





۹۲۱۴۲۲۷

دانشگاه شهید چمران اهواز

دانشکده مهندسی

پایان نامه کارشناسی ارشد کامپیوتر

گرایش هوش مصنوعی

عنوان :

فیلتر صفحات وب با استفاده از آنتولوژی و ابزارهای وب معنایی

استاد راهنما:

دکتر بیتا شادگار

استاد مشاور:

دکتر علیرضا عصاره

نگارنده :

مرتضی جادریان

شهریور ماه ۱۳۹۲

باسمه تعالی

دانشگاه شهید چمران اهواز

دانشکده مهندسی

(نتیجه ارزشیابی پایاننامه کارشناسی ارشد)

پایاننامه آقای مرتضی جادریان دانشجوی رشته: مهندسی کامپیوتر گرایش: هوش مصنوعی

دانشکده مهندسی به شماره دانشجویی ۹۰۱۴۲۰۱

با عنوان :

فیلتر صفحات وب با استفاده از آنتولوژی و ابزارهای وب معنایی

جهت اخذ مدرک : کارشناسی ارشد در تاریخ : ۳۰ شهریور ۱۳۹۲ توسط هیأت داوران مورد ارزشیابی قرار گرفت و با درجه عالی تصویب گردید.

اعضاى هیأت داوران :	امضاء	رتبه علمی
استاد راهنمای: دکتر بیتا شادگار	استادیار
استاد مشاور: دکتر علیرضا عصاره	دانشیار
استاد داور: دکتر مرجان نادران طحان	استادیار
استاد داور: دکتر سید عنایت‌الله علوی	استادیار
نماينده تحصيلات تكميلي: دکتر محمدرضا صفاريان	استادیار
مدیرگروه: دکتر سید عنايت‌الله علوی	استادیار
معاون پژوهشی و تحصیلات تکمیلی دانشکده: دکتر علی حقیقی	استادیار
مدیر تحصیلات تکمیلی دانشگاه: دکتر مسعود قربان‌پور نجف‌آبادی	استاد

لعدیم به

م در و مادر دل سوز، فدا کار

✿

و عزیزتر از حانم

در ابتدا از خداوند منان سپاس‌گزارم که به من لطف نمود و در این راه همیشه باری رسان بود، هر چند که من آن طور که باید
و شاید سپاس‌گزار لطف و رحمت‌های او نبودم.

در ادامه لازم است که از استاد راهنمای بندۀ سرکار خانم دکتریتا شادگار مشکر کنم که همیشه به من گفک نمودند و
پسچ وقت راهنمایی‌هایی ارزشمند را از بندۀ دریغ نکردند. همچنین لازم است از استاد مشاور بندۀ جناب آقا دکتر
علیرضا عصماره مشکر کنم که همیشه باروی باز به سوالات بندۀ پاسخ داده و من را راهنمایی کرده‌اند. در پیان لازم است که
از تمامی استادی‌گران قدری که افتخار علم آموزی از ایشان را داشتم سپاس‌گزاری نمایم و از تمام دوستانی که به من در
این مهم‌گفک نمودند قدردانی کنم.

فهرست مطالب

فصل اول: مقدمه

۲	۱-۱ تعریف مساله و انگیزه انجام آن
۶	۲-۱ اهداف رساله
۸	۳-۱ ساختار رساله

فصل دوم: مروری بر ادبیات موضوع و تاریخچه پژوهش‌های پیشین

۱۰	۱-۲ آشنایی با مفاهیم کلیدی در حوزه فیلتر اطلاعات و کاربرد آنها
۱۱	۱-۱-۲ فیلتر اطلاعات
۱۲	۱-۲-۱-۲ فیلتر مشارکتی
۱۵	۱-۱-۲-۱ فیلتر محتوایی
۱۷	۱-۲-۱-۲ ساختن پروفایل
۱۹	۱-۲-۱-۳ شخصی‌سازی فیلتر
۲۱	۱-۲-۴ محاسبه شبهات
۲۳	۱-۲-۵ پایگاه‌دانش
۲۴	۱-۲-۶ آنتولوژی
۲۵	۲-۲ تاریخچه پژوهشی مرتبط با فیلتر محتوایی وب و اسناد

۲۶.....	۱-۲-۲ بستری برای انتخاب محتوا.....
۲۷.....	۲-۲-۲ بلاک کردن URL.....
۲۷.....	۳-۲-۲ فیلتر کردن کلمات کلیدی.....
۲۸.....	۴-۲-۲ تحلیل هوشمند محتوا.....
۳۰.....	۱-۴-۲-۲ دسته‌بندی متن.....
۳۱.....	۱-۴-۲-۲ بیز.....
۳۲.....	۲-۱-۴-۲-۲ نزدیک‌ترین همسایه.....
۳۳.....	۳-۱-۴-۲-۲ درخت تصمیم.....
۳۴.....	۴-۱-۴-۲-۲ ماشین بردار پشتیبان.....
۳۵.....	۵-۱-۴-۲-۲ شبکه‌های عصبی مصنوعی.....
۳۶.....	۲-۴-۲-۲ وب معنایی و تکنیک‌های مبتنی بر آنتولوژی و پایگاه‌دانش.....
۴۰.....	۳-۲ روش‌ها و ابزارها.....
۴۰.....	۱-۳-۲ داده‌کاوی مبتنی بر آنتولوژی.....
۴۳.....	۲-۳-۲ ساختار آنتولوژی و پایگاه‌های دانش استفاده شده در این پروژه.....
۴۴.....	۱-۲-۳-۲ آنتولوژی سطح بالا.....
۴۵.....	۲-۲-۳-۲ وردنت.....
۴۶.....	۳-۲-۳-۲ ویکی‌پدیا و BNC.....

فصل سوم: روش پیشنهادی و پیاده‌سازی سیستم فیلتر

۴۸.....	۱-۳ روش پیشنهادی.....
۵۱.....	۲-۳ تولید پروفایل کاربری با توجه به علایق و اولویت‌های کاربر.....
۵۲.....	۱-۲-۳ ساختن پروفایل کاربری اولیه.....
۵۳.....	۲-۲-۳ غنی‌سازی پروفایل کاربری.....
۵۵.....	۱-۲-۲-۲ غنی‌سازی مبتنی بر آنتولوژی.....
۵۹.....	۲-۲-۲-۲ غنی‌سازی مبتنی بر ویکی‌پدیا.....
۶۰.....	۳-۲-۲-۲ غنی‌سازی مبتنی بر BNC.....
۶۰.....	۳-۳ ساختن پروفایل استناد و صفحات وب.....
۶۱.....	۱-۳-۳ مرحله‌ی اول ساخت پروفایل استناد و صفحات وب.....
۶۲.....	۲-۳-۳ مرحله‌ی غنی‌سازی پروفایل استناد و صفحات وب.....
۶۴.....	۴-۳ روش‌های فیلتر محتوایی مبتنی بر شباهت معنایی.....
۶۶.....	۱-۴-۳ فیلتر محتوایی مبتنی بر ساختار آنتولوژی.....
۶۹.....	۲-۴-۳ فیلتر محتوایی مبتنی بر ساختار ویکی‌پدیا و BNC.....
۷۰.....	- مشابهت بردار مرتبه اول.....
۷۰.....	- مشابهت بردار مرتبه دوم.....
۷۱.....	۴-۳-۳ فیلتر محتوایی مبتنی بر ساختار وردنت.....
۷۲.....	- روش Lin.....
۷۲.....	- روش Jiang and Conrath.....

۷۲	- روش Resnik
۷۳	- روش Leacock and Chodorow
۷۳	- روش Path
۷۳	- روش Wu and Palmer
۷۵	۳-۵ فیلتر محتوایی مبتنی بر ساختار ترکیب خبرگان
	فصل چهارم: ارزیابی سیستم فیلتر پیشنهادی
۸۱	۴-۱ مجموعه داده‌های استفاده شده برای ارزیابی
۸۴	۴-۲ مرحله ارزیابی روش‌های شbahت معنایی
۸۶	۴-۳ مرحله ارزیابی روش‌های فیلتر محتوایی دانش محور
	فصل پنجم: نتیجه‌گیری و پیشنهادها
۹۹	۱-۵ پیشنهادهایی برای ادامه پژوهش
۱۰۰	پیوست‌ها
۱۱۸	مراجع
۱۳۲	واژه نامه فارسی به انگلیسی

فهرست شکل‌ها و نمودارها

شکل ۱-۲ : ساختار کلی فرآیند گسترش مجموعه‌ای	۴۲
شکل ۲-۲ : چگونگی گسترش مجموعه مفاهیم اولیه به مجموعه مفاهیم گسترش یافته	۴۳
شکل ۲-۳ : نمونه‌ای از ساختار سلسله‌مراتبی وردنت در ساماندهی مفاهیم اطلاعاتی	۴۷
شکل ۱-۳ : ساختار کلی روش پیشنهادی	۴۹
شکل ۲-۳ : ساختار کلی فرآیند غنی‌سازی پروفایل‌ها	۵۵
شکل ۳-۳ : چگونگی فراخوانی مدل سه‌تایی‌های RDF با استفاده از Jena	۵۶
شکل ۳-۴ : نمونه‌ای از نقشه‌های مفهوم تولید شده با استفاده از آنتولوژی	۵۸
شکل ۳-۵ : چگونگی بازیابی کلاس‌های موجود در آنتولوژی Ontowordnet	۵۸
شکل ۳-۶ : چگونگی بازیابی کلاس‌های والد مفاهیم مورد نظر	۵۹
شکل ۷-۳ : چگونگی استخراج سلسله‌مراتبی مفاهیم مورد نظر از ساختار آنتولوژی	۶۸
شکل ۸-۳ : الگوریتم محاسبه شباهت معنایی میان مفاهیم پروفایل‌های کاربری و اسناد در روش مبتنی بر آنتولوژی	۷۹
شکل ۹-۳ : الگوریتم محاسبه شباهت معنایی میان مفاهیم پروفایل‌های کاربری و اسناد در روش مبتنی بر ویکی‌پدیا و BNC	۷۱

شکل ۳ : الگوریتم محاسبه شباهت معنایی میان مفاهیم پروفایل‌های کاربری و اسناد در روش مبتنی بر وردنت.....	۷۴
شکل ۱۱-۳ : چگونگی تصمیم‌گیری در مورد فیلتر اسناد در ساختار ترکیب خبرگان.....	۷۶
شکل الف-۱: نمایی کلی از واسط گرافیکی کاربری.....	۱۰۰
شکل الف-۲ : نمایی از بخش ساختن پروفایل کاربری.....	۱۰۱
شکل الف-۳ : نمایی از بخش غنی‌سازی پروفایل کاربری.....	۱۰۲
شکل الف-۴ : نمایی از بخش ساخت پروفایل اسناد.....	۱۰۳
شکل الف-۵ : نمایی از بخش غنی‌سازی پروفایل اسناد.....	۱۰۴
شکل الف-۶ : نمایی از بخش فیلتر مبتنی بر آنتولوژی.....	۱۰۵
شکل الف-۷ : نمایی از بخش فیلتر مبتنی بر وردنت.....	۱۰۵
شکل الف-۸ : نمایی از بخش فیلتر مبتنی بر ویکی‌پدیا.....	۱۰۶
شکل الف-۹ : نمایی از بخش فیلتر مبتنی بر BNC.....	۱۰۷
شکل الف-۱۰ : نمایی از بخش فیلتر مبتنی بر مقایسه‌ی رشته‌ای و ترکیب خبرگان.....	۱۰۸
شکل الف-۱۱ : نمایی از بخش دسته‌بند معنایی اسناد.....	۱۰۹
شکل ب-۱ : شبکه‌کد سازنده ماتریس شباهت روش Needleman-Wunch	۱۱۳
شکل ب-۲ : شبکه‌کد تولیدکننده امتیاز هم‌ترازی در روش Needleman-Wunch	۱۱۴

فهرست جداول

جدول ۱-۲ : نتایج ارزیابی ابزارهای فیلتر توسط پروژه NetProtect	۲۹
جدول ۱-۳ : نتایج ارزیابی روش‌های فیلتر مبتنی بر شباهت رشته‌ای	۶۵
جدول ۲-۳ : وزن‌های مخصوص به هر یک از روش‌های دانشمحور پیاده‌سازی شده	۷۸
جدول ۱-۴ : امتیاز قضاوت بشر برای جفت مفاهیم موجود در مجموعه داده M-C	۸۱
جدول ۲-۴ : کلاس‌ها و تعداد نمونه‌های آن‌ها در مجموعه داده 20newsgroup	۸۲
جدول ۳-۴ : موضوعات خبری موجود در مجموعه داده 20newsgroup و کلاس‌های تشکیل دهنده	۸۳
جدول ۴-۴ : نتایج ارزیابی روش‌های شباهت معنایی پیاده‌سازی شده و مقایسه آن‌ها با روش‌های مشابه	۸۵
جدول ۴-۵ : چگونگی ارزیابی تصمیمات فیلتر یک سیستم فیلتر محتوایی	۸۸
جدول ۴-۶ : نتیجه ارزیابی روش فیلتر دانشمحور مبتنی بر آنتولوژی	۸۹
جدول ۴-۷ : نتیجه ارزیابی روش فیلتر دانشمحور مبتنی بر ویکی‌پدیا	۸۹
جدول ۴-۸ : نتیجه ارزیابی روش فیلتر دانشمحور مبتنی بر BNC	۸۹
جدول ۴-۹ : نتیجه ارزیابی روش فیلتر دانشمحور مبتنی بر وردنت	۹۰
جدول ۴-۱۰ : نتیجه ارزیابی روش فیلتر دانشمحور مبتنی بر ساختار ترکیب حبره‌گان	۹۰

جدول ۱۱-۴ : زمان اجرایی هر کدام از روش‌ها برای فیلتر اسناد ورودی.....	۹۳
جدول ۱۲-۴ : نتایج ارزیابی صحت برخی روش‌های مشابه دسته‌بندی و فیلتر اسناد.....	۹۳
جدول ۱۳-۴ : نتیجه ارزیابی نرخ دسته‌بندی روش ترکیبی <i>Tree-Bagging</i> با تعداد درخت‌های مختلف.....	۹۴
جدول ۱۴-۴ : نتیجه ارزیابی نرخ دسته‌بندی روش‌های معروف دسته‌بندی اسناد متنی.....	۹۴

نام خانوادگی : جادریان	نام: مرتضی	شماره دانشجویی : ۹۰۱۴۲۰۱
عنوان پایان نامه : فیلتر صفحات وب با استفاده از آنتولوژی و ابزارهای وب معنایی		
استاد راهنما: دکتر بیتا شادگار		استاد مشاور: دکتر علیرضا عصاره
درجه تحصیلی: کارشناسی ارشد	رشته: مهندسی کامپیوتر	گرایش: هوش مصنوعی
دانشگاه: شهید چمران اهواز	دانشکده: مهندسی کامپیوتر	گروه :
تاریخ فارغ التحصیلی : شهریورماه ۱۳۹۲ صفحه ۱۲۴	تعداد صفحه:	کلید واژه ها :
کلید واژه ها : فیلتر اطلاعات، فیلتر محتوایی، پروفایل، آنتولوژی، پایگاه‌دانش، ترکیب خبرگان.		
<p>در سال‌های اخیر، تکنیک‌های فیلتر محتوایی دانش‌محور مبتنی بر پایگاه دانش و آنتولوژی به روش‌هایی کارا و قابل قبول برای فیلتر اطلاعات تبدیل شده‌اند. در این تحقیق از ساختار آنتولوژی و پایگاه‌دانش‌های ویکی‌پدیا، وردنت و BNC برای عمل فیلتر اسناد، بهبود نمایش اولویت‌های کاربری و محتوای اسناد و محاسبه شباهت معنایی استفاده می‌شود. همچنین ساماندهی علایق کاربری و محتوای اسناد در پروفایل‌ها امکان استخراج دانش درباره علایق احتمالی کاربران و محتوای اسناد را با استفاده از آنتولوژی و پایگاه‌دانش فراهم می‌آورد. این تحقیق روشهای نوین و منحصر به فرد در ساختار ترکیب خبرگان برای فیلتر اسناد ارائه می‌کند و مجموعه‌ای از بهترین و کارترین روش‌های فیلتر را پیاده‌سازی و با هم یکپارچه می‌کند. ارزیابی سیستم در دو مرحله ارزیابی روش‌های 20Newsgroup محاسبه شباهت معنایی و روش‌های فیلتر محتوایی با استفاده از مجموعه داده‌های میلر-چارلز و</p> <p>انجام می‌شود. نتایج ارزیابی، همبستگی زیاد روش‌های محاسبه شباهت معنایی میان مفاهیم را با قضاوت بشر نشان می‌دهد. روش مبتنی بر ویکی‌پدیا با میزان همبستگی ۰/۷۷۹ نه تنها از دیگر روش‌های پیاده‌سازی شده بهتر عمل می‌کند بلکه از روش‌های مشابه و شناخته‌شده‌ای مانند CODC با میزان همبستگی ۰/۶۹۳ و روش ESA با میزان همبستگی ۰/۵۸ بهتر عمل می‌کند. به علاوه در ارزیابی روش‌های فیلتر دانش‌محور ملاحظه می‌شود که روش مبتنی بر آنتولوژی با نرخ صحت و کارآیی ۹۸.۹ و ۹۸ درصد و روش مبتنی بر ویکی‌پدیا با نرخ صحت و کارآیی ۹۸.۲ و ۹۶ درصد نتایج بهتری نسبت به دیگر روش‌های مشابه و شناخته شده مانند NB-SVM Hybrid دارد.</p> <p>همچنین نتایج ارزیابی روش مبتنی بر ساختار ترکیب خبرگان با نرخ صحت و کارآیی ۹۹.۴ و ۹۸.۹ درصد نشان می‌دهد که این روش نه تنها از تک‌تک روش‌های پیاده‌سازی شده کارآیی و صحت بالاتری دارد، بلکه می‌تواند خطاهای عمل فیلتر را تصحیح کند. براساس این نتایج، سیستم پیاده‌سازی شده می‌تواند به عنوان رویکرد جدیدی در فیلتر محتوایی و به عنوان چارچوبی برای استفاده در کاربردهای فیلتر اطلاعات استفاده شود.</p>		

مقدمه

امروزه اینترنت و وب جهان گستر^۱ به بزرگترین منبع اطلاعاتی شناخته شده برای بشر تبدیل شده است. با این حال جنبه دیگری که تاثیر اینترنت و وب را قوی تر کرده است، آسانی دسترسی به حجم عظیم اطلاعات است. همچنین پیشرفت های فراوان در قابلیت های موتورهای جست و جو، فاصله این منبع اطلاعاتی عظیم را با کاربران به یک کلیک تبدیل کرده است [۲]. اگرچه چنین موضوعی می تواند به عنوان مزیت اینترنت به شمار رود ولی از طرف دیگر کاربران وب را تا حدودی در برابر مجموعه ای منابع اطلاعاتی خاص آسیب پذیر می کند. سیل عظیم محتوای نامناسب موجود در سطح وب و در معرض قرار گرفتن کلیه کاربران در برابر این اطلاعات، ضرورت وجود نوعی مکانیزم فیلتر^۲ را بیش از پیش نمایان می کند. به عبارت دیگر با انفجار اطلاعات، نگرانی اصلی در دسترس بودن اطلاعات نیست بلکه به دست آوردن اطلاعات درست و مفید است. اطلاعاتی که برای کاربر مفروضی ممکن است خیلی مهم و حیاتی باشد، ممکن است معنی خاصی برای خیلی از کاربران دیگر نداشته باشد. با این اوصاف ضرورت وجود چارچوبی که از طریق آن بتوان تنها اطلاعاتی را به کاربران نمایش داد که با نیازهای آنها مطابقت دارد، احساس می شود. این جاست که اهمیت سیستم های فیلتر اطلاعات به عنوان پایه و اساس این چارچوب پرنگ می شود.

¹ World Wide Web

² Filtering

درواقع ظهور اولین وبسایت^۱ هرزه‌نگاری^۲ در دهه ۹۰ میلادی بود که جرقه‌های ایجاد سیستم‌های فیلتر محتوای وب را پدید آورد [۳]. مطالعات اخیری که توسط شرکت گوگل انجام شده است، نشان می‌دهد که بیش از ۲۵۰ میلیون صفحه وب با محتوای هرزه‌نگاری صریح در اینترنت وجود دارد. باید توجه داشت که اکثر این محتوای نامناسب به صورت رایگان در اختیار کاربران قرار می‌گیرد و بخش عمدتی از میزبانان این محتواها در صفحات خود جاسوس افزارهایی را میزبانی می‌کنند که امنیت کاربران را در فضای مجازی به خطر می‌اندازد [۴]. عمل فیلتر به بررسی محتوا و منابع وب به منظور سنجش سازگاری آنها با مجموعه‌ای از پارامترها و معیارهای مشخص گفته می‌شود [۵]. در برنامه‌نویسی کامپیوترا، فیلتر به عنوان قطعه کدی تعریف می‌شود که وظیفه دارد تا روی محتوای ورودی تحلیل جامعی انجام دهد و مشخص کند که آیا محتوا با اولویت‌های^۳ مشخص شده توسط کاربر مطابقت دارد یا خیر. به عبارت دیگر فیلتر را می‌توان به عنوان کد غربال‌گری تصور کرد که محتوای ورودی را دریافت کرده و آنها را تحلیل می‌کند و از نتایج این تحلیل برای تصمیم‌گیری در مورد مجاز یا غیرمجاز بودن محتوا استفاده می‌کند. امروزه سیستم‌های فیلتر محتوایی^۴ از شکل سنتی خود خارج شده‌اند و وارد حوزه‌های کاربردی دیگری نظیر مدیریت منابع اطلاعاتی^۵ در شرکت‌ها و سازمان‌های درگیر با منابع اطلاعاتی وسیع شده‌اند.

۱-۱ تعریف مساله و انگیزه انجام آن

بحث فیلتر محتوایی اسناد و صفحات وب همواره یکی از موضوعات مهم تحقیقاتی و البته جنجال‌برانگیز در حوزه فیلتر اطلاعات^۶ بوده است. از یک طرف سیل عظیم اطلاعات موجود در وب همگام با گسترش و همگانی شدن این تکنولوژی ضرورت وجود سیستم فیلتر محتوایی را برای جلوگیری از مشاهده اطلاعات با محتوای نامناسب توسط کاربران بیش از پیش آشکار می‌کند.

¹ Web Site

² Pornography

³ Preferences

⁴ Content-based Filtering

⁵ Information Resource Management

⁶ Information Filtering

و از طرف دیگر نگرانی‌هایی در مورد فیلتر ناخواسته‌ی صفحات وب (صفحاتی فیلتر می‌شوند که محتوای مناسبی دارند)، فیلتر نشدن سایت‌ها با محتوای نامناسب و نقض حقوق افراد در مشاهده آزادانه محتوای وب باعث شده است تا عمل فیلتر به موضوع بحث برانگیزی در میان محققان این حوزه تبدیل شود [۶]. مشکل دیگری که اهمیت استفاده از فیلتر را بیش‌ازپیش نمایان می‌کند، آلوه شدن کامپیوترها به بدافزارها است. در واقع طبیعت متغیر این تهدیدات دیجیتال باعث شده تا محققان عملاً در برابر این تهدیدات ناتوان بمانند [۴]. تحقیقات نشان می‌دهد که این کدهای مخرب قادر هستند در کمتر از ۱۰ دقیقه به جمعیت وسیعی از سیستم‌های مستعد نفوذ کرده و آنها را آلوه کنند [۷]، [۸]، [۹]. از آنجایی که اکثر کاربران این سیستم‌ها به اصول اولیه امنیتی در محیط وب آشنایی ندارند، آن‌ها تبدیل به قربانیان بدافزارها، حملات فیشینگ^۱ و غیره می‌شوند. بنابراین، ایجاد سیستم‌های فیلتر محتوایی به عنوان روشی پیشگیرانه برای جلوگیری از ورود کاربران به وب سایت‌های حاوی بدافزارها مطرح می‌شود [۴]. ظهور و رواج جرایم اینترنتی از قبیل هرزه‌نگاری کودکان^۲، کلاهبرداری مالی^۳، دانلود غیرمجاز محتوای نامناسب و رواج خشونت و نژادپرستی مرتبط با اینترنت سبب شده تا والدین برای محافظت از فرزندان خود در برابر این جرایم زشت و ناپسند از سیستم‌های فیلتر محتوایی استفاده کنند [۴] و این سیستم‌ها را به عنوان عاملی پیشگیرانه در برابر این تهدیدات به کار برند. پتانسیل سیستم‌های فیلتر در جلوگیری از تهدیدات مخرب نرم‌افزاری، صاحبان مشاغل و شرکت‌ها را برآن داشت تا از قابلیت‌های این سیستم‌ها برای جلوگیری از استفاده نامشروع از منابع سازمانی و اطلاعاتی مشترک بهره بگیرند و منابع اشتراکی^۴ را به بهترین شکل ممکن میان مشتری‌ها^۵ مدیریت نمایند [۱۰].

اگر چه سیستم‌های فیلتر محتوایی موجود پتانسیل‌های زیادی برای مقابله در برابر تهدیدات نامبرده دارند، ولی مشکلات و موانعی از قبیل بلاک کردن بیش از حد^۶ و عدم تشخیص سایت‌ها با محتوای نامناسب^۷ سبب شده تا کاربران از عملکرد این سیستم‌ها راضی نباشند. این مشکلات

¹ Phishing Attacks

² Child Pornography

³ Fraud

⁴ Shared Resources

⁵ Clients

⁶ Over-Blocking

⁷ Under-Blocking

ناشی از آن است که این روش‌ها غالباً قادر نیستند تا معنای^۱ نهفته‌ی محتوا را تشخیص دهند. این پدیده «ابهام واژگان»^۲ نامیده می‌شود. ورود تکنیک‌های یادگیری ماشین^۳ مانند شبکه‌های عصبی به این عرصه، تا حدی توانست این مشکلات را برطرف کند ولی مشکل عدمه این روش‌ها، وابستگی زیاد آن‌ها به داده‌های آموزشی است که سبب می‌شود کوچک‌ترین تغییر در ماهیت داده‌ها، کارآیی سیستم را کاهش دهد. از طرف دیگر این روش‌ها نمی‌توانند ارتباطات معنایی میان مفاهیم موجود در محتوا را تشخیص داده و آن‌ها را بررسی نمایند. ظهور وب‌معنایی با ایده قابلیت درک مفاهیم توسط ماشین‌ها، محققان را به سمت استفاده از آنتولوژی به منظور استخراج مفاهیم سوق داد به‌طوری که آن‌ها را قادر ساخت تا بتوانند روش‌های فیلتر دانش محور را بر مبنای دانش مستخرج از آنتولوژی توسعه دهند. در این روش‌ها آنتولوژی به عنوان ابزاری برای ارائه‌ی تفسیری دقیق، جامع و سازگار با محتوا به شمار می‌آید [۱۱]. آنتولوژی‌ها این قابلیت را دارند که معنا و مفهوم نهفته در محتوا را به شیوه‌ای واضح و دقیق به تصویر بکشند. آنتولوژی می‌تواند به عنوان ابزاری برای غلبه مشکل ابهام واژگان نیز استفاده شود [۱۲]. امروزه آنتولوژی به عنوان ابزاری قابل قبول برای یکپارچگی دانش در سیستم‌های فیلتر محتوا شناخته شده است [۱۳]. همچنین تحقیقات صورت گرفته در مورد استفاده از پایگاه‌های دانش^۴ در کار فیلتر محتوا نشان می‌دهد که ویکی‌پدیا به عنوان پایگاه دانش توسعه یافته می‌تواند اطلاعات دقیق و ارزشمندی را در ارتباط با حوزه‌ای خاص^۵ در اختیار کاربران قرار دهد [۱۴]. امروزه استفاده از ابزارهای مبتنی بر تکنولوژی وب‌معنایی مانند آنتولوژی، زبان‌های ساخت آنتولوژی و مدل داده‌ای چارچوب توصیف منابع^۶ (RDF) در پیاده‌سازی روش‌های فیلتر دانش محور بسیار مورد توجه محققان قرار گرفته است.

این رساله سعی دارد تا با استفاده از ساختار دانش محور آنتولوژی، روشی برای فیلتر محتوای صفحات وب یا اسناد ارائه دهد. این روش از ساختار یک آنتولوژی سطح بالا^۷ برای پیدا کردن شباهت معنایی میان محتوای موجود در اسناد (یا صفحات وب) و اولویت‌های کاربران

¹ Semantics² Term Ambiguity³ Machine Learning⁴ Knowledge Bases⁵ Specific Domain⁶ Resource Description Framework⁷ Top-Level Ontology

استفاده می‌کند. از روابط معنایی تعریف شده میان مفاهیم موجود در آنتولوژی و ساختار سلسله‌مراتبی آن استفاده می‌شود تا دانش و معنای نهفته در محتوا و اولویت‌های کاربران استخراج شود. ساختار آنتولوژی سطح بالا، امکان شناسایی مفاهیمی را که از لحاظ رشته‌ای به هم نزدیک نیستند ولی از نظر معنایی در یک قالب محتوایی یکسان قابل استفاده هستند فراهم می‌کند. چنین قابلیتی امکان ایجاد مکانیزم فیلتری را فراهم می‌کند که در آن فرآیند یافتن میزان شباهت میان محتوای صفحات و اولویت‌های کاربران در سطح بسیار بالاتری از روش‌های سنتی و به صورت معنایی انجام می‌شود.

همچنین این رساله از اطلاعات موجود در پایگاه‌های دانش عمومی نظیر ويکی‌پدیا^۱، BNC^۲ و وردنت^۳ به صورت جداگانه استفاده می‌کند تا روش‌هایی را برای محاسبه شباهت معنایی میان محتوای صفحات و اولویت‌های کاربری پیاده‌سازی کند. در اکثر روش‌های پیشین تنها از یک پایگاه‌دانش برای محاسبه شباهت معنایی استفاده شده است ولی این رساله از چهار پایگاه‌دانش (آنтолوژی، ويکی‌پدیا، BNC و وردنت) برای این منظور استفاده می‌کند. هدف از این کار علاوه‌بر ارزیابی کارآیی چهار پایگاه‌دانش مذکور در فیلتر محتوایی، به کارگیری آن‌ها برای ایجاد یک سیستم فیلتر مبتنی بر ساختار ترکیب خبرگان^۴ و مقایسه کارآیی آن است که برای اولین بار در این حوزه انجام شده است.

یکی از قسمت‌های مهم سیستم فیلتر پیشنهادی این رساله بخشی است که از ساختار پایگاه‌دانش‌های نامبرده برای غنی‌سازی^۵ و بهبود نمایش^۶ محتوای اسناد یا صفحات وب و اولویت‌های کاربران بهره می‌گیرد. در این قسمت مفاهیمی که از نظر معنایی به محتوا و اولویت‌های کاربران مرتبط هستند، شناسایی شده و در فرآیند محاسبه شباهت معنایی وارد می‌شوند. فرآیند شخصی‌سازی^۷ فیلتر نیز از طریق ساماندهی اولویت‌های کاربران مختلف در

¹ Wikipedia

² British National Corpus

³ WordNet

⁴ Mixture of Experts

⁵ Enrichment

⁶ Representation

⁷ Personalization

پروفایل‌های^۱ کاربری متفاوت و ساماندهی محتوای اسناد یا صفحات وب در پروفایل‌های اسناد انجام می‌شود.

درنهایت این رساله سعی می‌کند تا روش‌هایی برای فیلتر محتوایی پیاده‌سازی کند که نه تنها در حوزه فیلتر صفحات وب قابل استفاده‌اند بلکه ساختار آن‌ها به‌گونه‌ای است که در حوزه‌های دیگری نظیر سیستم‌های پیشنهاددهنده^۲، سیستم‌های فیلتر اطلاعات^۳ و سیستم‌های دسته‌بندی معنایی اسناد^۴ نیز به‌راحتی قابل استفاده است. به عبارت دیگر این رساله سیستم فیلتر پیشنهادی خود را به صورت سیستمی چند منظوره^۵ طراحی و پیاده‌سازی می‌کند.

۲-۱ اهداف رساله

این رساله با هدف استفاده از مفهوم به‌جای کلمه کلیدی یا حتی الگوهای ریاضی یا آماری درصد بر می‌آید تا سیستم فیلتر پیشنهادی خود را به آن‌چه مورد نظر و نیاز کاربر است نزدیک‌تر کند و نتایج بهتری تولید کند. این رساله دیدگاه جدیدی را در فیلتر اسناد مطرح می‌کند. از جمله مزایای مهم روش‌های پیشنهادی این رساله می‌توان به موارد زیر اشاره کرد:

- استفاده از ساختار غنی آنتولوژی در ساماندهی مفاهیم، ساختار سلسله‌مراتبی و ارتباطات معنایی میان مفاهیم موجود در آن برای پیش‌برد اهداف سیستم فیلتر پیشنهادی: چنین ایده‌ای امکان استفاده از محتوای اسناد و صفحات وب و همچنین دانش نهان مستخرج از آنتولوژی را برای سیستم فیلتر محتوایی فراهم می‌کند.
- تسهیل در شناسایی مفاهیم از نظر معنایی مرتبط که لزوماً از لحاظ رشته‌ای به هم نزدیک نیستند ولی در قالب‌های محتوایی متفاوت معادل یکدیگر هستند: به عنوان نمونه سیستم قادر به تشخیص معادل بودن مفاهیمی نظیر "Convict" و "Inmate" باشد اگرچه این دو مفهوم از لحاظ رشته‌ای هیچ شباهتی به‌هم ندارند. چنین قابلیتی پردازش زبان طبیعی^۶ محتوا

¹ Profile

² Recommender system

³ Information Filtering

⁴ Semantic Document Classification

⁵ Multi-purpose

⁶ Natural Language Processing