

وب کاوی

کاربردها و فنون

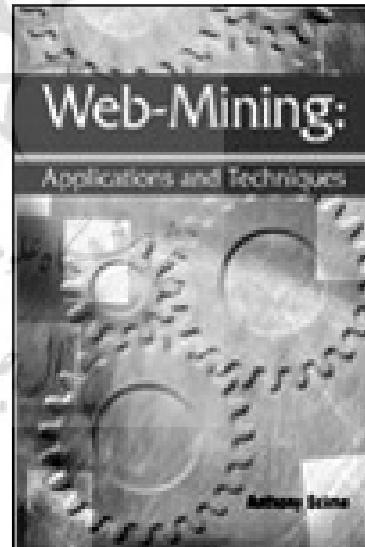
• حمید کشاورز

کارشناس ارشد کتابداری و اطلاع‌رسانی
کتابخانه ملی جمهوری اسلامی ایران

این رسانه اساساً ارتباطی است. مواردی از این قبیل که محیط وب به لحاظ محتوایی، ساختاری و کاربری از چه الگوهایی پیروی می‌کند؛ چگونه می‌توان محتوای منابع اطلاعاتی موجود در وب را تحلیل کرد، آنگونه که علاوه بر تأثیرگذاری بر الگوریتم‌های پیش‌بینی شده برای بازیابی منابع و نیز ساختاردهی به آنها، بتواند به کاربر در دستیابی به منابع اطلاعاتی مرتبط، دسته‌بندی شده و کارآمد کمک کند؛ چگونه می‌توان ساختار ارتباطی بین منابع اطلاعاتی مختلف را شناسایی و حتی ترسیم کرد؛ و اینکه چگونه می‌توان نوع کاربرد وب را از سوی کاربران شناسایی کرده و در خدمات و سیستم‌های آتی گنجاند؟

هر نوع پاسخی که به این پرسش‌ها داده شود، بر منافع دارندگان سایتها و نیز کاربران آنها و در نهایت بر کیفیت ارائه خدمات در وب تأثیر خواهد گذاشت. برای یافتن پاسخ این پرسش‌ها باید اطلاعات موجود در محیط وب را بررسی و بازبینی کرد و بر اساس آن درک درستی از ویژگی‌های محتوایی، ساختاری و کاربری این محیط به دست آورده؛ چیزی که در ادبیات پژوهشی به «وب کاوی»^۱ مشهور شده است. این موضوع البته خود به بحث گسترده‌تری بهنام داده کاوی^۲ که خود بخشی از فرآیند کشف دانش است، ارتباط دارد (اریناکی^۳، ۲۰۰۴). موضوع داده کاوی حدود چندین دهه قدمت دارد، یعنی از زمانی که سیستم‌های اطلاعاتی به وجود آمدند، وجود دارند. اما با ظهور وب این موضوع گسترش بیشتری یافت و به حوزه‌های کوچکتری از جمله وب کاوی تقسیم شد. از سوی دیگر، وب، مقایم سنتی بازیابی اطلاعات و فنون مربوط به آن را به چالش کشانده است (شنکر^۴ و دیگران، ۲۰۰۵، ص. ۸). به عبارت دیگر، خصوصیات مدارک موجود در وب، سیک و میزان ارائه مدارک در وب و از همه مهم‌تر پویایی و ب، الگوریتم‌های بازیابی اطلاعات را که بر تطابق کلیدواژه‌های و دسته‌بندی در فضای برداری^۵ مبتنی بود، ناکارآمد ساخته است.

در نتیجه عواملی نظریه آنچه در پیش آمد، متخصصان روش‌های



■ Scime, Anthony. (Ed.) (2005). *Web Mining: Applications and Techniques*. Idea Group Inc. 442 pp. ISBN: 1-59140-414-2

یکی از مهم‌ترین رسانه‌های اطلاعاتی و ارتباطی که در حال حاضر به فراوانی مورد استفاده قرار می‌گیرد، شبکه جهانی وب است. محیط وب ویژگی‌های گوناگونی دارد که از جمله بر جسته‌ترین آنها باید به گستردگی، گوناگونی منابع و پویایی آن اشاره کرد. با رشد سریع وب هریک از این ویژگی‌ها جنبه‌های گوناگون و بیشتری نیز پیدا می‌کنند. اما آنچه اهمیت فوق العاده‌ای دارد، دریافت قوانین حاکم بر





با توجه به گستردگی منابع و خدمات وب، وب کاوی خود به سه حوزه تقریباً جداگانه تقسیم شده است: محتوکاوی وب، ساختارکاوی وب و کاربردکاوی وب

نوینی را در پیش گرفته‌اند تا بتوانند کمبودهای موجود در بازیابی اطلاعات را مرتفع ساخته و الگوهای ساختاری، محتوایی و کاربری موجود در وب را به خوبی نشان دهند. در نتیجه چنین بحث‌هایی وب کاوی به عنوان موضوعی مستقل و قابل پژوهش در دهه اخیر مطرح شده است. اگرچه متخصصان از حوزه رایانه پیش‌تاز چنین بحث‌هایی بوده‌اند، اما به دلیل گستردگی استفاده از وب در امور مختلف تجاری، ارتباطی و اطلاع‌رسانی و مانند آن وب کاوی به بحث متخصصان سایر حوزه‌ها نیز تبدیل شده است.

وب کاوی که اولین بار از سوی اتریونی^۶ (۱۹۹۷) به کار رفته، چنین تعریف شده است: «کاربرد فنون داده کاوی برای کشف و استخراج خودکار اطلاعات از منابع و خدمات وب» (کسالا و بلوکل^۷، ۲۰۰۰، ص۴؛ شنکر و دیگران، ۲۰۰۵، ۳؛ برت، هوتو و استم^۸، ۲۲۶، ۲۰۰۲؛ فاكا و لانزی^۹، ۲۰۰۳؛ کولی، مباشر و سریواستاو^{۱۰}، ۱، ۱۹۹۷).

با توجه به گستردگی منابع و خدمات وب، وب کاوی خود به سه حوزه تقریباً جداگانه تقسیم شده است: محتوکاوی وب^{۱۱}، ساختارکاوی وب^{۱۲}، و کاربردکاوی وب^{۱۳} (کسالا و بلوکل، ۲۰۰۰، ص۲؛ برت، هوتو و استم، ۲۰۰۲، ص۲۶۵؛ اریناکی، ۲۰۰۴؛ اریناکی، ۲۰۰۲). در هریک از این حوزه‌ها موضوعات متقاضی مورد توجه قرار می‌گیرد. هدف محتوکاوی، کشف اطلاعات مفید از مدارک و مطالب موجود در وب است. اگرچه مطالب موجود در مدارک وب بسیار متنوع هستند مانند متن، تصویر، صدا، ابرداده و پیوندهای فرامتنی^{۱۴}، در محتوکاوی ساختار منابع و نحوه کاربرد آنها کمتر مورد توجه قرار می‌گیرد. در ساختارکاوی ساختار موجود بین مدارک و پیوندهای فرامتنی^{۱۵}، در مدارک و فنون با هدف نشان دادن این فرامتنی مطالعه می‌شود. در کاربردکاوی نوع کاربرد مدارک و

به طور کلی نحوه استفاده از وب از سوی کاربران بررسی شده و الگوی استفاده مشخص می‌گردد. این امر با مطالعه گزارش‌های^{۱۶} تولیدشده از سوی کاربران که در انواع سرویس‌دهنده‌ها ذیخیره می‌گردد، صورت می‌گیرد. در حالی که در محتوکاوی و ساختارکاوی اطلاعات دسته اول مورد استفاده قرار می‌گیرد، در کاربردکاوی اطلاعات دسته دوم یعنی گزارش‌های موجود در سرویس‌دهنده‌ها مورد استفاده پژوهشگران قرار می‌گیرد. کاربردکاوی کمی دیرتر از دو روش دیگر مورد توجه قرار گرفته است (شنکر و دیگران، ۲۰۰۵، ۴؛ هرچه وب در مسیر تبدیل‌شدن به رسانه‌ای تجارتی، ارتباطی و آموزشی به پیش می‌رود، مطالعه دقیق نوع کاربرد آن دارای اهمیت بیشتری می‌شود. البته لازم به یادآوری است که نمی‌توان مز روشی بین این سه دسته از پژوهش‌ها قرار داد و در پژوهش‌های مختلف می‌توان با ترکیب آنها به نتایج معتبرتری دست یافت.

کتاب وب کاوی: کاربردها و فنون با هدف نشان دادن این

هرچه وب در مسیر تبدیل شدن به رسانه‌ای تجاری، ارتباطی و آموزشی به پیش می‌رود، مطالعه دقیق نوع کاربرد آن دارای اهمیت بیشتری می‌شود

مطلوب کتاب به پنج بخش تقسیم شده است. بخش دوم کتاب، «محتوای وب»، فصل‌های سوم تا نهم را شامل می‌شود. در فصل سوم، «کاربرد اطلاعات محیطی برای ساخت یک سیستم کاوش صنعتی»، چندین قاعده مهم برای ارزیابی ارتباط صفحات وب با یک موضوع خاص توصیف می‌شوند که مهم‌ترین آنها نظم رتبه‌ای بر اساس ترسیم ربط محیطی^{۱۸} است. بدین مفهوم که چگونه می‌توان ارتباط بین صفحات مختلف ناظر بر موضوعی خاص را در قالب نموداری ترسیم و رتبه‌بندی کرد.

در فصل چهارم، «یادگیری هستی‌شناسی از یک ساختار وب حوزه‌ای»، یک روش‌شناسی برای شناخت هستی‌شناسی‌ها از یک ساختار ویژه وب معرفی می‌گردد. کاربرد این روش‌شناسی که به استخراج واژگان^{۱۹} منجر می‌شود، نوعی تفسیر معنایی^{۲۰} از واژه‌های مرتبط را فراهم می‌کند و به طور خودکار هستی‌شناسی حوزه‌ای را در پی خواهد داشت.

در فصل پنجم، مارس^{۲۱} معرفی می‌شود. مقاله از یک الگوریتم تطبیق افزایشی پرده برمنی دارد که به کاربر در بازیابی مدارک مورد علاقه‌اش کمک می‌کند. این الگوریتم از یک استراتژی گسترش پرسش^{۲۲} کاربر برای پنهان و اجرای مجدد پرسش برای شناخت علاقه کاربر استفاده می‌کند. به عبارت دیگر، این الگوریتم با بررسی پرسش‌های کاربر از سیستم، واژه‌های مرتبط با آنها را به طور خودکار شناسایی کرده و با گسترش فراینده دامنه پرسش در صدد پاسخ‌گویی به نیاز کاربر برمی‌آید.

فصل ششم، «کاربرد عنایین برای داده‌کاوی وب»، یک رویکرد غیرمستقیم برای نمایه‌سازی منابع چندرسانه‌ای موجود در صفحات وب با استفاده از عنوان آنها را پیشنهاد می‌کند. این رویکرد ازین‌رو حائز اهمیت است که درک متن نسبت به چندرسانه‌ای‌ها برای موتورهای جستجو بسیار ساده‌تر است و عنایین صفحات معمولاً به محتوای مدارک اشاره دارند.

در فصل هفتم، «به سوی نظریه بحران برخاسته از سیستم امنیتی مصنوعی برای وب کاوی»، بخشی از یک پژوهش بزرگ‌تر معرفی می‌شود و آن ساخت یک سیستم محتوای‌پویای وب است. در این مقاله سیستم اینمنی مصنوعی برای طبقه‌بندی نامه‌های الکترونیکی معرفی می‌گردد که با استفاده از آن نامه‌های الکترونیکی با توجه به محتمولایشان طبقه‌بندی شده و برای تأمین امنیت آنها تابییر خاصی اندیشیده می‌شود.

در فصل هشتم، «معانی ایکس.ام. ال»^{۲۳}، نیز یک روش جدید برای افزودن معنا به مدارک ایکس.ام. ال با اضافه کردن اطلاعات

حوزه‌پژوهشی نوظهور و اهمیت آن به چاپ رسیده است. هرچند تأکید اصلی آن کاربرد فنون وب کاوی در بهبود جستجو عنوان شده است (بیشگفار کتاب) و همین امر باعث جذابیت بیشتر این کتاب و نیز پذیرش آن از سوی خوانندگانی غیر از علوم رایانه‌ای و سیستم‌های اطلاعاتی مانند ارتباطات، تجارت الکترونیکی و کتابداری و اطلاع‌رسانی خواهد شد.

کتاب شامل ۱۹ مقاله از نویسنده‌گان برجسته حوزه‌وب کاوی است که آنتونی اسکیم^{۲۴} آنها را گردآوری آورده است. از نکات جالب این کتاب تعداد نویسنده‌گان مقالات آن است که به ۴۰ نفر می‌رسند. این امر حاکی از ماهیت اینگونه پژوهش‌های است که غالباً از دون پژوهش‌های مختلف مایه می‌گیرند. نکته قابل توجه دیگر حضور نویسنده‌گانی با ملیت‌های آسیای شرقی و نیز مسلمان است که گواه علاقه‌مندی آنان به انجام پژوهش‌هایی از این دست می‌باشد.

نویسنده مقاله‌ای، «مدیریت ابرداده: الزامی برای انباشت و مدیریت داشن»^{۲۵}، به اهمیت کاربرد ابرداده‌ها در مدیریت محتوای مدارک موجود در وب می‌پردازد. ازین‌رو که سازمان‌ها و افراد مختلف برای معرفی خدمات خود از واژه‌های مختلفی استفاده می‌کنند، در این مقاله استفاده از ابرداده‌های استاندارد برای معرفی خدمات توصیه می‌شود. در طول مقاله به اهمیت وب کاوی در تأمین خواست کاربران و نیز دارندگان سایت‌ها اشاره شده است.

یکی از مباحث مهمی که در چند سال اخیر در پژوهش‌های وب کاوی مورد توجه ویژه قرار گرفته، شخصی‌سازی است. شخصی‌سازی در پی آن است تا با شناخت ویژگی‌ها و نیازهای کاربران، خدمات خاص آنها را فراهم کند. در حقیقت با استفاده از فنون شخصی‌سازی، افراد مختلف از خدمات ویژه خودشان بهره‌مند خواهند شد. در فصل دوم، «کاوش برای شخصی‌سازی وب»^{۲۶} نویسنده‌گان مقدمه‌ای درباره این بحث مهم ارائه می‌کنند. البته در طول کتاب در بخش‌های ۳، ۵، ۱۱، ۱۳، ۱۴، ۱۷، ۱۸، ۱۹ و نیز بحث شخصی‌سازی مطرح است که گویای اهمیت است که این موضوع در پژوهش‌های وب کاوی دارد. دو فصل اول و دوم با هدف تهییه مقدمه‌ای برای بخش‌های بعدی کتاب بهصورت بخش مستقلی در ابتدای کتاب آورده شده‌اند، اما بهدلیل محتوای تقریباً فنی آنها بهنظر می‌رسد که خوانندگان مبتدی با خواندن آنها نتوانند به آسانی به مطالعه بخش‌های بعدی کتاب پردازن.

به تبعیت از دسته‌بندی رایج، در ادامه فصل‌های مختلف کتاب در سه بخش جداگانه محتوای‌کاوی وب، ساختار کاوی وب و کاربرد کاوی وب گنجانده شده‌اند که با احتساب بخش نتیجه‌گیری و مقدمه،





کتاب در ارتباط مستقیم با حوزه‌های پژوهشی و کاربردی است که با ارائه خدمات مبتنی بر وب همچون سیستم‌های اطلاعاتی، بازیابی اطلاعات و تجارت الکترونیک سروکار دارند

با در نظر گرفتن وب به مثابة محیطی که در آن مدارک مختلف با هم ارتباط دارند، می‌توان آن را به یک نمودار متشكل از زنجیره‌های ارتباطی بین منابع تشییه کرد و بر اساس آن منحنی‌های مختلفی ترسیم کرد. در این فصل به خوشبندی و دسته‌بندی این نمودارها برای ساده‌سازی فرآیندهای نمایش و جست‌وجو اشاره شده است.

در بخش سوم که فصل‌های سیزدهم تا هجدهم را شامل می‌شود، به کاربرد کاوی و ب اختصاص دارد. در فصل سیزدهم، «یکپارچه‌سازی معنایی و کاربرد کاوی و ب برای شخصی‌سازی»، از ملزومات موردنیاز برای یکپارچه‌سازی دانش معنایی موجود در منابع مختلف از جمله محتوا و ساختار وب‌سایتها بحث شده است. آنچه در این فصل ارائه شده است، یک چارچوب عمومی برای یکپارچه‌سازی کامل هستی‌شناسی‌های مصنوعی و فنون کاربرد کاوی و شخصی‌سازی وب با استفاده از پیش‌پردازی^{۲۸} و کشف الگو می‌باشد.

در فصل چهاردهم بیتز^{۲۹} از صاحب‌نظران حوزه بازیابی اطلاعات و ویراستار کتاب ارزشمند بازیابی نوین اطلاعات به اهمیت بررسی گزارش‌های تولیدشده و ذخیره‌شده در سرویس‌دهندها و نیز

معناشناختی به نشانه‌های عناصر این زبان مورد بحث قرار می‌گیرد. در فصل نهم، «طبقه‌بندی بر اساس مکعب داده‌ای»^{۳۰}، روش جدیدی برای سازماندهی فایل‌های موجود در پایگاه‌های اطلاعاتی معرفی می‌شود که در آن سه طبقه‌بند^{۳۱} جدید روی یک مکعب داده‌ای برای اهداف مبادلاتی و تحلیلی طراحی می‌شوند. بخش دوم کتاب، «ساختار کاوی وب»، شامل فصل‌های دهم تا دوازدهم است. در فصل دهم، «پالایش و اعتباری‌خواهی داده‌ها برای تحلیل چندجانبه ساختاری پیوند سایتها»، چندین روش پالایش و اعتباری‌خواهی به داده‌های مربوط به پیوندهای استفاده در ساختار کاوی وب توصیف شده‌اند. از آنجاکه نویسنده مقاله، مایک ٹلوال^{۳۲}، از پژوهشگران فعال در حوزه وب‌سنگی و ساختار کاوی وب بوده و خود کتاب تحلیل پیوند: رویکرد اطلاع‌رسانی را تالیف کرده، توانسته است فنون کاربردی جدیدی را در زمینه پژوهش‌های مرتبط با تحلیل ساختار موجود بین مدارک وب معرفی کند. وی در این مقاله از روش تحلیل چندجانبه ساختار پیوند سایتها برای شناخت الگوهای موجود در مجموعه‌های مشخصی از سایتهای وب سخن گفته است. در فصل یازدهم، «استخراج و سفارش اطلاعات با استفاده از کارگزاران متعدد»، از چالش‌های پیش‌رو در محیط‌های پیچیده و مسائل مرتبط با سرریز اطلاعات^{۳۳} سخن به میان آمده است. برای مواجهه با این چالش‌ها، نویسنده الگوی استفاده از گارگزاران متعدد در سیستم‌های بازیابی را پیشنهاد می‌کند.

در فصل بعدی، «خوشبندی نموداری وب برای نمایش و گردش در فضای مجازی»، به موضوع ترسیم نموداری ساختار وب و چگونگی خوشبندی این نمودارها پرداخته شده است. به عبارت دیگر،



با در نظر گرفتن وب به مثابه محیطی که در آن مدارک مختلف با هم ارتباط دارند، می‌توان آن را به یک نمودار مت Shank از زنجیره‌های ارتباطی بین منابع تشییه کرد

در آخرین فصل از بخش دوم کتاب، «کاربرد کاوی و وب: الگوریتم‌ها و نتایج» بار دیگر بر بازکاوی گزارش‌های دسترسی و وب، تحلیل الگوریتم‌های پردازش و استخراج داشن از چنین گزارش‌هایی تأکید شده و نیز فنونی برای بازکاوی گزارش‌ها به صورتی جامع پیشنهاد می‌شود.

بخش پنجم کتاب نتیجه‌گیری نام دارد. اما بر خلاف تصور در آن مقاله‌ای همچون سایر مقالات گنجانده شده و ارزیابی کلی از مطالب کتاب صورت نگرفته است. در این مقاله با عنوان «ایجاد یک گروه خبری: فراهم‌آوری دسترسی مشخص به سایتها بوزن از طریق وب کاوی» کاربرد فنون و وب کاوی در مسیر برطرف کردن مسائل مرتبط با دسترسی شخصی به خدمات بوزن مورد ملاحظه قرار گرفته است. در این مقاله سه حوزه اصلی وب کاوی تحلیل شده است: محتواکاوی که در آن تأکید ویژه‌ای بر کشف موضوع می‌شود، ساختارکاوی که در آن ساختار خبرهای بوزن با کاربرد فنون ساختارکاوی مورد بررسی قرار می‌گیرد و کاربرد کاوی که در آن فنونی برای ردیگری^{۳۰} و پرونده‌سازی^{۳۱} کاربران بر اساس مطالعه گزارش‌های وب به کار گرفته می‌شود. این فصل با مروری بر فنون شخصی‌سازی و نیز توصیف شخصی‌سازی ویژه دسترسی به بوزن به پایان می‌رسد.

از نقاط قوت کتاب باید عنوان آن را ذکر کرد. زیرا به خوبی از محتوای کتاب خبر می‌دهد. به علاوه پیروی از دسته‌بندی رایج شیوه‌های وب کاوی و گنجاندن فصل‌های مختلف کتاب زیر هریک از این دسته‌ها به خواننده در درک مفاهیم و نیز فنون کاربرد آنها در پژوهش‌های مختلف کمک شایانی می‌کند. دیگر اینکه کتاب

پرسش‌هایی که از سوی کاربران ارائه شده، پرداخته شده است. در طول مقاله با توجه فراوان به بحث کاربرد کاوی و ب خاطر شناس شده است که باید پرسش‌ها و رفتار کاربر بدقت تحلیل شود تا بتوان از نتایج این تحلیل در طراحی و بهبود رابطه‌ای کاربری موتورهای جستجو، عملکرد نمایه‌سازی و رتبه‌بندی نتایج استفاده کرد. فصل پانزدهم به یکی از موضوعات مهم در حوزه تحلیل گزارش‌های وب، حجم فراوان داده‌های ناظر بر رفتاری مشخص و تکراری از سوی جستجوی کاربر، پرداخته است. از آنجاکه کاربران در جستجوی مسیرهای تقریباً مشخص و مشابهی را دنبال می‌کنند، در گزارش‌های وب حجم انبوهی از داده‌ها به این رفتارها اختصاص دارد و این امر تحلیل گزارش‌ها را با مشکل مواجه می‌سازد. در این فصل، «وب کاوی کارآمد برای الگوهای مسیریمایی»^{۳۲} نویسنده‌گان از دو الگوریتم جدید برای حل این مسئله سخن گفته‌اند.

فصل شانزدهم، «تحلیلی از الگوهای مشاهده مدارک کاربران موتورهای جستجوی وب» که از جانب دو تن از پژوهشگران حوزه اطلاع‌رسانی به نگارش درآمده، الگوی مشاهده صفحات نتایج جستجو و سایر صفحات وب توسط کاربران مورد توجه قرار می‌گیرد. در این فصل از ارش کاربرد تحلیل‌های سنتی گزارش در شناسایی این الگوها بحث شده است.

در فصل هفدهم، «معماری نرم‌افزار مبتنی بر جاوا توزیعی برای کاربرد کاوی و وب» تکنیکی از هریک از رویکردهای مختلف کاربرد کاوی و وب مانند خوش‌سازی، قوانین همراهی^{۳۳} (همراهی عبارات و واژه‌ها در مدارک مختلف) و الگوی پی‌درپی سخن گفته شده است. این الگوها در عماری یادگیرنده با نام متالا^{۳۴} یکپارچه می‌شوند.

23. XML Semantics
24. Classification on Top of Data Cube
25. Classifier
26. Mike Thelwall
27. Information overload
28. Preprocessing
29. Yates
30. Efficient Web Mining For Traversal Path Patterns
31. Association rules
32. METALA
33. Tracking
34. Profiling

منابع و مأخذ

1. Berendt, B., Hotho, A. and Stumme, G. (2002). **Towards Semantic Web Mining. International Semantic Web Conference**, pp. 264-278
2. Cooley, R. Mobasher, B. and Srivastave, J. (1997) "Web Mining: Information and Pattern Discovery on the World Wide Web" In Proceedings of the 9th IEEE International Conference on Tool with Artificial Intelligence. [Online] Available at: maya.cs.depaul.edu/~mobasher/papers/webminer-tai97.pdf (Accessed 23 October 2007).
3. Eirinaki, M. (2004). Web Mining: A Roadmap, Technical Report, DB-NET 2004, available at <http://www.engr.sjsu.edu/meirinaki/papers/NEMIS.pdf> (accessed 23 October 2007).
4. Etzioni, O, (1996). "The World-Wide Web: quagmire or gold mine?", **Communications of the ACM**, v.39 n.11, p.65-68.
5. Facca, F. M. and Lanzi P. L.(2003). "Recent Developments in Web Usage Mining Research, In Kambayashi Y. et al., Data Warehousing and Knowledge Discovery": 5 International Conference, DaWak 2003 Prague, September 3-5, 2003 Proceedings, Czech Republic, page 140-150.
6. Kosala, R, and Blockeel, H. (2000). "Web mining research: A survey". **SIGKDD explorations**, 2(1):1-15.
7. Schenker, A., Bunke, H., Last, M. and Kandel, A. (2005). "Graph-Theoretic Techniques for Web Content Mining" World Scientific Publishing Company.

مجموعه‌ای از مقالات نویسنده‌گان و پژوهشگران فال حوزه وب کاوی است و خواننده می‌تواند با نگاهی به زندگینامه آنها در بیان کتاب از گشته آنان و نیز کیفیت پژوهش‌های در دست انجام آگاه شود و به طور کلی دیدگاه جامعی نسبت به موضوع کتاب پیدا کند.

از آنجاکه کتاب مجموعه‌ای از مقالات مختلف است، معایبی که برای اینگونه از کتاب‌ها متصور است برای کتاب حاضر نیز از قبیل نداشتن یکپارچگی در ارائه مطالب، گنجاندن فصل‌ها در چارچوبی از پیش تعریف شده یا اساساً چارچوبی ساختگی، در نظر نگرفتن نوع مخاطب و میزان داشش آنها، کاربرد فزاینده و ازهای تخصصی و ماهیت عملگرایانه مقالات وجود دارد.

با این همه کتاب از جمله نخستین تلاش‌ها برای معرفی این حوزه پژوهشی نوظهور، میان رشته‌ای و مهم به شمار می‌رود. کتاب در ارتباط مستقیم با حوزه‌های پژوهشی و کاربردی است که با ارائه خدمات مبتنی بر وب همچون سیستم‌های اطلاعاتی، بازیابی اطلاعات و تجارت الکترونیک سروکار دارد.

کتاب دارای یک نمایه پایانی است که فقط چهار صفحه است و برای بازنمایی مطلب کتابی با موضوعات جدید و ۴۴۲ صفحه خالی از اشکال نیست. بنظر می‌رسد در تهیه آن شتاب‌زده عمل شده است؛ امری که ظاهراً کل کتاب نیز با آن دست به گردان است.

پی‌نوشت‌ها

1. Web mining
2. Data mining
3. Eirinaki
4. Schenker
5. Vector Space Model
6. Etzioni
7. Kosala and Blockeel
8. Berendt, Hotho and Stumme
9. Facca and Lanzi
10. Cooley, Mobasher and Srivastave
11. Web content mining
12. Web structure mining
13. Web usage mining
14. Hyperlinks
15. Logs
16. Anthony Scime
17. Metadata Management: A Requirement for Web Warehousing and Knowledge Management
18. Relevancy context graph
19. Terminology
20. Semantic interpretation
21. MARS: Multiplicative Adaptive Refinement Web Search
22. Query expansion

