مرکز ملی فضای مجازی
پژوهشگاه فضای مجازی
CyberSpace Research Institute
CSRI

پژوهشکده فناوری اطلاعات

گروه سکوهای فناوری اطلاعات و فضای مجازی

گزارش فنی

تحلیل وردنت زبان فارسی در حوزه فاوا

مستخرج از پروژه: توسعه وردنت زبان فارسی در حوزه فاوا

کد پروژه: ۸۹۳۲۴۱۶

مجری:	محرم منصوری زاده
تهیه کننده/ تهیه کنندگان:	محرم منصوری زاده، محمد نصیری، محمد دادرس
کد گزارش:	ITF.ITP.TCH.۸۹۳۲۴۱۶.۱۱.V۰۲
تاریخ ارائه:	۹۱/۰۳/۲۷
نسخه/ وضعیت	۲,۰/ نهایی

پژوهشکده فناوری اطلاعات	عنوان گزارش: تحلیل وردنت زبان فارسی در حوزه فاوا	
	کد گزارش: ITF.ITP.TCH.۸۹۳۲۴۱۶،۱۱.V۰۲	وضعیت گزارش: نهایی

شناسنامه گزارش		
عنوان گزارش: تحلیل وردنت زبان فارسی در حوزه فاوا		**شماره نسخه:** ۲،۰
کد: ITF.ITP.TCH.۸۹۳۲۴۱۶،۱۱.V۰۲	**نوع گزارش:** فنی	**تاریخ ارائه گزارش:** ۹۱/۰۳/۲۷
نام پروژه: : توسعه وردنت زبان فارسی در حوزه فاوا		**نوع پروژه:** راهبردی-توسعه ای - بنیادی
تاریخ شروع: ۹۰/۰۴/۲۸		**تاریخ پایان:** ۹۱/۱۱/۱۱
نام گروه: سکوهای فناوری اطلاعات و فضای مجازی		
کد پروژه: ۸۹۳۲۴۱۶		**شماره و تاریخ قرارداد:** ۵۰۰/۶۶۱۴-۹۰/۰۴/۲۸/ت
مجری: محرم منصوری زاده		**ناظر/ ناظرین:** مریم محمودی، آنیتا هادیزاده، بهروز مینایی بیدگلی
تهیه کننده/ تهیه کنندگان: محرم منصوری زاده، محمد نصیری، محمد دادرس		
نام و نشانی مجری: همدان، دانشگاه بوعلی سینا، دانشکده مهندسی، گروه مهندسی کامپیوتر، کد پستی ۶۵۱۴۸۳۳۶۹۵، تلفن: ۸-۸۲۹۲۵۰۵-۰۸۱۱ فکس: ۸۲۹۲۶۳۱-۰۸۱۱		
نام و نشانی حمایت کننده: تهران، انتهای خیابان کارگر شمالی، پژوهشگاه فضای مجازی، کد پستی ۱۴۳۹۹۵۵۴۷۱، تلفن: ۸۴۹۷۷۷۷		
ملاحظات: ندارد		

چکیده:

در این سند تحلیل نیازها و دامنه پروژه توسعه وردنت زبان فارسی در حوزه فاوا ارائه شده است. تعریف حوزه فاوا و زیردامنه های آن، نحوه جمع آوری واژگان، متدلوژی ساخت وردنت فاوا و همچنین چرخه حیات واژگان به تفصیل در این سند مورد بحث قرار گرفته است. استراتژی اصلی ما ساخت یک وردنت دوزبانه انگلیسی-فارسی فاوا است که طی آن مفاهیم تخصصی حوزه فاوا از منابع متنوعی مانند کتاب‌های تخصصی، فرهنگ نامه‌ها و سایت‌های وب جمع آوری می‌شوند و سپس ارتباطات بین آنها به کمک روش‌های متن کاوی خودکار و نیمه خودکار استخراج می‌گردد. این مجموعه واژگان و روابط بین آن‌ها وردنت انگلیسی فاوا را تشکیل می‌دهند که در مرحله دوم به فارسی ترجمه شده و روابط ساختاری بین واژگان به آن اضافه می‌شود. روش‌ها و ایده های مطرح شده در این سند طی فازهای مختلف پروژه پیاده سازی شده و نتایج آن‌ها در سندهای جداگانه ارائه می‌شود.

کلمات کلیدی: وردنت فارسی، حوزه فاوا، تحلیل

وضعیت گزارش: نهایی	**زبان گزارش:** فارسی
وضعیت دسترسی: عادی	**تعداد صفحات:** ۳۲

چکیده

در این سند تحلیل نیازها و دامنه پروژه توسعه وردنت زبان فارسی در حوزه فاوا ارائه شده است. تعریف حوزه فاوا و زیردامنه های آن، نحوه جمع آوری واژگان، متدلوژی ساخت وردنت فاوا و همچنین چرخه حیات واژگان به تفصیل در این سند مورد بحث قرار گرفته است. استراتژی اصلی ما ساخت یک وردنت دوزبانه انگلیسی-فارسی فاوا است که طی آن مفاهیم تخصصی حوزه فاوا از منابع متنوعی مانند کتاب‌های تخصصی، فرهنگ نامه‌ها و سایت‌های وب جمع آوری می‌شوند و سپس ارتباطات بین آنها به کمک روش‌های متن کاوی خودکار و نیمه خودکار استخراج می‌گردد. این مجموعه واژگان و روابط بین آن‌ها وردنت انگلیسی فاوا را تشکیل می‌دهند که در مرحله دوم به فارسی ترجمه شده و روابط ساختاری بین واژگان به آن اضافه می‌شود. روش‌ها و ایده های مطرح شده در این سند طی فازهای مختلف پروژه پیاده سازی شده و نتایج آن‌ها در سندهای جداگانه ارائه می‌شود.

.

لیست مستندات مرتبط		
شماره مستند	نوع مستند	نام مستند

لیست تغییرات اعمال شده در نسخه های قبلی گزارش		
شماره نسخه	تاریخ	تغییرات اعمال شده
۱,۰	۱۳۹۰/۰۸/۱۱	نسخه اولیه
۲,۰	۱۳۹۱/۰۳/۲۷	نسخه نهایی

تایید کنندگان				
	نام و نام خانوادگی	تاریخ	امضاء	ملاحظات
مجری پروژه	محرم منصوری‌زاده			
تهیه کننده/ تهیه کنندگان	محرم منصوری زاده، محمد نصیری، محمد دادرس			
ناظر پروژه	مریم محمودی، آنیتا هادیزاده، بهروز مینایی بیدگلی			
مدیر گروه	علیرضا یاری			
مسئول مستندات پژوهشکده	زهره ساعی			
رئیس پژوهشکده/ معاون پژوهشی	علیرضا یاری			

تقدیر و تشکر

بدین وسیله از ناظرین و مشاورین محترم پروژه قدردانی می‌شود. همچنین از سرکار خانم دکتر نعمت زاده و جناب آقای دکتر مینایی به خاطر پیشنهادهای ارزشمندشان سپاسگزاریم.

در تدوین این گزارش و همچنین تعریف زیر دامنه های حوزه فاوا از راهنمایی‌ها و مشاوره های بسیار مفید کارشناسان و اساتید فناوری اطلاعات و زبان شناسی در دانشگاهی داخل و خارج کشور بهره برده‌ایم. کمترین کاری که می‌توان کرد، نام بردن از این عزیزان است. امیدواریم در آینده نیز بتوانیم از راهنمایی‌های سودمند این بزرگواران بهره‌مند باشیم.

ردیف	گروه	نام و نام خانوادگی	محل کار
۱	فاوا	دکتر سید وحید ازهری	دانشگاه علم و صنعت ایران
۲	فاوا	مهندس حسن بشیری	دانشگاه صنعتی همدان
۳	فاوا	مهندس نرگس بطحائیان	دانشگاه بوعلی سینا
۴	فاوا	دکتر حسن ختن‌لو	دانشگاه بوعلی سینا
۵	فاوا	دکتر میرحسین دزفولیان	دانشگاه بوعلی سینا
۶	فاوا	دکتر غلامرضا شاه محمدی	دانشگاه علوم انتظامی
۷	فاوا	دکتر محمد قدسی	دانشگاه صنعتی شریف
۸	فاوا	دکتر نصرا... مقدم چرکری	دانشگاه تربیت مدرس
۹	فاوا	مهندس محسن ملانوری	دانشگاه کالگری، کانادا
۱۰	فاوا	دکتر علی یزدیان	دانشگاه تربیت مدرس
۱۱	زبان‌شناسی	دکتر محمد راسخ مهند	دانشگاه بوعلی سینا
۱۲	زبان‌شناسی	دکتر امید طبیب زاده	دانشگاه بوعلی سینا

فهرست مطالب

عنوان **شماره صفحه**

فهرست اشکال

فهرست جداول

فهرست اختصارات

۱- درباره سند تحلیل

کلیات

هدف اصلی این سند تعریف دقیق نیازمندی‌ها، کاربردها و محدودیت‌های سیستم فوق می‌باشد. به صورت خلاصه، اهداف کلی تنظیم این سند عبارتند از:

- شناسایی مسائل و مشکلاتی که منجر به احساس نیاز برای وردنت فارسی فاوا شده‌اند
- شناسایی و استخراج نیازمندی‌ها و وظایف وردنت فارسی فاوا
- شناسایی کاربران، بهره برداران و دیگر افراد مرتبط با سیستم
- معرفی حوزه فاوا و تعیین دامنه واژگانی آن
- ارائه راه حل پیشنهادی برای توسعه وردنت فاوا

در ادامه و در فصل‌های بعدی جزئیات هر کدام از مباحث فوق به تفصیل توضیح داده می‌شوند.

۲- تعریف مسئله

۲-۱- لزوم تولید وردنت زبان فارسی در حوزه فاوا

زبان فارسی زبان رسمی کشور است و بر همین اساس زبان اول اسناد و مکاتبات رسمی و علمی است. از گذشته های دور کتاب‌ها، مقالات، گفتارها و نشریات متعددی در حوزه های گوناگون به این زبان تولید و منتشر شده است و هر روز هم بر حجم عظیم این محتوای زبانی اضافه می‌شود. بهره برداری از این همه محتوای تولید شده و پویا با روش‌های سنتی کتابخانه ای مقدور نیست و نیاز است که برای کاربردهایی نظیر مطالعات زبان شناختی، بازیابی اطلاعات و ترجمه ماشینی؛ ابزارهای نرم افزاری خودکاری تولید شوند تا این منابع ساختار دهی شده و به صورت منسجمی در دسته بندی‌های دستوری و معنایی قرار گیرند.

تاکنون مطالعات و تحقیقات متعددی در حوزه عمومی زبان انجام یافته و محصولات مفید و کاربردی هم داشته‌اند. پیکره واژگانی روزنامه همشهری محصول دانشگاه تهران یا طرح واژگان پایه دانش آموزان دوره ابتدایی محصول وزارت آموزش و پرورش نمونه های قابل ذکر در این حیطه هستند. اما در حوزه های تخصصی مانند فنی و مهندسی یا پزشکی فعالیتی جدی انجام نشده است. در این پروژه وردنت فارسی در حوزه تخصصی فناوری اطلاعات و ارتباطات (فاوا) ساخته می‌شود. این وردنت باید تسهیلات و امکانات نسخه ۳ وردنت زبان انگلیسی را برای زبان فارسی در این حوزه ارائه دهد.

۲-۲-شرح وظایف سیستم

وردنت فارسی فاوا باید مطابق با وردنت زبان انگلیسی نسخه ۳ بوده و امکانات زیر را داشته باشد:

۱- ثبت واژگان به زبان و خط فارسی

۲- ۳۰۰۰۰ (سی هزار) مدخل از پرکاربردترین واژه‌ها در حوزه تخصصی فوق

۳- پوشش مقوله های دستوری اسم، صفت، فعل و قید

۴- درج روابط میان مقوله ای و بین مقوله ای

۵- درج ویژگی‌های نحوی، ساخت واژی، آوایی، ویژگی‌های واژه‌ها و مجموعه ترادف‌ها

۶- امکان جستجوی پیشرفته و دو زبانه

۷- قابلیت اتصال به وردنت‌های دیگر

۸- قابلیت گسترش از لحاظ دامنه و پوشش لغوی و قابلیت تغییر، حذف و درج واژگان با استفاده از واسط کاربری واژه های از سوی کاربران مجاز

۹- قابلیت دسترسی و بکار گیری به صورت منفک، با واسط و همچنین به صورت API در اختیار سامانه های دیگر

۱۰- نرم افزار مدیریت واژگان به منظور اجازه اجرای عملیات حذف، درج و به هنگام سازی واژگان به صورت برخط از روی شبکه وب

۱۱- نحوه ساخت به صورت نیمه خودکار

۱۲- ارزیابی در چهار مرحله:

a. آزمون سازگاری توسط نرم افزار به منظور جلوگیری از ورود اطلاعات ناسازگار
b. تایید تیمی تخصصی به سرپرستی زبان‌شناسان حاذق و متخصص در حوزه فاوا و در حوزه فرهنگ نگاری
c. ثبت در حوزه جهانی وردنت
d. پذیرش مقالات

۲-۳- کارفرما، کاربران و همه افراد دخیل در سیستم

کارفرمای این پروژه موسسه تحقیقات ارتباطات و فناوری اطلاعات است و تیمی تخصصی وظیفه نظارت بر پروژه را بر عهده دارند.

کاربران این پروژه عبارتند از :

۱- ویرایشگران: وظیفه ورود و ویرایش اطلاعات را بر عهده دارند.

۲- پژوهشگران: دانشجویان و اساتید حوزه زبان که برای تحقیقات خود از دادگان این مرجع استفاده می‌کنند

۳- نرم افزارهای دیگر که با استفاده از واسط برنامه نویسی به این نرم افزار متصل می‌شوند.

۲-۴- بررسی پیشینه کارهای مرتبط

وردنت‌های موجود در سند مطالعه تطبیقی به تفصیل معرفی و بررسی شده‌اند. برای اطلاع از آخرین وردنت‌های ساخته شده می‌توانید به سایت انجمن جهانی وردنت[۱] مراجعه کنید. البته این سایت هیچ وردنت تخصصی را گزارش نکرده است[۲].

وردنت‌های موجود را می‌توان در قالب دسته های زیر مطالعه کرد:

- **وردنت انگلیسی:** وردنت انگلیسی نسخه اصلی وردنت بوده و ایده ساخت چنین شبکه معنایی برای واژگان این وردنت معرفی شد.
- **وردنت‌های تک زبانه غیر انگلیسی:** این وردنت‌ها ایده وردنت انگلیسی را برای زبان‌های مختلف پیاده سازی کرده‌اند. بسیاری از آن‌ها مانند وردنت یونانی، وردنت انگلیسی را به زبان دیگر ترجمه کرده‌اند [۱]. برخی از آن‌ها نیز مانند فارس‌نت، قالب وردنت را حفظ کرده و واژگان و روابط معنایی آن‌ها را بر اساس متون زبان مقصد استخراج نموده‌اند.
- **وردنت‌های چند زبانه:** نمونه شاخص این نوع وردنت‌ها، بالکانت است که زبان‌های شبه جزیره بالکان را پوشش می‌دهد.
- **وردنت‌های تخصصی:** وردنت‌های تخصصی موجود عموماً گسترش وردنت عمومی برای واژگان حوزه های تخصصی هستند که از میان آنها می‌توان به گسترش وردنت عمومی یونانی به حوزه روانشناسی را نام برد.

مطالعه روش‌شناسی توسعه وردنت‌های عمومی و گسترش آنها به حوزه‌های تخصصی می‌تواند کمک شایانی به توسعه وردنت فارسی فاوا بنماید.

[۱] http://www.globalwordnet.org/

[۲] این اطلاعات بر اساس آخرین مراجعه به سایت فوق در تاریخ ۱۳۹۰/۰۸/۰۱ به دست آمده است.

۳- حوزه فناوری اطلاعات و ارتباطات (فاوا)

برای درک صحیح از حوزه تخصصی فناوری اطلاعات و ارتباطات (فاوا) نیاز است ابتدا مفاهیم و اصطلاحات آن را تعریف کنیم. در اینجا سعی می‌کنیم تعاریف ساده، مختصر و قابل درکی از هر یک از مفاهیم مورد نظر ارائه کنیم. ادعایی نداریم که این تعاریف جامع و کامل می‌باشند اما حداقل برای اهداف ما کافی هستند.

۳-۱- داده، اطلاعات و دانش

داده[۱] محصول اندازه گیری کمیت‌ها یا سیگنال‌هاست. طول و عرض یک جسم، دمای یک اتاق در زمانی معین و نام گل‌های بومی یک منطقه جغرافیایی نمونه‌هایی از کمیت‌ها هستند. مقادیر اندازه گیری این کمیت‌ها اعداد و علایمی هستند که داده‌ها را تشکیل می‌دهند. به عنوان نمونه طول = ۳ متر و عرض = ۴ متر، دما =۲۲ درجه سانتی‌گراد و گل بومی = زنبق کوهی داده های حاصل از کمیت‌های فوق هستند.

اطلاعات[۲] به داده معنی‌دار گفته می‌شود. مثلاً اگر دمای اتاق در مقاطع معینی اندازه گیری و ثبت شود، میانگین حسابی این مقادیر بیانگر دمای متوسط اتاق در طول زمان و نوعی **اطلاعات** است. اگر دما از حد معینی بالاتر رود، باید پنجره را باز کرد. این *قانون* در کنار اطلاعات ***دانش***[۳] را می‌سازد.

۳-۲- فناوری اطلاعات و ارتباطات چیست ؟

فناوری اطلاعات و ارتباطات (فاوا) اصطلاحی است که تعریف واحدی که همه متخصصان و کاربران بر آن اتفاق نظر داشته باشند؛ ندارد. بسته به نیاز، هر شخص، سازمان و کشوری می‌تواند تعریف مورد نظر خود را از

[۱] Data
[۲] Information
[۳] Knowledge

آن ارائه کند. بر اساس گزارشی که سازمان جهانی مخابرات (ITU) درباره اندازه گیری فعالیت‌های مرتبط با فاوا در کشورهای مختلف منتشر کرده است؛ هر کشوری تعریف خاص خود را از این مقوله دارد [۲]. البته نکات مشترکی در اغلب این تعاریف وجود دارد که بیان آنها می‌تواند به درک مفهوم این حوزه تخصصی کمک کند. بر اساس تعاریف موجود در فرهنگ لغات، سایت‌های مرجع کتاب‌های تخصصی این حوزه می‌توان چنین استنباط کرد که :

فناوری اطلاعات و ارتباطات به مجموعه دستگاه‌ها، ابزارها و روش‌هایی اطلاق می‌شود که برای تولید، فرآوری، جابجایی و کاربری اطلاعات بکار می‌روند.

بر اساس تعریف فوق، رادیو، تلویزیون، تلفن، دورنگار، کامپیوتر و اینترنت، چاپگر، اسکنر و دوربین‌های دیجیتال را می‌توان از جمله ادوات فاوا نام برد. نرم افزارها و الگوریتم‌های ثبت و ضبط داده‌ها و تحلیل آن‌ها در زمره ابزارهای تولید و فراوری اطلاعات قرار می‌گیرند. همچنین انواع شبکه‌ها و پروتکل‌های مورد استفاده در آن‌ها نیز وظیفه جابجایی اطلاعات را بر عهده دارند.

۳-۳- زیر دامنه های حوزه فاوا

حوزه فاوا مشتمل بر زیر دامنه های متعدد و متنوعی مانند تئوری اطلاعات، شبکه های کامپیوتری، بازی‌های رایانه ای می‌باشد. مطالعه حوزه فاوا در قالب زیر دامنه‌ها این امکان را ایجاد می‌کند که برای هر مفهوم واژه حوزه کاربردی خاص تعریف و معین گردد.

چندین انجمن و نهاد علمی مانند ACM[۱] ، دایرکتوری وب dmoz[۲] و Wikipedia[۳] زیر دامنه های پیشنهادی خود را برای حوزه فاوا معرفی کرده‌اند. در این پروژه از فهرست پیشنهادی ACM تا دو سطح استفاده می‌کنیم. در جدول زیر عناوین تعدادی از این زیر دامنه‌ها را آورده‌ایم. فهرست کامل زیر دامنه‌ها در پیوست ۳ آمده است.

جدول ۳-۱) عناوین تعدادی از زیر دامنه های حوزه فاوا

عنوان فارسی	عنوان انگلیسی
تحلیل الگوریتم‌ها و پیچیدگی مسئله‌ها	ANALYSIS OF ALGORITHMS AND PROBLEM COMPLEXITY
مداری‌های منطقی و محاسباتی	ARITHMETIC AND LOGIC STRUCTURES
هوش مصنوعی	ARTIFICIAL INTELLIGENCE
کدگذاری و تئوری اطلاعات	CODING AND INFORMATION THEORY

[۱] www.acm.org
[۲] www.dmoz.org
[۳] www.wikipedia.com

گرافیک کامپیوتری	COMPUTER GRAPHICS
شبکه های ارتباطی کامپیوتری	COMPUTER-COMMUNICATION NETWORKS
رمزنگاری داده‌ها	DATA ENCRYPTION
ساختار داده‌ها	DATA STRUCTURES
مدیریت پایگاه داده‌ها	DATABASE MANAGEMENT
ریاضیات گسسته	DISCRETE MATHEMATICS
پردازش متن و اسناد	DOCUMENT AND TEXT PROCESSING
پردازش تصویر و بینایی ماشین	IMAGE PROCESSING AND COMPUTER VISION
ذخیره و بازیابی اطلاعات	INFORMATION STORAGE AND RETRIEVAL
ساختارهای حافظه	MEMORY STRUCTURES
سیستم‌های عامل	OPERATING SYSTEMS
ساختار پردازنده‌ها	PROCESSOR ARCHITECTURES
زبان‌های برنامه سازی	PROGRAMMING LANGUAGES
مهندسی نرم افزار	SOFTWARE ENGINEERING
بازی سازی و تئوری بازی‌ها	GAIMING AND GAME THEORY

باید توجه کرد که برخی از این زیر دامنه‌ها با علوم دیگر نیز خویشاوندی نزدیکی دارند. مثلاً *الگوریتم و محاسبات* هم در زمینه فاوا و هم در زمینه ریاضیات قابل طرح و بررسی است.

۳-۴- زبان و واژگان حوزه فاوا

فاوا علمی پویاست و هر روز نوآوری‌هایی در جنبه های مختلف آن ظاهر می‌شود. این پویایی ادبیات فاوا را هم دستخوش تغییر می‌سازد و واژگان جدیدی به آن اضافه می‌کند. رواج اینترنت سبب ایجاد واژگان جدیدی در حوزه عمومی زبان نیز شده است. حجم این واژگان جدید آنقدر قابل توجه است که به فرهنگ لغات معتبری مانند آکسفورد فصل جدیدی با عنوان لغات حوزه فناوری اطلاعات و اینترنت اضافه شده است [۳]. بر این اساس منابع واژگانی فاوا باید جدید، به روز و غنی باشند. در این راستا می‌توان از منابع زیر استفاده کرد.

- اصطلاح‌نامه‌ها[۱] و فرهنگ لغت‌های تخصصی فاوا (یک زبانه و دو زبانه)
- کتاب‌هایی که در حوزه عمومی و کاربردی فاوا منتشر می‌شوند و معمولاً مطابق با جدیدترین تغییرات فناوری ویرایش و چاپ می‌شوند.

[۱] Thesaurus

- روزنامه‌ها، مجلات و انواع گاهنامه های تخصصی و نیمه تخصصی که عمدتاً تغییرات و اخبار فاوا را منتشر می‌کنند.
- پایگاه های وب

بیشتر اصطلاحات فاوا به زبان انگلیسی است و متخصصین این حوزه در محاورات علمی و حتی عمومی از همان صورت انگلیسی استفاده می‌کنند. در مقابل، کاربران عمومی فاوا معمولاً از ترجمه متون به زبان خودشان استفاده می‌کنند. تحول پرشتاب فاوا در این بخش هم اثرگذار است و معادل سازی‌ها و ترجمه های انجام شده معطل فرایندهای دقیق اما زمان‌بر واژه گزینی نمی‌مانند. هر مترجم بنا بر توانایی‌ها و اطلاعات و گاهی سلیقه خودش معادل‌های مناسب را انتخاب می‌کند. به همین دلیل هم هست که در ادبیات فاوا معادل‌های متعددی برای یک اصطلاح یافت می‌شوند. به عنوان نمونه می‌توان به اصطلاح Context Free Grammars اشاره کرد. اگر کتاب‌های طراحی زبان‌های برنامه سازی را بررسی کنید به معادل‌هایی مانند *گرامرهای بدون متن، گرامرهای متن باز و گرامرهای مستقل از متن* برخورد خواهید کرد. یک خواننده – به ویژه خواننده ای که از مفهوم این اصطلاح در زبان اصلی آگاهی ندارد- معمولاً در مواجهه با این معادل‌ها دچار ابهام و تردید می‌شود. استفاده از این معادل‌های ناهمگون در پردازش‌های لغوی و زبانی بسیار زیان‌آورتر است. زیرا یک مفهوم در زبان مبدأ با چندین اصطلاح در زبان مقصد معرفی شده که هر کدام از این اصطلاحات حوزه معنایی خاص و متفاوت خود را دارند. مثلاً *گرامر بدون متن* بیانگر این مفهوم است که گرامر مذکور پارامتری با نام متن را ندارد و مثلاً ساده تر و محدود تر از گرامرهای دارای متن است. در حالی که گرامر مستقل از متن نشان دهنده این است که این گرامر نیازی به متن ندارد و دامنه آن وسیع‌تر است. بر اساس این حقایق، پژوهش‌های لغوی و معنایی واژگانی باید بر اساس همان صورت اصلی واژه انجام گیرد و نهایتاً در صورت لزوم یافته های آن به زبان‌های مقصد ترجمه گردد.

مجموعه واژگان حوزه فاوا را از منابع فوق‌الذکر می‌توان استخراج کرد. البته تشخیص واژگان فاوا از واژگان غیر فاوا کاملاً خودکار نیست اما می‌توان بخش‌های زیادی از آن را به صورت خودکار انجام داد. مثلاً استخراج واژگان پرکاربرد کتاب‌ها و سپس پالایش خودکار و دستی آن‌ها یکی از این روش‌هاست. در این روش بسامد تک‌تک واژگان کتاب‌ها (یا هر منبع مورد استفاده دیگر) محاسبه شده و واژگانی که بسامد آن‌ها از حد معینی بالاتر باشد؛ استخراج می‌شوند. پر بسامدترین واژگان کتاب‌های فارسی کلمات و حروف ربط مانند *که، و ، به، می* و مانند آن و کتاب‌های انگلیسی the, it , is , و موارد مشابه هستند. این نوع کلمات ، کلمات ایست (توقف) می‌نامند. واژگان پربسامد بعد از کلمات ایست هستند که امید می‌رود جزو کلمات تخصصی کتاب باشند. بر اساس مطالعاتی که Nation انجام داده است، تنها ۲۰ درصد کلمات پربسامد کتاب‌های علمی و فنی نیمه تخصصی و حداکثر ۱۰ درصد آن‌ها جزو کلمات تخصصی محسوب می‌شوند [۴]. مجموعه اولیه واژگان ممکن است بیش از صد هزار واژه داشته باشد. انتخاب دستی واژگان تخصصی کاری زمان‌بر بوده و به دقت زیاد نیاز دارد. برای حذف کلمات غیر ضروری می‌توان از فرهنگ لغت‌های عمومی بهره گرفت.

مقوله های دستوری اسم، صفت، فعل و قید جداگانه در وردنت مطالعه می‌شوند. همان‌طوری که در جدول و شکل زیر دیده می‌شود، بیشتر واژگان بررسی شده از مقوله اسم هستند. برای مقایسه حوزه تخصصی فاوا با حوزه عمومی از فرهنگ لغات مایکروسافت استفاده کردیم [۵]. این فرهنگ حدود ده هزار مدخل دارد و مقوله دستوری هر کدام از آن‌ها را نیز مشخص کرده است. در حوزه فاوا نیز مقوله اسم با اختلاف زیاد از سایر مقوله‌ها بیشتر است و مقوله قید تنها با هفت مدخل کمترین بسامد را دارد.

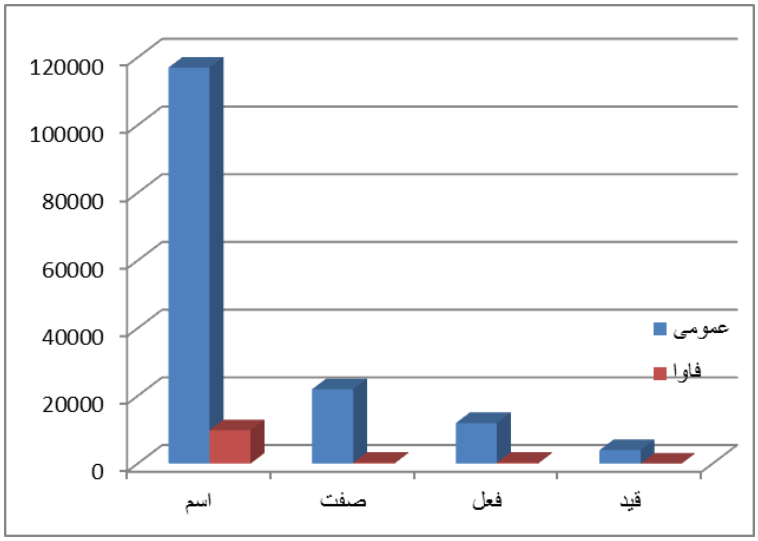

شکل ۳-۱) نمودار بسامد واژگان مقوله های مختلف دستوری

جدول ۳-۲) بسامد واژگان زبان در مقوله های مختلف

	عمومی	فاوا
اسم	۱۱۷۰۰۰	۹۹۰۰
صفت	۲۲۰۰۰	۳۰۲
فعل	۱۲۰۰۰	۳۲۶
قید	۴۰۰۰	۷

۳-۵- جمع بندی

منابع مهم واژگانی در حوزه فاوا کتاب‌ها و صفحات وب تخصصی هستند و از این منابع می‌توان برای استخراج واژگان استفاده کرد. با توجه به حجم کم واژگان فاوا که معادل‌های فارسی مصوبی دارند، رویکرد اصلی در این پروژه توسعه وردنت فاوا و زبان انگلیسی و سپس ترجمه آن به فارسی است. حوزه تخصصی فاوا دامنه واژگانی محدودتری نسبت به حوزه عمومی زبان دارد اما ترکیب مقوله های مختلف دستوری آن تقریباً شبیه حوزه عمومی است. در این حوزه قید کمترین بسامد را دارد.

۴- روش شناسی توسعه وردنت فاوا

در این بخش متدولوژی ساخت وردنت فاوا را معرفی می‌کنیم. از آنجایی که واژگان فارسی حوزه فاوا از زبان انگلیسی برگرفته شده‌اند، در این متدلوژی ابتدا وردنت فاوا را در زبان انگلیسی توسعه داده و سپس به زبان فارسی ترجمه می‌کنیم. به این ترتیب وردنت توسعه داده شده دارای دو نسخه انگلیسی و فارسی است که در کنار هم قرار دارند و مفاهیم متناظر آنها به همدیگر نگاشت می‌شوند.

با توجه به اینکه که در زبان انگلیسی برای واژه‌ها تعاریف مناسبی ارائه شده و همچنین روش‌های کارآمدی برای استخراج خودکار روابط معنایی بین واژگان و مفاهیم ارائه شده است، این روش شناسی فرایند توسعه وردنت فاوا به زبان انگلیسی خیلی سریع اجرا می‌شود. توسعه نسخه فارسی وردنت فاوا مشتمل بر ترجمه مفاهیم از زبان انگلیسی به فارسی و ایجاد روابط ساختاری بین واژگان است.

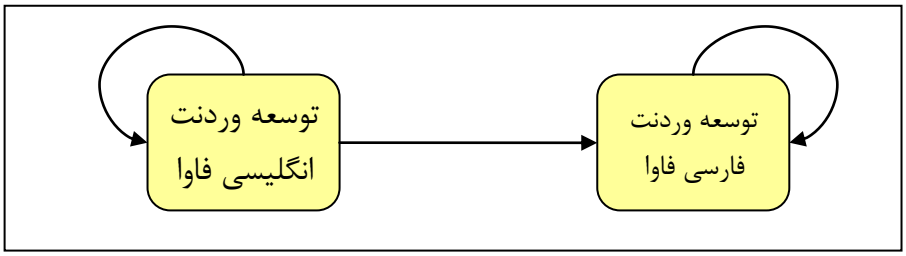

شکل ۴-۱) توسعه وردنت دوزبانه انگلیسی-فارسی فاوا

اگر از بعد حجم واژگان به توسعه وردنت فاوا نگاه کنیم، این فرایند شامل دو مرحله اصلی است که در مرحله اول آن بانک واژگانی اولیه وردنت فاوا ایجاد می‌شود. این بخش شامل تعریف زیردامنه های فاوا و مجموعه واژگان اولیه آن‌هاست و فقط یک‌بار اجرا می‌شود(شکل زیر).

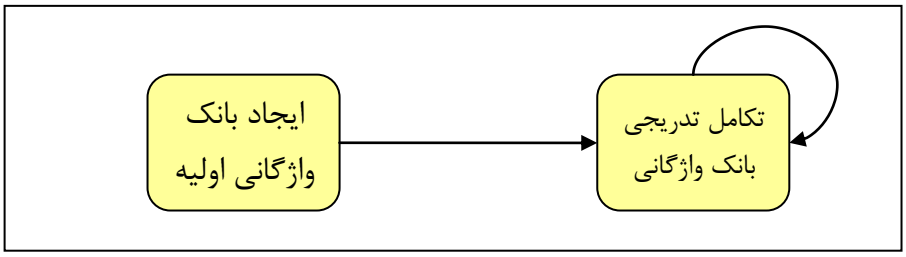

شکل ۴-۲) توسعه حجمی وردنت فاوا

فرایند تکمیل واژگانی یک فرایند تکراری است که به مرور به حجم واژگان وردنت اضافه می‌شود. این کار از طریق ویرایشگر رومیزی و تحت وب انجام می‌گیرد.

۴-۱- نحوه تعامل تیم زبان شناسی و تیم فناوری اطلاعات

در پروژه توسعه وردنت فاوا با همکاری تیم‌های فناوری اطلاعات و زبان‌شناسی توسعه می‌یابد. وظایف اصلی تیم فناوری اطلاعات عبارتند از:

- ایجاد زیرساخت نرم افزاری برای میزبانی وردنت
- گزینش و معرفی واژگان تخصصی حوزه فاوا به زبان انگلیسی
- توسعه روش‌های خودکار استخراج اطلاعات مورد نیاز از متن‌های خام یا ساختاریافته

تیم زبان‌شناسی بر تولید محتوا نظارت دارد و فرایند های زبانی را برای استخراج انواع اطلاعات پیشنهاد یا طراحی می‌نماید. وظایف اصلی این تیم عبارت است از:

- نظارت بر ترجمه واژگان و ترادف‌ها
- تعریف ساختارهای واژگانی فارسی و روابط بین آن‌ها
- طراحی روش‌هایی برای استخراج روابط و اطلاعات ساختاری

برای پرهیز از هرگونه ناسازگاری و ناهماهنگی در بانک اطلاعاتی، ورود و ویرایش دادگان بانک اطلاعاتی تنها به وسیله تیم فناوری اطلاعات انجام می‌گیرد. نحوه تعامل با تیم زبان‌شناسی به این صورت است که داده های مورد نیاز این تیم در قالب‌هایی که استفاده از آن‌ها راحت است، در اختیار این تیم قرار می‌گیرد. پیش بینی شده است که دو قالب اصلی پایگاه داده های Microsoft Access و فایل‌های Microsoft Excel برای ورود یا ویرایش اطلاعات به وسیله تیم زبان شناسی مورد استفاده قرار گیرند. امروزه تقریباً همه دانشگاهیان با این ابزارها آشنا هستند و دوره های معین کسب مهارت‌های پایه فناوری اطلاعات برای آموزش اساتید و دانشجویان همه رشته‌ها برگزار می‌شود. برای آشنایی بیشتر با این نحوه از تعامل، فرایند ترجمه واژگان را به صورت مثال در اینجا ذکر می‌کنیم:

تیم فناوری اطلاعات برای هر کدام از واژگان تخصصی، معادل یا معادل‌های فارسی را پیشنهاد کرده و فهرست این واژگان به همراه معادل‌های فارسی را در قالب فایل Excel در اختیار تیم زبان‌شناسی قرار می‌دهد. تیم زبان شناسی این فایل را ویرایش کرده و به تیم فناوری اطلاعات برمی گرداند. تیم فناوری اطلاعات دادگان ویرایش شده را به پایگاه اضافه می‌نماید.

پر واضح است که فعالیتی مانند گزینش معادل فارسی برای معمولاً به تعامل و بحث‌های دو سویه بین دو تیم نیاز دارد. به همین سبب جلسات منظمی بین این دو تیم برگزار شده و تبادل نظر انجام می‌گیرد.

۴-۲-توسعه هسته اولیه وردنت فاوا

همان‌طوری که در شکل زیر به صورت نمودار گردش کار نشان داده شده است، فرایند توسعه هسته اولیه وردنت شامل مراحل زیر است. توضیحات مفصل این مراحل در قالب زیربخش هایی در ادامه ارائه شده است.

- طراحی شمای واژگانی
- استخراج واژگان تخصصی حوزه فاوا در زبان انگلیسی
- تعریف ترادف‌ها و استخراج روابط معنایی بین آن‌ها در زبان انگلیسی
- ترجمه و ثبت واژگان در وردنت فارسی
- تکمیل اطلاعات ساختاری وردنت فارسی
- آزمون صحت و کیفیت وردنت تولید شده

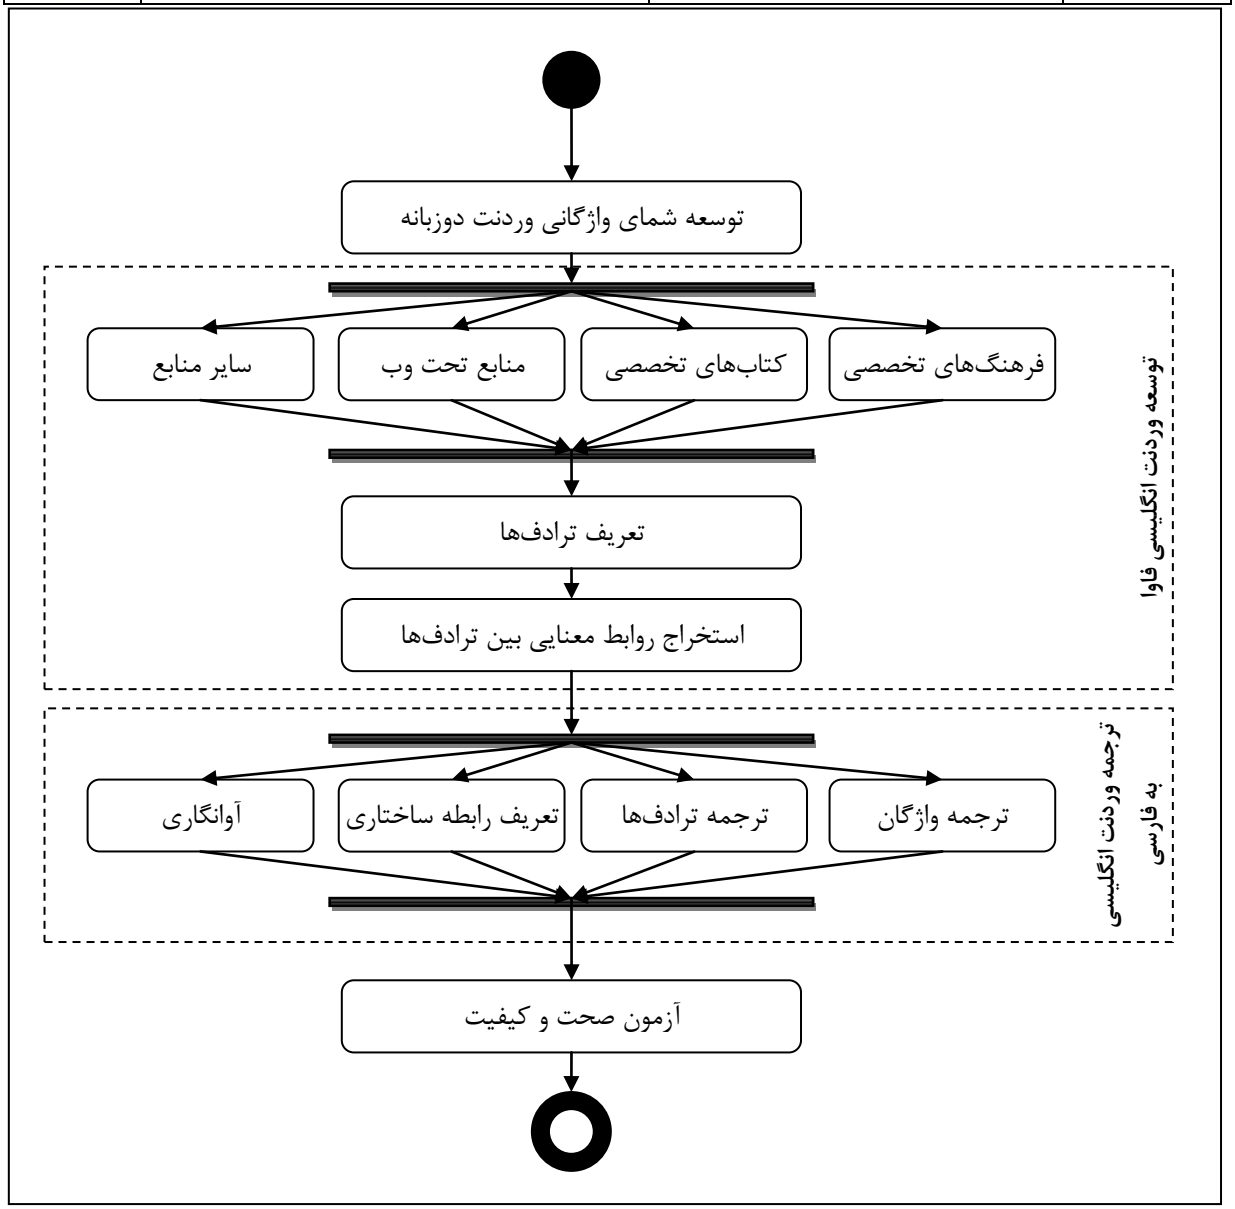

شکل ۴-۳) توسعه هسته اولیه وردنت دوزبانه انگلیسی-فارسی فاوا

۴-۳- توسعه شمای واژگانی وردنت فاوا

شمای واژگانی وردنت دوزبانه انگلیسی-فارسی فاوا ساختار اطلاعاتی پایگاه داده را تشریح می‌کند که در آن جدول‌ها و نماها برای نگهداری اطلاعات واژگان و روال‌ها برای پرس و جو و ویرایش این اطلاعات تعبیه شده‌اند. این شما نگاشت بین وردنت انگلیسی و فارسی فاوا را در سطح واژگان و ترادف‌ها ممکن می‌سازد.

نرم افزارهای کاربردی مانند مرورگر و ویرایشگر از این امکانات استفاده کرده و خدمات خاص خود را ارائه می‌دهند. از جمله خدمات این برنامه‌ها می‌توان درج، ویرایش و حذف واژگان و اطلاعات آن‌ها و جستجو در پایگاه و تهیه گزارش‌ها را می‌توان نام برد. برای اطلاع بیشتر درباره شمای واژگانی به سند « طراحی شمای واژگانی » مراجعه نمایید.

۴-۴-توسعه وردنت فاوا به زبان انگلیسی فاوا

همان‌طوری که پیش‌تر گفتیم، وردنت تخصصی فاوا ابتدا به زبان انگلیسی ساخته می‌شود. در این مرحله واژگان تخصصی استخراج شده و سپس در قالب ترادف‌ها دسته بندی می‌شوند. در انتها روابط معنایی بین ترادف‌ها استخراج می‌شود. در ادامه هرکدام از این کارها را بیشتر توضیح می‌دهیم.

۴-۴-۱- استخراج واژگان و اصطلاحات تخصصی حوزه فاوا در زبان انگلیسی

واژگان حوزه فاوا را از منابع مختلف می‌توان جمع آوری کرد. در زبان فارسی چندین فرهنگ لغت در حوزه فاوا منتشر شده‌اند که تعدادی از آن‌ها ترجمه های متفرقه از فرهنگ لغت‌های دیگر هستند و تعدادی نیز وجود دارند که به صورت تلفیقی از متون فاوا و فرهنگ لغت‌های دیگر ساخته شده‌اند. نمونه‌هایی از فرهنگ لغت‌های قابل استفاده فاوا در این پروژه را می‌توان چنین برشمرد:

- اصطلاح‌نامه‌ها و فرهنگ لغت‌های فارسی
  - اصطلاح‌نامه های علوم، سازمان اسناد و مدارک ملی ایران[۶]
  - فرهنگ معاصر، واژه نامه کامپیوتر [۷]
  - فرهنگ تشریحی کامپیوتر مایکروسافت [۸]
- اصطلاح‌نامه‌ها و فرهنگ لغت‌های غیر فارسی
  - فرهنگ علوم و تکنولوژی مک‌گروهیل[۹]
  - فرهنگ تخصصی مایکروسافت [۵]

امروزه تقریباً همه کتاب‌ها به صورت کامپیوتر تایپ و صفحه بندی می‌شوند و نسخه الکترونیکی بسیاری از آن‌ها نیز به همراه نسخه چاپی در قالب محصول جداگانه منتشر می‌شود. به کمک تکنیک‌های آماری و متن کاوی می‌توان واژگان پربسامد این کتاب‌ها را استخراج کرده و پس از پالایش‌های ماشینی انبوه، به صورت دستی نیز آن‌ها را کنترل کرد. روش‌های متعدد آماری و ساختاری برای تشخیص کلمات مرکب وجود دارد که از بین آنها می‌توان تحلیل آماری باهم‌آیی[۱] واژگان را می‌توان نام برد.

در مرحله انتخاب واژگان تخصصی، کتاب‌ها، سایت‌ها، فرهنگ نامه‌ها و مجموعه های لغت که به صورت بالقوه می‌توانند شامل تعداد قابل توجهی از واژگان تخصصی فاوا باشند انتخاب می‌شوند. سپس مجموعه واژگان هر منبع استخراج می‌شود.از میان این منابع کتاب‌های تخصصی و متون مشابهی که ساختار معینی ندارند به پیش پردازش‌هایی مانند محاسبه n-gram ها نیازمند هستند اما منابع ساختاریافته چنین پیش پردازش‌هایی نیاز ندارند. نهایتاً کارشناس متخصص فاوا مجموعه واژگان منتخب را بررسی کرده و واژگان

[۱] Collocation

غیر فاوا را حذف می‌نماید. در سند «فرهنگ نگاری و تکمیل بانک واژگانی» نحوه استخراج واژگان تخصصی و منابع آنها به تفصیل معرفی شده است.

۴-۴-۲- تعریف ترادف‌ها و استخراج روابط معنایی بین آن‌ها

واژگان استخراج شده ابتدا در قالب ترادف‌ها دسته بندی می‌شوند و سپس رابطه معنایی بین این ترادف‌ها تعریف می‌شود. برای تعیین ترادف‌ها، به کمک تکنیک‌های مختلف مانند متن کاوی رابطه *مترادف بودن* بین واژگان کشف می‌شوند.

با نگاهی به هرکدام از وردنت‌های موجود می‌توان دریافت که تعداد ترادف‌های آن‌ها حداکثر حدود ۸۰ درصد تعداد کل واژگان آن‌هاست. بر این اساس اگر حوزه فاوا دارای حدود ده هزار واژه باشد؛ می‌توان امیدوار بود که حدود هشت هزار مجموعه ترادف داشته باشیم. فرایندهای متن کاوی حداکثر دو برابر این تعداد را به عنوان مجموعه اولیه مترادف‌ها گزارش می‌کنند. پالایش و انتخاب مجموعه نهایی برای این حجم از داده‌ها رامی توان به صورت دستی انجام داد. در سند «استخراج روابط معنایی » به صورت مفصل در این باره بحث می‌نماییم.

۴-۵- ترجمه وردنت انگلیسی فاوا به فارسی

ساخت وردنت فارسی فاوا شامل ترجمه واژگان، ترجمه تعریف ترادف‌ها و همچنین تعریف ساختار و روابط ساختاری واژگان است. در ادامه هرکدام از این فعالیت‌ها را بیشتر توضیح می‌دهیم.

در فرایند ترجمه سعی می‌شود به کمک متخصصان حوزه فاوا و زبان‌شناسان مجرب در حوزه واژه‌گزینی از بین معادل‌های موجود، مناسب‌ترین معادل فارسی برای واژگان و اصطلاحات فاوا انتخاب گردد. برای واژگانی که معادل فارسی برای آن‌ها هنوز وجود ندارد نیز می‌توان معادل‌های مناسبی با رعایت قواعد واژه گزینی مصوب فرهنگستان، پیشنهاد داد.

فرایند ترجمه واژگان و ترادف‌ها برای همه واژگان یکی نیست. ترجمه بسیاری از واژگان در فرهنگ لغت‌ها و واژه نامه های تخصصی معتبر موجود است. منظور از منابع معتبر در اینجا فرهنگ لغت‌های تخصصی مانند فرهنگ کامپیوتر معاصر یا واژه نامه‌ها یا کتاب‌های است که متخصصان برجسته حوزه فاوا آن‌ها را تألیف نموده‌اند. فهرست زیر نمونه‌هایی از این آثار است:

- محمد تقی روحانی رانکوهی، مفاهیم بنیادی پایگاه داده‌ها، نشر جلوه، ۱۳۹۰
- محمد قدسی، داده ساختارها و مبانی الگوریتم‌ها، انتشارات فاطمی، ۱۳۸۸
- محمدرضا محمدی فر، مبانی نمایه سازی، سازمان چاپ و انتشارات وزارت ارشاد، ۱۳۸۱

اگر ترجمه واژه ای در این قبیل از منابع موجود باشد، همین ترجمه مستقیماً در وردنت فارسی فاوا درج می‌شوند. فرایند کار به این شکل است که تیم ترجمه برای هر دسته معنایی این واژه از بین معادل‌های فارسی موجود مناسب‌ترین گزینه را انتخاب و ثبت می‌نماید. بسیاری دیگر از واژگان تخصصی فاوا اسم خاص هستند و نیازی به ترجمه ندارند. این واژگان به همان صورت انگلیسی وارد پایگاه داده فارسی می‌شوند.

برای مجموعه باقیمانده واژه‌ها تیم ترجمه گزینه‌هایی را از کتب تخصصی پر تیراژ انتخاب می‌کند. این کتب ممکن است به اندازه منابع فوق معتبر نباشند اما به هر حال تنها منابع باقیمانده هستند. این ترجمه‌ها در دو مرحله بازبینی و ویرایش می‌شوند. در مرحله اول کارشناسان خبره فاوا و در مرحله دوم کارشناسان زبان شناسی فرایند معادل‌های انتخاب شده را بررسی و و در صورت لزوم تصحیح می‌نمایند.

ترجمه تعریف ترادف‌ها هم مسیر مشابهی را طی می‌کند. بدین معنی که ابتدا تیم ترجمه برای هر ترادف معنی آن را ترجمه کرده و به تیم کارشناسان فاوا تحویل می‌دهد. سپس این تیم ترجمه‌ها را بازبینی و ویرایش کرده و جهت اعلام نظر به تیم زبان شناسی ارائه می‌دهد. تیم زبان شناسی اصلاحات نهایی را انجام می‌دهد و پس از آن تعریف ترادف در پایگاه وردنت درج می‌گردد.

درج اطلاعات ساختاری واژگان مانند ساختار ظرفیتی افعال و همچنین رابطه اشتقاق بین واژگان کلاً به وسیله تیم زبان شناسی انجام می‌پذیرد. بخش‌هایی از این فرایند مانند استخراج ریشه واژگان یا نوع اشتقاق به صورت خودکار صورت می‌گیرد.

۴-۶-آزمون صحت و کیفیت

پس از ساخت وردنت فاوا، محصول نهایی به روش‌های مختلف تحت آزمون قرار می‌گیرد. همان‌طوری که در سند طرح آزمون هم به تفصیل بیان شده است، به صورت عمده دو دسته آزمون نرم افزار و آزمون محتوا در اینجا انجام می‌گیرد. آزمون‌های نرم افزار به منظور اطمینان از صحت عملکرد و ارائه امکانات خواسته شده در تعریف پروژه انجام می‌گیرند. آزمون محتوا نیز به منظور اطمینان از درستی اطلاعات ارائه شده درباره واژگان و روابط بین آن‌ها انجام می‌گیرند. برای اطلاع بیشتر درباره این آزمون‌ها به سند «طرح آزمون وردنت فاوا » مراجعه نمایید.

۵- چرخه حیات یک واژه

آنچه که در نسخه های نهایی وردنت وجود دارد، واژگان و اطلاعات آن‌هاست. برای پرهیز از پیچیدگی‌های طراحی، اطلاعات جنبی مانند مرجع واژه، وضعیت فعلی واژه یا نام کاربری که آن را وارد پایگاه کرده در به صورت جداگانه در قالب فایل‌های Excel نگهداری می‌شود.

۵-۱- چرخه حیات واژه در وردنت انگلیسی

پس از گزینش واژگان تخصصی، برای هر واژه پرونده ای تشکیل می‌شود. در این پرونده اطلاعاتی مانند مرجع اصلی، تعریف، فونتیک، واژگان مرتبط، ترجمه و همچنین وضعیت فعلی ثبت واژه در پایگاه وردنت ذخیره می‌شود. وضعیت ثبت واژه پس از انجام هر فعالیتی درباره آن، به روز می‌شود. هنگام ذخیره واژه قواعد زیر رعایت می‌شود:

- حداقل اطلاعات لازم برای ذخیره یک واژه در پایگاه صورت املایی آن است. یعنی هیچ واژه بدون صورت املایی در پایگاه وجود ندارد.
- اطلاعات جنبی یک واژه مانند آوانگاری، عضویت در ترادف یا اطلاعات ساختاری آن در هر زمانی پس از ذخیره واژه قابل تعریف یا تغییر است.
- هر واژه تنها در صورتی در پایگاه ذخیره می‌شود که حداقل یک تعریف برای آن وجود داشته باشد.

شرط لازم و کافی برای اینکه ثبت یک واژه در وردنت فاوا کامل تلقی شود این است که :

- صورت املایی و آوایی آن در پایگاه ثبت شده باشد.
- اطلاعات ساختاری آن مانند ساختار ظرفیتی فعل یا نوع صفت ثبت شده باشد.
- واژه مورد نظر عضو حداقل یک ترادف تعریف شده باشد.

بدیهی است که هر واژه ممکن است عضو بیش از یک ترادف باشد یا صورت‌های مختلف املایی و آوایی داشته باشد. وظیفه ثبت نهایی واژگان در وردنت انگلیسی فاوا به عهده ویرایشگران تیم فاوا است. پس از تعریف واژگان، ترادف‌ها را می‌توان تعریف کرد.

شرط لازم و کافی برای ثبت نهایی یک ترادف در وردنت انگلیسی فاوا این است که:

- برای این ترادف تعریف ارائه شود
- مقوله دستوری و مقوله معنایی (زیر دامنه فاوا) آن مشخص شده باشد
- حداقل یک واژه عضو ترادف شود.

در مرحله بعد با استفاده از روش‌هایی که در سند« استخراج روابط معنایی به صورت خودکار» به تفصیل معرفی شده‌اند، روابط معنایی حاکم بین واژگان استخراج می‌شود. از آنجایی که رابطه های معنایی بین ترادف‌ها تعریف می‌شوند؛ شرط لازم و کافی برای ایجاد یک رابطه معنایی بین دو ترادف این است که هر دو ترادف و رابطه معنایی مذکور تعریف شده باشند.

۵-۲- چرخه حیات واژه در وردنت فارسی

وردنت فارسی ترجمه واژگان و ترادف‌های وردنت انگلیسی است. بر اساس معانی مختلف، یک واژه در زبان انگلیسی ممکن است به چندین واژه در زبان فارسی ترجمه شود. در حوزه عمومی زبان می‌توان واژه Spring را مثال زد که معانی فارسی آن *بهار*، *چشمه* و *فنر می‌باشد*. در حوزه فاوا نیز می‌توان واژه Index را نام برد که معادل‌های فارسی *شاخص*، *اندیس* و *شماره ردیف* برای آن وجود دارند. برای پرهیز از ابهام، ترادف‌های وردنت انگلیسی و فارسی به همدیگر نگاشت می‌شوند. بر این اساس شرط لازم و کافی برای اینکه یک ترادف در وردنت زبان فارسی وجود داشته باشد این است که ترادف متناظر آن در وردنت زبان انگلیسی وجود داشته باشد.

هنگام ترجمه یک ترادف از زبان انگلیسی به فارسی، برای هر واژه معادل مناسبی گزینش می‌شود. باید توجه داشت که ممکن است دو واژه انگلیسی یک معادل فارسی داشته باشند. به عنوان نمونه در متون فارسی به جای هر دو واژه Efficiency و Performance از *کارایی* استفاده می‌شود. در اینگونه موارد کافی است واژه کارایی تنها یک‌بار در وردنت فارسی ثبت شود. با ثبت یک واژه در وردنت فارسی، حیات آن آغاز می‌گردد و پرونده ای برای آن گشوده می‌شود که بیانگر آخرین اطلاعات درباره ثبت اطلاعات ساختاری و آوایی آن می‌باشد.

۶- جمع بندی

در این سند تحلیل نیازها و دامنه پروژه توسعه وردنت زبان فارسی در حوزه فاوا ارائه شده است. در بخش اول این سند ابعاد پروژه بررسی شده و تعاریف مفاهیم لازم ارائه شده است. در ادامه حوزه فاوا و محدوده واژگانی آن تعیین شده و منابعی برای جمع آوری واژگان این حوزه معرفی شده است. راه حل پیشنهادی ما برای توسعه وردنت فارسی در حوزه فاوا این است که وردنت انگلیسی فاوا را ایجاد نموده و سپس آن را به فارسی ترجمه کنیم. برای آزمون امکان‌پذیری، یک مطالعه پایلوت انجام داده‌ایم که خلاصه نتایج آن در این سند و نتایج مبسوط آن در لوح فشرده پیوست ارائه می‌گردد. این نتایج نشان می‌دهد که توسعه وردنت در حوزه فاوا امکان‌پذیر است.

مراجع

[۱] Harry KORNILAKIS,Eleni GALIOTOU۱ Maria GRIGORIADOU and Evangelos PAPAKITSOS Sofia STAMOU, "The Software Infrastructure for the Development and Validation of the Greek Wordnet," *ROMANIAN JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY*, vol. ۷, no. ۱-۲, ۲۰۰۴.

[۲] ITU, "Measuring ICT:the global status of ICT indicators," Geneva, ۲۰۰۵.

[۳] Oxford University Press, "Oxford Advanced Learners Dictionary," ۲۰۰۶.

[۴] I.S.P. Nation, *Learning Vocabulary in another Language*. Cambridge, UK: Cambridge University Press, ۲۰۰۱.

[۵] Microsoft Corp., *Microsoft Computer Dictionary*, ۵th ed.: Microsoft Press.

[۶] Iranian Research Institute for Scientific Information and Documentation. (۲۰۱۱) Irandoc Thesauri. [Online]. http://thesauri.irandoc.ac.ir/

[۷] محمدرضا محمدی فر, *واژه نامه کامپیوتر انگلیسی-فارسی*. تهران: فرهنگ معاصر, ۱۳۸۵.

[۸] نسرین محمدی, *فرهنگ تخصصی کامپیوتر*. تهران: فروزش, ۱۳۸۹.

[۹] McGraw-Hill, *McGraw Dictionary of Scientific and Technical Terms*.: McGraw-Hill, ۲۰۰۰.

[۱۰] A. and Konstantinidi, I. and Papadaki, M. and Keramidas, G. and Grigoriadou, M. Kremizis, "Greek Wordnet Extension in the Domain of Psychology and Computer Science," in *Proceedings of the ۸th Hellenic European Research Computer Mathematics and its Applications Conference (HERCMA ۲۰۰۷)*., Athens, ۲۰۰۷.

[۱۱] J. and Grobelnik, M. and Mladenic, D. Brank, "A survey of ontology evaluation techniques," in *Proceedings of the Conference on Data Mining and Data Warehouses (SiKDD ۲۰۰۵)*, ۲۰۰۵.

[۱۲] P. and Cimiano, P. and Magnini, B. Buitelaar, "Ontology learning from text: methods, evaluation and applications," *Computational Linguistics*, vol. ۳۲, no. ۴, ۲۰۰۵.

[۱۳] Daniel Jurafsky and James H. Martin, *SPEECH and LANGUAGE PROCESSING*, ۲nd ed.: Pearson Prentice Hall, ۲۰۰۹.

واژه نامه انگلیسی به فارسی

فارسی	انگلیسی
دسترسی	Access
فعالیت	Activity
کاربرد	Application
کاربردی	Applied
رویکرد	Approach
معماری	Architecture
خودکار	Automatic
خودکارسازی	Automation
پشتیبان	Backup
پایگاه	Base
پایه	Basic
مرورگر	Browser
کد	Code
ارتباط	Communication
ارتباطات	Communications
مؤلفه	Component
اتصال	Connection
ناسازگار	Contradictor
پیکره	Corpus
دادگان	Data
داده	Datum
رومیزی	Desktop
توسعه	Development
پویا	Dynamic
ویرایش	Edit
مدخل	Entry
ارزیابی	Evaluation
وسیع‌تر	Expanded
آزمون	Experiment
صدور	Export
استخراج	Extraction
ویژگی	Feature
کارکردی	Functional
فازی،	Fuzzy
عمومی	General
اکتساب	Import

Inference	استنتاج
Inflections	تصریف
Information and Communication Technology	فناوری اطلاعات و ارتباطات
Information Technology	فناوری اطلاعات
Infrastructure	زیر ساخت
Input	ورودی
Insert	درج
Institute	موسسه
Interface	واسط
Isolated	منفک،
Lexical	لغوی
Linguistic	زبان شناختی
Login	ورود
Mapping	نگاشت
Monitor	ناظر
Network	شبکه
Normal	عادی
Noun	اسم
Online	برخط
On time	به هنگام
Permission	اجازه
Persian	فارسی
Plural	جمع
Primary	ابتدایی
Process	فرایند
Protocol	پروتکل
Reliability	صحت
Retrieval	بازیابی
Risk	ریسک
Scientific	علمی
Secure	امن
Semantic	معنایی
Semantic	نحوی
Sentence	جمله
Specialized	اختصاصی
Spectrum	طیف
Standard	استاندارد
Strategic	راهبردی
Structure	ساختار
Synonym	مترادف
Synset	ترادف

سامانه	System
تزاروس	Thesaurus
لایه	Tier
وسیله	Tool
ابزارها	Tools
جهانی	Universal
استفاده	Usage
کاربر	User
اعتبار	Validity
فعل	Verb
فضای مجازی	Virtual Space
وب	Web
واژه	Word
وردنت	WorldNet
واژگان	Words

واژه نامه فارسی به انگلیسی

فارسی	انگلیسی
ابتدایی	Primary
ابزارها	Tools
اتصال	Connection
اجازه	Permission
اختصاصی	Specialized
ارتباط	Communication
ارتباطات	Communications
ارزیابی	Evaluation
استاندارد	Standard
استخراج	Extraction
استفاده	Usage
استنتاج	Inference
اسم	Noun
اعتبار	Validity
اکتساب	Import
امن	Secure
آزمون	Experiment
بازیابی	Retrieval
برخط	Online
به هنگام	On time
پایگاه	Base
پایه	Basic
پروتکل	Protocol
پشتیبان	Backup
پویا	Dynamic
پیکره	Corpus
ترادف	Synset
تزاروس	Thesaurus
تصریف	Inflections
توسعه	Development
جمع	Plural
جمله	Sentence
جهانی	Universal
خودکار	Automatic
خودکارسازی	Automation
دادگان	Data

داده	Datum
درج	Insert
دسترسی	Access
راهبردی	Strategic
رومیزی	Desktop
رویکرد	Approach
ریسک	Risk
زبان شناختی	Linguistic
زیر ساخت	Infrastructure
ساختار	Structure
سامانه	System
شبکه	Network
صحت	Reliability
صدور	Export
طیف	Spectrum
عادی	Normal
علمی	Scientific
عمومی	General
فارسی	Persian
فازی،	Fuzzy
فرایند	Process
فضای مجازی	Virtual Space
فعالیت	Activity
فعل	Verb
فناوری اطلاعات	Information Technology
فناوری اطلاعات و ارتباطات	Information and Communication Technology
کاربر	User
کاربرد	Application
کاربردی	Applied
کارکردی	Functional
کد	Code
لایه	Tier
لغوی	Lexical
مترادف	Synonym
مدخل	Entry
مرورگر	Browser
معماری	Architecture
معنایی	Semantic
منفک،	Isolated
موسسه	Institute
مؤلفه	Component

ناسازگار	Contradictor
ناظر	Monitor
نحوی	Semantic
نگاشت	Mapping
واژگان	Words
واژه	Word
واسط	Interface
وب	Web
وردنت	WordNet
ورود	Login
ورودی	Input
وسیع‌تر	Expanded
وسیله	Tool
ویرایش	Edit
ویژگی	Feature

پیوست ۳ سرفصل‌های پیشنهادی حوزه فاوا

سرفصل‌های پیشنهادی ACM برای علوم و مهندسی کامپیوتر

ACM سرفصل‌های حوزه علوم و مهندسی کامپیوتر را به صورت سلسله مراتبی و در سه سطح تنظیم نموده است. در زیر عناوین اصلی این سرفصل‌ها تا سطح دوم آمده است. همچنین فهرست کامل این سرفصل‌ها تا سه سطح در لوح فشرده پیوست این گزارش موجود است.

Code	Title
A.	General Literature
A.1	INTRODUCTORY AND SURVEY
A.2	REFERENCE (e.g., dictionaries, encyclopedias, glossaries)
B.	Hardware
B.1	CONTROL STRUCTURES AND MICROPROGRAMMING (D.3.2)
B.2	ARITHMETIC AND LOGIC STRUCTURES
B.3	MEMORY STRUCTURES
B.4	INPUT/OUTPUT AND DATA COMMUNICATIONS
B.5	REGISTER-TRANSFER-LEVEL IMPLEMENTATION
B.6	LOGIC DESIGN
B.7	INTEGRATED CIRCUITS
B.8	PERFORMANCE AND RELIABILITY (C.4) (NEW)
C.	Computer Systems Organization
C.1	PROCESSOR ARCHITECTURES
C.2	COMPUTER-COMMUNICATION NETWORKS
C.3	SPECIAL-PURPOSE AND APPLICATION-BASED SYSTEMS (J.7)
C.4	PERFORMANCE OF SYSTEMS
C.5	COMPUTER SYSTEM IMPLEMENTATION
D.	Software
D.1	PROGRAMMING TECHNIQUES (E)
D.2	SOFTWARE ENGINEERING (K.6.3)
D.3	PROGRAMMING LANGUAGES
D.4	OPERATING SYSTEMS (C)
E.	Data
E.1	DATA STRUCTURES
E.2	DATA STORAGE REPRESENTATIONS
E.3	DATA ENCRYPTION
E.4	CODING AND INFORMATION THEORY (H.1.1)
E.5	FILES (D.4.3, F.2.2, H.2)
F.	Theory of Computation
F.1	COMPUTATION BY ABSTRACT DEVICES
F.2	ANALYSIS OF ALGORITHMS AND PROBLEM COMPLEXITY (B.6-7, F.1.3)
F.3	LOGICS AND MEANINGS OF PROGRAMS
F.4	MATHEMATICAL LOGIC AND FORMAL LANGUAGES

G.	Mathematics of Computing
G.1	NUMERICAL ANALYSIS
G.2	DISCRETE MATHEMATICS
G.3	PROBABILITY AND STATISTICS
G.4	MATHEMATICAL SOFTWARE
H.	Information Systems
H.1	MODELS AND PRINCIPLES
H.2	DATABASE MANAGEMENT (E.5)
H.3	INFORMATION STORAGE AND RETRIEVAL
H.4	INFORMATION SYSTEMS APPLICATIONS
H.5	INFORMATION INTERFACES AND PRESENTATION (e.g., HCI) (I.7)
I.	Computing Methodologies
I.1	SYMBOLIC AND ALGEBRAIC MANIPULATION (REVISED)
I.2	ARTIFICIAL INTELLIGENCE
I.3	COMPUTER GRAPHICS
I.4	IMAGE PROCESSING AND COMPUTER VISION (REVISED)
I.5	PATTERN RECOGNITION
I.6	SIMULATION AND MODELING (G.3)
I.7	DOCUMENT AND TEXT PROCESSING (H.4-5) (REVISED)
J.	Computer Applications
J.1	ADMINISTRATIVE DATA PROCESSING
J.2	PHYSICAL SCIENCES AND ENGINEERING
J.3	LIFE AND MEDICAL SCIENCES
J.4	SOCIAL AND BEHAVIORAL SCIENCES
J.5	ARTS AND HUMANITIES
J.6	COMPUTER-AIDED ENGINEERING
J.7	COMPUTERS IN OTHER SYSTEMS (C.3)
K.	Computing Milieux
K.1	THE COMPUTER INDUSTRY
K.2	HISTORY OF COMPUTING
K.3	COMPUTERS AND EDUCATION
K.4	COMPUTERS AND SOCIETY
K.5	LEGAL ASPECTS OF COMPUTING
K.6	MANAGEMENT OF COMPUTING AND INFORMATION SYSTEMS
K.7	THE COMPUTING PROFESSION
K.8	PERSONAL COMPUTING

سرفصل‌های دایرکتوری وب[۱] dmoz

[۱] http://www.dmoz.org

دایرکتوری dmoz به صورت دستی مدیریت و بروز رسانی می‌شود. در زیر سرفصل‌های این دایرکتوری زیر عنوان Computers and Internet آمده است.

Title

Algorithms
Artificial Intelligence
Artificial Life
Associations
Bulletin Board Systems
CAD and CAM
Chats and Forums
Companies
Computer and Technology Law
Computer Science
Conferences
Consultants
Consulting
Customer Relationship Management
Data Communications
Data Formats
Desktop Publishing
Developers
Directories
E-Books
Education and Training
Education
Employment
Emulators
Ethics
FAQs, Help, and Tutorials
Fonts
Games
Graphics
Hacking
Hardware
History
Home Automation
Human-Computer Interaction
Imaging
Internet Marketing
Internet
Intranet
Legal Information
Mailing Lists

Marketing and Advertising
Merchant Account Services
MIS
Mobile Computing
Multimedia
News and Media
Newsgroups
Open Source
Operating Systems
Order Fulfillment
Organizations
Outsourcing
Parallel Computing
Performance and Capacity
Product Support
Programming
Robotics
Security
Services
Shopping
Software
Speech Technology
Strategy
Supercomputing
Systems
Technology Vendors
Telecommunications
Usenet
Virtual Reality
Website Promotion

سرفصل‌های ویکی‌پدیا

دایره‌المعارف عمومی ویکی‌پدیا اسناد خود را به صورت سلسله مراتبی دسته بندی می‌کند. در این دسته بندی کلیه موضوعات اصلی، فرعی و جنبی علوم و مهندسی کامپیوتر و همچنین فاوا به صورت فهرست الفبایی آمده است. در زیر عناوین سرفصل‌های اصلی آمده است که سرفصل‌های جزئی‌تر از هرکدام قابل دسترسی است.

[+] Areas of computer science (16 C)
[+] Computer science awards (8 C, 55 P)
[+] Computer science conferences (10 C, 85 P)
[+] Computer science education (2 C, 34 P)
[+] Computer science literature (6 C, 5 P)
[+] Computer science organizations (16 C, 52 P)
[+] Computer science stubs (12 C, 782 P)
[+] Computer scientists (10 C, 25 P)
[+] History of computer science (2 C, 9 P)
[+] Philosophy of computer science (1 C, 4 P)
[×] Unsolved problems in computer science (19 P)
[×] Wikipedia books on computer science (19 P)

Abstract

This document presents requirement analysis of Persian WordNet in ICT domain. At first, we determine boundary of ICT domain and then identify vocabulary resources. Identification of ICT sub-domains and their related glossaries and life-cycle of words and concepts are described in depth. Our main strategy is to develop an English WordNet for ICT domain and then translate it to Persian. ICT related words and phrases are collected from various resources such as text books and web pages. Using text-mining tools and methods several types of semantic relations are extracted from free text. The set of words and their relations builds up the English ICT WordNet which will be translated to Persian subsequently. Ideas and method introduced in this document are implemented or planned to be implemented and their results will be reported in separate documents.

Information Technology Faculty

Information Technology Platform Group

Technical Report

Analysis Document of Persian WordNet for ICT Domain

Project Name: Persian WordNet for ICT Domain

Project code: ۸۹۳۲۴۱۶

Project Director	Muharram Mansoorizadeh
Author(s)	M. Mansoorizadeh, M. Nassiri, M. Dadrass
Document Code	ITF.ITP.TCH.۸۹۳۲۴۱۶.۱۱.V۰۲
Preparing Date	۹۱.۰۳.۲۷
Status/Version	Final/۱,۰