

وازگان محاسباتی: ساختار مرکزی در سیستم‌های پردازش زبان طبیعی

احمد عبدالله راده
استادیار

مهرنوش شمس فرد
دانشجوی دکترا

دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر

چکیده

امروزه مرکزت وازگان در سیستم‌های پردازش زبان طبیعی مورد تأکید است و لذا طراحی و ساخت وازگان محاسباتی بکی از فعالیت‌های زیربنایی ساخت چنین سیستم‌هایی به شمار می‌آید. در این مقاله ابتدا به تعریف وازگان و اجزاء آن، بررسی عوامل افتراق وازگان‌ها و انواع حاصله می‌پردازیم. سپس بدنبال تشریح اصول نظری طراحی و ساخت وازگان‌ها، یک نمونه عملی را در یک زیرسیستم پردازش زبان فارسی ارائه خواهیم نمود. در این نمونه عملی، پارامترها و عوامل تأکید شده در مباحث نظری را مورد توجه قرار داده و مقدار دهی می‌نماییم.

كلمات کلیدی

وازگان محاسباتی، پردازش زبان طبیعی، پایگاه دانش، هستان‌شناسی، یادگیری ماشینی

Computational Lexicon: The Central Structure in Natural Language Processing Systems

M. Shamsfard
Ph. D Student

A. Abdollahzadeh Barforoush
Assisstant Professor

Computer Engineering Department,
Amir Kabir University of Technology

Abstract

Lexicons play a central role in natural language processing (NLP) systems, so design and implementing computational lexicons are of foundamental activities in development of such systems.

In this paper first, we define lexicon, introduce its parts, study the difference factors in lexicons and describe their various types. Then after discussing the theoretical aspects design and implementation of lexicons, we will study a practical instance in a Persian natural language processing system. In this system, we will consider the mentioned theretical parameters and factors and initiate them practically.

Key words

Computational Lexicon, Natural Language Processing, Knowledge Base, Ontology, Machine Learning.

در این مقاله ابتدا پس از ارائه تعریفی از واژگان، اجزاء و همچنین وجوده افتراق انواع مختلف واژگان‌ها را بررسی خواهیم کرد. سپس مقایسه‌ای میان واژگان‌های محاسباتی و زبانی انجام داده و در نهایت به طرح ساختار و ویژگی‌های نمونه‌ای از واژگان‌های محاسباتی در یک سیستم پردازش زبان فارسی خواهیم پرداخت.

۲- تعریف واژگان

هر فرهنگ^۴ نکاشتی از «مجموعه نمادها» به «مجموعه تفاسیر» است. مجموعه نمادها می‌تواند شامل ترکیبات حروف الفباء ارقام، اصوات، تصاویر، اشکال و ... و یا دنباله‌ای از ترکیب آنها باشد و مجموعه تفاسیر بسته به نوع فرهنگ مورد نظر، معانی نمادهای یا نمادهای دیگری متضاظر با نمادهای داده شده را در بر می‌گیرد. به عبارت دیگر اگر فرض کنیم رابطه D یک رابطه فرهنگ‌سازی، مجموعه S مجموعه n عضوی نمادها و مجموعه I مجموعه m عضوی تفاسیر باشد، آنگاه خواهیم داشت:

$$D = \{(x,y) \mid x \in S, y \in I\}$$

$S = \{x \mid x \text{ is a string of symbols; symbol} \in A\}$

$I = \{y \mid y \text{ is a string of interpretations; interpretation} \in B\}$

$A = \text{Alphabet} \mid \text{Digits} \mid \text{Phonemes} \mid \text{Graphemes} \mid \dots$

$B = \text{Sememes} \mid \text{Alphabet} \mid \text{Digits} \mid \text{Phonemes} \mid \text{Graphemes} \mid \dots$

متداول ترین نوع فرهنگ، فرهنگ لغوی یا واژگان می‌باشد. در این نوع فرهنگ، مجموعه A مجموعه حروف الفباء و مجموعه B بسته به نوع کاربرد می‌تواند اجتماع مجموعه‌های واحدهای معنایی، الفبایی و صوتی باشد. واژگان در حقیقت انبارهای از اطلاعات در مورد زبان و ویژگی‌های اجتماعی آن است. یک واژگان اطلاعات لغوی مناسب و مرتبط (مانند طرز تلفظ و معنا) را برای واحدهای مناسب و مربوط لغوی^۵ (مانند لغات) ارائه می‌کند [۲]. معروف ترین شکل واحد لغوی کلمه است. اشکال دیگر آن می‌توانند قسمتی از کلمه یا ترکیبات کلمات باشند که در مورد آنها در بخش‌های بعد صحبت خواهیم کرد. هر واحد لغوی مجموعه‌ای از صور (تکوازها^۶) است که مجموعه‌ای از محتواها (واحدهای معنا)^۷ را بینمایی می‌کند. این صور با مجموعه‌ای

امروزه مرکزیت واژگان در سیستم‌های پردازش زبان مورد تأکید است. تقریباً بیش از ۱۰ سال است که محققین کار بر روی مسئله ورودی نامحدود را آغاز کرده‌اند، با این هدف که سیستم‌های پردازش زبان طبیعی بتوانند هر نوع جمله‌ای را دریافت کنند. به این منظور لازم است سیستم بتواند بطور وسیع واژگان و دستور زبان موردنظر را بپوشاند. لذا طراحی ساختار واژگان، اکتساب دانش لغوی، روش‌های جستجو و ذخیره و بازیابی اطلاعات در واژگان و نحوه ارتباط واژگان با سایر اجزاء سیستم از مباحث مطرح در تحقیقات جهانی هستند.

در دهه ۸۰، منابع لغوی رادیکشنری‌ها (فرهنگ‌های لغات) تشکیل می‌دادند. فرهنگ‌های ماشین خوان^۱ (MRDs) فقط شکل تایپ شده فرهنگ‌های چاپی بودند که برخی اطلاعات فرهنگ نویسی اضافی مانند تغییرات قلم، دستورات تایپی و نمادهای خاص را در برداشتند. به مرور زمان نقش کامپیوترها در آماده سازی این فرهنگ‌ها بیشتر شد و جمع‌آوری داده‌ها، انتخاب و ساخت تعاریف، مرتب سازی مدخل‌ها و آزمون کامل و سازگار بودن اطلاعات وارده توسط خود ماشین صورت گرفت.

در دهه ۹۰، مهمترین منابع لغوی، پیکره‌های زبانی^۲ بوده‌اند. یک پیکره یک منبع اولیه^۳ است و حاوی مجموعه استراتژیکی از مواد زبان طبیعی (تمام متن یا نمونه‌هایی از متن با جملات بی‌ربط ازیک یا چند زبان) می‌باشد که در شکل ماشین خوان ذخیره شده است. داده‌های این پیکره‌ها معمولاً پوشاننده حالات گفتاری و نوشتاری زبان است و محدوده وسیعی از زبان غیر فنی رایج (در زمان حال) را که به صورت عادی (ونه در شعر یا داستان‌های درام یا تخیلی) توسط بزرگسالان بالهجه استاندارد (ونه محلی)، استفاده می‌شود، دربر می‌گیرد.

امروزه واژگان‌های محاسباتی در گستره وسیعی از کاربردها پکار می‌آیند. از آن جمله می‌توان به سیستم‌های ویرایشگر، تصحیح املاء، تجزیه نحوی، تولید گرامر، ساخت و شناسایی کفتار، تولید و درک متن، طبقه‌بندی معنایی، رفع ابهام و ... اشاره نمود. برای ساخت یک واژگان محاسباتی دو راه اصلی وجود دارد [[۱]]: راه اول بازسازی یک چند MRD و تبدیل آن به شکل مورد نیاز کاربرد است و راه دوم ساخت مستقیم واژگان از روی پیکره‌های زبانی می‌باشد. در بسیاری موارد از ترکیب این دو روش استفاده شده، ابتدا با استفاده از MRD‌ها واژگان اولیه ساخته و سپس بر اساس پیکره‌ها اطلاعات آن تصحیح و سازگار شده و یا تکمیل می‌گردد.

محدوده و تنوع اطلاعات موجود در یک واژگان به عوامل مختلفی وابسته خواهد بود که الزاماً مستقل از یکدیگر نیستند. برخی از این عوامل در زیر آورده شده است.

الف - درجه پوشایی و واژگان: این عامل نشان دهنده وسعت دانشی است که واژگان تحت پوشش قرار می‌دهد. یک واژگان از این جهت می‌تواند در دو سطح عمل کند: [۲]

الف - ۱ - لغت نامه: در چنین واژگانی هر لغت با کمک دانش زبانی موجود تعریف می‌شود. به عبارت دیگر لغات با کمک ارتباطاتشان باللغات دیگر مانند تراوید، تضاد و در برگیری معرفی می‌شوند. چنین واژگانی دانش جهان را که برای عملیات استنتاج و استدلال مورد نیاز است، در بر نمی‌گیرد.

الف - ۲ - دائرة المعارف: دایرة المعارف‌ها از جهت مجموعه تفاسیر باللغت نامه‌ها متفاوتند. آنها بخش عظیمی از دانش جهان را در بر دارند. این دانش انجام استنتاج و استخراج دانش جدید را ممکن می‌سازد.

ب - گروه مخاطبین واژگان: واژگان بسته به این که برای چه گروه از مخاطبین و به چه منظور طراحی می‌شود دارای اطلاعات متفاوتی خواهد بود. دو نمونه از عوامل دسته بندی مخاطبین در زیر آمده است:

ب - ۱ - سن: رده سنی مخاطب در انتخاب نوع توضیحات، رسانه مورد استفاده و ابزارهای بکار گرفته شده در تفسیر کلمات مؤثر است. به عنوان نمونه واژگان طراحی شده برای کودکان به زبان ساده‌تر، با توضیحات بسیط‌تر و اکثراً همراه با تصاویر و اشکال متنوع ارائه می‌شود. در چنین واژگانی مجموعه تفاسیر حاوی زیر مجموعه‌ای از اشکال و تصاویر است.

ب - ۲ - تخصص: برخی واژگان‌ها تخصصی هستند و با در برگیری لغات و اصطلاحات فنی یک‌رشته، برای متخصصین آن رشته طراحی می‌شوند، در حالیکه برخی دیگر عمومی هستند و کلمات و لغات معمول زبان که افراد عادی از آنها استفاده فرهنگ‌ها هم در مجموعه نمادهای انتخابی و هم در مجموعه تفاسیر ارائه شده قابل مشاهده است.

ج - تعداد زبان‌های تحت پوشش: برخی واژگان‌ها تک زبانه هستند و برخی دیگر چند زبانه.

ج - ۱ - تک زبانه: واژگان‌های تک زبانه لغات و اصطلاحات یک زبان را به همان زبان معنی کرده و یا در مورد آنها توضیحاتی ارائه می‌کنند. فرهنگ‌های لغات و دائرة المعارف‌ها نمونه‌هایی از چنین واژگان‌هایی هستند.

ج - ۲ - چند زبانه: واژگان‌های چند زبانه لغات و عبارات متراوید در دو یا چند زبان را معرفی می‌نمایند. این فرهنگ‌ها بیشتر برای ترجمه بکار می‌روند. در چنین حالتی مجموعه نمایها از لغات زبان مبدا و مجموعه تفاسیر از لغات زبان

گرافیکی مثل حروف و یا مجموعه‌ای صوتی مثل صداها محقق می‌شوند. ارتباط بین صورت و معنا برای یک واحد لغوی یک ارتباط n به m است که n می‌تواند بزرگتر، کوچکتر و یا مساوی m باشد. به بیان دیگر:

$$L = \{(x, y) \mid x \text{ is a set of morphemes, } y \text{ is a set of sememes}\}$$

انواع دیگری از فرهنگ‌ها نیز وجود دارند که مورد توجه ما در این مقاله نیستند. مانند فرهنگ انتساب اشکال گرافیکی به حروف (مثلًاً جهت بازشناسی متن)، انتساب کلمات به تصاویر (مثلًاً برای استفاده کودکان)، انتساب اصوات به حروف (مثلًاً برای تشخیص گفتار) و ...

۳- اجزاء واژگان

هر واژگان دارای دو جزء اصلی است:

- ساختار کلی
- رویه جستجو

ساختار کلی واژگان حاوی همه اطلاعاتی است که در واژگان جای گرفته است و خود از کنار هم قرار گرفتن اجزاء مستقلی بنام «مدخل»⁸ تشکیل شده است. یک مدخل، ساختاری است که اطلاعات مرتبط با یک واحد لغوی را در خود جای می‌دهد. این مدخل‌ها طوری مرتب شده‌اند که با یک رویه جستجو به سادگی قابل دستیابی‌اند. به بیان دیگر رویه جستجو امکان دستیابی سریع و آسان به مدخل‌های مرتب شده را فراهم می‌کند. نمونه‌ای از یک رویه جستجو می‌تواند ترتیب الفبایی باشد که بر اساس شکل نوشتاری واحد لغوی (و نه معنای آن) صورت می‌گیرد.

تصمیماتی نظری تعیین اطلاعات مندرج در هر مدخل، نحوه کنار هم نشستن مدخل‌ها، چگونگی تخصیص واحدهای لغوی به مداخل و انتخاب رویه جستجوی مناسب بر عهده طراح واژگان است که بسته به نوع واژگان و کاربرد آن تعیین می‌نماید. اتخاذ تصمیمات متفاوت در هر زمینه می‌تواند منجر به ایجاد واژگان‌های مختلف گردد. نمونه‌هایی از این تفاوت‌ها در بخش بعد بررسی شده‌اند.

۴- انواع واژگان

واژگان‌ها بر اساس عوامل مختلفی طبقه بندی می‌شوند: از جمله این عوامل می‌توان به نوع و حدود اطلاعات مندرج در آنها و نحوه سازمان دهنده این اطلاعات اشاره داشت. در دو بخش بعد عوامل طبقه بندی را بر اساس محتوا و ساختار واژگان خواهیم دید.

۴-۱- تنوع در محتوا

۴-۲- تنوع در ساختار و نحوه انجام عملیات

سازمان دهی اجزاء یک واژگان بر اساس پارامترهای مختلف و به صور متفاوتی انجام می‌شود. این تفاوت در ساختار منجر به ایجاد تنوع در واژگان‌ها خواهد شد. برای سازمان دهی واژگان، طراحی ساختار و الگوریتم‌های انجام عملیات اصلی در واژگان، لازم است طراح به سؤالاتی پاسخ دهد. مجموعه پاسخ‌های طراح به این سؤالات، ساختار و اعمال لازم برای واژگان را تعیین خواهد کرد. نمونه‌هایی از موارد سؤال و برخی پاسخ‌های نوعی به آنها در زیر آورده شده است:

الف- نحوه برخورد با کلماتی با چند معنی

در هر زبانی تعدادی از کلمات دارای بیش از یک معنی هستند. نحوه سازمان دهی این معانی برای کلمه یکی از مسائلی است که طراح باید به آن پاسخ دهد. به این منظور دو امکان بررسی می‌شود:

الف-۱- آوردن همه معانی تحت یک مدخل: در این روش برای هر کلمه با هر تعداد معنی تنها یک مدخل در نظر گرفته می‌شود و تمامی معانی کلمه در همان مدخل جای می‌گیرند. در این حالت واژگان تابعی از مجموعه نمادها به مجموعه تفاسیر است. به عنوان مثال در چنین واژگانی برای کلمه «شیر» تنها یک مدخل وجود دارد که در مقابل آن معانی چون: حیوانی درنده، وسیله خروج آب یا مایعات از لوله و مایع خوارکی مترشحه از سینه پستانداران، درج می‌شود.

الف-۲- استفاده از مدخل‌های مختلف در مدخل‌های مختلف کلمه بر اساس معیارهای مختلف در مدخل‌های جداگانه جای داده می‌شوند. این معیارها می‌توانند داشتن ریشه کلمه، منشأ تاریخی، ویژگی‌های نحوی یا کاربرد شناسی متفاوت باشند. در این حالت واژگان دیگر یک تابع از مجموعه نمادها به مجموعه تفاسیر نیست بلکه رابطه‌ای است که عضو اول آن لزوماً یکتا نیست. در این واژگان برای همان کلمه «شیر» سه مدخل جداگانه در نظر گرفته می‌شود که هر یک حاوی یکی از معانی کلمه است.

الف-۳- حالت ترکیبی: این حالت که معمولاً متدوال تراز حالات قبل است ترکیبی از حالات الف-۱ و الف-۲ است. در این واژگان میانهای تفکیکی محدود شده و تنها به ازای برخی معیارها مثلاً منشاء تاریخی کلمه مدخل‌ها مجزاً و سایر تفاوت‌ها تحت یک مدخل بیان می‌شوند.

ب- نحوه نکاشت مدخل‌ها به واحدهای لغوی

ب-۱- یک به یک: در این حالت هر واحد لغوی با هر تعداد معنی یک و فقط یک مدخل را به خود اختصاص می‌دهد (مشابه حالت الف-۱) و هر مدخل نیز تنها به یک واحد لغوی تخصیص می‌یابد.

مقصد انتخاب می‌شوند. متدوال‌ترین این فرهنگ‌ها

دیکشنری‌های دوزبانه هستند.

د- کاربرد واژگان: یکی دیگر از عوامل تنوع در واژگان نوع کاربرد آن است. اطلاعات مندرج در واژگان بسته به کاربرد و استفاده مورد نظر، متفاوت خواهد بود. به عنوان نمونه چند کاربرد در زیر آورده شده است:

د-۱- درک: واژگان مورد استفاده در درک متون لازم است از لحاظ معنایی و کاربردشناصی بسیار غنی باشد. این نوع واژگان بیشتر در سطح دائرة المعارف عمل می‌کند و وظیفه آن نکاشت لغات و عبارات زبان به مفاهیم و معانی جهان واقعی است. در این حالت مجموعه تفاسیر، اجتماعی از مجموعه ویژگی‌های صرفی، نحوی و کاربرد شناسی است.

د-۲- تولید: واژگان مورد نیاز از جهت ویژگی شبیه به مورد قبل است با این تفاوت که در جهت معکوس و به منظور نگاشت معانی و مفاهیم به لغات و عبارات زبان بکار می‌رود. به عبارت دیگر در این واژگان (نسبت به مورد د-۱)، جای مجموعه نمادها و مجموعه تفاسیر عوض شده است.

د-۳- ترجمه: واژگان مورد نیاز چند زبان است و میزان پوشای بودن آن بستگی به سطح ترجمه مورد نظر دارد. در این حالت مجموعه نمادها و تفاسیر از الفبای دو یا چند زبان متفاوت گرفته می‌شوند.

۵- کاربر واژگان: عامل مؤثر دیگر در تعیین محتوای واژگان، کاربر آن است. اطلاعات عمومی و قبلی کاربر در هنگام استفاده از واژگان، تعیین کننده سطح اطلاعاتی است که لازم و کافی است در واژگان جای گیرد.

۵-۱- انسان: در صورتی که کاربر انسان باشد، سطح وسیعی از دانش عرفی و عمومی را دارد. لذا می‌توان با استفاده از اصل کم کوشی، از درج مجدد اطلاعاتی که فرض می‌شود مخاطب دارد خودداری نمود. در این حالت انسان با دانش عمومی خود دانش مندرج در واژگان را تفسیر و خلاصه‌ای اطلاعاتی آن را بسهولت پر می‌کند. در چنین واژگانی بخشی از مجموعه تفاسیر و همچنین زیر مجموعه‌ای از مجموعه نمادها، دانسته فرض شده و از واژگان حذف می‌شوند.

۵-۲- ماشین: اگر کاربر واژگان ماشین یا سیستم کامپیوتری باشد، لازم است دانش عرفی و عمومی مورد نیاز نیز در واژگان تعییه شود. لذا حجم و محتوای دانش مندرج در واژگان محاسباتی که کامپیوتر از آن استفاده می‌کند با واژگان زبان شناسی مورد استفاده انسان‌ها متفاوت است. در واژگان محاسباتی، مجموعه تفاسیر و نمادها بزرگتر از واژگان زبان شناسی بوده، از جهت صورت بندی نیز بدليل محدودیت‌های قابلیت خوانایی توسط ماشین، متفاوت خواهد بود.

د-۱- **تک ساختاری**: در این روش همه واحدها در یک ساختار ریخته می شوند. شکل واژگان برای همه مدخل‌ها یکسان بوده، واژگان یکدست و بدون ضمایم ارائه می شود.

د-۲- **چند ساختاری**: در روش چند ساختاری در کنار ساختار اصلی واژگان، از ضمایم برای معرفی واحدهای خاص مانند اسمی خاص و مخفف‌ها استفاده می گردد. ساختار این ضمایم و نوع اطلاعات مندرج در آنها می تواند به کلی با ساختار اصلی واژگان متفاوت باشد.

ه- **تعیین مدخل‌های اصلی و زیر مدخل‌ها**

متداول ترین ترتیب نزولی بر اساس احتمال مدخل بودن و ترتیب صعودی بر اساس احتمال زیر مدخل بودن در انگلیسی به شکل زیر است: **تکواژها** (مثل home)، واحدهای ترکیبی (مثل smog)، واحدهای آغازگرا (مثل VIP)، ترکیبات اسمی با نوشتر بسته (بدون فاصله) (مثل Black-bird)، ترکیبات اسمی با نوشتر باز (با فاصله) (مثل night owl)، ترکیبات فعلی (فعال مرکب) (مثل give up)، اصطلاحات غیر فعلی (مثل kick the bucket) و (at all)، اصطلاحات فعلی (مثل pre-war) و مشتقات با معنای شفاف (که معنای آنها از معنای اجزائشان قابل درک است) شامل: ترکیبات پسوند (zir قسمت اصلی کلمه) (مثل lameness تحت مدخل lame)، و پیشوندی (به ترتیب الفبایی زیر پیشوند و یا به ترتیب غیر الفبایی زیر قسمت اصلی کلمه با ارجاع به محل اصلی الفبایی آنها) (مثل pre-war تحت مدخل pre).

و- **ترتیب واحدهای با تشابهات صوری**

در هر زبانی کلماتی وجود دارند که از لحاظ شکل نوشتری بهم شبیه هستند ولی معنی متفاوتی دارند. این تشابهات صوری بردو گونه‌اند: دسته اول کلمات با چند معنی هستند. در این حالت نه تنها شکل نوشتری بلکه تلفظ کلمه نیز در معنی مختلف ثابت می‌ماند. (مانند کلمه شیر با سه معنی متفاوت) اما دسته دوم کلمات با شکل نوشتری یکسان و تلفظ متفاوت هستند (مانند کلمه حکم با تلفظهای hokm, hakam). هر دو دسته در گروه تشابهات صوری قرار می‌گیرند. نکته قابل توجه طراح در مورد این تشابهات تعیین ترتیب وقوع این واحدهای واژگانی است که بر اساس شکل صوری کلمات مرتب شده است. به این منظور معیارهای مرتب سازی زیر پیشنهاد می‌گردد:

و-۱- به ترتیب قاریخی: در این روش واحدهای مشابه بر اساس منشاء تاریخی‌شان (معمولًاً از قدیم به جدید) مرتب می‌شوند.

و-۲- به ترتیب فراوانی: در این روش واحدهای پرمصرف تر پیش از واحدهای مشابه کم مصرف آورده می‌شوند. به عبارت دیگر بر اساس مطالعات آماری، واحدهای بر مبنای

ب-۲- یک به چند: در این حالت یک مدخل به چند واحد لغوی تخصیص می‌یابد. در چنین شرایطی یک واحد لغوی مدخل اصلی محسوب شده و چندین واحد دیگر تحت این مدخل به عنوان زیر مدخل برای یک واحدهای آن قرار می‌گیرند.

ب-۳- چند به یک: در این حالت چند مدخل برای یک واحد لغوی صرف می‌شوند. این حالت وقتی اتفاق می‌افتد که یک واحد لغوی با چند معنی داریم که برای هر معنی یک مدخل در نظر گرفته ایم (مشابه حالات الف-۲ و الف-۳).

ج- **نحوه تعیین واحدهای لغوی**

ج-۱- **کلمات**: ساده ترین و بدیهی ترین شکل واحدهای لغوی کلمات هستند. مانند خانه، آوردن و ...

ج-۲- **زیر کلمات**: زیر کلمات تکواژهایی هستند که به ساخت تصrifی‌ها یا مشتقات کمک می‌کنند مانند پیشوندها، پسوندها و میانوندها.

ج-۳- **زیر کلمات**: ترکیباتی که از بیش از یک کلمه درست شده‌اند نیز می‌توانند واحد لغوی باشند. این ترکیبات در دو گروه اصلی جای دارند:

- **واحدهای ترکیبی و آغازگرا**: هر دو نوع این واحدها اجزائی از چند کلمه دارند با این تفاوت که در واحدهای ترکیبی این اجزاء از هر کجا کلمه می‌توانند انتخاب شوند ولی در واحدهای آغازگرا این اجزاء از حروف اول کلمات برگرفته می‌شوند. به عنوان مثال می‌توان به واحد «مشاصد» (ترکیبی از حروف کلمات مشاورین صنایع دفاع) به عنوان یک واحد ترکیبی و به واحد «نزاجا» (ترکیبی از حروف آغازین کلمات نیروی زمینی ارتش جمهوری اسلامی ایران) به عنوان یک واحد آغازگرا اشاره نمود.

- **اصطلاحات و عبارات مرکب**: این واحدها ترکیبی از چند کلمه کامل هستند. راه تشخیص این واحدها از دنباله‌ای از کلمات متوالی این است که در این حالت معنی کل عبارت با مجموع معنای کلمات تشکیل دهنده آن متفاوت است. مثل واحد «سردواندن» یا اصطلاحات و ضرب المثل‌ها.

ج-۴- **موارد خاص شامل اسامی خاص**: یک گروه مهم از مدخل‌ها را اسامی خاص تشکیل می‌دهند. این مدخل‌ها ممکن است به اسامی اشخاص (مثل ارسسطو یا فردوسی)، مکان‌ها (مانند پنی سیلین یا رایانه) تخصیص یابند. برخی واژگان‌ها برای محدود نمودن مجموعه لغات خود این مدخل‌ها را حذف می‌نمایند.

صورت‌های روزمره: این عبارات واحدهای غیر لغوی هستند که کاربرد عملی دارند یا ترجمه واحد لغوی در زبان دیگر می‌باشند (مانند ترجمه استعارات).

د- **یگانگی ساختار واژگان**

ز-۹- اطلاعات در مورد منشأ واحد: در مورد ریشه کلمه و پیدایش و تغییر شکل آن در طول زمان تا رسیدن به شکل فعلی صحبت می‌کند.

ز-۱۰- اطلاعات جانشینی^۹ مانند متراواف، متضاد، وارون، فراگیر و ...: مثال: (برد: (متراواف: انتقال داد)، (فراگیر: انتقال فیزیکی)، (وارون: آورده)، (کتاب: (فراگیر: شیء فیزیکی - بی جان))

ز-۱۱- اطلاعات هم نشینی^{۱۰} مانند عبارات و ترکیباتی که این کلمه معمولاً در آنها واقع می‌شود و یا محدودیت‌های گزینشی آن: مثال: (برد: (چیزی یا کسی را بردن: فاعل: متحرك، مفعول: قابل حمل)، (کتاب خواندن، کتاب نوشتن: فاعل: انسان، باسواد))

ز-۱۲- اطلاعات تشابهی^{۱۱} (قیاس پذیر) حاوی اطلاعاتی در مورد حوزه لغوی که این واحد را شامل می‌شود (مانند استفاده از see also)

ز-۱۳- اطلاعات نظام متدی^{۱۲} زبان مانند تعلق واحد به هسته زبان یا قرضی بودن آن، تعلق به زمان یا مکان و یا قلمروی تخصصی خاص، و یا رسمی یا غیررسمی بودن واحد: مثال: (برد: متعلق به هسته زبان، عام)

ح- تکنیک‌های انجام توضیحات:

ح-۱- نمایش: با جدول، شکل یا دیاگرام

ح-۲- مثال آوری: ارائه مثال‌های مختلف از کاربرد واحد لغوی و نحوه ترکیب آن با واحدهای دیگر

ح-۳- بسط: این نوع توضیح برای مخفف‌ها یا واحدهای ترکیبی و آغازگرای بیشتر بکار می‌رود و شکل کامل عبارتی را که واحد لغوی از آن گرفته شده بیان می‌کند. گاهی بیان شکل کامل عبارت اطلاعات کافی در اختیار کاربر می‌گذارد و نیازی به توضیح بیشتر نیست مانند توضیح واحد نزاوج به شکل نیروی زمینی ارتش جمهوری اسلامی ایران. اما بعضی مواقع بسط واحد به تنها بی اطلاع زیادی در مورد آن به ما نمی‌دهد مثلاً بسط واحد ناتو (NATO) به شکل "North Atlantic Treaty Organization" است که اطلاعی در مورد این سازمان، اعضاء عملکرد و اهداف آن نمی‌دهد.

ح-۴- بحث: توضیح ساده استفاده روزانه از این واحد

ح-۵- تعریف: شکستن واحد به اجزاء سازنده و ترکیب مجدد آنها طوری که محتواهای واحد ساخته شده، معنی یا تعریف واحد مورد نظر باشد. تعریف ممکن است به صورت تعریف با متراواف، تعریف تحلیلی و یا تعریف فرمولی باشد.

۵- مقایسه واژگان محاسباتی و واژگان زبان

واژگان محاسباتی و واژگان زبان از جنبه‌های مختلف با هم متفاوتند. مهمترین و واضح ترین تفاوت در انتظاری است

بیشترین رخداد معانی مرتب می‌شوند.

و-۳- به ترتیب الفبایی اجزاء کلامشان: راه دیگر مرتب سازی واحدهای مشابه در نظر گرفتن ترتیب الفبایی طبقه نحوی آنهاست. مثلاً اسم و صفت پیش از فعل و قید پس از آن ظاهر می‌شود.

و-۴- استفاده از الگوریتم‌های خاص مثلاً

- قائل شدن ترتیب بین حروف کوچک و حروف بزرگ

- قائل شدن ترتیب بین واحدهای بسته (بی فاصله) و واحدهای باز (فاصله دار)

- قائل شدن ترتیب بین حروف خاص مثل خط فاصله و آپاستروف

ز- اهم اطلاعات ذخیره شده برای هر مدخل (واحد لغوی) یکی از مهمترین مسائلی که طراح باید در مورد آن تصمیم بگیرد، انتخاب اطلاعاتی است که لازم است برای هر واحد لغوی ذخیره شود. در زیر برخی از این اطلاعات آورده شده است. واژگان‌های مختلف بسته به نوع و کاربردشان ممکن است برخی یا همه این اطلاعات را در خود جای دهند.

ز-۱- شکل واحد (با گونه‌های نوشتاری مختلف): همان رسم الخط واحد لغوی است که معمولاً به عنوان اندیس مدخل هم استفاده می‌شود. مانند: برد، کتاب، ...

ز-۲- اطلاعات آوایی (تلفظ و الگوهای تأکید): مانند: (برد: (keta'b)، (کتاب: bord

ز-۳- طبقه بندی و زیر طبقه بندی‌های نحوی شامل: اجزاء کلام (اسم، فعل، صفت و غیره): مثال: (برد: فعل)، (کتاب: اسم)

- اطلاعات دستوری بیشتر (شمارش پذیری، تعدی و غیره): مثال: (برد: ماضی، متعددی)، (کتاب: مفرد، شمارش پذیر)

ز-۴- گونه‌های تصریفی (جمع، ماضی، اشکال بی قاعدة و ...)؛ مثال: (برد: (مضارع: برد: barad)، (کتاب: (جمع: کتب: (kotob

ز-۵- گونه‌های اشتراقی و ترکیبی: مثال: (برد: (برد و باخت: نتیجه مسابقه)، ...)، (کتاب: (مکتوب: نوشته شده)، (مکتب: محل نوشتن)، ۲- نوع نگرش خاص)، (سر کتاب باز کردن: دعا نویسی) ...)

ز-۶- معرف معنی (ها) با ارائه تعاریف یا ارجاع به متراواف‌ها: مثال: (برد: ۱- انتقال داد، ۲- پیروز شد)، (کتاب: مجموعه چاپی از اوراق نوشته شده)

ز-۷- مثال‌هایی از طرق مختلف استفاده از کلمه: (برد: ۱- علی کتاب را به مدرسه برد، ۲- علی مسابقه را برد، علی شرط را برد)، (کتاب: کتاب را خواندم.)

ز-۸- موارد استفاده یا استفاده خاص: مثال: (برد: از میان برد: او آبروی مرا برد)

ارتباطات اضافه می‌تواند تعیین معنی ای از گره پدر باشد که گره جاری فرزند آن است. در بسیاری موارد گره پدر دارای بیش از یک معنی است. در واژگان‌های غیر محاسباتی، در چنین حالتی گره‌های فرزند تنها به گره پدر خود به شکل عام اشاره دارند و معنی مورد نظر خود از گره پدر را تعیین نمی‌کنند. در بسیاری از واژگان‌های محاسباتی (و از جمله در وردنت [۵]) برای افزایش سرعت استخراج اطلاعات چنین ارتباطاتی بوجود می‌آیند.

ثالثاً بدلیل استفاده ماشین از واژگان محاسباتی، لازم است این واژگان به صورت کاملاً ساخت یافته و با ساختار از پیش تعیین شده ارائه گردد. به همین دلیل واژگان‌های مختلف، جهت تطابق ساختارهای لازم برای نمایش همه طبقات نحوی و معنایی زبان، تدبیر متفاوتی اندیشیده اند. مثلاً وردنت از واژگان چندساختاری بهره گرفته، ساختارهای مقاومتی برای بازنمایی اطلاعات در مورد اعضاء طبقات نحوی مختلف درنظر می‌گیرد. در برخی واژگان‌های محاسباتی دیگر، تک ساختاری ترجیح داده شده و ساختمندانه داده‌های مورد نیاز به شکل پویا و قابل انطباق تعریف می‌شوند. این در حالی است که اکثر واژگان‌های غیر محاسباتی تک ساختاری هستند و از رویه‌ای مسطح برای معرفی همه واحدهای لغوی استفاده می‌کنند (یا حداقل اگر چندساختاری باشد، معیار تقسیم بندی کاملاً متفاوت با واژگان‌های محاسباتی دارند). در چنین واژگانی اصراری برای انطباق ساختاری و یکسان سازی اجزاء تعریف همه واحدهای لغوی وجود ندارد.

تفاوت دیگری که هم از جهت ساختاری و هم از جهت محتوایی قابل بررسی است، تفاوت در نحوه ارائه معنی در دو نوع واژگان است. در واژگان زبان‌شناسی، معمولاً هر واحد لغوی با معرفی متراffها، بیان توضیحات و یا ارائه تصاویر معنی می‌شود. استفاده از کلمات ساده‌تر برای معرفی کلمات و عبارات دیگر بدلیل احتمال زیاد شناخت کاربر از کلمات ساده، معمول است. در چنین واژگانی گاهی بدلیل استفاده از کلمات برای تعریف کلمات دیگر، با حلقه مواجه می‌شویم. اما در واژگان‌های محاسباتی نحوه معرفی معنا متفاوت است. در بعضی سیستم‌هایی که از واژگان بهره می‌گیرند (مانند مایکروکاموس [۱۶]), برای نمایش معنا از ساختار دیگری به نام هستان‌شناسی استفاده می‌شود. هستان‌شناسی داشت مفاهیم جهان را درون خود سازمان دهی می‌نماید. معنی نمودن هر واحد لغوی در واژگان با معرفی جایگاه آن در سلسله مراتب هستان‌شناسی انجام می‌پذیرد. به این ترتیب کلمات متراff آنها می‌هستند که به مفاهیم و معانی یکسان در هستان‌شناسی ارجاع داشته

که از آنها داریم. در واژگان زبان (اعم از شکل چاپی و یا تایپ شده آن) کاربر انسان است. لذا اطلاعات مندرج به زبان طبیعی و با صورت بندی قابل فهم برای انسان در واژگان ذخیره می‌شوند. در مقابل، کاربر اصلی واژگان محاسباتی، ماشین است. لذا اطلاعات با فرمت قابل خواندن توسط ماشین و عموماً به یک زبان بازنمایی می‌انجامند. در این سیستم‌ها در صورت نیاز، واسطه‌های کاربری تعیینه می‌شود که اطلاعات مورد نیاز کاربر انسانی را تغییر شکل داده به صورت قابل فهم توسط انسان به او ارائه نماید.

به دلیل اختلاف فوق واژگان‌های محاسباتی و زبانی هم از جهت محتوایی و هم از جهت ساختاری با هم متفاوتند. اختلاف محتوایی واژگان محاسباتی و زبان‌شناسی ناشی از اختلاف در کاربر آنهاست: در جایی که کاربر واژگان انسان است، حجم زیادی از دانش عرفی و عمومی بشر، با فرض علم خواننده نسبت به آن صراحتاً آورده نمی‌شود. این بخش از دانش که برای انسان دانسته فرض شده، برای ماشین ناشناخته است. لذا در واژگان‌های محاسباتی لازم است صراحتاً بیان گردد. این تفاوت بیشتر در دانش‌های معناشناختی و کاربردشناختی نمود دارد.

اما اختلاف ساختاری واژگان‌های زبان‌شناسی و محاسباتی از چند جهت قابل بررسی است:

اولاً واژگان محاسباتی بدلیل دارا بودن حجم بیشتری از دانش، نیاز به ساختار بزرگ‌تر و پیچیده‌تری جهت ذخیره سازی این دانش دارد.

ثانیاً در واژگان محاسباتی برای دستیابی سریع و چند جهته به اطلاعات، اتصالات و ارتباطات بیشتری (نسبت به واژگان زبان‌شناسی) تعییه شده‌اند. به عنوان نمونه در یک واژگان غیر محاسباتی که از سلسله مراتب ارث بری برای نمایش معنا استفاده می‌کند، معمولاً هر گره به گره پدرش اشاره دارد ولی به فرزندان و برادرانش اشاره نمی‌کند. مثلاً در تعریف کلمه «درخت» گفته می‌شود که «درخت» یک نوع «گیاه» است و در تعریف کلمه «گیاه» ارتباط فرزندی با گره «موجود نزدیک» قید می‌گردد. اما در تعریف گره «درخت» به فرزندان دیگر گره پدر (برادران) مانند «گل» اشاره نمی‌شود. همچنین ارتباط معکوس میان گره پدر و فرزند برقرار نیست. مثلاً از همان گره «درخت» راهی برای رسیدن به گره‌های «راش» و «افرا» وجود ندارد. در حقیقت این اطلاعات مفقوده اطلاعات ساختاری هستند. چراکه به هر حال از روی واژگان غیر محاسباتی نیز می‌شود آنها را استخراج کرد ولی کار بسیار مشکل و زمان بری خواهد بود. در حالیکه با افزایش اطلاعات ساختاری و ارتباطات میان اجزاء واژگان، سرعت دستیابی به این اطلاعات را افزایش داده‌ایم. نمونه دیگر این

می شود. به عبارت دیگر واژگان، ساختاری با محتوای پویاست. برای طراحی واژگان لازم است نوع واژگان، اطلاعات مندرج در آن، ساختار مورد نیاز و نحوه دستیابی، ذخیره سازی، بازیابی و بهنگام سازی این اطلاعات مشخص گردد. در ادامه این بخش به بررسی مشخصات مذکور در طراحی واژگان در سیستم «هستی» می پردازیم.

الف - نوع واژگان

- درجه پوشایش بودن: واژگان این سیستم خود به تنها یی به صورت یک لفظ نامه عمل می کند. اما از آنجا که در ارتباط با هستان شناسی قرار می گیرد و از طریق مدخل های آن می توان به داشتن گستره مفاهیم و ارتباطات جهان دسترسی داشت، در سطح داده های المعرف مورد استفاده قرار می گیرد.
- گروه مخاطبین: مخاطب این واژگان در حقیقت سیستمی است که قرار است از متون در حد کتاب فارسی کلاس اول دبستان، اطلاعاتی را استخراج کند. لذا در برگیرنده واژه هایی در حد همین کتاب است و واژه ها و عبارات تخصصی در آن جای ندارند.

- تعداد زبان های تحت پوشش: واژگان مورد نظر در هستی تک زبانه است و فقط اطلاعات در مورد واژه های زبان فارسی را در بردارد.

- کاربرد واژگان: این واژگان فعلًاً جهت درک متون به کار می رود اگر چه می توان در مراحل بعدی پرورش و یا در گسترش های آتی آن به مستله تولید نیز توجه نمود.

- کاربر آن ماشین می باشد.

- نحوه برخورد با کلماتی با چند معنی: در این واژگان، برای حفظ نمود^{۱۵} ها (مفهوم ها) مختلف یک کلمه از یک کلمه از مدخل با فلیدهای مختلف استفاده می شود. این تصمیم براساس ساختار انتخابی برای واژگان و امکانات زبان برنامه نویسی منتخب [۱۰] اتخاذ شده است. کلمات یکسان نه تنها ممکن است معانی مختلفی داشته باشند (مثل سه معنی کلمه شیر)، بلکه ممکن است دارای ویژگی های لغوی و نحوی مقاوتمی نیز باشند (مثل شکست: فعل ماضی سوم شخص مفرد و

باشدند. با این روش اگر چه مشکل معرفی مفاهیم در هستان شناسی اضافه می شود، ولی امکان بروز حلقه از میان رفته کار معرفی معنا در واژگان تسهیل می گردد. در برخی واژگان های دیگر نیز که از هستان شناسی بهره نمی گیرند (مانند وریدت) معرفی معنی واحد لغوی با بیان ارتباطات مختلف آن با واحدهای دیگر انجام می گیرد. وسعت این ارتباطات منجر به حذف حلقه و رفع ابهام در واژگان می گردد.

۶- طرح یک نمونه عملی: واژگان در پروژه هستی

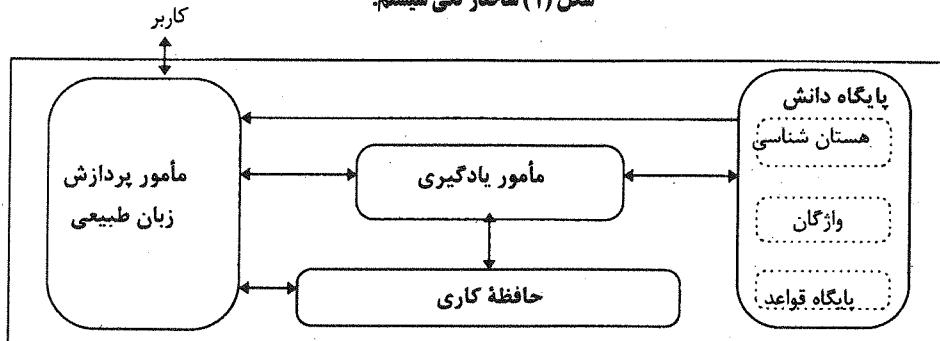
۶-۱- معرفی هستی

هستی [۷۸] سیستم ساخت خودکار هستان شناسی^{۱۳} بر اساس پردازش زبان فارسی است. این سیستم از مدل یک هسته یادگیر و تکاملی برای ساخت پایگاه دانشی برای مفاهیم استفاده می کند. هسته اولیه دارای مفاهیم و عملکردهای بنیادی است که برای اکتساب خودکار دانش مورد نیازند. به عبارت دیگر هسته حاوی فرادانش لازم جهت ساخت انواع هستان شناسی ها ببروی آن، با توجه به داشتن دریافتی از محیط از طریق جملات ساده زبان فارسی است. سیستم با شروع بکار با این هسته، با تراکنش هایی که به زبان طبیعی با محیط خود نارد، لایه های بعدی هستان شناسی را حول هسته اولیه می سازد. تنها وسیله ارتباطی هستی با محیط، متون نوشتاری زبان فارسی و هدف آن ساخت هستان شناسی براساس اطلاعات دریافتی از متون ورودی است. تأمین این اطلاعات وظیفه «مامور پردازش زبان طبیعی» است که واژگان یکی از اجزاء اصلی در ساختار پایگاه دانش آن است. شکل (۱) ساختار کلی سیستم هستی را نشان می دهد.

۶-۲- ویژگی های واژگان در هستی

ساختار واژگان برای حفظ دانش لغات در سیستم طراحی شده است. این ساختار در ابتدا حاوی بخشی از دانش اولیه در مورد لغات است و سپس در طول حیات سیستم^{۱۴} دانش های جدید توسط سیستم، اخذ [۹] و در آن درج

شکل (۱) ساختار کلی سیستم.



شکست: اسم). با توجه به اینکه در زبان منتخب (زبان لیسب [۱۱]) امکان تخصیص پویای حافظه در صورت لزوم وجود دارد و اطلاعات به صورت نمادی پردازش می‌شوند، لذا می‌توانیم برای مدخل‌های مختلف تعداد و نوع ویژگی‌ها را متغیر در نظر بگیریم و هر گونه اطلاعات مرتبط با یک واژه را تنها در یک مدخل در کنار هم نمایش دهیم.

- نحوه نگاشت مدخل‌ها به واحدهای لغوی: با توجه به نحوه برخورد با کلمات هم شکل، نحوه نگاشت مدخل‌ها به واحدهای لغوی به صورت یک به یک خواهد بود. چراکه هر مدخل به یک واحد لغوی (یک کلمه با نمودهای مفهومی متفاوت) تخصیص می‌یابد.

- نحوه تعیین واحدهای لغوی: واحدهای لغوی در این واژگان کلمات هستند. زیر کلمات (پیشوندها، پسوندها، میانوندها) در ساختار جدآگانه‌ای در بخش ساختواری نگهداری می‌شوند. زیر کلمات (کلمات مرکب یا چند کلمه‌ای‌ها) با توجه به انتخاب کلمات ساده در متون آزمون، در واژگان قرار نمی‌گیرند.

- یگانگی ساختار واژگان: واژگان موره نظر از دو ساختار جداگانه بهره می‌برد: ساختار واژه‌ها و ساختار واژه‌سازها. ساختار واژه‌ها (که در این مقاله واژگان نامیده می‌شود) حاوی اطلاعات لازم در مورد واژه‌های زیان است و دارای ساختار یگانه است. به عبارت دیگر ساختار آن برای گروه‌ها و انواع مختلف واحدهای لغوی (اعم از اسم، فعل و ...) یکسان است. اما ساختار واژه‌سازها حاوی اطلاعات ساختواری زیان در مورد وندهاست و اگرچه خود ساختار یگانه دارد ولی با ساختار واژگان متفاوت است. این ساختار از این پس واژگان ساختواری نامیده می‌شود.

- تعیین مدخل‌های اصلی و زیر مدخل‌ها: در این واژگان مدخل‌ها تک سطحی بوده و زیر مدخلی وجود ندارد.

- ترتیب واحدهای با تشابهات صوری: واحدهای با تشابهات صوری به عکس ترتیب ورود (یا یادگیری) حفظ می‌شوند.

- تکنیک انجام توضیحات: از آنجا که کاربر، سیستم درک و پادگیری است، توضیحات به صورت متن نوشته‌ای تنها برای مواردی که لازم باشد عیناً در خروجی برای کاربر انسانی سیستم چاپ شود، ذخیره می‌شود. خود سیستم از این بخش استفاده‌ای نمی‌کند.

ب - اهم اطلاعات ذخیره شده برای هر مدخل در واژگان در هستی با توجه به اینکه در حال حاضر واژگان جهت درک متون با کلمات و جملات ساده زبان بکار می‌رود، لذا از ذخیره سازی اطلاعات واجی و همچنین اطلاعاتی که جهت تولید زبان بکار می‌زند (مانند برخی اطلاعات جانشینی) و اطلاعات لازم جهت ساخت کلمات مرکب (برخی اطلاعات اشتقاء) (امیرکبیر / سال دوازدهم / شماره ۴۸ / پاییز ۱۳۸۰)

صرف نظر می‌کنیم. با توجه به این موارد اطلاعات ذخیره شده در واژگان هستی به شرح زیر خلاصه می‌شود:

- شکل نوشتاری کلمه

- داشت ساختواری: در هستی بخش اعظم دانش ساختواری زیان در قالب قواعد ساختواری و یا به صورت جدآگانه در ساختار واژگان ساختواری (حاوی واژه سازها مانند پیشوندها، میانوندها و پسوندها) ذخیره می‌شود. بخش دیگری از این داشت که خاص کلمات و واژه‌های است، در واژگان در مقابل هر واژه آورده می‌شود. مانند نحوه جمع بستن، جمع مكسر یا شکل مفرد یک اسم، ریشه کلمه، شکل ماضی یا مضارع فعل و ... به عبارت دیگر ما بیشتر به حفظ اطلاعات تصریفی توجه داریم و فعلًا اطلاعات اشتقاء را نگهاری نمی‌کنیم.

- داشت نحوی: این بخش شامل طبقه یا نوع کلمه و ویژگی‌ها یا زیر طبقه کلمه می‌باشد. این زیر طبقات ویژگی‌های جزئی تری از کلمه را در طبقه خود بیان می‌کنند. به عنوان نمونه در طبقه فعل زیر طبقات می‌توانند نوع فعل (مثلًاً ماضی یا مضارع) و یکسری ویژگی‌های دودویی دیگر مانند متعددی یا مجھول بودن و در طبقه اسم شامل ویژگی‌های دودویی مانند جمع یا مفرد، ذات یا معنی، شمارا یا ناشمارا، عام یا خاص باشند. البته ما در مرحله اول پروره با اطلاعات هم نشینی کار نمی‌کنیم ولی در مراحل بعد برخی اطلاعات هم نشینی کلمه مانند نحوه ترکیب آن با کلمات دیگر یا با حروف اضافه و طبقات نحوی مجاز همراه شونده با فعل در این قسمت درج خواهد شد.

- داشت معنایی: در هستی، معنای اصلی واژه توسط اشاره به مفهوم متناظر آن در هستان شناسی تعیین می‌شود ولی ویژگی‌های خاص معنایی و یا محدودیت‌های گزینشی خاص واژه در واژگان قید می‌گردند. لذا بسیاری از اطلاعات معنایی که بعضًا در واژگان‌های محاسباتی دیده می‌شوند ([۵]) مانند اطلاعات جانشینی، در هستان شناسی هستی تعییه می‌شود و واژگان از طریق بخش معنایی واژه به این اطلاعات دسترسی دارد.

- داشت کاربردی: در هستی بیشتر داشت کاربردی مورد نظر (مانند بخشی از اشارات ضمنی، پیش شرایط و نتایج و آثار اعمال و ...) در هستان شناسی جای دارد و بخش دیگری که متصل به واژه است (مانند ارزش واژه در میان واژه‌های هم گروهش) در واژگان و در ارتباط با هستان شناسی ذخیره می‌گردد. مثلًاً برای ارزش گذاری واژه‌های داغ، گرم و ولیم در واژگان ارزش نسبی حرارتی به این واژه‌ها داده می‌شود که این ارزش مرتبط با مفهوم دما یا حرارت در هستان شناسی است و لذا بین همه واژه‌های مرتبط با این مفهوم مشترک بوده و قابل قیاس است.

۶-۳. ساختار واژگان در هستی

شده با تعداد ضریب جمله شاهد. جملات شاهد در ساختار نمایه سازی حفظ می شوند که شرح آن در بخش های بعد خواهد آمد. ضریب اطمینان کلی مفهوم مورد نظر توسط تابعی از ضرایب اجزاء بدست می آید. این تابع در مرحله اول به صورت ساده، تابع جمع است.

۶-۴. ساختار واژه سازها

ساختار واژه سازها ساختاری برای حفظ عناصر واژه سازی زبان (وندها) می باشد. این ساختار که در تحلیگر ساختواری مورد استفاده قرار می گیرد، حاوی اطلاعاتی در مورد اجزاء قابل تکیک واژه ها مانند پیشوندها، میانوندها و پسوندهاست. قواعد ساختواری زبان که با ترکیب واژه سازها با واژه های موجود در واژگان، لغات و عبارات جدید می سازند و یا لغات مرکب را تجزیه می کنند، در پایگاه قواعد قرار دارند.

اهم اطلاعات ذخیره شده برای هر مدخل در ساختار واژه سازها عبارتند از:

- شکل واژه ساز

- ویژگی های واژه ترکیب شونده: این بخش حاوی اطلاعاتی در مورد محدودیت های گزینشی واژه ای است که با این واژه ساز قابل ترکیب می باشد. مانند طبقه نحوی و ویژگی معنایی واژه.

- نوع ترکیب: نشان می دهد که ترکیب به صورت پیشوندی، پسوندی و یا میانوندی صورت می گیرد.

مفهوم های مختلف یک کلمه ممکن است دارای ویژگی های صرفی (ساختواری)، نحوی، معنایی و کاربردی متفاوتی باشند. لذا لازم است در هر مدخل (که اطلاعات لازم در مورد یک واژه را حفظ می کند)، مفهوم های مختلف واژه را با ویژگی های متفاوت ثبت نماییم. در هستی مجموعه مفهوم های یک واژه که در صرف و نحو یکسان و در معنا متفاوتند را یک گروه مفهومی^{۱۶} می نامیم. در هر گروه مفهومی، اطلاعات ساختواری، نحوی و لیستی از اطلاعات معنایی و کاربردی برای مفهوم های عضو این گروه ثبت می شود. ساختار یک مدخل شامل کلمه آن و لیستی از گروه های مفهومی منتنسب به آن کلمه است. طرح واره ای از این ساختار در شکل (۲) آمده است. در این شکل مدخل *A* ام واژگان نشان داده شده است. در اینجا فرض شده که واژه *M* مورد نظر دارای *N* گروه مفهومی است که در هر گروه *M* دسته ویژگی های معنایی متفاوت وجود دارد و هر یک از این دسته ها خود دارای *K* گونه متفاوت کاربردی است.

برای هر فیلد از نمودهای یک واژه علاوه بر اطلاعات مذکور ضریب اطمینانی نیز ذخیره می شود. در حال حاضر مقدار ۲۵۵ یعنی مقدار اولیه و موجود در هنگام شروع بکار سیستم (تعیین شده توسط مهندس سیستم)، مقدار میان ۱۲۹ و ۲۵۴ یعنی تأیید شده توسط کاربر شماره (ضریب منهای ۱۲۸)، مقدار ۱۲۸ یعنی تأیید شده با بیش از ۱۲۷ تأیید شاهد (جمله تأیید کننده در متن) و مقادیر کمتر از ۱۲۷ تأیید



شکل (۲) ساختار مدخل زام واژگان.

گفتن، بیان کردن و صحبت کردن است. شکل (۳) طرح واره‌ای از ارتباط واژگان و هستان‌شناسی را در هستی نشان می‌دهد.

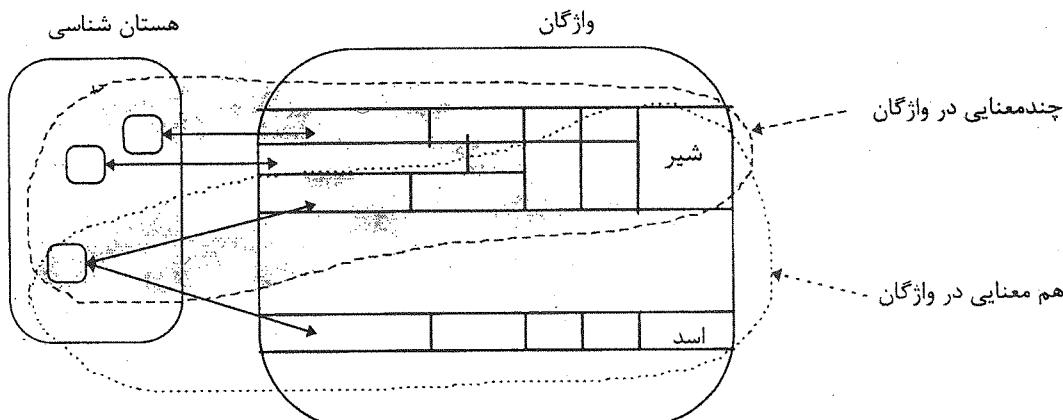
از آنجاکه سیستم معانی لغات (مفهوم‌ها و ارتباطات) را بتدریج و از روی متون دریافتی یاد می‌کیرد، به دلایل مختلف ممکن است لازم باشد در آموخته‌های خود تجدید نظر کرده ویا آنها را تغییر و تصحیح نماید. به این منظور لازم است سابقه‌ای از مسیر یادگیری خود را حفظ کند. ساختار نمایه سازی واژه‌ها، ساختاری است که با همین هدف طراحی شده است. این ساختار میان واژگان، هستان‌شناسی و ساختار متون قرار می‌کیرد و همه مفهوم‌های کلمه را در متن مشخص می‌کند. این ساختار برای هر واژه لیستی از شاخص‌های ساختار جملات متن نگه می‌دارد که در آن جمله، آن کلمه با معنی مورد نظر بکار رفته است. این ساختار در حافظه کاری^{۱۰} سیستم نگهداری و با

-ویژگی‌های واژه مرکب: طبقه نحوی و ویژگی‌های معنایی واژه حاصل از ترکیب را بیان می‌کند.

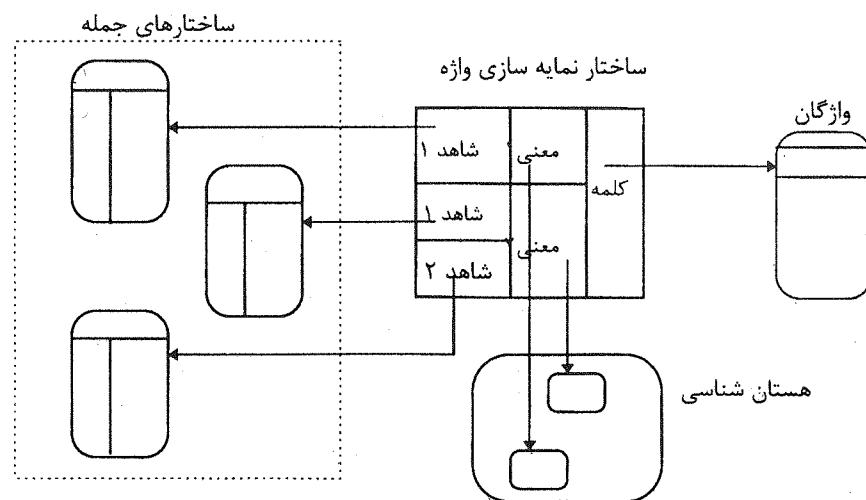
به عنوان نمونه، واژه ساز «بان» با واژه‌هایی با طبقه نحوی «اسم» می‌تواند ترکیب پسوندی بسازد و حاصل، واژه‌ای با طبقه نحوی «اسم» و ویژگی معنایی «محافظت» خواهد بود.

۶-۵. ارتباط واژگان با سایر اجزاء پایگاه دافش

در واژگان هستی، بخش اعظم اطلاعات معنایی و کاربردی از طریق ارتباط با هستان‌شناسی تأمین می‌گردد. برای هر کلمه ممکن است بیش از یک ارتباط با هستان‌شناسی برقرار باشد (چند معنا بودن)^{۱۷} مثل کلمه «شیر» که بیش از یک معنا دارد و لذا با بیش از یک ارتباط معنایی به هستان‌شناسی مرتبط می‌شود. همچنین ممکن است به یک مفهوم در هستان‌شناسی بیش از یک کلمه مرتبط باشد (هم معنا بودن^{۱۸}). مثل مفهوم "speak" که معنایی برای کلمات مترادف



شکل (۳) طرح واره‌ای از ارتباط واژگان و هستان‌شناسی.



شکل (۴) طرح واره‌ای از ارتباط واژگان، هستان‌شناسی و ساختارهای جمله در یک ساختار متن.

می شود، چرا که سیستم می داند پسوند «بان» بر سر اسم آمده و اسم دیگر می سازد.

مسیر دوم دریافت اطلاعات نحوی، از طریق تجزیه نحوی جمله است. در این حالت ابتدا سیستم با کمک یک تجزیه گر چارت بالا به پاشین²⁰ به دنبال قاعده‌ای در قواعد دستور زبان می گردد که با جمله جاری تطابق داشته باشد. این قاعده نقش دستوری کلمه یا کلمات ناشناس را تعیین می کند. در صورتی که بیش از یک قاعده برای جمله جاری یافته شده و یا بیش از یک نقش برای کلمه ناشناس بدست آمد، همه حالات ممکن برای تأیید یاره بعدی در ساختار فرضیات حفظ خواهند شد. تأیید یاره نتایج حاصله بر اساس جملات بعد و یا تراکنش با کاربر و توسط مأمور یادگیری انجام می پذیرد (برای بحث مفصل تر در مورد شرح وظایف و نحوه عمل مأمور یادگیری رجوع شود به [۱۳]). همچنین دریافت اطلاعاتی در مورد زیر طبقات افعال نیز در همین مرحله با توجه به کلمات یک جمله میسر است که در مراحل بعدی پروژه پیاده سازی خواهد شد.

د- اطلاعات معنایی و کاربردی: هنگامی که جمله با یکی از قواعد دستوری زبان تطابق یافته، با استفاده از الگوهای معنایی در نظر گرفته شده برای قواعد دستوری، نقش²¹ کلمات جمله استخراج شده و در ساختاری به نام ساختار جمله حفظ می شود. ساختار جمله در حقیقت قاب حالتی²² است که برای جملات کنشی شامل نقش‌های کنش، کنش گر، کنش پذیر، زمان، مکان، ابزار، توصیف گر کنش، مبدأ و مقصد است و برای جملات حالتی حاوی حالت پذیر، حالات، زمان و مکان می باشد.

پس از ساخته شدن ساختار جمله، به ازاء هر کلمه ای در جمله که معنای آن ناشناخته است مفهومی²³ در هستان شناسی ایجاد می گردد. این مفاهیم با توجه به طبقه کلمه و نقش آن در جمله در بالاترین سطح زیر هسته به ساختار هستان شناسی متصل می شوند²⁴ (به عنوان نمونه، اسمی تحت مفهوم Object، افعال تحت مفهوم Action و صفات تحت مفهوم Property). سپس این مفهوم از محل پدر اولیه خود به طرف برگ‌های سلسله مراتب ارشتی در هستان شناسی چرکت می نماید تا خاص ترین پدر خود را بیابد. منظور از یافتن خاصترین پدر، یافتن مفهومی است که او لآ از نظر ویژگی با مفهوم جدید تطابق داشته باشد، ثانیاً در میان مفاهیم مطابق، در پائین ترین سطح ممکن در سلسله مراتب قرار گرفته باشد. عمل یافتن تطابق خود رویه پیچیده ای دارد. ابتدایی ترین شکل تطابق در این مرحله، عدم وجود تضاد است.²⁵ در صورتی که همه یا هیچیک از فرزندان یک پدر با مفهوم جدید مطابقت داشته باشند، عمل انتقال متوقف و

تعویض متن وروی، آخرین نتایج مندرج در آن به ساختارهای واژگان و هستان شناسی منتقل و ساختار خالی خواهد شد. شکل (۴) طرح واره ای از ارتباط واژگان، هستان شناسی و ساختارهای جمله را در یک ساختار متن نشان می دهد.

۶- یادگیری لغات و معانی تازه

واژگان هستی در ابتدای کار دارای تعداد محدودی واژه است که معانی بیشتر آنها را نمی داند. سیستم به مرور با دریافت جملات ساده، با استفاده از قواعد دستور زبان فارسی و با توجه به جملات دیگر متن، اطلاعات مربوط به کلمات موجود را تکمیل و یا کلمات جدید را به واژگان می افزاید. برای روشن تر شدن بحث، عمل یادگیری سیستم را برای مواجهه با کلمه جدید، و تکمیل اطلاعات ساختواری، نحوی و معنایی به تفکیک بررسی می کنیم.

الف- کلمه جدید: در حالتی که یکی از کلمات متن در واژگان موجود نباشد ابتدا امکان تبدیل آن به یکی از کلمات موجود در واژگان با توجه به قواعد ساختواری موجود و بر اساس واژگان ساختواری بررسی می شود. مثلاً با برخورد به کلمه «کتابها» در شرایطی که واژه «کتاب» در واژگان هست، گذر از یک مرحله تحلیل ساختواری ما را با حذف علامت جمع به یک کلمه شناخته شده می رساند. اما اگر نتوانستیم کلمه را ساده‌تر کنیم (یعنی یا اجزاء کلمه در واژگان نبود یا کلمه قابل تفکیک نبود)، با یک کلمه جدید مواجهیم. در این حالت مدخلی برای آن در واژگان درنظر گرفته شده، بدنبال تکمیل اطلاعات این مدخل خواهیم بود.

ب) اطلاعات ساختواری: در مرحله اول ساخت هستی ما از میان اطلاعات ساختواری به نحوه جمع بستن، جمع مکسر یا شکل مفرد یک اسم جمع، ریشه کلمه، و شکل ماضی یا مضارع فعل توجه داریم. جمع‌های مکسر و اسامی جمع در بسیاری موارد از طریق مطابقه فاعل و فعل قابل تشخیص می باشند. همچنین نحوه جمع بستن یک اسم و یا ریشه کلمه با گذر واژه از تحلیل گر ساختواری استخراج می شود. اما در مورد بقیه موارد فوق در مرحله اول به یادگیری از طریق محاوره با کاربر بستنده کرده ایم.

ج- اطلاعات نحوی: برای دریافت و تکمیل اطلاعات نحوی یک واژه دو مسیر در سیستم وجود دارد. اول اینکه هنگام عبور واژه از مرحله تحلیل ساختواری ممکن است نقش نحوی واژه قابل تشخیص باشد چرا که حاصل اعمال بسیاری قواعد ساختواری برای سیستم شناخته شده است. مثلاً اگر سیستم به کلمه ناشناس باغبان برخورد کند، در شرایطی که پسوند «بان» در ساختار واژه سازها آمده باشد، پس از عبور از تحلیلگر ساختواری نقش نحوی کلمه، اسم تشخیص داده

آستانه‌ای (آستانه ادغام²⁸) فراتر رفت و در ضمن میزان اختلافاتشان از آستانه دیگری (آستانه تقسیک²⁹) کمتر بوده، تضاد ویژگی نیز میانشان وجود نداشت، می‌توان این دو مفهوم را به یک مفهوم کلی ترا ادغام و یا ابر مفهوم³⁰ مشترکی برای آنها در نظر گرفت ([۱۲]).

۶- پیاده‌سازی

واژگان در این سیستم به زبان لیسپ و در محیط Allegro CL 6.0 تحت سیستم عامل Windows پیاده شده است. جهت ذخیره و بازیابی اطلاعات در واژگان از ساختار Hash-table استفاده شده و جستجو در آن مرحله اول با توابع hash موجود در محیط انجام می‌گیرد. واژگان در مرحله اول حاوی حروف اضافه، افعال ربطی، و تعدادی (کمتر از ۱۰ مورد) اسم و فعل است که به صورت تصادفی انتخاب شده‌اند.

۷- نتیجه‌گیری

درگذشته سیستم‌های پردازش زبان طبیعی (NLP)، به واژگان به عنوان یک جزء لازم که از توجهات نظری اندکی برخودار بود و به سادگی با کمک مجموعه‌ای از بزنامه‌ها ساخته می‌شد، نگاه می‌کردند. در حالیکه امروزه مرکزیت واژگان در سیستم‌های پردازش زبان مورد تأکید است. انتخاب صحیح ویژگی‌های ساختاری و محتوایی و تعیین دقیق نوع و ساختار واژگان مورد نیاز بر اساس کاربرد سیستم مورد نظر از وظایف طراح است که نقش اساسی در عملکرد سیستم خواهد داشت. در نمونه عملی مورد مطالعه اگر چه هدف اصلی سیستم، پردازش زبان نبوده و عمل پردازش زبان به صورت محدود (بر روی ورودی محدود) و تنها به عنوان تغذیه کننده سیستم اصلی انجام می‌شود ولی بدلیل تعیین کننده بودن واژگان در کارآیی سیستم نهایی و اکتساب دانش مورد نیاز از متون به ساختار واژگان توجه خاص نموده‌ایم. این ساختار به سهولت قابل تعمیم برای دربرگیری ورودی‌های نامحدود زبان و یا تعمیم به کاربرد تولید متن می‌باشد.

زیرنویس‌ها

1- Machine Readable Dictionaries

2- Corpora

۳- منابع زبانی به دو دسته اصلی تقسیم می‌شوند: الف - منابع اولیه منابع زبانی مورد استفاده هستند که به صورت عام وجود دارند و خاص استخراج اطلاعات واژگانی طراحی نشده‌اند. از جمله این منابع می‌توان به متون نوشتاری یا بخش‌های ضبط شده‌ای از گفتار اشاره

مفهوم تحت پدر قرار می‌گیرد. در صورتی که بیش از یک فرزند مطابقت داشته باشد، با استفاده از یک تکنیک نگاه به جلو²⁶، تا N سطح جلوتر (در مرحله اول N=۱) آزمایش می‌شود تا نزدیک ترین تطابق پیدا شود. در صورتی که همچنان بیش از یک انتخاب وجود داشت، در این مرحله مفهوم به گره پدر منتبث می‌شود.²⁷

به مرور که مفاهیم مختلف به ازاء کلمات زبان تشکیل می‌گردند، این مفاهیم بر اساس ویژگی‌های مشترک در هم ادغام و یا بر اساس عوامل تقسیک به دسته‌های ریزتر شکسته می‌شوند. در شرایطی که اختلافی میان معنی موجود و معنی دریافتی از جمله جاری بیاید، نخست معنی جدید را با جملات قبل مقایسه می‌کند. در صورتی که معنی جدید با جملات معانی سابق باشد (مثلًاً زیر مجموعه یا زیر مجموعه می‌کند، در غیر این صورت معنی جدید را به عنوان مفهوم دیگری از واژه مورد نظر می‌آزماید. در هر دو صورت پیغامی مبنی بر تصمیم سیستم به کاربر انسانی ارسال می‌شود تا کاربر در صورت تمایل این تصمیمات را تصحیح یا تأیید نماید.

مثلًاً فرض کنید اولین جمله ورودی جمله «حسن سیب را خورد» بوده، واژگان حاوی مدخل‌هایی با محتویات زیر باشد:

سیب: اسم، مفرد.

را: حرف اضافه - نشانه

خورد: فعل ماضی، متعدد

ساختار جمله ساخته شده بر اساس قاعده دستوری:

«جمله ← گروه اسمی (کنش گر) + گروه اسمی (کنش پذیر) + را + فعل متعدد (کنش)»

نشان می‌دهد که حسن فاعل (کنش گر)، سیب مفعول (کنش پذیر) و خورد کنش جمله است. لذا در هستان شناسی مفاهیمی برای حسن، سیب و خورد تحت ابر مفاهیم چیز و کنش ایجاد می‌شود. در این مرحله چون این ابر مفاهیم خود در برگ‌ها قرار دارند، انتقالی صورت نمی‌گیرد. سپس روابط قوه کنش کاری، قوه کنش پذیری، قوه کنش کاری بر وقوه کنش پذیری از، میان این مفاهیم برقرار می‌گردد. پس از آن با رسیدن به جمله‌ای مثل «حسین سیب را خورد» با توجه به وجود مفاهیمی برای سیب و خورد، مفهومی برای حسین در هستان شناسی تشکیل می‌شود. در این لحظه حسن و حسین هر دو توان کنش گری یک کنش بر روی یک کنش پذیر را دارند و این یک اشتراک محسوب می‌شود. به مرور که جملات بیشتری توسط سیستم دریافت می‌شود، این اشتراکات افزایش می‌یابد. هنگامی که اشتراکات دو مفهوم از یک

- ۲۴ - هسته هستان شناسی حاوی مجموعه کوچکی از مفاهیم و عملگرهای ابتدایی برای شروع به کار سیستم است. این مفاهیم در مرحله اول شامل: Thing در بالاترین سطح و Action, Object در سطح دوم می باشند. همچنین عملگرهای اولیه در این مرحله عملگرهای Add جهت دفع یک مفهوم، Delete حذف یک مفهوم، Update جهت بهنگام سازی ویژگی های یک مفهوم، Merge جهت ادغام دو یا چند مفهوم، Split جهت تفکیک یک مفهوم و Transfer جهت انتقال یک مفهوم در ساختار هستان شناسی، می باشند.
- ۲۵ - به منظور یافتن تطابق، هر ویژگی دارای نشانگری است که نشان می دهد مقدار آن قابل ادغام، اجتماع، بازنویسی و یا تغییر توسط مقدار جدید هست یا نه. به منظور یافتن تطابق لازم است ویژگی های غیر همسان، اولاً متضاد نباشند، ثانیاً مقادیر آنها متضاد نباشند، ثالثاً این مقادیر براساس نشانگرشان با هم قابل تطابق باشند. تشخیص تضاد براساس ویژگی های منصوب به مفهوم ویژگی مورد نظر در هستان شناسی میسر می گردد.
- 26- Look Forward
- ۲۷ - توضیح در مورد محتوای اولیه هستان شناسی، رویه های ادغام، تفکیک و انتقال مفاهیم و نحوه تشخیص تضاد، همسانی و تطابق، بحث مفصلی را می طلبد که با توجه به تأکید این مقاله بر بخش واژگان، در حوصله این بخش نیست. شرح این موارد در مرجع [۱۲] آورده شده است.
- 28- Marge Treshold
29- Split Threshold
30- Super Concept

نمود. منابع ثانویه: منابعی هستند که خود از منابع اولیه یا ثانویه دیگر استخراج شده اند مانند دیکشنری ها یا دستور زبان های موجود.

- 4- Dictionary
5- Lexical Unit
۶- Morphemes - اجزاء ساخت یک کلمه، مثلًا «نا» (نفعی) + «مادر» + «ی» تکوازهای ساخت کلمه «نامادری» هستند.
۷- Sememes - اجزاء معنا که در کاربردهای مختلف متفاوت است مثلًا مفاهیم اولیه متاظر در هستان شناسی

- 8- Entry
9- Paradigmatic
10- Syntagmatic
11- Analogical
12- Diasystematic
13- Ontology
۱۴ - از لحظه آغاز بکار سیستم تا هر زمانی که سیستم مورد استفاده قرار گیرد.

- 15 - Sense
16- Sense Group
17- Polysemy
18- Synonymy
۱۹ - حافظه کاری محل نگهداری اطلاعات میان اکتسابی از محیط و حفظ ساختارهای کمکی سیستم برای انجام تحلیلات لازم است.
- 20- Top Down Chart Parser
21- Role
22- Case Frame
23- Concept

مراجع

- [1] Atwell E. S., "Machine Readable Dictionaries and Lexical Databases", School of computer Studies, Leeds university, 1998.
- [2] Malmkjaer K., "The Linguistics Encyclopedia", Routledge, 1996.
- [۳] شمس فرد م، «واژگان: مباحث زبانی و محاسباتی»، گزارش فنی شماره ۱۰۰-۱-۱۰۰، آزمایشگاه سیستم های هوشمند، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر، شهریور ماه ۱۳۷۸
- [4] Cavazza M., Zweigenbaum P., "Lexical Semantics: Dictionary or Encyclopedia?", in [14], pp 336-347, 1995.
- [5] Miller G. A., "WordNet: A Lexical Database for English", Communication of the ACM, Vol 38, No. 11, p 39-41, NOV. 1995.
- [6] Nirenburg S., et al, "Lexicons in the Mikrokosmos project", AISB Workshop on Multilinguality in the Lexicon, Brighton, UK, 1996.
- [۷] عبدالله زاده ا، شمس فرد م، «هسته مدل پیشنهادی هستان شناسی در سیستم های درک زبان طبیعی»، هفتینم کنفرانس مهندسی برق ایران، اردیبهشت ۱۳۷۸
- [8] Shamsfard M., Abdollahzadeh A., "A Basis for Evolutionary Ontology Construction", 18th Iasted International Conference on Applied Informatics
- [۹] شمس فرد م، «یادگیری ماشینی»، گزارش فنی شماره ۱۰۰-۱-۱۰۰، آزمایشگاه سیستم های هوشمند، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر، شهریور ماه ۱۳۷۸
- [۱۰] شمس فرد م، «طراحی محیط پیاده سازی و تست هستی: سیستم یادگیری هستان شناسی مبتنی بر درک متون فارسی»، گزارش فنی شماره ۱۰۰-۱-۱۰۰، آزمایشگاه سیستم های هوشمند، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر، خرداد ماه ۱۳۷۹
- [11] Winston P. H., Horn B. K. P. "Lisp", 3rd edition, Addison Wesley, 1993.
- [۱۲] شمس فرد م، «هسته هستان شناسی، مفاهیم و عملگرهای اولیه»، گزارش فنی شماره ۱۰۰-۱-۱۰۰، آزمایشگاه سیستم های هوشمند، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر، بهار ۱۳۸۰
- [۱۳] شمس فرد م، «طراحی ساختار اولیه هستی: سیستم یادگیری هستان شناسی مبتنی بر درک متون فارسی»، گزارش فنی شماره ۱۰۰-۱-۱۰۰، آزمایشگاه سیستم های هوشمند، دانشکده مهندسی کامپیوتر، دانشگاه صنعتی امیرکبیر، شهریور ماه ۱۳۷۹
- [14] Saint-Diez P., Viegas E., "Computational Lexical semantics", Cambridge university press, 1995.