

## شالوده داده کاوی و کشف دانش

• فریبوز درودی

دانشجوی دکتری کتابداری و اطلاع‌رسانی دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

بالایی می‌طلبد. نظریات داده کاوی و بازیابی داده‌های مرتبط، در کنار فنون و الگوهای انجام این فرآیند، حوزه‌ای از مباحث نظری و کاربردی را مطرح ساخته که امروزه در طراحی، تدوین و مدیریت پایگاه داده بسیار مؤثر است. همچنین با توسعه پایگاه‌های دانش<sup>۱</sup> و بهره‌گیری از آن در سازمان‌ها و مؤسسات مختلف، بحث اکتشاف دانش و آشنایی با ساختارهای اثربخش آن، اهمیت بسیاری یافته است. بر این اساس امروزه موضوع داده کاوی در کنار اکتشاف دانش، از جمله مباحثی است که در میان متخصصان علوم رایانه با استقبال کم‌نظیری روپیدرو شده است و کتاب حاضر که حاصل مقامات مهمی در این حوزه مطالعاتی است، اخیراً به چاپ رسیده است.

این اثر در حوزه مطالعاتی هوش محاسباتی و ششمین مجلد از این فروrost است که یافته‌های نوین و حوزه‌های تخصصی گوناگونی را در این عرصه پوشش می‌دهد. کتاب حاوی مقالات ارزشمندی است و تلاش نویسنده‌گان در معرفی و بررسی آخرین یافته‌های پژوهشی در عرصه کلی هوش محاسباتی، که به حوزه تخصصی داده کاوی و اکتشاف دانش ختم شده، درخور ستایش است. از نکات برجسته دیگر باید به ترکیب مناسب میان نظریات، کاربردها و طراحی روش‌های علمی اشاره کرد که جملگی در این عرصه به‌شکل مطلوبی بیان شده است.

برخی از مباحث کتاب در زمینه دانش رایانه است که با مباحث مهندسی و مکانیک نیز ارتباط دارد. استفاده از علوم مختلف در ایجاد فضایی مناسب برای ارائه یافته‌های نوین پژوهشی نشان‌دهنده توأم‌مندی‌های بالای نویسنده‌گان است. مطالع این اثر در واقع مقالات ارائه شده در یک کارگاه آموزشی است که ششم می ۲۰۰۲ در تایپه<sup>۲</sup> مرکز تایپون<sup>۳</sup> برگزار شد و بخشی از ششمین همایش آسیا-اقیانوسیه در موضوع اکتشاف دانش و داده کاوی<sup>۴</sup> بود. کتاب در سه بخش تدوین شده است. بخش اول، «مبانی داده کاوی»، هشت مقاله را در بر می‌گیرد. بخش دوم، «روش‌های داده کاوی» شامل هُ مقاله است و بخش سوم «کشف دانش عمومی» از چهار مقاله تشکیل شده است.

مقاله اول درباره موضوع اکتشاف دانش به مثابه ترجمه است. در این بخش، موروی بر تسریخ اکتشافی دانش به عنوان ترجمه از ارائه غیرنامدین<sup>۵</sup> به نمایش نمادین<sup>۶</sup> شده است. هر دو مفهوم در چارچوب مفاهیم اکتشافی دانش بهروشی مورد توجه قرار گرفته و ویژگی‌های نمایش نمادین در قالب سنجش‌های کمی مطرح شده است. مراحل پردازش ارائه غیرنامدین ویژگی‌های مغایر با نوع نمادین دارد؛ بنابراین شکاف و فاصله عمیقی میان آنها وجود داشته که در این مقاله تلاش



■ **Foundations of Data Mining and Knowledge Discovery.** Tsau Young Lin ...[et al.]. Berlin; New York : Springer-Verlag.

**ISBN:** 978-3-540-26257-2

تسو یانگ لین<sup>۱</sup> سروبراستار اثر حاضر، استاد علوم رایانه در دانشگاه ایالتی سن ژوزه<sup>۲</sup> است. اوی متخصص علوم رایانه و در حوزه‌های مختلف صاحب پیشینه‌آموزشی و پژوهشی است. زمینه‌های حرفه‌ای که لین بدانها پرداخته، عبارت‌اند از: پایگاه‌های داده، داده کاوی،<sup>۳</sup> امنیت داده<sup>۴</sup>، نظام‌های داده و دانش‌مدار<sup>۵</sup>، محاسبات فازی<sup>۶</sup>، کنترل هوشمند<sup>۷</sup> و مهندسی الکترونیک<sup>۸</sup>. اوی با ارائه ۲۱۵ مقاله علمی در مجلات تخصصی و همایش‌ها، و نیز تدوین ۱۱ کتاب، کارنامه‌ای پریار از خود بر جای نهاده است (صفحة خانگی تسو یانگ لین<sup>۹</sup>). چهار و پریار از داده کاوی و پایگاه‌های داده، و نیز نظام‌های اکتشافی فعالیت حرفه‌ای داده کاوی و پایگاه‌های داده، و نیز نظام‌های اکتشافی دانش صاحب آثار مهم و قابل توجهی آند.

داده کاوی یکی از زمینه‌های مهم درباره موضوع پایگاه داده است. با افزایش روزافزون منابع اطلاعاتی و داده‌های علمی و ورود آنها به پایگاه‌های اطلاعاتی، حجم داده‌ها افزایش چشمگیری یافته، به گونه‌ای که بازیابی اطلاعات مرتبط در درون این پایگاه‌ها با دشواری‌های خاص خود روپیدرو شده و دستیابی به اطلاعات ظرفت

## با توسعهٔ پایگاه‌های دانش و بهره‌گیری از آن در سازمان‌ها و مؤسسه‌های مختلف، بحث اکتشاف دانش و آشنایی با ساختارهای اثربخش آن، اهمیت بسیاری یافته است

آماری برای اهدافی که هریک می‌توانند بسیار متفاوت از روش‌های اکتشاف دانش در پایگاه‌های داده باشند، طراحی شده‌اند. در این مقاله بیان شده که حوزهٔ اکتشاف دانش در پایگاه‌های داده از روش‌شناسی آمار استفاده بسیار مفیدی می‌کند.

مقالهٔ هفتم به موضوع انتخاب فرضیه و تأیید درستی آن در داده‌کاوی اختصاص دارد. نویسنده‌گان در این مقاله با بیان این مطلب که داده‌کاوی نمونه‌ای از یک روش‌شناسی استقرائی<sup>۷</sup> است، به تبیین ملاحظات فلسفی و معروفی آن می‌پردازند. به طور خاص، اثبات صحت و درستی روش استقرائی یک مشکل تاریخی در عرصهٔ مباحث معرفت‌شناسی است که تلاش برای فرمول‌بندی و تبیین دقیق ویژگی‌های آن فعالیت مهمی محسوب می‌شود. مقالهٔ هشتم به بررسی استقلال آماری دربارهٔ جدول احتمالی می‌پردازد. در این مقاله تحلیل مناسبی از وضع استقلال آماری با توجه به منطق ریاضی ارائه شده که در قالب جدول‌های احتمالی و تأثیر بر کاربرد آن مورد بررسی قرار گرفته است.

در مقالهٔ نهم پژوهشی تطبیقی درخصوص انتخاب مدل بهشیوهٔ تحلیل عامل صفر و یک انجام شده که در مباحث تحلیل داده کاربرد وسیع و متعددی دارد. این بررسی‌ها بیشتر دربارهٔ تبیین مدلی است که بنوادر در فرآیندهای تحلیل داده و بررسی‌های مربوط به آن به پاری متخصصان آید. علاوه بر آن تلاشی درخور انجام پذیرفته تا معیارهای اصلی در انتخاب مدل معروفی شده و بر مبنای محاسبات آماری ارتقا داده شود. در مقالهٔ دهم دربارهٔ مستلة استخراج قوانین عمومی مربوط به ویژگی‌های انتزاع خودکارسازی شده و استفاده از روش ناول<sup>۸</sup> برای قوانین عمومی شده کاوش به همراه پشتیبانی قوی از ساختارهای آن بحث می‌شود.

مقالهٔ یازدهم به بررسی فرآیند تصمیم‌گیری بر مبنای نظام دوگانه<sup>۹</sup> در دانش‌های چندگانه اختصاص دارد. تصمیم‌گیری مبتنی بر منطق ریاضی و با بهره‌گیری از روش‌های آماری یکی از فعالیت‌های خاص داده‌کاوی است که در این مقاله با معرفی مدلی ویژه آن بیشتر تحلیل شده است. در مقالهٔ دوازدهم مباحثی دربارهٔ ویژگی‌های صورت‌گیرایی منطق‌دار برای داده‌کاوی موقتی مطرح و روش‌شناسی خاص آن برای اکتشاف دانش بیان شده است. از جمله مسائل مورد توجه در این مقاله، مفهوم ساختار زمانی خطی است که در قوانین داده‌کاوی کاربرد دارد.


مقالهٔ سیزدهم به موضوع رویکرد جانشین در قوانین پیوند کاوی اختصاص دارد که پایه و مبنای آن در ارائهٔ داده‌های تحلیلی بوده که از طریق رشته‌های مناسبی از واحد بیت<sup>۱۰</sup> تبیین شده است. برای

شده است تا با ارائهٔ سنجشی کمی و روش‌مند، ابعاد و خصوصیات آن معرفی شود. مقالهٔ دوم به مبانی ریاضی قوانین پیوند و پیوند کاوی با شیوهٔ حل نامعادله‌های خطی انگرال اختصاص دارد. نویسنده در این مقاله با بیان الگوهای ریاضی قوانین پیوند می‌کوشد تا رویکرد نوینی از پیوند کاوی ارائه دهد. به طور غیررسمی، داده‌کاوی از الگوهای برآمده از داده مشتق می‌شود. مکانیک ریاضی کاوش پیوند از این دیدگاه، به دقت مورد بررسی و آزمایش قرار گرفته است. داده جدولی از نمادهای احتمالی و الگوی هر تجربهٔ منطقی- جبری بوده که از این جدول با پشتیبانی زیاد منشأ گرفته است. علاوه بر آن مدلی از داده در این مقاله ارائه شده که به این فرآیند یاری می‌رساند.

در مقالهٔ سوم، «ارائهٔ مطالعه‌ای تطبیقی دربارهٔ مدل‌های کاوش الگوی متوالی»، مشکلات مربوط به الگوهای متوالی کاوش بررسی شده و با بهره‌گیری از یک روش ارزشیابی عمومی، ارزش کیفی تعیین شده است. در این پژوهش چهار مدل مؤلفهٔ اصلی ارزشیابی مطرح و تحلیل دقیق شده است. این مطالعه همچنین با سنجش وضع پایگاه‌های داده ترکیبی و بهره‌گیری از روش پیمایشی به شیوهٔ تصادفی وضع آنان را بررسی و سطوح اختلال ایجاد شده را معرفی می‌کند. همچنین راه حل‌های احتمالی و قریب به واقع معرفی و مدل مورد نظر بیان می‌شود. نویسنده‌گان در مقالهٔ چهارم با معرفی مدل‌های همیستگی توانند به توضیح بیشتر دربارهٔ کاربرد آنها می‌پردازند. کانون توجه این مطالعه بر ترجیح‌هایی است که نسبت به مدل‌های رقابتی وجود دارد. آمار کلاسیک، بخشی از فنون شناخته شده برای انتخاب مدل‌های در رگرسیون‌های چندجمله‌ای است؛ که در این مقاله مورد مذاقه قرار گرفته است. همچنین اصول انتخاب مدل با ویژگی‌های خاص بررسی و نتایج مهمی از آن به دست آمده است.

مقالهٔ پنجم نیز به چارچوب‌های احتمالی منطقی مدار دربارهٔ ویژگی‌های اکتشاف دانش در پایگاه‌های داده<sup>۱۱</sup> می‌پردازد. به‌منظور ارتقاء و توسعهٔ فرآیند پردازشی اکتشاف دانش در پایگاه‌های داده، انواع شیوه‌های اکتشاف دانش بررسی می‌شود. در این مقاله بیان‌های منطقی در فرآیند اکتشاف دانش تحلیل شده و برخی از ویژگی‌های مهم آن مطرح می‌شود. نویسنده‌گان پس از بررسی‌ها، منطق احتمالی باچیوس<sup>۱۲</sup> را گزینهٔ مطلوب و مناسبی در فعالیت اکتشاف دانش معرفی می‌کنند. در ادامه بر اساس زبان خاص این منطق احتمالی، الگویی ارائه می‌شود که پیش از آن مطرح نشده، و در اکتشاف دانش سودمند لست. مقالهٔ ششم دربارهٔ نگرش دقیق در استفاده از روش‌شناسی آماری در داده‌کاوی است. اکتشاف دانش در پایگاه‌های داده بهصورت ذاتی یک فعالیت آماری است. بسیاری از روش‌شناسی‌های کلاسیک

## انتخاب عنوان‌های هر مقاله و نیز عنوان‌های فرعی در ساختار مقاله بر مبانی محتوای اثر صورت پذیرفته و ارتباط عمیقی میان آنها وجود دارد



با بهره‌گیری از روش‌های ریاضی به تبیین این مقوله می‌پردازند. در مقاله بیستم موضوع گزارش‌های نتایج داده کاوی در قالب زبان طبیعی مطرح و بعد خاص آن بررسی می‌شود. همچنین شیوه‌های نوین سنجش گزارش‌ها و ارائه نتایج در محیط‌های دیجیتالی با بهره‌گیری از زبان طبیعی به تفصیل بیان شده است. مقاله بیست و یکم به الگوریتم محاسباتی مقدار محتمل درباره افزایش کنترل کار کاپر اختصاص دارد. در این مقاله شیوه‌های نظرات بر فعالیت کاری کاربران در فعالیت داده کاوی در پایگاه‌های اطلاعاتی با تکیه بر الگوریتم خاص محاسباتی مقدار محتمل بررسی و نتایج آن ارائه شده است.

کتاب مبانی داده کاوی و کشف داش شامل آخرین نتایج و راهنمایی‌های نوین در زمینه پژوهش‌های داده کاوی است. داده کاوی که با فناوری‌های متعددی مرتبط بوده، شامل مباحثی چون هوش رایانه‌ای،<sup>۲۴</sup> پایگاه داده و مدیریت داش،<sup>۲۵</sup> آموزش ماشینی،<sup>۲۶</sup> محاسبه تقریبی،<sup>۲۷</sup> و آمار است که از جمله حوزه‌هایی اند که سرعت بالایی در رشد و توسعه علوم رایانه دارند. این کتاب به ارائه نتایج پژوهش‌های انجام شده، درباره بنیادهای رشتۀ علمی و ارائه موقعيت پیشرفت‌ترین فناوری برای بسیاری از پژوهش‌های جاری می‌پردازد. علاوه بر آن اثر حاضر به اثبات ارزش و سودمندی داده کاوی برای پژوهشگران نیز می‌پردازد. به گونه‌ای که اگر آنان مایل نباشند اصول بنیادی داده کاوی را در پژوهش‌های خود پوشش دهند یا به نظریات کاربردهای عملی توجه داشته باشند، در هر دو صورت می‌توانند از آن استفاده مناسبی داشته باشند (سایت آمارون).

مطالب کتاب، از مباحث نوین حوزه مطالعاتی داده کاوی و اکتشاف داشت. این مباحث در قالب مقالات مستقل در مجلات علمی به

انواع متعددی از قوانین پیوند شامل قوانین پیوند موقعیتی می‌توان از آن بهره‌گرفت. مقاله چهاردهم به کاوش مستقیم قوانین از داده می‌پردازد. چگونگی کسب قوانین مهم این حوزه از طریق تجزیه منطقی داده به فرآیند مطالعاتی خاصی نیاز دارد که نویسنده‌گان این مقاله به تبیین آن پرداخته‌اند. همچنین موضوع از دست دادن مقادیر از منظر ریاضی مطرح و بررسی می‌شود.

مقاله پانزدهم درباره مبحث تعیین شناسایی خوش‌های<sup>۲۸</sup> است. پدیده خوش‌هی یکی از مباحث عمده‌ای است که در عرصه داده کاوی و اکتشاف داش مطرح می‌شود و کاربرد وسیعی در نظام‌های بازیابی اطلاعات دارد. در این مقاله همچنین بهره‌گیری حداکثری از پیکربندی آنتروپی<sup>۲۹</sup> مطرح شده و درباره ویژگی‌های آن مطالب سودمندی ارائه شده است. در مقاله شانزدهم الگوهای کاوش در شبکه‌های عصبی با ساختار خاص آن و عناصر تأثیرگذار در فرآیند داده کاوی مورد بحث و بررسی قرار می‌گیرد.

مقاله هفدهم شامل مبحث دانش کاوی توسعه‌یافته است. در این مقاله با ارائه رویکردی چندروشی، فرآیند کاری داش کاوی و عوامل مهم دخیل در این شیوه بررسی شده است. مقاله هجدهم به موضوع آموزش بر اساس شیوه ارسال و بهره‌گیری از روش برچسبزنی از مجازی پیوسته اختصاص دارد. در این مقاله سیاهه‌ای از برچسب‌های قابل ارسال در فرآیند تعاملی معرفی و تحلیل شده است.

مقاله نوزدهم نیز درباره شناسایی مقادیر تحلیلی است که در ارتباط با نمایه‌سازی معنایی راکد<sup>۳۰</sup> بیان می‌شود. روش نمایه‌سازی معنایی یکی از شیوه‌های مفیدی است که در فعالیت داده کاوی استفاده شده و مبتنی بر تحلیل آماری است. نویسنده‌گان در این مقاله

5. Data and Knowledge Based System
6. Fuzzy Computing
7. Intelligent Control
8. E-Engineering
9. Tsau Young Lin» home page
10. Knowledge base
11. Taipei
12. Taiwan
13. 6th Pacific-Asia Conference on Knowledge Discovery and Data Mining
14. Non-symbolic representation
15. symbolic representation
16. Knowledge Discovery in Databases(KDD)
17. Bacchus» probability logic
18. Inductive methodology
19. Novel method
20. Hybrid
21. Bit
22. Clusters
23. Entropy
24. Latent semantic indexing
25. Computational intelligence
26. Database and knowledge management
27. Machine learning
28. Soft computing

#### منابع و مأخذ

1. Amazon [web site], **Foundations of Data Mining and Knowledge Discovery.** Tsau Young Lin ... [et al.]. Editorial Reviews by Amazon.[on-line] Available:  
[http://www.cs.sjsu.edu/~tylin/index.php?goto=index.php](http://www.amazon.com/Foundations-Knowledge-Discovery-Computational-Intelligence/dp/3540262571/ref=sr_1_7274500-9532555?ie=UTF8&s=books&qid=1191833211&sr=1-8[accessed 8, , Oct., 2007].</a></li>
<li>2.Tsau Young Lin' home pag. [on-line]. Available:<br/>
<a href=) [accessed 9 , Oct., 2007]

چاپ رسیده یا در همایش ارائه شده‌اند. علاوه بر آن در برخی از متون درسی از آنها استفاده شده یا مقالات در قالب درس‌های تخصصی نیز ارائه شده‌اند. اهمیت موضوع در حد بالایی است و نویسنده‌اند نیز با پژوهش‌های کاربردی و پیمایشی به غنای اثر افزوده‌اند. یکی از وزیرگی‌های مهم کتاب برقراری ارتباط منطقی میان روش‌های داده‌کاوی و اکتشاف دانش است. الگوهای برجسته‌ای که توانمندی بازیابی اطلاعات را افزایش می‌دهد، حاصل تجربه‌های سودمندی است که در قالب نگارش‌های پژوهشی به دست آمده است. از همین‌رو برخی از الگوریتم‌های مناسب برای طراحی الگوهای مطلوب معرفی و تحلیل شده است.

معرفی فناوری‌های نوین حوزه داده‌کاوی و اکتشاف دانش نیز یکی دیگر از نقاط مثبت اثر است. برخی از این فناوری‌ها در مراحل نوین فعالیت خود هستند و می‌توانند مورد بررسی و تحلیل پیشتر قرار گیرند. از سوی دیگر توضیحات ارائه شده در کتاب کاملاً فنی و تخصصی است و به زبان ریاضی بیان شده است. در واقع رویکرد اصلی در بیان مطالب، قوانین و الگوهای ریاضی بوده که تا حد زیادی برای خوانندگان آشنا با دانش ریاضیات و ریانه سودمند است. الگوهایی که در اثر بررسی شده، درباره ساختارهای کلی قوانین ریاضی شرح داده شده و مدل‌هایی که مورد تحلیل قرار گرفته است، از همین شیوه تبعیت می‌کند. از مزایای اثر به ارائه نتایج نوینی که از بررسی‌ها و مطالعات پیمایشی به دست آمده، می‌توان اشاره کرد که برخی از آنها کاملاً جدید بوده و در پژوهش مورد نظر بدست آمده است. الگوهایی که ارائه شده بیشتر با روش‌شناسی منطق ریاضی بیان شده و این یکی از نقاط مثبت در ساختار اثر محاسب می‌شود.

ارائه چکیده مباحث در ابتدای هر مقاله سبب شده تا خواننده بتواند در آغاز مطالعه خود از محتوای مقاله به خوبی آگاهی یافته و با کلیات بحث آشنا شود. در برخی از مطالعات شیوه‌های برجسته‌سازی و نمایش اطلاعات و نتایج مهم به خوبی رعایت و اهمیت بحث مطرح شده است. انتخاب عنوان‌های هر مقاله و نیز عنوان‌های فرعی در ساختار مقاله بر مبنای محتوای اثر صورت پذیرفته و ارتباط عمیقی میان آنها وجود دارد. منابع کتاب‌شناسی هر مقاله در پایان آن آورده شده است. این اثر را می‌توان یکی از منابع مهم در زمینه داده‌کاوی و اکتشاف دانش بهشمار آورد.

#### پی‌نوشت‌ها

1. Tsau Young Lin
2. San Jose State University
3. Data Mining
4. Data Security

