژه‌های رجوع کنند. شمّ زبانی به آنها می‌گوید که هیچ واژه انگلیسی‌ای نمی‌تواند با *ا* آغاز شود. اما همین انگلیسی زبانان اگر *trip* را بروشوند—گرچه این واژه را نمی‌شناسند—ممکن است ناچار شوند از واژه‌نامه یاری بجوینند. لفظ *trip* دست‌کم از لحاظ نظری بالقوه می‌تواند واژه‌ای انگلیسی باشد، چرا که هیچ یک از محدوددهای عامی را که در زنجیره‌های اوایی مجاز زبان انگلیسی هست، نقض نمی‌کند.

می‌بینیم که حتی در همین سطح ابتدایی واچ‌شناسی نیز حشو قابل توجهی وجود دارد: تحمیل محدودیت‌هایی به زنجیره‌های بالقوه، و در نتیجه ورود اطلاعات زائد به نظام زبان.

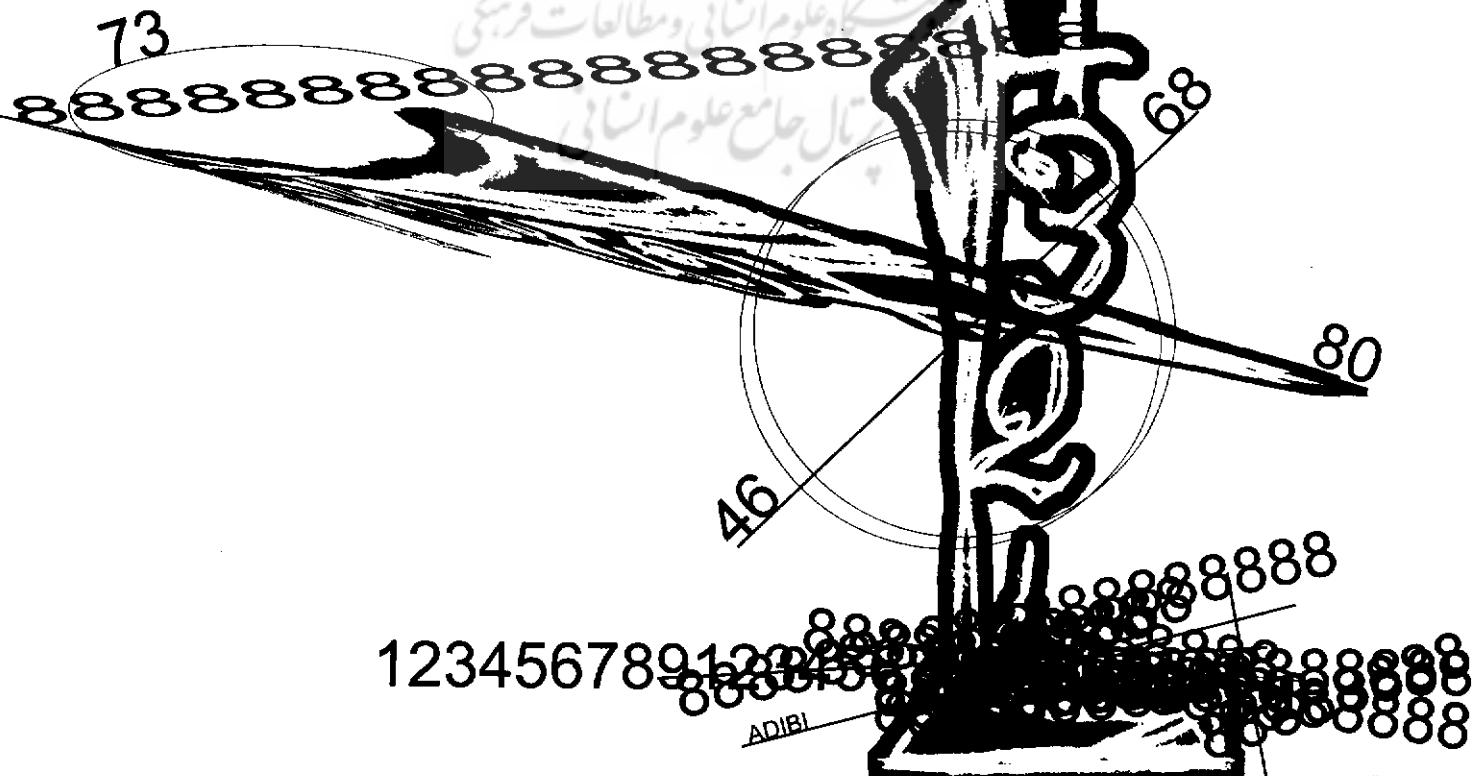
وجود این اطلاعات زائد لازم است، تا ما را قادر سازد که بدون انبوهی از اشتباهات و سوءتفاهمات، با دیگران ارتباط برقرار کنیم. اگر هر جای‌گشته بالقوه آواها در انگلیسی واژه‌ای بالفعل می‌بود، نظام ارتباطی

سطوح بالاتر نیز این حکم صادق است. زبان ترکیبی انگلیسی برای نشان دادن بسیاری از کارکردهای دستوری خود متکی به ترتیب واژه‌های است. در این زبان اما در زبان‌های «آزاد» است، ظاهرًا جای گشتهای واژه‌ها نامحدود است. آن‌چه نامحدود بودن جای گشتهای واژه‌ها نامحدود است. آن‌چه نامحدود بودن جای گشتهای واژه‌ها و زنجیره‌های آوازی ای، و همچنین تولید و درک آواها و زنجیره‌های آوازی، و همچنین ویژگی‌های حافظه انسان، آموزش و به کارگیری چنین نظامی را عملأ غیرممکن می‌سازد. حتی اگر به فرض بتوانیم چنین زبان کارآمدی را بیاموزیم، هر صدایی، هر عیب و نقص یا اشتباهی که به دریافت ولو تنها یک صدای طمهم بزند، درک ما را مخدوش خواهد ساخت. علت این امر آن است که فقدان حشو در نظام به ما اجازه نخواهد داد که حدس بزنیم چه چیزی را احتتمال‌آز دست داده‌ایم. از این هم بدتر آن که اگر صدایی را به جای صدای دیگری بشنویم، واژه‌ای معقول—اگرچه برخلاف مراد گوینده— را شنیده‌ایم. بنابراین حشو، که ویژگی تمام زبان‌های جهان است، یکی از ارزش‌مندترین دوستان ارتباطی ماست.

بدیهی است که محدودیت‌های زنجیره‌های اوایی مجاز که برای دست‌بایی به این حشو به کار می‌روند، ممکن است در زبان‌های گوناگون تفاوت‌های چشم‌گیری داشته باشند. مثلاً زبان‌های بسیاری هست که در آنها واژه‌ای می‌تواند با خوشه اوایی—*ا* آغاز شود، همان خوشه اوایی ای که در انگلیسی جایی ندارد. در

شاخه‌ای از ریاضیات به نام «نظریه اطلاعات» ابزاری صوری برای سنجش حشو در یک نظام ارتباطی به دست می‌دهد. این سنجش‌ها برای زبان‌های طبیعی پیچیده و دشوارند؛ با این حال، برآوردهایی اجمالی را با آنها می‌توان انجام داد. در سطح واچ‌شناسی برای چند زبان (انگلیسی، آلمانی، روسی و چکی) محاسبه کرده‌ایم که میزان حشو به حدود ۵۰٪ می‌رسد، البته در این محاسبه تنها محدودیت‌های زنجیره‌های اوایی درون هجاها را در نظر گرفته‌ایم. بدیهی است که ترتیب فرار گرفتن هجاها نیز در تمام زبان‌ها محدودیت‌هایی دارد. بدین ترتیب در مجموع میزان حشو را باید دست‌کم حدود ۸۰٪ برآورد کرد.

روی دیگر سکه در زبان «کارآیی» است. از دیرباز



دانسته شده است که واژه‌های بسیار پریسامد معمولاً کوتاه هستند. وقتی واژه‌ها را بیشتر می‌شنوند، ما آنها را کوتاه یا مخفف می‌کنیم: telephone را به صورت airplane, phone و مانند آنها.

تجزیه و تحلیل کامپیوتری نمونه‌های فراوانی از متون زبان، اطلاعات دقیق در تأیید این نتیجه گیری کلی به دست می‌دهد. پیکرهای یک میلیون واژه‌ای از انگلیسی آمریکایی امروز تهیه شده که به نام «پیکره برآون» نیز معروف است. این پیکره با استفاده از نمونه‌هایی برگرفته از ۵۰۰ منبع گوناگون از پاتزده گونه و سبک نوشتاری مختلف تالیف شده است. در این پیکره واژه‌هایی که ۵۷٪ متن‌های مورد مطالعه (به عبارت دیگر، ۵۷٪ از یک میلیون نشانه) را تشکیل می‌دهند، دارای چهار حرف یا کمترند. چند نمونه از این واژه‌ها

عبارت‌اند از: have, that, of, but, and, the؛ اما چنان‌چه واژه‌نامه‌ای از این پیکره تهیه کنیم، مسئله شکلی کاملاً متفاوت خواهد داشت. یعنی مجموعه‌ای از واژه‌های گوناگون — که در زبان‌شناسی صوری «گونه‌ها» نامیده می‌شوند — فراهمن کنیم، به طوری که هر واژه فقط یک بار در فهرست بیاید، بدون در نظر گرفتن دفاتری که آن واژه ممکن است در متن تکرار شده باشد. در این صورت، واژه‌ای دارای چهار حرف یا کمتر نزدیک به ۹٪ واژه‌نامه را تشکیل می‌دهند.

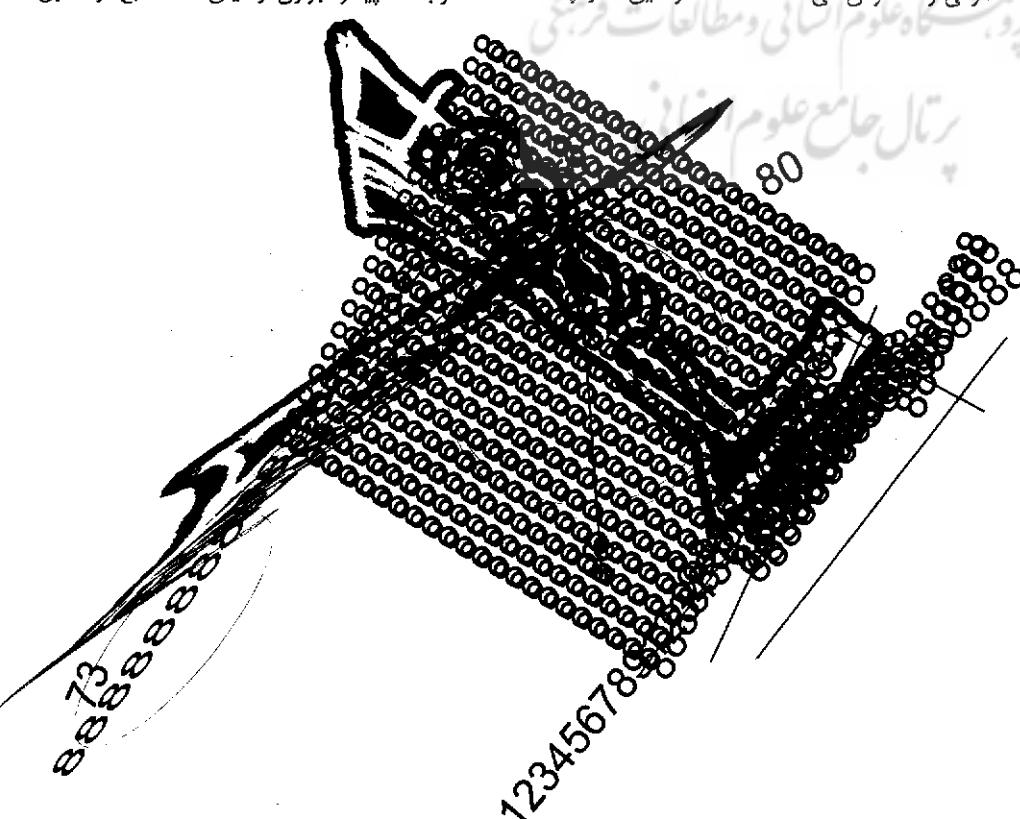
اختلاف میان دو رقم مذکور نشان‌دهنده کارآیی ارتباطی زبان است: نظام زبان به گونه‌ای طراحی شده که واژه‌های کوتاه بارها در یک متن معمولی تکرار می‌شوند و بدین ترتیب بسادم بالایی را به خود اختصاص می‌دهند. واژه‌های بلندتر کم به کار می‌روند، باز کاربرد یک واژه‌ای واقعاً بلند نیز ناچیز است. درازای هر صرفی و شمارشی متفاوت هستند، اختلاف میان تعداد صورت‌های واژه و تعداد لاماها حقیقتاً چشم‌گیر است.

با این حال، در بررسی واژگان و بسادم واژگان یک نویسنده یا مجموعه‌ای از متون، معمولاً صورت‌های صرفی را شمارش می‌کنند، نه لاماها را. این کار چند محدود است که پیکره نوشتۀ‌های شکسپیر از نظر محتوا و سیک کاملاً متعجّلس است. حال آن که پیکره برآون تعمداً نامتعجّلس تهیه شده، تا نمایانگر زبان معاصر باشد. پیکره برآون از میان ۵۰۰ منبع گوناگون

تعداد واژه‌ها

هر زبان‌شناسی که به جنبه‌های کمی زبان علاقه‌مند باشد، گاه به نوعی این پرسش‌های نهایتاً عددی به ذهن‌ش خطور می‌کند که: «شکسپیر چند واژه به کار برده است؟»، «هر شخص چند واژه بلد است؟»، «واژه‌نامه چند واژه باشد؟».

دستکم پرسش نخست پاسخی مشخص — هر چند نه ساده — دارد: کلیات شکسپیر جمیعاً ۸۸۴۶۴۷ واژه متن دارد، که از ۲۹۰۶۴ واژه متمایز — ازجمله نام‌های خاص، — تشکیل یافته است. برای درک معنای این



برنامه ریزی کردن کامپیوتر به طوری که اشتباهات دستوری را در ساختار جمله تشخیص دهد و تصحیح کند، کاری است بس دشوار؛ اما اگر به کمتر از کمال مطلوب راضی باشیم، یقیناً کاری است شدنی. اساس این کار آن است که به کامپیوتر تجزیه جمله را بیاموزیم؛ یعنی این که چگونه جمله را به مقوله‌های دستوری اش تجزیه کند و روابط نحوی آنها را آشکار سازد، اجزای مهم جمله (از قبیل گروه‌های منفرد، فاعل‌ها، و مفعول‌ها) را بیابد، تعیین کند که آیا فاعل و فعل با هم مطابقت می‌کنند یا نه، و مانند آنها.

آنچه باید به خاطر داشت، این است که تجزیه و تحلیل دستوری تنها از آن رو میسر است که ما می توانیم قواعد ساخت های زبانی را تبدیل کنیم. کامپیوترها فقط در صورتی می توانند کارهای شگفت انگیز انجام دهند که ما به شیوه های صوری دقیق و بسیار روشن طرز کار را به آنها بیاموزیم. توصیف قواعد انتزاعی دستور زبان - ویژگی های ریاضی زبان در عالم تربیت معنای اصطلاح - این کار را ممکن می سازد. بدین ترتیب می توانیم کاملاً مطمئن باشیم که چه کسی رابطه متقابل انسان - کامپیوتر را کنترل می کند: عملکرد نهایی کامپیوترها هر قدر هم که عظیم و تحسین برانگیز باشد، هنوز هم بر عهده انسان است که قواعد زبانی را کشف کند و به کامپیوتر طرز استفاده از آنها را بیاموزد.

من

Kucera, Henry. "The Mathematics of Language". in *The American Heritage Dictionary of the English Language*, Third Edition, Boston, USA: Houghton Mifflin Company, 1992, pp. xxxi - xxxiii.

اصطلاحات

**انگلیسی جدید (Modern English)** زبان انگلیسی از حدود سال ۱۵۰۰ میلادی به بعد.

**پیکره (corpus)** مجموعه بزرگی از نوشته‌های دارای سبک، موضوع، یا مؤلف مشخص.

**جایگشت** (permutation) هر یک از آرایه‌های عضای یک مجموعه، مثلاً سه حرف «د»، «و» و «س» حداکثر دارای شش جایگشت هستند: دوس، دس، دس، دس، دس، در.

**لما** (lemma) مجموعه‌ای از صورت‌های دستوری دارای مستهنه مشترک. مثلاً صورت‌های «رفتم»، «رفته بودم»، «می‌روم»، «برو»، «برو و (رفتن) همگی یک لما را تشکیل می‌دهند؛ و یا صورت‌های «دست»، «دستی» (یک دست)، «دست‌ها»، و «دستن».

**لِمَابِنْدِی (lemmatization)** دسته‌بندی واژه‌ها بر اساس ماهیت آنها.

**معناوازه (content word)** واژه معنادار که در تقابل با  
قشر، واژه قرار می‌گیرد.

**نقش واژه (function word)** واژه فاقد معنا یا دارای بار عتایی ضعیف که برای نشان دادن روابط دستوری واژه‌های دیگر

کار می‌رود. برخی از نقش‌واژه‌ها عبارت‌اند از: حروف اضافه،  
حروف ربط، حروف تعریف.

**واژگان (vocabulary)** ۱. مجموعه واژه‌های یک زبان. ۲. مجموعه واژه‌هایی که فرد می‌داند یا به کار می‌نمذد.

- اعتبار، هرچه واژه‌ای کم‌بسامدتر باشد، اهمیتش دستکم از لحاظ آماری - برای درک خبر بیشتر خواهد بود.

اگر درک ۸۰٪ هر متن برایمان کافی باشد تا باسوس  
و قلمداد شویم، می توانیم با واژگانی کمتر از ۳۰۰۰ گذران  
کنیم، و از واژه‌نامه‌ها بی نیاز گردیم. اما از آن جا که چنین  
نیست، واژه‌نامه‌ها که املا، تلفظ، و تعاریف واژه‌ها (اعم  
از پرسامد و نادر) را در اختیارمان می‌گذارند، یاران  
جدایی ناپذیر ما هستند.

کامپیوٹر و دسٹورنیشن

در چند سال گذشته کامپیوترهای ساخته ایم که از توانایی های زیانی چشم گیرتری برخوردارند: اکنون برنامه هایی در اختیار داریم که دست کم برخی از اشتباها دستوری را می توانند بیابند و تصویح کنند. در نگاه نخست، این نوع توانان را ممکن است

شگفت‌انگیز بنماید. تسلط یافتن بر ظرائف املای انگلیسی شاید کار دشواری باشد، اما درک طرز کار غلط‌یاب کامپیوتري از آن دشوارتر نیست. واژه‌نامه املای با فهرست مشخصی از واژه‌ها سروکار دارد؛ اما چنین نیست که دستور زبان هم با فهرست‌های مشخصی از جملات سروکار داشته باشد. سروکار دستور زبان با انواع بالقوه بی‌شماری از عبارات انسان است. جملاتی که به آنها برمی‌خوریم، اغلب برایمان کاملاً تازگی دارند؛ با این حال، می‌توانیم آنها را بفهمیم، هرچند که پیش از این هرگز آنها را ندیده یا نشنیده‌ایم. بی‌گمان هیچ‌کس زبان بومی اش را از راه حفظ کردن جملات نمی‌آموزد، بلکه هر کسی دانشی انتزاعی از ساخت‌های پذیرفته‌شده زبان خود دارد که از آن برای ساختن و درک زنجیره‌های جدید واژه‌ها استفاده می‌کند. از طریق ملکه ذهن کردن این دانش است که فرد زبان بومی اش را فرامگیرد.

همه انگلیسی زبانان، حتی آنها بی که هرگز دستور زبان نخواهد داشت، دارای شمر زبانی اساسی و قابل اعتمادی هستند که به آنها می گوید کدام جمله می تواند انگلیسی باشد و کدام نمی تواند، درست همان طوری که می دانند کدام واژه می تواند انگلیسی باشد و کدام نمی تواند. اما این شم دستوری به مراتب نتراضی تر و پیچیده تر از شم واج شناختی گوینده است. یعنی مثال ساده را در نظر بگیرید: هر انگلیسی زبانی می داند که جمله She told him to behave himself راست است، اما جمله She told him to behave him و She told himself to behave himself کاملاً مردودند.

اگر به جزئیات فرآیند ذهنی ای که ما را قادر می‌سازد تا این قضاوت‌های به ظاهر ساده را انجام دهیم بیندیشیم، عمق پیچیدگی آنها بی‌درنگ نمایان خواهد شد. می‌دانیم که در مثال نخست، آخرین و ازهاید himself باشد، نه him زیرا شخصی که از او خواسته شده تا مؤذب باشد، در آن واحد هم فاعل زیرساختی فعل behave است و هم مفعول آن. زبان‌شناسان این را ساختار انعکاسی<sup>۱</sup> می‌نامند. از سوی دیگر، سومین ازهای همان مثال، یعنی ضمیر dim مفعول فعل told است که به‌وضوح از فاعل، یعنی she، متمازی است، و از سهmin ره‌گز نمی‌توان آن را با ضمیر انعکاسی بیان

برگزیده شده، از روزنامه‌ها گرفته تا نوشه‌های علمی و ادبیات داستانی.

اگر تمام واژه‌ها به دفعات یکسان به کار رفته باشند، آن‌گاه هر صورت واژه تقریباً ۱۶ بار و هر لاما تقریباً ۲۶ بار در متن یک میلیون واژه‌ای به چشم می‌خورد. در عمل، میزان تکرار واژه‌های منفرد، و بنایارین بسامد آنها، فوق العاده ناهمسان است. آمار کلی بسیار قابل توجه است: میزان کاربرد صد واژه نخست پرسامد چنان زیاد است که این صد واژه  $\frac{47}{4}$ % کل متن را تشکیل می‌دهند. از میان تمام واژه‌های (نشانه‌هایی)، متن یک میلیون واژه‌ای، صد لامی نخست پرسامد  $\frac{49}{6}$ % کل متن را تشکیل می‌دهند.  $2854$  صورت واژه متمایز، که به  $2124$  لامی متمایز تعلق دارند، به تنها یکی از  $80$ % کل متن یک میلیون واژه‌ای را به خود اختصاص داده‌اند.

برای درک ۸۰٪ یک متن نمونه انگلیسی جدید دانستن کمتر از ۳۰۰۰ واژه کفایت می‌کند. اما این حقیقت بدان معنا نیست که این نوع واژگان می‌تواند حقایقی فرهنگی هیچ‌یک از ما در جامعه‌ای مدرن تضمن کند. پیش از هر چیز باید دانست که بسیاری از پیر بسامدترين واژه‌های زبان انگلیسی نقش واژه‌ها هستند: حروف تعریف، حروف اضافه، و صورت‌های فعل معین، مثلًا صورت‌های have، be و ya do. حرف عرفه the با فاصله بسیار، پر بسامدترين واژه زبان انگلیسی است. این واژه ۶۹۹۷۵ بار در متن بیکمیلیون واژه‌ای به کار رفته است. گرچه در کل متن، اسم‌ها و افعال مقوله‌های دستوری غالباً، که به ترتیب نزد حدود ۲۶٪ و ۱۸٪ کل نشانه‌های واژه‌ای را تشکیل می‌دهند، اما در پر بسامدترين طبقه، از میان مقوله‌های دستوری، کفه نقش واژه‌ها کاملاً سنگین تر است. لاما که رتبه ۱ تا ۳۲ بسامد را دارند، همگی نقش واژه یا ضمیرند. نخستین معناواژه، یعنی فعل say، رتبه ۳۳، و نخستین اسم، یعنی man، رتبه ۴۴ را به خود اختصاص دارد.

نقش واژه‌ها، که وجودشان برای نشان دادن نقش حقیقی معناواژه‌ها و رابطهٔ نحوی آنها در جمله ضروری است، دقیقاً همان واژه‌هایی نیز هستند که به دلیل بسیار کلیشه‌ای و قابل پیش‌بینی بودن، اگر در متنی حذف شوند، بسیار راحت‌تر از واژه‌های دیگر می‌توان در دس زد که حذف شده‌اند. چنین حذف‌هایی دقیقاً شخصه سنک، تبت‌های، وزننامه‌های است.

**Actor Found in Critical Condition after  
Explosion**

تیتر فوق فاقد هرگونه حرف تعریف و فعل معینی است. در یک متن کامل، جمله مذکور به صورت زیر خواهد بود:

An actor has been found in a critical  
stage of an operation.

بدین ترتیب جمله‌ای دوازده‌وازه‌ای به تیتری افت و ازهای تقلیل یافته، بی آن که چیزی از اطلاع رسانی آن کاسته شود. بر عکس، هرچه در متنی ازهای کمتر کلیشه‌ای باشد، وجودش به شگفتی آفرینی نقش اطلاع رسانی جمله بیشتر کمک می‌کند. به این