

افقهای جدید آمار: تحلیل داده‌های نمادین

محمد رضا مشکانی^۱

چکیده

پیشرفت شگفت‌انگیز در محاسبات آماری با رایانه‌های سریع، موجب تحولاتی ژرف در اکثر علوم و از آن جمله در آمار شده است. تا چند دهه پیش، تحلیل مجموعه داده‌هایی که شامل بردارها یا ماتریس‌های با ابعاد زیاد بودند، مشکلی عمده به شمار می‌آمد، ولی امروزه چنین محاسباتی امری عادی به شمار می‌روند، اما تحلیل چنین داده‌های حجمی با ابزارها و روشهای سبق تا حدودی به معنای نادیده انگاشتن اطلاعات جالب توجهی است که در آنها نهفته‌اند. بنابراین، از چندی قبل، ضرورت ابداع روشهایی جدید که از این پیشرفت‌های محاسباتی بهره بر گیرند، احساس شده است. برای بهره‌گیری از این امکانات جدید، باید نگرش ما به مجموعه داده‌ها تغییر باید و مفاهیمی جدید تعریف شوند تا بر اساس آنها روشهای جدید بنا نهاده شوند. با تعریف داده‌های نمادین که می‌توانند رده‌هایی از بردارها یا ماتریس‌هایی اندازه‌گیری شده از هر فردی آماری باشند، به تعیین جالبی می‌توان دست یافت.

در این مقاله، ابتدا ضرورت استفاده از داده‌هایی نمادین و تحلیل آنها را مورد بحث قرار می‌دهیم. سپس با معرفی مفاهیم و اصطلاحات مورد استفاده در این رشته به اجمال و همراه با مثال روشهایی از تحلیل داده‌های نمادین را عرضه می‌کنیم.

واژه‌های کلیدی: داده‌های نمادین، متغیرهای نمادین، داده کاوی، رده‌بندی، خوشه‌بندی، متغیرهای بازه-مقدار، چند مقداره.

نیستند. زیرا در اغلب موارد، داده‌ها یک «کل» را تشکیل می‌دهند. مثل سوابق حسابهای کارت‌های اعتباری همه کسانی که از کارت استفاده می‌کنند. سؤال مربوط دیگر آن است که آیا داده‌های یک نقطه زمانی مشخص را می‌توان از همان جامعه‌ای دانست که در زمان دیگر گردآوری می‌شوند. مثلاً، آیا داده‌های کارت‌های اعتباری لین هفته، از همان جامعه داده‌های هفته «بعد»ند؟ یا اگر دو مجموعه داده‌ها در هم ادغام شوند، باز هم متعلق به همان جامعه اولیه‌اند؟ دلیل عمدۀ دیگر که روشهای شناخته شده را نمی‌توان به کار برد، صرفاً اندازه مجموعه داده‌هاست. برای مثال، فرض کنید n مشاهده در مورد p متغیر از هر فرد

۱. مقدمه

با اختراع رایانه‌ها، انواع پایگاههای داده‌ای بزرگ و بسیار بزرگ امری عادی شده است. چیزی که عادی نیست، نحوه تحلیل داده‌های موجود در این پایگاهها و یا چگونگی استخراج اطلاعات مفید از درون این پایگاههای گسترده است، اما روشن است که در مواردی هم که نظریه و روش‌شناسی موجود به نظر می‌رسد که قابل کاربرست باشد، استفاده روزمره از این گونه روشهای آماری اغلب مناسب نیست. دلیل‌های زیادی وجود دارند. به طور کلی، یکی از دلایل عمدۀ آن است که این گونه مجموعه‌های داده‌ها واقعاً نمونه‌ای از یک جامعه

^۱ دانشکده علوم ریاضی، گروه آمار، دانشگاه شهید بهشتی

یا تپش قلب (مثل ۷۲ و ۶۰)، فشار خون سیستولیک (۱۳۰ و ۱۲۰) برای مثلاً ۱۲۰ بیمار (یا مثلاً برای $1/2 \times 10^7$ بیمار). یا، ممکن است ۲۰ دانشجو داشته باشیم که به وسیله بافتگار یا توزیع نمره‌هایشان برای چند متغیر ریاضی، فیزیک، آمار و غیره مشخص شده باشند. ممکن است پرنده‌گان بر حسب رنگشان مشخص شوند. مثلاً پرنده ۱ (سیاه)، پرنده ۲ (زرد و آبی)، پرنده ۳ = (نیمی زرد و نیمی قرمز) ... یعنی، متغیر «رنگ» تنها یک رنگ ممکن را برای هر پرنده اختیار نمی‌کند، بلکه فهرستی از رنگ‌ها را اختیار می‌کند، یا حتی فهرستی را با نسبت‌های متناظر از هر رنگ را برای هر پرنده اختیار می‌کند. از سوی دیگر، نقطه داده‌ای {سیاه} ممکن است گردایه‌ای از پرنده‌گان را که همگی سیاه‌اند، نشان دهد و نقطه {قرمز ۰/۶} و {زرد ۰/۴} گردایه‌ای از پرنده‌گانی خواهد بود که 40% زرد و 60% قرمزد یا گردایه‌ای که از آنها 40% کلاً زرد و 60% کلاً قرمزند. مثالهایی بی‌شمار را می‌توان ذکر کرد. در راستای دیگر، ممکن است پرنده خاصی را مدنظر نداشته باشیم، بلکه به مفهوم پرنده‌ای سیاه، یا پرنده‌ای زرد و قرمز علاقه‌مند باشیم. به همین ترتیب، می‌توانیم یک شرکت مهندسی را با پایگاه علمی آنکه مشتمل بر تجارت کارمندانش است، مشخص کنیم. این گونه تجارب بیشتر با مفاهیم توصیف می‌شوند تا با داده‌های استاندارد و بدین طریق، مثالهایی از داده‌های نمادین‌اند. در مورد مجموعه‌های کوچک از داده‌های نمادین سؤال این است که تحلیل چگونه صورت می‌گیرد. در مورد مجموعه‌های بزرگ، سؤال نخست این است که رویکرد انتخابی برای خلاصه‌سازی چیست تا لزوماً به مجموعه‌ای کوچکتر خلاصه شوند. برخی روش‌های خلاصه‌سازی الزاماً شامل داده‌های نمادین و تحلیل نمادین در قالبی از انواع قالبها هستند، در حالی که در برخی دیگر لازم نیست که آن گونه عمل شود.

در این مقاله، سعی بر آن است که مفاهیم و روش‌های گوناگون ابداع شده تحت عنوان تحلیل داده‌های نمادین یا سایر عنوان‌ها را مرور کنیم. در حقیقت، این روشها تاکنون محدود به ابداع روش شناسی‌هایی بوده‌اند که داده‌ها را در قالب‌های معقول و قابل اداره سازمان دهند، کاری تا حدودی مشابه با تشکیل جدول‌های توزیع فراوانی و بافتگارها و دیگر آمارهای خلاصه‌پایه‌ای در دوره قبل از سال ۱۹۰۰ است. همین اقدامات خلاصه‌سازی بود که بنیاد آمار استباطی را در قرن بیست میلادی پایه‌گذاری کرد. در زیر مروری کوتاه بر روش‌های آماری نمادین موجود می‌آوریم. موضوعی که سریعاً آشکار می‌شود این است

آماری داریم. در اغلب موارد، ماتریس داده‌های X که از بعد $n \times p$ است، به صورت $(X'X)^{-1}$ که از بعد $p \times p$ است، در محاسبه وارد می‌شود. اگر n از بعد صدها هزار و p از بعد صد یا بیشتر باشد، در عین حال که از حیث نظری، چنین کاری ممکن است، از حیث عملی کاری بسیار سنگین خواهد. حتی وقتی توانایی رایانه‌ها (مثالاً برای وارون کردن ماتریس‌ها در مدت زمانی معقول) افزایش یابند، در نتیجه، مجموعه داده‌های بسیار بزرگتر تولید خواهند شد و مساله تقریباً به همین شکل باقی خواهد ماند. بنابراین، در حالی که روش‌های سنتی در مورد مجموعه‌هایی کوچک از داده‌ها که در گذشته وجه غالب بوده‌اند، به خوبی کار کرده است. اکنون انتظار از آمارشناسان تحلیل داده‌ها آن است که شیوه‌هایی را ابداع کنند که در مورد مجموعه‌های بزرگ داده‌های جدید خوب کار کنند. این شیوه‌ها، باید چنان باشند که ما را از اطلاعات زیر ساختی (یا دانش) نهفته در داده‌ها آگاه سازند.

یک رویکرد آن است که مجموعه‌های بزرگ داده‌ها را به طریقی خلاصه کنیم که مجموعه داده‌های خلاصه اندازه‌ای کوچک داشته باشد تا بتوانیم از عهده‌اش برآیم. بدین ترتیب، در مثال کارت اعتباری به عرض صورت زیر عملیات بانکی برای هر فرد (یا هر کارت) در طی زمان، خلاصه‌ای از این عملیات برای هر کارت (یا برای هر واحد زمان مثل هفته، ماه) تهیه کنیم. یک چنین خلاصه‌ای می‌تواند گروه‌بندی معاملات بر حسب میزان پول خرج شده (مثالاً ۱۰-۱۰۰ هزار ریال، غیره)، یا بر حسب خرید نوع کالا (مثالاً غذا، لباس، بنزین، غیره)، یا بر حسب پول خرج شده و نوع کالا (مثل «خدا-۱۵-۲۰»، «لباس ۳۰-۱۰»...) یا هر نوع خلاصه‌سازی دیگر باشد.

در هر یک از این مثالها، داده‌ها دیگر مقداری تک مثل داده‌های سنتی از قبیل: ۱۶۴۰۰ ریال کل هزینه کارت اعتباری، یا ۵۲ مورد معامله، برای هر نفر در هر واحد زمان ندارند. این گونه داده‌ها، مثالهایی از داده‌های نمادین‌اند. بدینهی است که کاریست روشنی ساده مثل گرفتن میانگین حسابی در مورد آنها چندان مناسب ندارد. برای چنین داده‌های نمادین، باید از روش‌های تحلیل داده‌های نمادین استفاده کرد.

در حالی که خلاصه‌سازی مجموعه‌هایی بزرگ از داده‌ها می‌تواند مجموعه‌هایی کوچک از داده‌ها مشتمل بر داده‌های نمادین را تولید کند، داده‌های نمادین اصلتاً در مورد هر اندازه از مجموعه داده‌ها، خواه کوچک یا بزرگ متمایزند. مثلاً، نامعقول نیست که داده‌هایی داشته باشیم که مشتمل بر متغیرهایی‌اند که در دامنه‌ای ثبت شده‌اند، مانند نمض

ضروری برای تحلیل‌های آماری است، در بخش ۳ بررسی می‌شود. در بخش ۵، به اجمال روش‌های موجود برای تحلیل داده‌های نمادین را ارائه می‌کنیم. آنچه که از این بحث‌ها آشکار می‌شود آن است که داده‌های نمادین به طور فرایندی‌ای شایع می‌شوند و بنابراین نیازی مبرم به ابداع روش‌شناسی‌های آماری برای این گونه داده‌ها وجود دارد. همچنین، ملاحظه خواهد شد که در حال حاضر، روش‌هایی محدود وجود دارند و حتی برای آنها که وجود دارند، نیاز به تاسیس مبانی آماری-ریاضی مطرح است.

که تاکنون روش‌شناسی آماری اندکی برای صورت‌های مختلف داده‌های نمادین ابداع شده‌اند. اما به تعبیری دیگر، تحلیل اکتشافی داده‌ها که از سوی توکی و همکارانش (توکی، ۱۹۹۷) ابداع شدن، نویدی است از آنچه هم اکنون در حال بسط و گسترش است.

تحلیل اکتشافی داده‌ها، داده‌کاوی، کشف دانش در پایگاه‌های داده‌ها، آماره‌ها، داده‌های نمادین و مانند آنها اصطلاحاتی هستند که امروزه به فراوانی به چشم می‌خورند. تحلیل داده‌های نمادین اندیشه‌های به کار رفته در تحلیل اکتشافی سنتی را به داده‌های کلی تر و پیچیده‌تر گسترش می‌دهد.

ساییس (۱۹۹۸) سعی دارد که داده‌کاوی را به عنوان گامی که طی آن الگوهای موجود در داده‌ها به طور خودکار (مثلاً با استفاده از الگوریتم‌های محاسباتی) کشف می‌شوند، معرفی کند. در حالی که کشف دانش نه تنها مرحله داده‌کاوی، بلکه گامهای پیش‌فرآوری (از قبیل پاک‌سازی داده‌ها) و گامهای پس‌فرآوری (نظیر تفسیر نتایج) را نیز در بردارد. روشن است که همین مرحله پس‌فرآوری است که نقش سنتی آمارشناسان بوده است. الدر و پریگیبون (۱۹۹۶) دورنمایی از کشف دانش در پایگاه‌های داده‌ها را عرضه می‌کنند. هند و همکاران (۲۰۰۰) داده‌کاوی را به عنوان «تحلیل ثانی پایگاه‌های داده‌ای بزرگ با هدف یافتن روابط غیرمنتظره که مورد علاقه صاحبان پایگاهها هستند و برایشان ارزشمندند» تعریف می‌کنند.

غالباً اندازه پایگاه داده‌ای چنان بزرگ است که تحلیل‌های اکتشافی داده‌ها به روش کلاسیک برای آنها نارسا هستند. چون برخی مسائل موجود در داده‌کاوی و کشف دانش در پایگاه‌های داده‌ای به طور طبیعی به صورت‌های داده‌های نمادین می‌انجامند، تحلیل‌های داده‌های نمادین در اینجا نیز نقشی برای ایفا دارند. بدین ترتیب، همکاری تیمهای علمی بین رشته‌ای در هنگام کار با مجموعه‌های بزرگ داده‌ها (مثل متخصصان رایانه و آمارشناسان) به امری اساسی تبدیل می‌شود.

۲. مجموعه داده‌های نمادین

یک مجموعه داده‌ای از همان ابتدا ممکن است به صورت مجموعه‌ای از داده‌های نمادین تشکیل شود. به شق دیگر، ممکن است از ابتدا به صورت داده‌های کلاسیک فراهم آید، اما بعداً به صورت داده‌های نمادین سازمان داده شود تا به قالبی بیشتر قابل اداره درآید، به ویژه هنگامی که در ابتدا دارای اندازه‌ای بسیار بزرگ باشد.

در این بخش، مثالهایی از هر دو نوع داده‌های کلاسیک و داده‌های نمادین را عرضه می‌کنیم.

همچنین، نوعی نمادگذاری را معرفی می‌کنیم که مجموعه‌های داده‌های نمادین آماده برای تحلیل را توصیف می‌کند. این فرآیند وضعیت‌های را دربرمی‌گیرد که مثلاً دو یا چند مجموعه از داده‌ها در هم ادغام می‌شوند یا گاهی که بر ویژگی‌های مختلفی از داده‌ها باید تأکید شود.

فرض کنید مجموعه‌ای از داده‌ها را داریم که مشتمل بر سوابق پزشکی افراد در کشور است. فرض کنید برای هر فرد، سابقه‌ای از متغیرهای مکان جغرافیایی، مانند ناحیه (شمال، شمال شرق، جنوب، ...)، شهر (بابلسر، سبزوار، کرمان، ...)، شهر یا روستا (بلی، خیر) و غیره وجود دارد. متغیرهای جمعیت شناختی از قبیل جنس، وضع تأهل، سن، اطلاعات درباره پدر و مادر (هنوز زنده یا نه)، برادر و خواهر، تعداد فرزندان، کارفرما، عرضه کننده خدمات تدرستی و غیره نیز در کار خواهند بود. متغیرهای پایه‌ای پزشکی می‌توانند شامل وزن، تپش نبض، فشار خون و غیره باشند. دیگر متغیرهای تدرستی (که برای آنها فهرست متغیرهای ممکن بی‌پایان است) شامل بروز ناراحتی‌ها و بیماریهای معین خواهند بود. همچنین، برای شیوع یا تشخیص یک

هدف این مقاله، آن است که مفاهیم داده‌های نمادین و شیوه‌های تحلیل آنها را که در حال حاضر در آثار مکتوب موجودند، مرور کند. بنابراین، داده‌های نمادین که گاهی به اصطلاح «اتم‌های دانش» خوانده می‌شوند، در بخش ۲ تعریف شده با داده‌های کلاسیک مقایسه می‌شوند. ساختن رده‌هایی از اشیاء، نمادین که وقتی اندازه داده‌ها برای تحلیل‌های کلاسیک بسیار بزرگ باشد، یا هنگامی که به عوض داده‌های استاندارد دانش به عنوان درونداد داده شود، از مقدمات

بر عکس، یک نقطه داده‌ای نمادین ممکن است یک ابر مکعب در فضای P بعدی با حاصلضرب دکارتی توزیعها باشد.

درایه‌های موجود در مجموعه داده‌های نمادین (که با \mathbb{Y}_{ij} نمایانده می‌شوند) محدود به مقادیر مشخص تک نیستند، بدین ترتیب، سن را می‌شود به صورتی که در یک بازه واقع باشد، ثبت کرد. مثل، $[10, 20]$ و ... این وضع وقتی می‌تواند رخداد که نقطه داده‌ای نمایشگر سن یک خانواده، یا گروهی از افراد باشد که سن آنها به طور دستجمعی در بازه‌ای قرار دارد (مانند زن و شوهری مسن $[60, 70]$) یا داده‌ها ممکن است مربوط به یک فرد تنها باشد که سن دقیقش معلوم نیست، جز آنکه می‌دانیم در یک بازه سنی قرار دارد، یا سن او در طی زمان همراه با اجرای آزمایشی که داده‌ها را ایجاد کرده است، تغییر کرده است، یا ترکیبی از این حالتها و انواع مختلف آنها باشد، که داده‌های با دامنه بازه‌ای را به وجود می‌آورند.

در راستایی متفاوت، ممکن است اندازه گیری مشخصه‌ای دقیقاً به صورت مقداری تک میسر نباشد، نتوان اندازه گرفت که نبض ۶۴ است، بلکه بتوان اندازه گرفت که مقدار آن (64 ± 1) یا به طور کلی اندازه متغیری $(x \pm \delta)$ است.

شخصی ممکن است $x \leq 2$ یا $x \geq 2$ خواهد و برادر (یا فرزند یا ...) داشته باشد. متغیر فشار خون ممکن است به صورت مقادیر [بالا، پایین] آن، مثلاً $[78, 120] = \mathbb{Y}_z$ ثبت شود. این متغیرها، متغیرهای نمادین بازه-مقدارند.

نوعی متفاوت از متغیر می‌تواند متغیری مربوط به سرطان باشد که ممکن است قلمرو {...، کبد، سینه، استخوان، ریه} = \mathbb{Y} را داشته باشد که فهرستی از همه سرطان‌های ممکن است و شخص معینی مثلاً دارای مقادیر خاص $\{\text{کبد، ریه}\} = \mathbb{Y}_z$ است. در مثالی دیگر، فرض کنید متغیر \mathbb{Y}_z نمایشگر نوع خودرویی باشد که خانواده‌ای داراست با $\{\text{تویوتا، بنز، پژو، پیکان}\} = \mathbb{Y}_z$. خانواده خاص آن ممکن است مقدار $\{\text{بنز، پیکان}\} = \mathbb{Y}_z$ را دارا باشد. چنین متغیرهایی، متغیرهای چند مقداره نامیده می‌شود.

نوع سوم متغیر نمادین متغیر مدلی است. متغیرهای مدلی متغیرهای چند وضعی با فراوانی، احتمال یا وزن منسوب به هر یک از مقادیر خاص در داده‌های آن. یعنی، متغیر مدلی \mathbb{Y} نگاشتی است مانند

$$\mathbb{Y}(i) = \{U(i), \pi_i\}, \quad i \in \Omega$$

بیماری معین معالجات و سایر متغیرهای مربوط به آن بیماری ثبت می‌شوند. برای مثال، مجموعه‌ای نوعی از این گونه داده‌ها مثل جدول ۱ خواهد بود.

گیریم P تعداد متغیرهای مربوط به فرد i ، به ازای $\{\mathbb{Y}_j\}_{j=1}^p$ باشد، روشن است که p و n می‌توانند عددهایی بزرگ یا حتی فوق العاده بزرگ باشند و گیریم $\mathbb{Y}_j = x_j$ به ازای $j = 1, \dots, p$ نشانگر متغیر زام باشد. گیریم $\mathbb{Y} = X$ مقدار خاصی باشد که \mathbb{Y} برای فرد آم در آرایش کلاسیک اختیار می‌کند و به عنوان ماتریس $n \times p$ شامل کل مجموعه داده‌ها بنویسیم $X = (x_{ij})$ گیریم $X = (Y_1, Y_2, \dots, Y_p)$ به طوری که مقادیری را در فضای $\mathbb{Y} = X$ اختیار کند.

چون بود یا نبود مقدارهای گمشده در حال حاضر اهمیتی ندارد، گیریم همه مقادیر وجود دارند، اگر چه در مورد مجموعه‌های بزرگ داده‌ها محتمل ترین وضع آن است که داده گمشده داشته باشیم. متغیرهای می‌توانند کمی باشند، مثل سن با $\mathbb{Y}_{age} = \{x \geq 0\}$ به عنوان متغیر تصادفی پیوسته، یا به صورت $\mathbb{Y}_{age} = \{0, 1, 2, \dots\}$ به عنوان متغیر تصادفی گسته. متغیرها ممکن است رسته‌ای باشند، مثل شهر با $\{\text{اصفهان، تهران}\} = \mathbb{Y}_{city}$ یا رمزیده باشند، به صورت $\mathbb{Y} = \{1, 2, \dots\}$. متغیرهای بیماری ممکن است به صورت رسته‌هایی (رمزیده با نارمزیده) از یک متغیر با قلمرو {...، کبد، سرطان، قلب} = \mathbb{Y} یا به طور محتمل تر به صورت متغیری نشانگر، مثل سرطان = \mathbb{Y} با قلمرو {بلی، خیر} = $\mathbb{Y} = \{0, 1\}$ یا با سطوح رمزیده دیگر که نشانگر مراحل بیماری است، ثبت شوند.

به همین ترتیب، برای ثبت انواع بسیار زیاد سرطان‌های ممکن، هر نوع سرطان ممکن است با متغیری مثل \mathbb{Y} نمایش داده شود، یا با رسته‌ای از متغیر سرطان نمایش داده شود.

ماهیت دقیق توصیف متغیرها چندان مهم نیست. آنچه که اساسی است این است که در آرایش کلاسیک برای هر \mathbb{Y} موجود در X ، دقیقاً تنها یک مقدار محقق ممکن وجود دارد. یعنی، مثلاً مشخصات یک فرد عبارتند از $\mathbb{Y}_{age} = 24$ ، $\mathbb{Y}_{city} = \text{پلاسکا} = \mathbb{Y}_{cancer}$ ، $\mathbb{Y}_{pulse} = 24$ و مانند آن. بدین ترتیب یک نقطه داده‌ای کلاسیک تک نقطه‌ای است در فضای P بعدی X .

Y_j زیر مجموعه‌ای از خط حقیقی R است، یعنی $B_j \subseteq R$ ، اگر $Y_j = [\alpha, \beta], -\infty < \alpha, \beta < \infty$ باشد، $\{[\alpha, \beta]\}$ رسته‌ای (نامی، ترتیبی)، زیر مجموعه‌ای از یک قلمرو متغیر Z باشد، $\{B_j | B \subseteq Z\}$ و اگر Y_j متغیری مدلی باشد، $(Y_j = M)$ که در آن (Y) خانواده‌ای از همه اندازه‌های نامنفی روی Z است. در این صورت، داده نمادین برای مجموعه اشیاء E با ماتریس $(x_{ij}) = X$ از مرتبه $N \times p$ نمایش داده می‌شود که در آن $x_{ij} = Y_j(u) \in B_j$ مقدار نمادین مشاهده شده برای متغیر Y_j ، $p = 1, \dots, n$ در مورد شیئی E است. سطر i از X توصیف نمادین شیئی i خوانده می‌شود. بدین ترتیب برای داده‌های جدول ۲ سطر اول،

((۷۰، ۲۰)، {مرد}). {سرطان مغز}، بوشهر، [۲۰ و ۷۹] و [۳۰ و ۷۰])

نمایشگر مردی است در سنین ۲۰ سالگی که سرطان مغز دارد، با فشار خون ۱۲۰/۷۹، وزنی بین ۷۰-۸۰ کیلوگرم و در بوشهر می‌زید.

شیئی i مربوط به این x_{ij} می‌تواند مرد خاصی باشد که طی دوره ده ساله‌ای تحت نظارت بوده که در این مدت وزنش بین ۷۰ و ۸۰ کیلوگرم تغییر کرده، یا i می‌توانست گردد آیهای از افراد باشد که سنشان از ۲۰ تا ۳۰ سال متغیر بوده و دارای مشخصاتی بوده‌اند که با x_{ij} توصیف شده است. داده‌های x_{ij} در جدول ۲ ممکن است معرف همان فردی باشد که به عنوان فرد i چهار از جدول ۱ معرفی شده، اما تنها این امر معلوم است که او (با احتمال p) دارای سرطان سینه یا (با احتمال $1-p$) دارای سرطان ریه است، ولی معلوم نیست کدام یک. از سوی دیگر، داده‌های فوق می‌توانند معرف مجموعه زنان ۴۷ ساله از بابلسر باشند که از آنها به نسبت p دارای سرطان ریه و $(1-p)$ دارای سرطان سینه‌اند، یا می‌توانند نمایشگر افرادی باشد که دارای هر دو سرطان ریه و سینه‌اند و مانند آن (در مرحله‌ای از کار، اینکه متغیر (در اینجا نوع سرطان) از نوع رسته‌ای، فهرستی، مدلی یا هرچه هست، باید به صراحت تعریف شود).

موضوع دیگر، به متغیرهای وابسته مربوط می‌شود که برای داده‌های نمادین به معنای وابستگی منطقی، وابستگی سلسله مراتبی، یا وابستگی تصادفی است. وابستگی منطقی همان گونه که از معنای واژه پیداست به صورت اگر-آنگاه است که در مثال فوق اگر [۱ کسن] آنگاه [۰ = تعداد فرزندان]. وابستگی سلسله مراتبی وقتی رخ می‌دهد که

که در آن π اندازه‌ای نامنفی یا توزیعی روی قلمرو Z مشکل از مقادیر مشاهده‌ای ممکن و $Z \subseteq U$ تکیه π گاه است. مثلاً اگر سه نفر از خواهران و برادران شخصی مرض قند داشته باشند و یک نفر نداشته باشد، متغیر توصیف گر استعداد مرض قند می‌تواند مقدار خاص $\frac{1}{4}$ سال، $\frac{3}{4}$ مرض قند $= z_1$ را اختیار کند. به طور کلی تر، z_1 می‌تواند یک بافتگار، توزیع تجربی، توزیع احتمال، یک مدل یا مانند آنها باشد. در واقع شرایتر (۱۹۸۴) نظر داد که «توزیعها عده‌های آینده‌اند». در حالی که در این مثال، وزن‌های $(\frac{1}{4}, \frac{3}{4})$ ممکن است معرف فراوانی‌های نسبی باشند، انواع دیگر وزن‌ها از قبیل «گنجایش‌ها»، «باورمندی‌ها»، «بایستگی‌ها»، «امکانات» و غیره می‌توانند به کار گرفته شوند. در اینجا «گنجایش» را به تعبیر شوک (۱۹۵۴) به عنوان احتمال اینکه دست کم یک فرد در رده مذکور دارای مقدار Z معین (مثلاً مرض قند) است، تعریف می‌کیم و «باورمندی» به تعبیر شیفر (۱۹۷۶) تعریف می‌شود به احتمال اینکه هر فرد موجود در رده دارای آن مشخصه باشد (دیدی، ۱۹۹۵).

پس به طور کلی، برخلاف داده‌های کلاسیک که برای آنها هر نقطه داده‌ای مشتمل بر تک مقدار (رسته‌ای یا کمی) است، داده‌های نمادین می‌توانند تغییراتی درونی را در برداشته باشند و می‌توانند ساختار یافته باشند. وجود همین تغییرات درونی است که نیاز به فنون جدید برای تحلیل را لازم می‌نماید. این فنون به طور کلی با فنون مربوط به داده‌های کلاسیک تفاوت خواهد داشت.

از نظر نمادگذاری، مجموعه‌ای پایه‌ای از اشیاء را داریم که اعضاء یا هسته‌ای هستند، $\{E, \dots, N\}$ مجموعه اشیاء خوانده می‌شود. این مجموعه اشیاء می‌تواند معرف کیهانی از افراد Ω (مثل بالا) باشد که در آن حالت $N=n$ یا اگر داشته باشیم $N \leq n$ ، هر یک مجموعه از اشیای مذکور زیر مجموعه‌ای از Ω است. همچنین، چنانکه در داده‌کاوی یا تحلیل‌های نمادین کرراً رخ می‌دهد، اشیاء n در Ω رده‌های C_1, \dots, C_m از افراد موجود در Ω هستند، با $E = \{C_1, \dots, C_m\}$ و $N=m$ بدین ترتیب، مثلاً رده C_1 ممکن مشتمل بر همه افراد موجود در Ω باشد که سرطان داشته بودند. هر شیئی E با p متغیر نمادین $Z_j, j=1, \dots, p$ با قلمرو Z تعریف می‌شود که Z نگاشتی از مجموعه اشیاء E به بردار Z است که به نوع متغیر Z_j بستگی دارد. بدین ترتیب، اگر Z متفاوتی کمی کلاسیک باشد، قلمرو

تحلیل آماری به دست دهد. توجه کنید که این ساخت ممکن است از رده‌های حاصل از یک شیوه خوشبندی فرق داشته باشد، اما لزوماً چنین نیست. توجه داشته باشید که این m رده ابوجهده ممکن است معرف m الگوی به دست آمده از یک شیوه داده کاوی باشد.

این توصیف ما را به مفهوم شیئی نمادین رهنمون می‌شود که در سلسله‌ای از مقالات دیدی و همکارانش بسط یافته است (مثلًا دیدی، ۱۹۸۷، ۱۹۸۹، ۱۹۹۰، باک و دیدی، ۲۰۰۰ و استفن و همکاران، ۲۰۰۰). این مطلب را ابتدا با چند مثال معرفی می‌کنیم و در پایان بخش تعریفی دقیق ارائه می‌شود.

برآمد یک متغیر (مثلًا معالجه سرطان = Y_2) با $\{ \dots, \text{پرتو درمانی}, \text{شیمی درمانی} \} = Y_2$ [به برآمد واقعی تحقق یافته متغیری دیگر (مثلًا سرطان دارد = Y_1 با $\{\text{بلی، خیر}\} = Y_1$) وابسته است. اگر Y_1 دارای مقدار $\{\text{بلی}\}$ باشد، آنگاه $\{\text{مثلًا شیمی درمانی}\} = Y_2$. در حالی که اگر $\{\text{خیر}\} = Y_1$ آنگاه روشن است که Y_2 کاربرد ندارد [به منظور توضیح مطلب فرض می‌کنیم که معالجه شیمی درمانی به دلیل دیگر صورت نگیرد]. در این موارد، متغیر کاربرد ندارد Z را با قلمرو $\{ \text{کن} \} = Z$ تعریف می‌کنیم. این گونه متغیرها را متغیرهای مادر (Y_1)-دختر (Y_2) نیز گویند.

چند مثال

فرض کنید به مفهوم «شمال خاوری» علاقه‌مندیم. بدین ترتیب، توصیفی مانند Ω داریم که معرف مقادیر خاص $\{ \dots, \text{ساير شهرهای شمال خاوری}, \dots, \text{نيشابور، مشهد} \}$ در قلمرو Y_{city} است و رابطه‌ای مانند R (در اینجا \subseteq) داریم که متغیرهای Y_{city} را با توصیف خاص مورد نظر ربط می‌دهد. این مطلب را به صورت مثلاً $[\{\text{ساير شهرهای ش-خ}, \dots, \text{نيشابور، مشهد} \} \subseteq Y_{\text{city}} = a]$ نویسیم. در این صورت، هر فرد i در $\{1, \dots, n\} = \Omega$ یا یک فرد شمال خاوری است یا نیست. یعنی، a نگاشتی است از Ω بر $\{0, 1\}$ که برای فردی مانند Ω که در شمال خاوری زندگی می‌کند $= 1$ و $a(i) = 0$ به ازای $i \in \Omega$. پس، اگر فرد Ω در مشهد زندگی کند (یعنی، مشهد = $(Y_{\text{city}})_i$)، آنگاه

$a = [\{\text{ساير شهرهای ش-خ}, \dots, \text{نيشابور، مشهد} \} \subseteq \text{مشهد}] = 1$

مجموعه $\{i \in \Omega \mid \text{برای آنها } a(i) = 1\}$ ، گستره a در Ω نامیده می‌شود. سه گانه $S = (a, R, d)$ یک شیئی نمادین است که در آن R رابطه‌ای بین توصیف (i) Y از متغیر (بی صدای) Y و توصیف d و a نگاشتی از Ω به S است که i به R و d بستگی دارد (در مثال شمال خاوری، $\{0, 1\} = L$). توصیف d می‌تواند توصیف قصده باشد. مثلًا همان طور که از نامش پیداست، قصد داریم که مجموعه افراد موجود در Ω را که در «شمال خاوری» زندگی می‌کنند، بیایم. بدین ترتیب، مفهوم «شمال خاوری» تا حدی شیئی به مفهوم جامعه کلاسیک است و گستره موجود در Ω متناظر با نمونه افراد از شمال خاوری در مجموعه داده‌های واقعی است، اما به نجاط بیاورید که همان طور که در بخش ۲

۳. ردیف‌ها و طرز تشکیل آنها؛ اشیاء نمادین

مجموعه داده‌های نمادین ممکن است از آغاز کار پیش‌اپیش از حیث اندازه به قدر کافی کوچک باشد که به منظور انجام هر نوع تحلیل آماری نمادین به طور مستقیم، نیاز به پیش‌فرآوری نباشد. مثالی از این نوع داده‌ها جدول ۳ است که برای تحلیل مولفه‌های اصلی نمادین به کار رفته‌اند. اما به طور کلی تر و تقریباً به طرزی گریز ناپذیر قبل از آنکه هر نوع تحلیل نمادین از داده‌ها را بتوان انجام داد، به ویژه برای مجموعه‌های بزرگ داده‌ها، نیاز خواهد بود که در جات مختلفی از داده‌آمایی برای سازماندهی اطلاعات در رده‌هایی که مناسب برای سؤال مورد نظر باشند، صورت گیرند.

در برخی موارد، اشیاء موجود در E (یا Ω) پیش‌اپیش در رده‌هایی جمع شده‌اند، حتی در این موارد هم سؤال‌هایی خاص ممکن است سازماندهی مجدد در رده‌بندی متفاوتی را ضروری سازند، صرفنظر از اینکه مجموعه داده‌ها کوچک است یا بزرگ. مثلًا یک مجموعه از رده‌های C_1, \dots, C_m ممکن است افراد را که بر حسب m نوع مختلف از بیماریهای مهم رسته‌بندی شده‌اند، نمایش دهد. در حالی که تحلیل دیگر ممکن است ضروری نماید که ساختار رده‌ها بر حسب شهر، جنس یا بر حسب جنس و سن و غیره باشد. مرحله ابتدایی دیگر وقتی است که داده‌ها در ابتدا برای پایگاههای داده‌ای آمار کلاسیک یا علوم ریاضی برای هر فرد $i \in \{1, \dots, n\}$ با n فوق العاده بزرگ ثبت شده‌اند. همین طور است وقتی که پایگاههای داده‌ای نمادین بسیار بزرگ باشد. در این صورت، این مرحله از تحلیل داده‌های نمادین متناظر است با ابوجهده m شیئی در m رده که m بسیار کوچکتر از n است و طوری طراحی شده که قالبهای قابل اداره‌تری را پیش از هر

مجموعه جدیدی از داده‌ها را به یک «مشاهده» برای هر رده به دست بدهد. در این حالت اخیر، صرفنظر از اینکه مقادیر اولیه داده‌های کلاسیک یا نمادین باشند، مقادیر مجموعه داده‌ها به احتمال زیاد داده‌های نمادین خواهد بود. مثلاً حتی اگر هر فرد موجود در Ω به صورت دارای سرطان و یا بدون سرطان (بلی، خیر = Y_{cancer})، یعنی به صورت یک مقدار داده‌ای کلاسیک ثبت شده باشد، وقتی این متغیر با رده مربوط به شهر ارتباط داده شود، به صورت $\{0/9, 1/0\}$ خیر، (۱/۰) بلی، یعنی ۱۰٪ دارای سرطان و ۹۰٪ بدون سرطان در خواهد آمد. پس اکنون متغیر Y_{cancer} متغیری مدل است.

به همین نحو، رده‌ای که از گستره یک شیئی نمادین ساخته می‌شود، نوعاً به وسیله یک مجموعه داده‌های نمادین توصیف می‌شود. مثلاً فرض کنید که علاقه‌ما متوجه است به «کسانی که در مشهد زندگی می‌کنند» یعنی، [مشهد] = $[Y_{city} = a]$ و فرض کنید که متغیر Y_{child} تعداد فرزندان هر فرد $\in \Omega$ است که مقادیر ممکن $\{0, 1, 2, 3\}$ را دارد. فرض کنید مقدار داده‌ای برای هر امقداری کلاسیک است تبدیل آنها به یک داده نمادین از قبیل اینکه فرد A دارای ۱ یا ۲ فرزند است، یعنی $\{1, 2\} = f_i$ به آسانی نتیجه می‌شود. در این صورت، شیئی که معرف همه کسانی است که در مشهد زندگی می‌کنند، اکنون دارای متغیر نمادین Y_{child} خواهد بود با مقدار خاص،

$$Y_{child} = \{(0, f_0), (1, f_1), (2, f_2), (3, f_3)\}$$

که در آن $f_i = \{i, 1, 2, 3\}$ ، فراوانی نسبی افراد این رده است که دارای i فرزندند.

حالی خاص از یک شیئی نمادین عبارت است از یک حکم. حکم‌ها، مخصوصاً هنگام انبوھیدن افراد درون رده‌ها از یک پایگاه داده‌ای آغازین (رابطه‌ای)، دارای اهمیت‌اند.

گیریم توصیف لازم مورد نظر از یک فرد یا از یک مفهوم w را با $Z = (Z_1, \dots, Z_p)$ بنماییم. در اینجا، Z_j می‌تواند هستی تک مقداره کلاسیک x_j یا هستی نمادین z_j باشد. یعنی در حالی که x_j معرف مقدار داده‌ای کلاسیک تحقیق یافته‌ای است و z_j معرف مقدار داده‌ای نمادین تحقیق یافته‌ای است، Z مقداری است که مشخصاً به دنبال آن هستیم یا مقدار تصریح شده است. بدین ترتیب، مثلاً فرض کنید که به شے نمادینی علاقه‌مندیم که معرف کسانی است که در شمال خاوری

ذکر شده Ω ممکن است پیش‌بیش خود «جامعه» باشد یا ممکن است به معنای نمونه‌گیری آمار کلاسیک یک «نمونه» باشد. اشیاء نمادین به یکی از سه طریق در محدوده عمل تحلیل‌های نمادین داده‌ها نقش ایفا می‌کند. نخست، یک شیئی نمادین ممکن است به کمک قصد آن (مثلاً توصیفی و راهی برای محاسبه گستره‌اش) نمادین به کار گرفته شود. بدین ترتیب، مفهوم «شمال خاوری» را می‌توان با یک شیئی نمادین نمایش داد که قصد آن از طریقی توصیفی سرشتمان و راهی برای پیدا کردن گستره‌اش که مجموعه افرادی است که در شمال خاوری زندگی می‌کنند، تعریف می‌شود.

مجموعه‌ای از این گونه ناحیه‌ها و اشیاء نمادین همراه با آنها می‌تواند درونداد یک تحلیل داده‌های نمادین را تشکیل دهد. دوم، می‌توان آن را به عنوان بروندادی از یک تحلیل داده‌های نمادین مورد استفاده قرار داد، مثل وقتی که تحلیل خوشای حاکی از آن است که شمال خاوری متعلق به خوشای خاص است که خود خوش را به عنوان یک مفهوم می‌توان تلقی کرد و به وسیله یک شیئی نمادین نمایش داد. وضعیت سوم زمانی که فردی جدید (i') را داریم که دارای توصیف d' است و می‌خواهیم بدانیم که آیا این فرد (i') با شیئی نمادینی که توصیف d است، تطبیق می‌کند یا خیر. یعنی d و d' را به کمک R مقایسه می‌کنیم تا $\{d, d'\} \in L = \{0, 1\}$. $d' Rd$ که در آن $d' Rd$ به معنای آن است که ارتباطی بین d و d' وجود دارد. این فرد «جدید» ممکن است فردی «قدیم» اما با داده‌های روزآمد شده باشد یا ممکن است فردی جدید باشد که به پایگاه داده‌ها اضافه شده و امکان دارد که او با یکی از رده‌های قبلًا موجود اشیاء نمادین «همسان» باشد یا نباشد (مثلاً آیا باید برای این شخص پوشش بیمه‌ای خاص را فراهم ساخت؟).

در خصوص انبوھیدن داده‌هایمان در تعداد کمی از رده‌ها، اگر قرار باشد که افراد موجود در Ω را بر حسب شهر، یعنی بر حسب مقدار متغیر y_{city} بیانوھیم، رده‌های مربوطه C_i با $i \in \{1, \dots, m\}$ متشکل از آن افرادی در Ω است که در گستره نگاشت متناظر a قرار دارند. تحلیل آماری متعاقب می‌تواند یکی از دو راستای وسیع را در پیش گیرد. یا آنکه برای هر رده بر حسب اقتضا، به طور جداگانه داده‌های کلاسیک یا نمادین را برای افراد موجود در C_i به عنوان نمونه‌ای مرکب از n_i مشاهده تحلیل می‌کنیم، یا داده‌های هر رده را خلاصه می‌کنیم تا

رده افرادی را که دارای سرطان کبد، یاریه یا هر دو هستند، توصیف می‌کرد.

همچنین، یک حکم می‌تواند صورت زیر را اختیار کند.

$$a = [Y_{age} \subseteq [20, 30]] \wedge [Y_{city} \in \{مشهد\}] \quad (7)$$

یعنی، این حکم کسانی را که در مشهد زندگی می‌کنند و از لحاظ سنی در سنین بیست سالگی هستند، توصیف می‌کند.

رابطه‌های R می‌تواند هر یک از صورت‌های $=, \neq, \subseteq$ و غیره را اختیار کند یا می‌تواند رابطه‌ای تطبیقی (مانند مقایسه‌ای از توزیعهای احتمال) یا دنباله‌ای ساختار یافته و غیره باشد. این روابط پیوند بین متغیر نمادین Y و توصیف خاص مورد نظر Z را تشکیل می‌دهند. قلمرو شیئی نمادین را می‌توان به صورت زیر نوشت.

$$D = D_1 \times \dots \times D_p \subseteq X = \bigcup_{j=1}^p Y_j$$

که در آن $j \in Y_j \subseteq D_j$. هر p گانه (D_1, \dots, D_p) از مجموعه‌ها یک نظام توصیف خوانده می‌شود و هر زیر مجموعه D یک مجموعه توصیف مشتمل بر بردارهای توصیف $Z = (Z_1, \dots, Z_p)$ است. در حالی که ترکیب عناصر $j \in Y_j$ و مجموعه‌های $j \subseteq D_j$ مثلاً مثل آنچه در (7) دیده می‌شود، صرفاً یک توصیف است. وقتی قیودی در مورد هر یک از متغیرها وجود داشته باشد (مانند مواردی که وابستگی‌های منطقی وجود دارند)، آنگاه فضای D در خود «سوراخی» دارد که متناظر با مقادیری است که با قیود تطبیق می‌کنند. کل همه توصیف‌های D عبارت است از فضای توصیف D . بنابراین، حکم را می‌توان چنین نوشت.

$$a = [Y \in D] \equiv \bigwedge_{k=1}^v [Y_{jk} R_{jk} Z_{jk}] = [YRZ]$$

که در آن $R = \bigwedge_{k=1}^v R_{jk}$ رابطه حاصل‌ضربی خوانده می‌شود.

دقت کنید که اگر حکمی تلویحاً متغیری خاص مانند Y را دربرنداشته باشد، قلمرو مربوط به آن متغیر در Y بی تغییر باقی می‌ماند. مثلاً، اگر داشته باشیم $p = 3$ و $Y_1 = Y_2 = Y_3$ و سن = ۳ وزن = Y_1 آنگاه حکم $[Y_{city} \in \{مشهد, مشهد\}]$ دارای قلمرو $\times Y_1 \times Y_2 \times \{مشهد\}$ است و در جستجوی همه آن کسانی است که (صرف‌نظر از سن و وزن) فقط در مشهد و نیشابورند.

زندگی می‌کنند. در این صورت، Z_{city} مجموعه شهرهای شمال خاوری است. این موضوع را با حکم،

$$a = [Y_{city} \in \{مشهد, نیشابور, مشهد\}] \quad (1)$$

که در آن a نگاشتی از Ω بر $\{5, 1\}$ است، به قسمی است که برای فرد یا شیئی w ، داریم $a(w) = 1$ ، اگر {سایر شهرهای ش-خ,...، مشهد} درست باشد.

به طور کلی، هر حکمی صورت زیر را اختیار می‌کند

$$a = [Y_{j_1} R_{j_1} Z_{j_1}] \wedge [Y_{j_2} R_{j_2} Z_{j_2}] \wedge \dots \wedge [Y_{j_v} R_{j_v} Z_{j_v}] \quad (2)$$

به ازای $j_1, \dots, j_v \leq p$ که در آن $\{8\}$ به معنی «و» ضریب منطقی است و R رابطه تصریح شده بین متغیرهای نمادین Z و مقدار توصیفی Z_j است. برای هر فرد $\Omega \in a$ وقتی که حکم برای آن فرد درست (یا غلط) باشد، داریم $a(i) = 1$ (یا 0). به طور دقیق تر بگوییم، هر حکم عبارت از ترکیب عطفی v پیشامد $[Y_k R_k Z_k]$ است. $k = 1, \dots, v$. مثلاً حکم‌های

$$a = [Y_{cancer} = 1] \text{ و } b = [Y_{age} \geq 60] \quad (3)$$

به ترتیب، نمایشگر افراد دارای سرطان و افراد ۶۰ سال به بالا هستند. حکم

$$a = [Y_{cancer} = 1] \wedge [Y_{age} \geq 60] \quad (4)$$

نمایشگر همه بیماران سرطانی است که ۶۰ سال به بالا هستند، در حالی که حکم

$$a = [Y_{age} < 20] \wedge [Y_{abc} > 70] \quad (5)$$

در جستجوی همه افرادی است که زیر ۲۰ سال و بالای ۷۰ سال‌اند. در هر مورد، با مفهومی مانند «افراد ۶۰ سال به بالا»، «افراد ۶۰ سال به بالای دارای سرطان» و غیره سروکار داریم و a افراد خاص حاضر در Ω را بر فضای $\{1, 0\}$ می‌نگارد.

اگر به عرض ثبت متغیر سرطان به صورت متغیر رسته‌ای {بلی، خیر} به صورت متغیری مانند {...، سنه، کبد، ریه} ثبت می‌کردیم، حکم

$$a = [Y_{cancer} \in \{\text{کبد، ریه}\}] \quad (6)$$

$$Ext\alpha(a) = Q\alpha = \{i \in a(i) \geq \alpha\}.$$

دیدي و اميlion (۱۹۹۶) و ديدي و همكاران (۱۹۹۶) اشياء نمادين مدي را برسی می کنند و برخی از زير ساخت های نظری آن را نيز عرضه می دارند. اکنون تعريف رسمي يك شيني نمادين را به صورت زير داريم.

تعريف: يك شيني نمادين عبارت است از سه گانه $S = (a, R, d)$ که در آن a نگاشتی است $L \rightarrow \Omega : a$: که افراد $\Omega \in L$ را بفضای R می نگارند و اين فضا به رابطه R بين توصيفها و توصيف d بستگی دارد. وقتی $\{0,1\} = L$ یعنی، هنگامی که a نگاشتی دودوی است، S يك شيني نمادين بولی است. هنگامی که $[0,1] = L$ ، آنگاه S يك شيني نمادين مدي است. یعنی، يك شيني نمادين مدلی رياضی از يك مفهوم است (ن. ک. به ديدى، ۱۹۹۵). اگر داشته باشيم $\{0,1\} \in [a, R, d]$ ، آنگاه S يك شيني نمادين بولی و اگر داشته باشيم $[0,1] \in [a, R, d]$ آنگاه S يك شيني نمادين مدي است. مثلا در (V) رابطه $R = (\subseteq, \in)$ و توصيف $\{\text{مشهد}\}$ و $\{0,1\} = d$ را داريم. قصد آن است که «۲۰-۳۰» سالهای را که در مشهد زندگی می کنند» بیابیم. گستره مشکل از همه افراد موجود در Ω که با اين توصيف تطبيق دارند، یعنی آن نهايی که برای آنها $a(i) = 1$.

در حالی که اذعان به ضرورت ابداع روشهایي برای تحليل نمادين و ابزارهایي برای توصيف اشياء نمادين ابداع نسبتا جديد است، انديشه برسی واحدهای سطح بالاتر مثل مفاهيم در واقع امری باستانی است. ارغونون ارسسطو در سده چهارم قبل از ميلاد مسيح (ارسطو، IVBC) به روشني افراد مرتبه نخست (از قبيل يك اسب يا يك انسان) را که معروف واحدهایي در جهان (جامعه آماري) اند از افراد مرتبه دوم (از قبيل اسب يا انسان) که به عنون واحدهایي از ردهای از افراد معرفی می شوند، تمايز می سازد.

بعدها آرنو و نيكول (۱۶۶۲) مفهوم را به كمك پنداشتهای قصد و گستره (که به معنای آنها در ۱۶۶۲ با معانی آنها در اين مقاله تطبيق می کنند) به شرح زير تعريف كردند.

اکنون در انديشه های كيهاني دو چيز وجود دارند که تمايز کامل آنها اهميت دارد؛ فراگيري و گسترش (به جاي «قصد» و «گستره»). فراگيري يك انديشه را صفاتي می ناميم که آن انديشه در بردارد و بدون از بين بردن انديشه نمي توان آنها را از آن گرفت. بدین ترتيب

تعريفهای رسمي

اکنون مفهوم های زير را به طور رسمي تعريف می کنیم.

تعريف: وقتی حكمي درباره شيني خاص $\Omega \in \Omega$ بيان می شود، اگر آن حکم درباره آن شيني صادق باشد، مقدار راست ($a = 1$) را و اگر دروغ باشد ($a = 0$) را اختيار می کند. می نویсим

$$(8) \quad a(i) = [Y(i) \in D] = 1, \quad Y(i) \in D \\ = 0, \quad o.w.$$

تابع (i) تابع راستي خوانده می شود و نمايشگر نگاشتی از Ω بر $\{0,1\}$ است.

مجموعه همه مقادير $\Omega \in \Omega$ که برای آنها حکم صادق است، گسترش در Ω خوانده می شود که با $Ext(a)$ يا Q نمایانده می شود

$$(9) \quad Ext(a) = Q = \{i \in \Omega \mid Y(i) \in D\} = \{i \in \Omega \mid a(i) = 1\}$$

نوعا، هر رده با شيني نماديني که توصيفش می کند، شناسابي می شود. مثلا حکم (V) متاظر است با شيني نمادين «۳۰-۲۰» سالهای که در مشهد زندگی می کنند». گسترش اين حکم، $Ext(a)$ رده مشکل از همه اشياء $\Omega \in \Omega$ را که با اين توصيف a تطبيق دارند، توليد می کند.

يک رده ممکن است، مثل بالا، با جستجوی گسترش يك حکم a ساخته شود. به شق ديگر، ممکن است مطلوب آن باشد که همه آن افراد $u \in \Omega$ (ديگر) در Ω را که با توصيف $(u)_j = Y_j(u)$ مربوط به فردی معين $u \in \Omega$ تطبيق دارند، پيدا کنیم. بدین ترتيب در اين حالت، حکم عبارت است

$$az = \bigwedge_{j=1}^p [Y_j = Y_j(u)]$$

که در آن اکنون $(u)_j = Y_j(u)$ و داراي گسترش زير است،

$$Ext(a_i) = \{i \in \Omega \mid Y_j(i) = Y_j(u), j = 1, \dots, p\}$$

به طور کلي تر، حكمي ممکن است با مقداری مدي (از قبيل يك احتمال) صادق باشد، يعني $1 \leq a(i) \leq 0$ که نمايشگر درجه اي از تطبيق يك شيني آبا يك حکم a است.

در اين حالات، نگاشت a بر بازه $[0,1]$ است، يعني $a : \Omega \rightarrow [0,1]$ در اين صورت، گسترش a داراي سطح $\alpha \leq a \leq 1$ است. که حال

در این صورت، بافتگار استاندارد مبتنی بر پرندگان طوری است که فراوانی «بلی» دو برابر فراوانی «خیر» است. شکل ۱ الف را بینید. بر عکس، اگر افراد آماری را گونه‌ها در نظر بگیریم، چون دو گونه بی‌پرواز و یک گونه با پرواز وجود دارند، فراوانی «خیر» اکنون دو برابر فراوانی «بلی» است. شکل ۱ ب را بینید.

دقت کنید که بافتگار گونه‌ها صرفاً یک بافتگار است. چیزی که این مثال نشان می‌دهد این است که نسبت به سطح افراد آماری (در اینجا پرندگان) و نسبت به مفهوم (در اینجا گونه‌ها) بافتگارهای کاملاً متفاوتی را به دست می‌آوریم. در اینجا گونه‌ها واقعاً در درون خود سطح دیگری از اطلاعات متاخر با نوع پرنده و فراوانی هر یک را دارا هستند. یعنی، «گونه‌ها» خود در بردارنده ساختاری در سطحی دیگر از متغیر گونه‌اند. به نحوی که در تولید بافتگار شکل ۱ ب به کار رفته است. بافتگاری نمادین (که در زیر تعریف خواهد شد) این ساختار را به حساب می‌آورد.

آمارهای تک متغیری را (برای داده‌های $1 \leq p \leq m$ متغیر) در نظر بگیریم. نظایر آنها آمارهای دو متغیری هستند که به خاطر نبود فضا و دقت فعلاً آنها را مورد بحث قرار نمی‌دهیم. در مورد متغیرهای با مقدار عدد صحیح و بازه‌مقدار از رویکردی که برتران و گوبیل (۲۰۰۰) پیش گرفته‌اند، پیروی می‌کنیم. دو کارواو (۱۹۹۴-۱۹۹۵) و چوآکریا و همکاران (۱۹۹۸) روش‌های متفاوت، ولی معادل را برای یافتن بافتگار و احتمال‌های بازه‌ای برای متغیرهای بازه‌مقدار به کار گرفته‌اند (رابطه (۲۶) را در زیر بینید).

پیش از توصیف این کیت‌ها، ابتدا نیاز داریم که مفهوم گسترش‌های واقعی را معرفی کنیم. از بخش ۳ به یاد بیاورید که توصیف نمادین یک شیئی $\forall u \in E$ (یا به طور معادل $\Omega \subseteq i$) با بردار توصیف

$$d_u = (\xi_{u1}, \xi_{u2}, \dots, \xi_{up}), \quad u = 1, \dots, m$$

یا به طور کلی تر با $D = \{D_1, \dots, D_p\}$ در فضای D_j داده شد که در آن در هر حالت خاص تحقق $\exists j$ می‌تواند یک x_j برای داده‌های کلاسیک یا یک ξ_j برای داده‌های نمادین باشد. توصیف‌های انفرادی، که با X نمایانده شده، همان توصیف‌هایی اند که برای آنها هر D_j یک مجموعه دارای تنها یک مقدار است. یعنی،

فراگیری اندیشه یک مثلث، در حد ظاهر، شامل شکل، سه خط، سه زاویه، برابر مجموع این سه زاویه با دو زاویه قائم و غیره است. گسترش این اندیشه را اشیایی می‌نامیم که این اندیشه درباره آنها مصدق دارد. این اشیاء زیرین‌های یک گزاره کیهانی نیز نامیده می‌شوند و آن گزاره زیرین آنهاست. بدین ترتیب، اندیشه یک مثلث به طور کلی به همه انواع مختلف مثلث گسترش می‌یابد.

سرانجام، کاربست محاسباتی ایجاد رده‌های مقتضی را می‌توان به وسیله احکام مورد استفاده در موتورهای کاوش اجرا کرد. انسواع متعددی از این گونه الگوریتمها وجود دارند، مانند نرم‌افزار (SQL) standard query language یا C++ یا JAVA. نمونه‌هایی از به کار گیری این الگوریتمها در تعیین رده‌ها در مراجع ذکر شده‌اند.

۴. تحلیل داده‌های نمادین

با در دست داشتن یک مجموعه از داده‌های نمادین، گام بعد انجام تحلیل‌های آماری مقتضی است. مثل داده‌های کلاسیک در اینجا نیز امکانات بی‌پایان هستند. برخلاف داده‌های کلاسیک که یک قرن سعی و کوشش، کتابخانه‌ای از روش‌شناسی‌های تحلیلی یا آماری را فراهم کرده است، تحلیل‌های آماری برای داده‌های نمادین جدید بوده و از نظر تعداد بسیار اندک‌اند. در زیر برخی از آنها را مرور می‌کنیم.

۵. آمارهای تک متغیره توصیفی

۱-۱- مقدمات

آمارهای توصیفی پایه‌ای عبارتند از بافتگارهای فراوانی و میانگین و واریانس نمونه. مشابه‌های این آمارهای را برای داده‌های نمادین مربوط به متغیرهای چند مقداره و بازه مقدار قاعده‌مند و متغیرهای مدلی در نظر می‌گیریم. در حین اینکه این آمارهای را بسط می‌دهیم، مثال زیر را در نظر داشته باشیم که نشان می‌دهد باید بین سطوح در داده‌های نمادین و داده‌های کلاسیک تمايز قابل شد. این نکته به ویژه هنگام تشکیل بافتگار این دو نوع داده آشکارتر می‌شود.

فرض کنید جزیره‌ای دوره افتاده دارای هزار پنگوئن و هزار شتر مرغ است که هر دو گونه‌هایی بی‌پرواز از پرندگان‌اند و چهار هزار بوتر دارد که گونه‌ای پرنده با پرواز است. فرض کنید به متغیر «پرواز» علاقه‌مندیم که در اینجا دو مقدار ممکن «بلی» یا «خیر» را می‌گیرد.

نوعی از متغیرهای تصادفی گسته باشد. فراوانی مشاهده شده ξ را به صورت

$$O_Z(\xi) = \sum_{u \in E} \pi_Z(\xi; u) \quad (12)$$

تعريف می‌کنیم که در آن مجموع یابی روی $\{1, \dots, m\}$ است و

$$\pi_Z(x; u) = \frac{|\{x \in \text{vir}(d_u) | x_Z = \xi\}|}{|\text{vir}(d_u)|} \quad (13)$$

در صد بردارهای توصیف انفرادی در $\text{vir}(d_u)$ است به طوری که داشته باشیم $\xi = x_z$ و $|A|$ تعداد توصیف‌های انفرادی موجود در فضای A است. در مجموع یابی (12) هر u که برای آن $\text{vir}(d_u)$ تهی باشد، نادیده گرفته می‌شود. ملاحظه می‌کنیم که این فراوانی مشاهده شده یک عدد مثبت حقیقی است و مثل مورد داده‌های کلاسیک لزوماً عددی صحیح نیست.

در حالت کلاسیک، $|\text{vir}(d_u)| = 1$ و بنابراین حالتی خاص از (13) است. به آسانی می‌توان نشان داد که

$$\sum_{\xi \in Z} O_Z(\xi) = m' \quad (14)$$

که $(m - m_0)$ و m_0 تعداد ناهاست که برای آنها $|\text{vir}(d_u)| = 0$.

برای یک متغیر نمادین چند مقداره Z، که مقادیر $Z \in \Xi$ را اختیار می‌کند، توزیع فراوانی تجربی عبارت است از مجموعه زوج‌های $(\xi, O_Z(\xi))$ به ازای $\xi \in \Xi$ و توزیع فراوانی نسبی یا بافتگار فراوانی عبارت است از مجموعه

$$[(\xi, (m')^{-1} O_Z(\xi))] \quad (15)$$

تعريف‌های زیر بلافاصله نتیجه می‌شود.

تابع توزیع تجربی Z به صورت زیر تعریف می‌شود.

$$F_Z(\xi) = (m')^{-1} \sum_{\xi_k \leq \xi} O_Z(\xi_k) \quad (16)$$

هنگامی که مقادیر ممکن Ξ برای متغیر نمادین چند مقداره $Z = Y$ کمی باشند، می‌توانیم به شرح زیر میانگین، واریانس و میانه را تعریف کنیم. میانگین نمونه نمادین برابر است با

$$\bar{Z} = (m')^{-1} \sum_{\xi_k} O_Z(\xi_k) \quad (17)$$

واریانس نمونه نمادین عبارت است از

$$x \equiv d = (\{x_1\}, \dots, \{x_p\}), x \in X = \prod_{j=1}^p Y_j$$

محاسبه بافتگار فراوانی نمادین شامل شمارش تعداد توصیف‌های انفرادی است که با وابستگی‌های منطقی تلویحی موجود در داده‌ها تطبیق می‌کند. وابستگی منطقی را می‌توان با قاعده‌ای مانند ۷ نمایش داد،

$$v = [x \in A] \Rightarrow [x \in B] \quad (10)$$

با ازای $A \subseteq D$ و $B \subseteq D$ و $x \in X$ و v نگاشتی از X بر $\{0, 1\}$ با $v(x) = 0$ اگر x در قاعده صدق نکند (صدق کند). مثلاً فرض کنیم $(x_1, x_2) = (1, 0)$ توصیفی انفرادی از سن $= Y_1^{(d)}$ تعداد فرزندان $= Y_2^{(d)}$ برای $\Omega \ni u$ باشد، فرض کنیم $12 \leq \text{سن} \leq 20$ و $\{0, 1\} = A$ و $\{0, 1\} = B$. در این صورت، قاعده‌ای که تصریح کند فردی که سنه کمتر از ۱۲ سال است، دال بر این است که فرزندی نداشته است منطقاً راست است، در حالی که فردی که سنه کمتر از ۱۲ سال است مستلزم آن باشد که دارای دو فرزند است، منطقاً راست نتیجه می‌شود که بردار توصیف انفرادی x در قاعده ۷ صدق می‌کند اگر و تنها اگر $x \in A \cap B$ یا $x \notin A$. این فرمول بندی قاعده وابستگی منطقی برای مقاصد محاسبه آماره‌های توصیفی پایه‌ای کافی است. ورده و دوکارووالو (۱۹۹۸) انواع گوناگون قواعد مرتبط (از قبیل هم ارزی منطقی، استلزم منطقی، وابستگی‌های چند گانه، وابستگی‌های سلسه مراتبی و مانند آن را) مورد بحث قرار می‌دهند. پس تعریف رسمی زیر را داریم

تعریف: توصیف واقعی بردار توصیف d عبارت است از مجموعه همه بردارهای توصیف انفرادی x که در همه قواعد (وابستگی منطقی) ۷ در x صدق می‌کنند. این تعریف را به صورت زیر می‌نویسیم،

$$\text{vir}(d) = \{x \in D, v(x) = 1, \forall v \in V_x\} \quad (11)$$

که در آن V_x مجموعه همه قواعد ۷ است که روی x عمل می‌کنند.

۵-۲-متغیرهای چند مقداره - آماره‌های تک متغیره

فرض کنید می‌خواهیم توزیع فراوانی را برای متغیر نمادین چند مقداره خاص $Z_j \equiv Y_j$ که مقادیر خاص $Z \in \Xi$ را اختیار می‌کند، بیاییم. این مقادیر می‌توانند مقادیر رسته‌ای (مثل انواع سرطان) یا هر

$$\text{بدین ترتیب، برای توصیف اول } d_1 \text{ داریم،}$$

$$\{vir(d_1) = \{x \in \{0,1\} \times \{0,1\} : v(x) = 1\}$$

توصیف‌های انفرادی $\{x \in \{0,1\} \times \{0,1\} : x \in \text{ubar} \text{ از } (0,0) \text{ و } (1,1)\}$ که از آنها تنها یکی، $(1,1) = x$ در فضای C نیز هست. بنابراین،

$$vir(d_1) = \{(1,1)\}$$

در واقع، این عملیات عبارت است از به اصطلاح پالایش داده‌ها از نظر ریاضی از راه شناسایی فقط آن داده‌هایی که (با صدق کردن در قاعده وابستگی منطقی رابطه $(0,0)$) معنای منطقی دارند. بدین ترتیب، مقادیر داده‌ای $(0,1, Y_1), (1,0, Y_2) = 0, 2$ که این اطلاع را ثبت می‌کنند که در عین حال که سرطان وجود نداشته دو معالجه مرتبط با سرطان صورت گرفته (تحت شرایط موجودی که با قاعده ۷ مشخص می‌شوند) به عنوان مقادیر داده‌ای غلط شناسایی می‌شوند و بنابراین برای محاسبه میانگین در این تحلیل به کار نمی‌روند. در حالی که سعی در انجام چنین کاری را در اینجا نداریم، این شناسایی مانع از آن نمی‌شود که این شیوه‌های دیگر را که متعاقباً به کار خواهند رفت، تا آنچه را که این داده‌ها می‌توانستند باشند چانشین آنها کنند، در تحلیل بگنجانیم. در مورد مجموعه‌های کوچک داده‌ها، ممکن است میسر باشد که داده‌ها را به طور بصری (یا به نوعی دیگر) «تصحیح» کنیم. برای مجموعه‌های بسیار بزرگ داده‌ها، این امر همیشه ممکن نیست، از این رو یک قاعده وابستگی منطقی برای انجام عمل تصحیح به طور ریاضی/محاسباتی امری اساسی است.

به طور مشابه برای توصیف دوم d_2 می‌توانیم به دست آوریم.

$$vir(d_2) = \{x \in \{0,1\} \times \{0,1\} : v(x) = 1\}$$

در اینجا، بردارهای توصیف انفرادی $\{x \in \{0,1\} \times \{0,1\} : x = (0,0) \text{ و } (1,1)\}$ عبارتند از $(0,0), (0,1) \text{ و } (1,0)$ که از آنها $(0,0) = x$ و $(1,1) = x$ و در C هستند. پس $\{vir(d_2) = \{(0,0), (1,1)\}\}$. گسترش‌های واقعی برای همه d_u ، $u = 1, \dots, 9$ در جدول ۳ ارائه شده‌اند. توجه کنید $vir(d_5) = \emptyset$ مجموعه‌هایی است، زیرا مقدار داده‌ای d_5 نمی‌تواند با وجود قاعده ۷ منطقاً درست باشد.

اکنون می‌توانیم توزیع فراوانی را بیاییم. فرض کنید ابتدا این توزیع را برای Y_1 پیدا کنیم. بنابراین تعریف (۱۲)، فراوانی‌های مشاهده شده

$$O_{Y_1}(0) = \sum_{u \in E'} \frac{|\{x \in vir(d_u) : x_{Y_1} = 0\}|}{|\{vir(d_u)\}|}$$

$$(18) S_Z^v = (m')^{-1} \sum_{\zeta_k} O_Z(\zeta_k) [\zeta_k - \bar{Z}]^v$$

و میانه نمادین آن مقدار از \bar{Z} است که به ازای آن

$$(19) F_Z(\zeta) \geq \frac{1}{2}, \quad F_Z(\zeta) \leq \frac{1}{2}$$

مثال

برای توضیح مطالب بالا، فرض کنید مجموعه‌ای بزرگ از داده‌ها (مشتمل بر بیمارانی که از سوی تامین اجتماعی، خدمات بهداشتی و درمانی دریافت می‌کنند) به طریقی ابوبهیده شده‌اند که داده‌های جدول ۳ را داده‌اند. این داده‌ها برآمدهای مربوط به وجود سرطان Y_1 با $\{1 = \text{بلی}, 0 = \text{خیر}\} = Y_2$ و تعداد معالجات مرتبط با سرطان Y_2 با $\{0, 1, 2, 3\} = Y_3$ را درباره $m = 9$ شیوه نمادین نشان می‌دهند.

بدین ترتیب، مثلاً $d_1 = \{(0,1,1)\}$ بردار توصیف برای شیوه مندرج در سطر ۱ جدول ۳ است. پس، برای افرادی که با این توصیف نمایش داده می‌شوند، مشاهده $(1,0,1) = Y_1$ بیان می‌کند که یا بعضی افراد سرطان دارند و برخی ندارند یا آنکه تشخیص خیر/بلی دقیق را برای افراد رده‌بندی شده در اینجا نمی‌دانیم، در حالی که مشاهده $d_2 = \{(0,1,2)\}$ به ما می‌گوید که همه افراد معرفی شده با d_1 دو مورد معالجه مرتبط با سرطان داشته‌اند. بر عکس، $d_3 = \{(1,0,0)\}$ افرادی است که همه آنان دارای تشخیص سرطانی بوده‌اند ($Y_1 = 1$) و آنها یی که 2 یا 3 معالجه داشته‌اند، $d_4 = \{(2,0,0)\}$. افزون بر آن فرض کنید یک وابستگی منطقی

$$(20) v = y_1 \in \{0\} \Rightarrow y_2 \in \{0\}$$

وجود داشته باشد، یعنی اگر سرطانی تشخیص داده نشده است، نباید معالجات سرطانی در بین باشد. دقت کنید که

$$y_1 \in \{0\} \Rightarrow A = \{(0,0), (0,1), (0,2), (0,3)\}$$

و

$$y_2 \in \{0\} \Rightarrow B = \{(0,0), (1,0), (2,0), (3,0)\}$$

از (۲۰) نتیجه می‌شود که یک قاعده توصیف انفرادی x که در این قاعده صدق می‌کند، عبارت است از $\{x \in A \cap B = \{(0,0)\}$ یا $x \in A \cap B = \{(1,0), (1,1), (1,2), (1,3)\}$ یعنی، $x \notin A$ یعنی، $x \in \{(1,0), (1,1), (1,2), (1,3)\}$. گیریم همه موارد ممکنی را که در این قاعده صدق می‌کنند با $x = (0,0), (1,0), (0,1), (1,1), (0,2), (1,2), (0,3), (1,3)$ نشان دهیم. رابطه (۲۰) را در هر مورد هر d_u ، $u = 1, \dots, m$ در داده‌ها به کار خواهیم بست تا گسترش‌های واقعی $vir(d_u)$ را بیاییم.

حساب کنیم که $w \geq 0$ و $\sum w_u = 1$. مثلاً اگر شیئی $u \in E$ رده‌های C_u مشکل از افرادی از مجموعه افراد $\Omega = \{1, \dots, n\}$ باشد، $w_u = |C_u|/|\Omega|$ یک وزن ممکن عبارت است از $u = 1, \dots, m$ است یا به که متناظر با اندازه‌های نسبی رده‌های C_u ، $w_u = 1/m$ است یا به طور کلی‌تر، اگر هر بردار توصیف انفرادی x را به صورت واحدی ابتدایی از شیئی u در نظر بگیریم، می‌توانیم برای $u \in E$ وزن‌های

$$w_u = \frac{|vir(d_u)|}{\sum_{u \in E} |vir(d_u)|} \quad (22)$$

را به کار ببریم.

مثلاً، اگر ناهای جدول ۳ رده‌های C_u با اندازه $|C_u|$ را نمایش دهنند، با وجود $|\Omega| = 1000$ همانگونه که در جدول ۳ نشان داده شده اگر از وزن $w_u = |C_u|/|\Omega|$ استفاده کنیم می‌توانیم نشان دهیم که

$$O_{Y_1}(0) = \frac{1}{1000} \left[\frac{1}{128} + \frac{1}{75} + \frac{1}{249} + \dots + \frac{1}{12} \right] = 0.229$$

$$O_{Y_1}(1) = 0.771$$

و از آنجا که فراوانی نسبی Y_1 عبارت است از،

$$[0.0 / 229, 1.0 / 771] : Y_1 \text{ فراوانی نسبی}$$

به همین ترتیب،

$$O_{Y_2}(2) = 0.2395, \quad O_{Y_2}(3) = 0.4095$$

$$O_{Y_2}(0) = 0.2540, \quad O_{Y_2}(1) = 0.097.$$

و بنابراین فراوانی نسبی Y_2 چنین است.

فراوانی نسبی Y_2 :

$$[(0.0 / 2540), (1.0 / 0.97), (2.0 / 2395), (3.0 / 4095)]$$

تابع توزیع تجربی Y_2 تبدیل می‌شود به

$$F_{Y_2}(\xi) = \begin{cases} 0 & \xi < 0 \\ 0.254 & 0 \leq \xi < 1 \\ 0.351 & 1 \leq \xi < 2 \\ 0.595 & 2 \leq \xi < 3 \\ 1 & \xi \geq 3 \end{cases}$$

به طور مشابه، می‌توانیم نشان دهیم که میانگین نمونه نمادین Y_1 برابر است با $0.771 = \bar{Y}_1$ و از آن Y_2 عبارت است از

واریانس نمونه نمادین Y_1 برابر است با $0.1760 = S_1^2$ و از آن Y_2

برابر است با $S_2^2 = 0.4843$.

$$= \frac{0}{1} + \frac{1}{3} + \frac{0}{1} + \frac{0}{2} + \frac{1}{1} + \frac{0}{2} + \frac{0}{2} + \frac{0}{3} = \frac{4}{3}$$

و به همین ترتیب $O_{Y_1}(1) = \frac{20}{3}$ که در آنها $(0, 1, 2, 3)$ طوری که $E' = E - (u = 0)$ بنا برای، توزیع فراوانی نسبی برای Y_1 طبق رابطه (15) عبارت است از

$$Y_1 \text{ فراوانی نسبی} : \left[\left(0, \frac{1}{6} \right), \left(1, \frac{5}{6} \right) \right]$$

به طور مشابه، فراوانی‌های مشاهده شده برای مقادیر ممکن Y_2 ، یعنی $0, 1, 2, 3$ را به ترتیب چنین داریم

$$O_{Y_2}(0) = \sum_{u \in E'} \frac{\{x \in vir(d_u) | x_{Y_2} = 0\}}{|vir(d_u)|} = \frac{0}{1} + \frac{2}{3} + \frac{0}{1} + \frac{0}{2} + \frac{1}{1} + \frac{0}{2} + \frac{0}{2} + \frac{0}{3} = \frac{5}{3}$$

$$O_{Y_2}(2) = 2/5 \quad \text{و} \quad O_{Y_2}(3) = 2/5$$

$$O_{Y_2}(1) = \frac{4}{3}$$

و از این رو، فراوانی نسبی Y_2 طبق رابطه (15) عبارت است از،

$$Y_2 \text{ فراوانی نسبی} : \left[\left(0, \frac{5}{24} \right), \left(1, \frac{1}{6} \right), \left(2, \frac{5}{16} \right), \left(3, \frac{5}{16} \right) \right]$$

تابع توزیع تجربی برای Y_2 طبق رابطه (16) چنین است،

$$F_{Y_2}(\xi) = \frac{5}{24} \quad \xi < 1$$

$$\frac{3}{8} \quad 1 < \xi \leq 2$$

$$\frac{11}{16} \quad 2 \leq \xi \leq 3$$

$$1 \quad \xi \geq 3$$

از روی رابطه (17) میانگین نمونه نمادین Y_1 و Y_2 به ترتیب برابر است

$$\bar{Y}_1 = \frac{5}{6} \quad \text{و} \quad \bar{Y}_2 = \frac{83}{84} \quad \text{از روی رابطه (18) واریانس نمونه نمادین}$$

$$S_1^2 = 0.1915 \quad \text{و} \quad S_2^2 = 0.1239 \quad \text{است و میانه}$$

Y_1 برابر ۲ است.

سرانجام ملاحظه می‌کنیم که می‌توانیم فراوانی‌های موزون، میانگین‌های موزون و واریانس‌های موزون را به جای (12) با استفاده از

$$O_Z(\xi) = \sum_{u \in E} W_u \prod Z(\xi, u) \quad (21)$$

خاطرنشان می‌سازند که توزیع حدی واقعی Z وقتی $m \rightarrow \infty$ فقط با توزیع دقیق (ξ) f مذکور در (۲۵) تقریب زده می‌شود، زیرا این توزیع به درستی توزیع یکنواخت درون هر بازه بستگی دارد.

برای ساختن بافتگار، گیریم $I = \left[\min_{u \in E} a_u, \max_{u \in E} b_u \right]$ بازه‌ای باشد که همه مقادیر مشاهده شده Z در X ایجاد می‌کنند و فرض کنید که I را به ξ زیر بازه (ξ_g, ξ_{g-1}) ، $I_g = (\xi_g, \xi_{g-1})$ ، $g = 1, \dots, r-1$ ، $I_r = (\xi_r, \xi_{r-1})$ افراز کنیم. آنگاه بافتگار Z نمایش نموداری توزیع فراوانی $\{I_g, p_g\}$ است که در آن

$$p_g = \frac{1}{m} \sum_{u \in E} \frac{\|Z(u) \cap I_g\|}{\|Z(u)\|} \quad (26)$$

یعنی، p_g احتمال آن است که یک بردار توصیف انفرادی دلخواه x در بازه I_g بیفتدا. اگر بخواهیم بافتگار را با ارتفاع f_g روی بازه I_g رسم کنیم، به طوری که «مساحت» برای p_g باشد، آنگاه

$$p_g = (\xi_g - \xi_{g-1}) \times f_g. \quad (27)$$

زیر ساخت‌های ریاضی موجود مربوط به بافتگار در دیدی (۱۹۹۵) با استفاده از قانون قوی عدددهای بزرگ و مفاهیم آنرمها و آنمنرها که از سوی شوایتر و اسکلر (۱۹۸۳) ابداع شده‌اند، بسط یافته‌اند.

میانگین نمونه نمادین

برای یک متغیر بازه-مقدار Z با

$$\bar{Z} = \frac{1}{2m} \sum_{u \in E} (b_u + a_u) \quad (28)$$

داده می‌شود. برای تحقیق (۲۸) به خاطر یاورید که میانگین تجربی \bar{Z} بر حسب تابع چگالی تجربی عبارت است از،

$$\bar{Z} = \int_{-\infty}^{\infty} \xi f(\xi) d\xi$$

پس از جایگذاری مقادیر از (۲۵) داریم،

$$\begin{aligned} \bar{Z} &= \frac{1}{m} \sum_{u \in E} \int_{-\infty}^{\infty} \frac{I_u(\xi)}{\|Z(u)\|} \xi d\xi \\ &= \frac{1}{m} \sum_{u \in E} \frac{1}{b_u - a_u} \int_{\xi \in Z(u)} \xi d\xi \\ &= \frac{1}{2m} \sum_{u \in E} \frac{b_u - a_u}{b_u - a_u} = \frac{1}{2m} \sum_{u \in E} (b_u + a_u) \end{aligned}$$

به همین ترتیب، می‌توانیم واریانس نمونه نمادین را به دست آوریم.

۳-۵- متغیرهای بازه مقدار - آماره‌های تک متغیره

آماره‌های توصیفی متناظر برای متغیرهای بازه-مقدار به طرز مشابه به دست می‌آیند. برتران و گوپیل (۲۰۰۰) را ببینید. گیریم به متغیر خاص $Y_j \equiv Z$ علاقه‌مند باشیم و فرض کنیم که مقدار مشاهده شده مربوط به شیوه u عبارت است از بازه $Z(u) = [a_u, b_u]$ ، به ازای $u \in E = \{1, \dots, m\}$.

بردارهای توصیف انفرادی ($d_u \in vir(d_u)$ فرض می‌شوند که به طور یکنواخت بر روی بازه $Z(u)$ توزیع شده‌اند. بنابراین، نتیجه می‌شود که برای هر ξ ،

$$P\{x \leq \xi \mid x \in vir(d_u)\} = 0, \quad \xi < a_u$$

$$\frac{\xi - a_u}{b_u - a_u}, \quad a_u \leq \xi < b_u$$

$$1, \quad \xi \geq b_u$$

بردار توصیف انفرادی به طور یکجا در $U_{u \in E} vir(d_u)$ اختیار می‌کند. به علاوه فرض بر آن است که هر شیوه با احتمال $1/m$ و به طور همسانس مشاهده می‌شود. بنابراین، تابع توزیع تجربی (ξ)، F_Z تابع توزیع آمیزه‌ای از m توزیع یکنواخت $\{Z(u), u = \{1, \dots, m\}\}$ است. بنابراین بنابر (۲۳)،

$$\begin{aligned} F_Z(\xi) &= \frac{1}{m} \sum_{u \in E} P\{x \leq \xi \mid x \in vir(d_u)\} \\ &= \frac{1}{m} \left\{ \sum_{\xi \in Z(u)} \frac{\xi - a_u}{b_u - a_u} + |(u \mid \xi \geq b_u)| \right\} \end{aligned}$$

از آنجا که از راه مشتق گیری نسبت به ξ ، تابع چگالی تجربی Z را به صورت زیر به دست می‌آوریم.

$$f(\xi) = \frac{1}{m} \sum_{u: \xi \in Z(u)} \left(\frac{1}{b_u - a_u} \right) \quad (24)$$

دقت کنید که مجموع یابی موجود در (۲۴) تنها روی آن اشیاء u است که برای آنها $\xi \in Z(u)$. می‌توانیم (۲۴) را به صورتی دیگر بنویسیم،

$$f(\xi) = \frac{1}{m} \sum_{u \in E} \frac{I_u(\xi)}{\|Z(u)\|}, \quad \xi \in \mathcal{R} \quad (25)$$

که در آن I_u تابع نشانگر است که ξ در بازه $Z(u)$ هست یا نیست و $\|Z(u)\|$ طول آن بازه است. شباهت با (۱۵) و (۱۶) آشکار است. برتران و گوپیل (۲۰۰۰) با استفاده از قانون عدددهای بزرگ،

همچنین بازه‌ها و احتمال‌های مربوط به متغیر بازه-مقدار Y_2 را که معرف فشار خون سیستولیک است و \bar{Y}_2 را که نمایشگر فشار خون دیاستولیک است، برای همان ۱۰ بیمارستان نشان می‌دهد.

با استفاده از روابط (۲۸) و (۲۹) به ترتیب میانگین و واریانس نمونه نمادین را به دست می‌آوریم. بدین ترتیب، میانگین نبض $\bar{Y}_1 = ۷۹/۱$ با واریانس $S^2_1 = ۱۶۲/۲۹$; میانگین فشار خون سیستولیک $\bar{Y}_2 = ۴۹۵/۴۱$ با واریانس $S^2_2 = ۴۹۵/۴۱$ و میانگین فشار خون دیاستولیک $\bar{Y}_3 = ۸۴/۶$ با واریانس $S^2_3 = ۱۸۲/۴۴$.

نظیر مفاهیم و روش‌های محاسباتی بالا را می‌توان در مورد متغیرهای مدلی، چند مقداره، و بازه-مقدار نیز تعریف کرد. همچنین می‌توان این گونه مفاهیم و روش‌ها را به آماره‌های توصیفی دو متغیری مربوط به متغیرهای چند مقداره و بازه-مقدار تعمیم داد.

راستایی دیگر برای تحويل مشاهدات به مجموعه‌های کوچکتر استفاده از روش‌های تحويل داده‌ها نظیر تحلیل مؤلفه‌های اصلی و خوشبندی نمادین است. کوشش‌هایی برای گسترش به داده‌های سه طرفه نیز به عمل آمده‌اند که برای اطلاع از آنها به بیلارد و دیدی (۲۰۰۱) مراجعه شود.

۶. نتیجه‌گیری

با وجود قالبهای داده‌ای و اندازه‌های مجموعه‌های داده‌ها، نیاز به ابداع روش‌های آماری به منظور تحلیل آنها اهمیت روزافزون دارد. جهان آمار گنجینه‌ای از روش‌شناسی‌ها را در طی قرن پیستم می‌لادی ابداع کرده است. روش‌هایی که (در مقام قیاس) عمدتاً محدود به مجموعه‌های کوچک داده‌ها و قالبهای داده‌ای کلاسیک (اسکالاری، برداری و ماتریسی)‌اند. این مقاله به اجمال فرمول‌بندی و ساخت اشیاء و رده‌های نمادین را مرور کردیم. به کوتاهی به روش‌های تحلیل نمادین اشاره کرده، با مثالهایی طرز کار را بیان کردیم. نیاز به پژوهش و ابداع بیشتر به منظور انجام استباطهای آماری درباره داده‌های نمادین آشکار بوده، افقی است که اخیراً پیش چشم آمارشناسان گشوده شده است.

$$S^2 = \frac{1}{4m} \sum_{u \in E} (b_u + a_u)^2 - \frac{1}{4m^2} \sum_{u \in E} (b_u + a_u)^2 \quad (29)$$

در مورد متغیرهای چند مقداره، اگر شیئی u دارای ناسازگاری‌های درونی نسبت به یک قاعده منطقی باشد، یعنی اگر u چنان باشد که $vir(d_u) = 0$ است که برای آنها $vir(d_u) \neq u$ است، و به جای m عدد m' گذاشته شود (که برابر با تعداد اشیاء u موجود در E' است).

در زیر قرار می‌گذاریم که m و E به آن تابعی اشاره کنند که برای آنها این قواعد صادق‌اند.

مثال: برای توضیح مطلب، داده‌های راجو (۱۹۹۷) را که در جدول ۴ آمده‌اند، در نظر بگیرید.

در آنچه نبض (Y_1)، فشار خون سیستولیک (Y_2) و دیاستولیک (Y_3) به صورت متغیرهای بازه-مقدار به ازای هر $1, 2, \dots, 10$ بیمار ثبت شده‌اند.

گیریم داده‌های نبض (Y_1) را برداریم. مجموعه کل داده‌ها بازه $I_1 = [4, 112]$ را ایجاد می‌کند که در آن

$$\min_{u \in E} a_u = 44, \quad \max_{u \in E} b_u = 112$$

فرض کنید می‌خواهیم بافتگاری را روی $r = 8$ بازه $[4, 5, \dots, 110, 120] = I_8$ بسازیم. با استفاده از رابطه (۲۶) می‌توانیم احتمال p_g را که بردار توصیف انفرادی دلخواه X در بازه $I_g = [8, 1, \dots, 8, 4] = I_4$ بیفتند، حساب کنیم. مثلاً وقتی $4 = g$ احتمال آنکه یک X در بازه $[70, 80] = I_4$ بیفتند، برابر است با

$$p_g = \frac{1}{10} \left\{ \frac{0}{12} + \frac{2}{24} + \frac{10}{42} + \frac{10}{18} + \frac{2}{30} + \frac{10}{28} + \frac{8}{22} + \frac{4}{0} + \frac{0}{0} \right\} = 0.1611$$

از آنجا، بنابر رابطه (۲۷) می‌توانیم ارتفاع f_g از بافتگار رسم شده را برای آن بازه برابر با

$$f_g = p_g / (I_g - I_{g-1})$$

يعنى،

$$f_g = 0.1611 / 10 = 0.01611$$

حساب کنیم. خلاصه‌ای از مقادیر محاسبه شده P_g و f_g در جدول ۵ داده شده‌اند و نمودار بافتگار در شکل ۲ رسم شده است. جدول ۵

جدول ۱

| i | Y_1 | Y_2 | Y_3 | ... | Y_k | ... | Y_{18} | Y_{19} | Y_{20} | شرح متغیرها |
|-----|--------|-------|-------|-----|-------|-----|----------|----------|----------|--|
| ۱ | بوشهر | M | ۲۴ | | . | . | N | N | . | y _۱ : شهر محل سکونت |
| ۲ | بوشهر | M | ۵۶ | | ۲ | . | N | N | ۱ | y _۲ : جنس (F,M) |
| ۳ | ایلام | F | ۴۸ | | ۲ | . | y | N | ۱ | y _۳ : سن به سال |
| ۴ | ایلام | F | ۴۷ | | ۱ | . | Y | . | . | y _۴ : تعداد (سفید W, سیاه B, دیگر O) |
| ۵ | آبادان | M | ۷۹ | | ۴ | . | N | . | . | y _۵ : تأهل (مجرد S, متأهل M) |
| ۶ | لامرد | M | ۱۲ | | . | . | N | . | . | y _۶ : تعداد والدین زنده (۰, ۱, ۲, ...) |
| ۷ | لامرد | M | ۶۷ | | . | . | Y | ۶ | . | y _۷ : تعداد برادران و خواهران (۰, ۱, ۲, ...) |
| ۸ | لامرد | F | ۷۳ | | ۴ | . | N | . | ۲ | y _۸ : تعداد فرزندان (۰, ۱, ۲, ...) |
| ۹ | شیراز | M | ۲۹ | | ۲ | . | N | . | . | . |
| ۱۰ | کرمان | F | ۴۴ | | ۳ | . | y | . | . | . |
| . | . | . | . | . | . | . | . | . | . | y _{۱۰} : تشخیص سرطان (بلی Y, خیر N) |
| . | . | . | . | . | . | . | . | . | . | y _{۱۱} : تعداد دفعات معالجه سرطان پستان = N _{۱۱} (۰, ۱, ۲, ...) |
| . | . | . | . | . | . | . | . | . | . | y _{۱۲} : تعداد دفعات معالجه سرطان ریه (۰, ۱, ۲, ...) |

جدول ۲ - نمونه‌ای از داده‌های نمادین

| U | سن | فشار خون | شهر | نوع سرطان | جنس | وزن |
|---|---------|----------|-------|----------------------------|-------|---------|
| ۱ | [۲۰,۳۰] | (۷۹,۱۲۰) | بوشهر | {سرطان مغزی} | {زن} | [۷۰,۸۰] |
| ۲ | [۵۰,۶۰] | (۹۰,۱۳۰) | بوشهر | {کبد، ریه} | {مرد} | [۶۰,۷۵] |
| ۳ | [۴۵,۵۵] | (۸۰,۱۳۰) | ایلام | {پروستات} | {مرد} | [۶۰,۶۵] |
| ۴ | [۴۷,۴۷] | (۸۶,۱۲۱) | ایلام | {ریه $(1-p)$, پستان p } | {زن} | [۵۵,۶۵] |

جدول ۳- مجموعه‌ای از داده‌های نمادین

| u | Y_1 | Y_2 | $vir(d_u)$ | $ vir(d_u) $ | $ C_u $ |
|-----|-------|-------|-----------------------|--------------|---------|
| ۱ | {۰,۱} | {۲} | {(۱,۲)} | ۱ | ۱۲۸ |
| ۲ | {۰,۱} | {۰,۱} | {(۰,۰), (۱,۰), (۱,۱)} | ۳ | ۷۵ |
| ۳ | {۰,۱} | {۳} | {(۱,۳)} | ۱ | ۲۴۹ |
| ۴ | {۰,۱} | {۲,۳} | {(۱,۲), (۱,۳)} | ۲ | ۱۱۳ |
| ۵ | {۰} | {۱} | ϕ | ۰ | ۲ |
| ۶ | {۰} | {۰,۱} | {(۰,۰)} | ۱ | ۲۰۴ |
| ۷ | {۱} | {۲,۳} | {(۱,۲), (۱,۳)} | ۲ | ۸۷ |
| ۸ | {۱} | {۱,۲} | {(۱,۱), (۱,۲)} | ۲ | ۲۳ |
| ۹ | {۱} | {۰,۳} | {(۱,۱), (۱,۳)} | ۲ | ۱۲۱ |

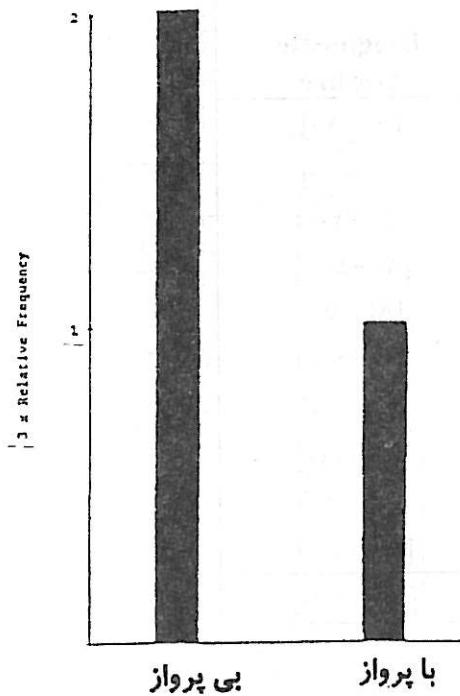
جدول ۴- سه متغیر نمادین

| u | : Y_1 Pulse rate | : Y_2 Systolic Pressure | : Y_3 Diagnostic pressure |
|-----|-----------------------|------------------------------|-----------------------------------|
| ۱ | [۴۴-۶۸] | [۹۰-۱۱۰] | [۵۰-۷۰] |
| ۲ | [۶۰-۷۲] | [۹۰-۱۲۰] | [۷۰-۹۰] |
| ۳ | [۵۶-۹۰] | [۱۴۰-۱۸۰] | [۹۰-۱۰۰] |
| ۴ | [۷۰-۱۱۲] | [۱۱۰-۱۴۲] | [۸۰-۱۰۸] |
| ۵ | [۵۴-۷۲] | [۹۰-۱۰۰] | [۵۰-۷۰] |
| ۶ | [۷۰-۱۰۰] | [۱۲۴-۱۴۲] | [۸۰-۱۱۰] |
| ۷ | [۷۲-۱۰۰] | [۱۳۰-۱۶۰] | [۷۶-۹۰] |
| ۸ | [۷۶-۹۸] | [۱۱۰-۱۹۰] | [۷۰-۱۱۰] |
| ۹ | [۸۶-۹۶] | [۱۲۸-۱۸۰] | [۹۰-۱۱۰] |
| ۱۰ | [۸۶-۱۰۰] | [۱۱۰-۱۵۰] | [۷۸-۱۰۰] |
| ۱۱ | [۶۳-۷۵] | [۸۰-۱۰۰] | [۱۴۰-۱۵۰] |

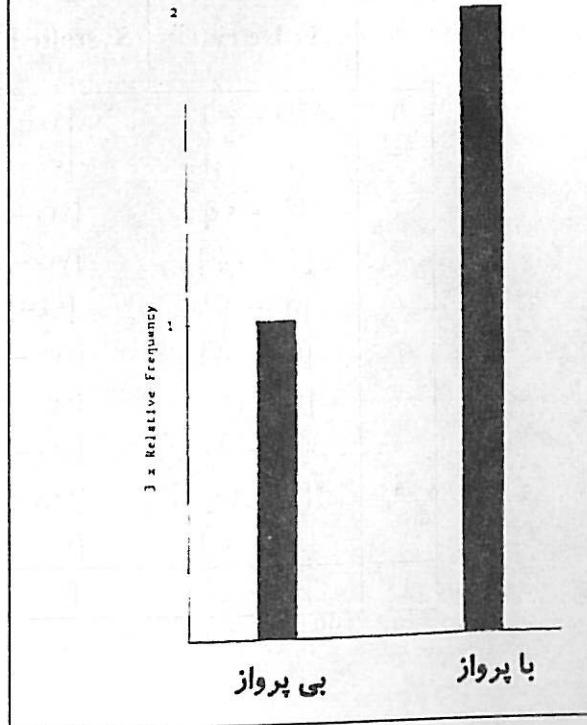
جدول ۵

| $Y_1 : Pulse Rate$ | | $Y_2 : Systolic pressure$ | | $Y_3 : Diagnostic pressure$ | |
|--------------------|-----------------------|---------------------------|-----------------------|-----------------------------|----------|
| I_g | p_g | I_g | p_g | I_g | p_g |
| [۴۰,۵۰) | .۰۰۲۵۰ | [۹۰,۱۰۰) | .۰۰۱۷۵۰ | [۵۰,۶۰) | .۰۰۱۰۰۰ |
| [۵۰,۶۰) | .۰۰۱۸۶۸ | [۱۰۰,۱۱۰) | .۰۰۱۷۵۰ | [۶۰,۷۰) | .۰۰۱۰۰۰ |
| [۶۰,۷۰) | .۰۰۱۰۱۶ | [۱۱۰,۱۲۰) | .۰۰۱۹۳۸ | [۷۰,۸۰) | .۰۰۱۱۲۷ |
| [۷۰,۸۰) | .۰۰۱۶۱۱ | [۱۲۰,۱۳۰) | .۰۰۱۹۳۸ | [۸۰,۹۰) | .۰۰۱۲۶۹ |
| [۸۰,۹۰) | .۰۰۲۳۶۳ | [۱۳۰,۱۴۰) | .۰۰۱۸۱۸ | [۹۰,۱۰۰) | .۰۰۱۲۸۹۵ |
| [۹۰,۱۰۰) | .۰۰۱۶۰۶ | [۱۴۰,۱۵۰) | .۰۰۱۵۰۹ | [۱۰۰,۱۱۰) | .۰۰۱۳۶۹ |
| [۱۰۰,۱۱۰) | .۰۰۲۳۸ | [۱۵۰,۱۶۰) | .۰۰۱۹۴۶ | | |
| [۱۱۰,۱۲۰) | .۰۰۰۴۸ | [۱۶۰,۱۷۰) | .۰۰۱۶۱۳ | | |
| | | [۱۷۰,۱۸۰) | .۰۰۱۶۱۳ | | |
| | | [۱۸۰,۱۹۰) | .۰۰۱۲۵ | | |
| Mean | $\bar{Y}_1 = ۷۹/۱$ | $\bar{Y}_2 = ۱۳۱/۱$ | $\bar{Y}_3 = ۸۴/۶$ | | |
| Variance | $S_1^2 = ۱۶۲/۲۹$ | $S_2^2 = ۱۶۲/۲۹$ | $S_3^2 = ۱۸۲/۴۴$ | | |
| Covariance | $S_{۱۲} = ۱۹۴/۱۷$ | $S_{۲۳} = ۲۵۷/۹۲$ | $S_{۱۳} = ۱۴۱/۰۴$ | | |
| Correlation | $r(Y_1, Y_2) = .۰۶۸۵$ | $r(Y_2, Y_3) = .۰۸۵۸$ | $r(Y_1, Y_3) = .۰۸۲۰$ | | |

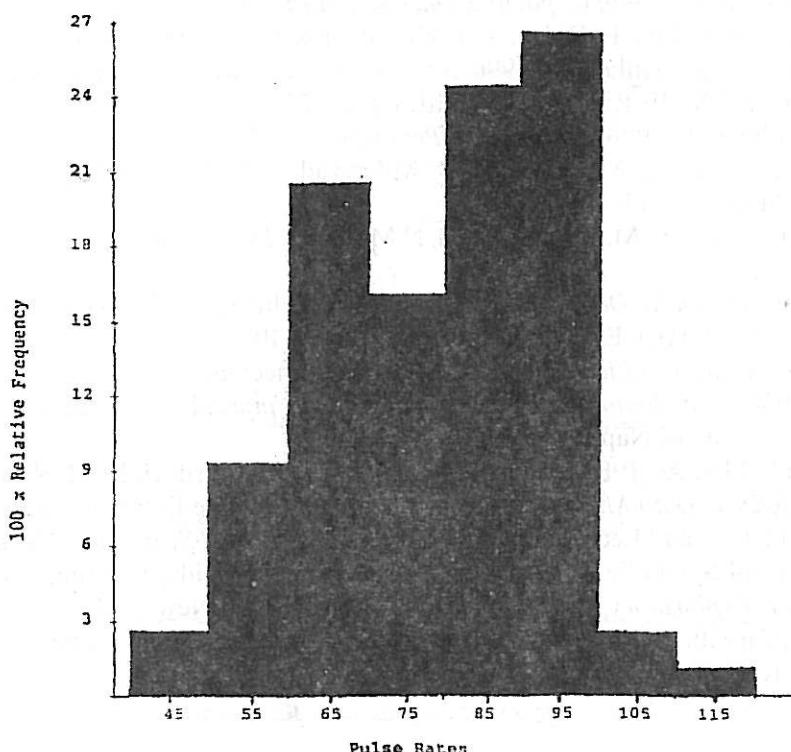
شکل ۱-ب بافتگار گونه‌های با پرواز / بی پرواز



شکل ۱-الف بافتگار گونه‌های با پرواز / بی پرواز



شکل ۲- بافتگار داده های راجو



مراجع

- [1] Aristotle (IVBC), 1994. *Des Categories De l'Interpretation*, Organ, Librairie Philosophique Journal Vrin.
- [2] Arnault, A. and Nicole, P., 1662. *La Logic ou l'Art Depensur*, Reprinted by Forman, Stuttgart (1965).
- [3] Bertrand, P., 1995. *Structural Properties of Pyramidal Clustering In: Partitioning Data Sets*, (eds. I. Corc, P. Hansen and B. Julesz), American Mathematical Society, 19, pp. 352-353.
- [4] Bertrand, P. and Goupil, F., 2000. *Descriptive Statistics for Symbolic Data*, In: Analysis of Symbolic Data (eds. H.H. Bock and E. Diday), Springer-Verlag, pp. 103-124.
- [5] Billard, L. and Diday, E., 2001. *From the Statistics of Data to the Statistics of knowledge: Symbolic Data Analysis*, Manuscript.
- [6] Bock, H.H. and Diday, E., 2000. *Symbolic Objects*, In: Analysis of Symbolic Data, (eds. H.H. Bock and E. Diday), Springer-Verlag, pp. 54-77.
- [7] Choquet, G., 1954. *Theory of Capacities*, Annals de l'Institute Fourier, 5, pp. 131-295.
- [8] Chouakria, A., 1998. *Extensions des methodes d'analyse factorielle a des donnee de type intervalle*, Ph.D. Thesis, University of Paris.
- [9] DeCarvalho, F.A.T., 1994. *Proximity Coefficients Boolean Symbolic Objects*, In: New Approaches in Classification and Data Analysis, (eds. E. Diday, Y. Lechevallier, M. Schader, P. Bertrand and B. Burtschy). Springer-Verlag, pp. 387-394.
- [10] DeCarvalho, F.A.T., 1995. *Histograms in Symbolic Data Analysis*, Annala of Operation Research. 55, pp.299-322.
- [11] Diday, E., 1987. *Introduction a l'Approach Symbolique en Analyse des Donnees*, Premere Jounelles Symbolique-Namerique, CEREMADE, Universite Paris-Dauphine, pp. 21-56.

- [12] Diday, E., (ed.), 1989. *Data Alalysis, Learning Symbolic and Numerical Knowledge*, Nova Science, Antibes.
- [13] Diday, E., 1990. *Knowledge Representation and Symbolic Data Analysis*, In: Knowledge Data and Computer Assisted Decisions, (eds. M. Schader and W. Gaul). Springer-Verlag, pp. 17-34.
- [14] Diday, E., 1995. *Probabilistic, Possibilistic and Belief Objects for Knowledge Analysis*, Annala of Operation Research, 55, pp. 227-276.
- [15] Diday, E. and Emilion, R., 1996. *Capacities and Credibilities in Analysis of Probabilistic Objects*, In: Ordinal and Symbolic Data Analysis, (Eds. E. Diday, Y. Lechevallier and O. Opitz), Springer-Verlag, pp. 13-30.
- [16] Diday, E., Emilion, R. and Hillali, Y., 1996. *Symbolic Data Analysis of Probabilistic Objects by Capacities and Credibilities*, Atti Della XXXVIII Riunione Scientifica, pp. 5-22.
- [17] Elder, J. and Pregibon, D., 1996. *A Statistical Perspective on Knowledge discover in Databases*, In: Advances in Knowledge Discovery and Data Mining (eds. U.M.Fayyad, G. Piatetesk-Shapiro, P. Symth and R. Uthurusamy), AAAI Press, 83-113.
- [18] Hand, D.J., Blunt, G., Kelly, M.G. and Adams, N.M., 2000. *Data Mining for Fun and Profit*, Statistical Science, 15, pp. 111-131.
- [19] Raju, S.R.K., 1997. *Symbolic Data Analysis in Cardiology*, In: Symbolic Data Analysis and its Applications (eds. E. Diaay and K.C. Gowda), CEREMADE, Paris, pp. 245-249.
- [20] Schafer, G., 1976. *A Mathematical Theory of Evidence*, Princeton.
- [21] Schweizer, B., 1984. *Distributions are the Numbers of the Future*, In: Proceedings The Mathematics of Fuzzy Systems Meeting. University of Naples, pp. 137-149.
- [22] Schweizer, B. and Sklar, A., 1983. *Probabilitic Metric Spaces*, North Holland, New York.
- [23] Siebs, A., 1998. *KESO: Data Mining and Statictics*, In: Knowledge Extraction from Statistical Data, pp. 1-13.
- [24] Stephan, V., Herbill, G. and Lechevallier, Y., 2000. *Generation of Symbolic Objects from Relational Databases*, In: Analysis of Symbolic Data, (Eds. H. -H. Bock and E. Diday). Springer-Verlag, pp. 78-105.
- [25] Tukey, J.W., 1977. *Exploratory Data Analysis*, Addison-Wesley, New York.
- [26] Verbe, R. and DeCarvallo, F.A.T., 1998 *Dependence Rules Influence on Factorial Representation of Boolean Symbolic Objects*, In: Knowledge Extraction from Statistical Data, pp. 14-23.