



NASTINFO

ویژگی‌های مشترک قوانین تجربی معروف در علم سنجی:

نگاهی از زاویه دسته‌بندی داده‌ها براساس توزیع فراوانی

محمد توکلی‌زاده راوری | فرامرز سهیلی

چکیده

هدف: بررسی چهار قانون معروف در حوزه کتاب‌سنجی و علم سنجی (لوتکا، برادفورد، زیپف، و پرتو) از زاویه دسته‌بندی داده‌های آنها براساس توزیع فراوانی.

روش/ رویکرد پژوهش: روش سندی- تحلیلی. با بررسی داده‌های مرتبط با قواعد چهارگانه علم سنجی به دسته‌بندی داده‌ها براساس توزیع فراوانی آنها پرداخته است.

یافته‌ها: شکل اولیه داده‌ها در این چهار توزیع، حاوی رتبه هر موجودیت، فراوانی ویژگی مورد مطالعه، و مقدار فراوانی مطلق آن ویژگی در آن موجودیت است. در هریک از این قوانین، موجودیت‌ها براساس میزان فراوانی در ویژگی مورد نظر به چند دسته تقسیم می‌شوند: پرتو (۲ دسته)، لوتکا (به تعداد حداقل فراوانی)، و زیپف (به تعداد واژگان متن).

نتیجه‌گیری: نتایج مربوط به نحوه دسته‌بندی موجودیت‌ها و تعیین تعداد موجودیت‌های درون هر دسته حاکی از آن است که تفاوت بین فراوانی دسته‌ها تابع یک توزیع مشخص است. قوانین چهارگانه را می‌توان برای دسته‌بندی موجودیت‌های مختلف براساس ویژگی‌های متعدد تعمیم داد.

ویژگی‌های مشترک قوانین تجربی معروف در علم سنجی:

نگاهی از زاویه دسته‌بندی داده‌ها براساس توزیع فراوانی

محمد توکلی‌زاده راوری^۱

فرامرز سهیلی^۲

تاریخ دریافت: ۹۳/۱۱/۱۴

تاریخ پذیرش: ۹۴/۰۴/۳۱

مقدمه

کشف قواعد، توزیعات، یا قوانین از اساسی‌ترین زیربنای‌های توسعه حوزه‌های سنجشی است (هود و ویلسون^۳، ۲۰۰۱) و بخش بزرگی از مطالعات علم سنجی به توزیع فراوانی موجودیت‌های علمی و روابط میان آنها می‌پردازد. موجودیت‌های علمی به متغیرهایی اطلاق می‌شود که به گونه‌ای با علم و فناوری در ارتباط هستند. مدارک و منابع علمی و فنی، همراه با اطلاعات کتابشناختی و سایر فراداده‌های مرتبط با آنها را می‌توان موجودیت‌های علمی و فنی نامید. برخی منابع علمی عبارت‌اند از: مقالات نشریات، مقالات همایش‌ها، صفحات وب، و پروانه‌های ثبت اختراع. موجودیت‌های اطلاعاتی مانند نویسنده‌گان، موضوعات، استنادها، تاریخ تولید، و زبان، نمونه‌هایی از اطلاعات کتابشناختی هستند.

یکی از فنونی که می‌توان از طریق آنها به مطالعات مربوط به توزیع فراوانی موجودیت‌های علمی و فنی پرداخت، به کارگیری قوانین تجربی معروف در علم سنجی و کتابسنجی است. به این قوانین، اصطلاح "توزیع" نیز اطلاق می‌شود. اینکه کدام قوانین تجربی را می‌توان قوانین پایه در این حوزه نامید، بیشتر از همه به زیپف، لوتکا، و برادفورد اشاره می‌شود. به طور نمونه، اوکنور و ووس^۴ (۱۹۸۱) بر این باورند که توزیع‌های برادفورد، لوتکا، و زیپف به عنوان قوانین پایه کتابسنجی شناخته می‌شوند و هریک از اینها به صورت تجربی حاصل شده‌اند. این توزیع‌ها مانند بخش‌هایی خاص از یک هذلولی شبیه هم هستند؛ در کنار آن، قانون پرتو نیز آمده است. از این رو، در مقاله حاضر به این چهار قانون پرداخته می‌شود. نام

۱. استادیار گروه علم اطلاعات و
دانش‌شناسی، دانشگاه بیزد
mrvavari@yahoo.com

۲. استادیار گروه علم اطلاعات و
دانش‌شناسی، دانشگاه پیام نور
(نویسنده مسئول)
fsohili@gmail.com

3. Hood & Wilson
4. O'connor & Voos

این قوانین، برگرفته از نام کاشفان آنها جورج کینگزلی زیپف^۱، آفرید جیمز لو تکا^۲، ساموئل کلمنت برادفورد^۳، و ویلفردو پرتو^۴ است (برادفورد، ۱۹۳۴ و ۱۹۸۵؛ زیپف، ۱۹۳۲؛ لو تکا، ۱۹۶۴؛ و پرتو، ۱۹۲۶).

قوانین تجربی در برابر قوانین طبیعی قرار می‌گیرند و به توصیف الگوهای می‌پردازند که قاعده‌مند و تکرارپذیرند و همانند قوانین طبیعی دو خاصیت اساسی دارند: نخست) این امکان را به ما می‌دهند که رخدادها را پیش‌بینی کنیم یا عکس العمل خود را نسبت به آنها مشخص کنیم؛ دوم) ممکن است منجر به نظریه‌هایی شوند که توضیح می‌دهند چرا یک الگوی خاص اتفاق می‌افتد (دروت، ۱۹۸۱). یکی از کاربردهای آنها در علم سنجی، دسته‌بندی موجودیت‌های علمی برای اهداف گوناگون است. این اهداف از دسته‌بندی نشریات برای فراهم‌آوری مجموعه کتابخانه تا کاهش تعداد موجودیت‌ها برای سنجش رابطه میان آنها از طریق فنون ترسیم نقشه علم گسترشده است. از این رو، مقاله حاضر با هدف مطالعه ویژگی‌های مشترک قوانین تجربی معروف در علم سنجی از زاویه دسته‌بندی موجودیت‌های علمی براساس توزیع فراوانی تدوین شده است.

هرگاه موجودیت‌ها براساس شباهتشان دسته‌بندی یا خوش‌بندی شوند مشاهده می‌شود که اندازه بسیاری از موجودیت‌هایی که در یک خوش‌بندی قرار گرفته‌اند نزدیک به هم است. سرعت ماشین‌های بزرگ‌راه‌ها، وزن سبیلهای، فشار هوای سطح دریا، و دمای هوای یک شهر نمونه‌ای از آن است. اگرچه در اندازه آنها تفاوت‌هایی وجود دارد، اما توزیع احتمالی آنها از یک مقدار خاص خیلی دور نیست. در حقیقت، این مقدار خاص نماینده بسیاری از مشاهدات است. به عنوان نمونه، قد مردان یک کشور حدود ۱۸۰ سانتی‌متر است، به این معنا که قد سایر مردان آن کشور از این مقدار کمی بیشتر یا کمتر است. حتی بزرگ‌ترین انحراف از این مقدار که استثناء و بسیار نادر است، انتظار می‌رود خیلی از آن دور نباشد. اما توزیع همه موجودیت‌ها از این قاعده پیروی نمی‌کند (کلاوزت^۵ و همکاران، ۲۰۰۹). از این رو، درک این چهار قانون معروف در حوزه کتاب‌سنجی و علم سنجی مستلزم داشتن داشن در زمینه توزیع آماری براساس قواعد خطی، توانی، نمایی، و لگاریتمی است. از این میان، توزیع‌های توانی و نمایی همخوانی بهتری با توزیع‌های تجربی مشاهده شده دارند و در بسیاری از حوزه‌ها نتایج مشابهی طی سال‌ها تکرار شده است (میتزن‌ماجر، ۲۰۰۴). البته، توزیع توانی به دلیل خواص ریاضی اش توجه بیشتری را در طول سال‌ها به خود جلب کرده است؛ زیرا این خواص گاهی به نتایج فیزیکی جالبی می‌انجامد. این توجه همچنین به دلیل منطبق بودن آن بر بسیاری از موجودیت‌های طبیعی و ساخت دست بشر است. جمعیت شهرها و شدت زلزله‌ها نمونه‌هایی منطبق بر توزیع توانی هستند. برای موجودیت‌هایی که چنین توزیعی

1. George Kingsley Zipf
2. Alfred James Lotka
3. Samuel Clement
4. Bradford
5. Drott Vilfredo Pareto
6. Clauset
7. Mitzenmacher

دارند، میانگین معنادار نیست (کلاوزت و همکاران، ۲۰۰۹).

مفهوم توزیع توانی این است که اشیا و موجودیت‌هایی که در یک ویژگی ارزش و فراوانی بالایی دارند، مثل تعداد نویسنده‌گان پرکار و شهرهای پر جمعیت، کم است (Milojević¹، ۲۰۱۰). این اتفاق معمولاً زمانی می‌افتد که تعداد موجودیت‌ها خیلی زیاد باشد. بنابراین، "اگر مقدار یا فراوانی موجودیت‌ها در کل کم باشد، توزیع توانی حاصل نمی‌شود" (ون ران، ۲۰۰۱). البته، گاهی به‌جز توزیع توانی ممکن است اصطلاحات دیگری برای آن نیز به‌کار برود. برای نمونه، فرانسچت^۳ (۲۰۰۸) بیان می‌دارد توزیع پرتو که توزیع توانی هم نامیده می‌شود، به عنوان وسیله‌ای برای مدل‌سازی موجودیت‌ها مورد استفاده قرار می‌گیرد. نمونه‌ای از موجودیت‌هایی که از توزیع پرتو پیروی می‌کنند عبارت‌اند از زیپف و لوتنکا، یا به‌گفته میترن‌ماچر (۲۰۰۴) "از آن به عنوان توزیع دنباله بزرگ، پرتو، زیپف و غیره یاد می‌شود".

با توجه به اهمیت قوانین تجربی در حوزه‌های سنجشی علم اطلاعات و دانش‌شناسی، مطالعات چندانی وجود ندارد که به صورت یک‌جا به نقاط مشترک و تفاوت این قوانین پرداخته و به کارکرد اصلی آنها (یعنی دسته‌بندی داده‌ها) خارج از پیچیدگی‌های ریاضی و به صورت کاربردی توجه کرده باشد. این موضوع، اهمیت مطالعه حاضر را روشن می‌سازد. مسئله مطالعه حاضر، روشن نبودن زوایای مختلف شباهت‌ها و تفاوت‌های قوانین تجربی در حوزه‌های سنجشی علوم اطلاعات و دانش‌شناسی از جنبه دسته‌بندی داده‌ها و براساس توزیع فراوانی آنها با بیانی خارج از فرمول‌های پیچیده ریاضی است.

هدف پژوهش حاضر، مطالعه ویژگی‌های مشترک قوانین تجربی یا توزیع‌های معروف در علم سنجی از زاویه دسته‌بندی داده‌ها براساس توزیع فراوانی است. برای رسیدن به این هدف، اهداف ویژه زیر مورد توجه قرار گرفته است:

۱. مطالعه شکل اولیه داده‌ها در توزیع‌های مورد مطالعه؛

۲. مطالعه تعداد دسته‌ها در هریک از توزیع‌های مورد مطالعه؛

۳. بررسی نحوه دسته‌بندی در هریک از توزیع‌های مورد مطالعه؛ و

۴. چگونگی تعمیم‌پذیری توزیع‌های مورد مطالعه.

مروری بر مطالعات گذشته نشان می‌دهد که در بسیاری از مطالعات مربوط به توسعه حوزه‌های سنجشی علوم اطلاعات و دانش‌شناسی (مانند کتاب سنجی، علم سنجی، و اطلاع‌سنجی) نگاه اصلی به قوانین تجربی این حوزه معطوف است که اهمیت این قوانین در حوزه‌های سنجشی را نشان می‌دهد. به عنوان نمونه، هرتزل^۴ (۱۹۸۷) از طریق آمارها و کتاب‌شناسی‌ها به مطالعه ریشه‌های توسعه کتاب سنجی می‌پردازد. او به قوانین کتاب سنجی به عنوان اساس توسعه این حوزه توجه کرده است. برادوس^۵ در سال ۱۹۸۷ به تاریخ

1. Milojević
2. Van Raan
3. Franceschet
4. Hertzel
5. Broadus

کتاب‌سنجدی تا سال ۱۹۶۹ می‌پردازد. سال ۱۹۶۹ با ظهرور اصطلاح کتاب‌سنجدی توسط پریچارد^۱ مصادف است. او در مطالعه تاریخچه کتاب‌سنجدی به مطالعات مربوط به سه قانون کتاب‌سنجدی، تحلیل استنادی، و استفاده از کتابخانه توجه دارد. ویلسون (۱۹۹۹) در سلسله بررسی‌های سالانه در حوزه علوم و فناوری اطلاعات^۲ به موضوع اطلاع‌سنجدی می‌پردازد و به تفصیل نشان می‌دهد که بین سه قانون زیپف، لوتكا، و برادرورد ارتباط وجود دارد.

پس از معرفی قوانین یادشده توسط کاشفان آنها کارهای بسیاری در زمینه قوانین تجربی صورت گرفته است. از جدیدترین آنها می‌توان به مطالعه اگه^۳ (۲۰۰۵) اشاره کرد. وی به مسائل نابرابری یا تمرکز در توابع زیپف و لوتكا توجه دارد و پس از یک نگاه مختصر به ارتباط بین توابع آنها نشان می‌دهد که قانون تمرکز پرایس منطبق بر قانون زیپف است.

مایر^۴ (۲۰۱۳) با هدف بهبود فرایند جستجو به توزیع فراوانی در سه ناحیه مختلف برادرورد می‌پردازد. او می‌خواهد بداند که آیا برادروردسازی^۵ می‌تواند جستجو را بهبود ببخشد. به عبارتی، او کارآمدی برادروردسازی را به عنوان یک فن کتاب‌سنجدی در بازیابی اطلاعات مورد ارزیابی قرار داد. وی در نظر داشت تا با برادروردسازی، مجموعه مدارکی را که از نماینامه‌ها و چکیده‌نامه‌های سنتی حاصل شده است دوباره رتبه‌بندی کند و آنها را به مدارک هسته و فرعی تقسیم نماید.

آوس لوس^۶ (۲۰۱۴) نشان داد که هر دانشمند براساس میزان همکاری در نوشتمن می‌توان یک رتبه مبنی بر اهمیت اختصاص داد. این رتبه به میزان همکاری او در انتشار مقالات بستگی دارد. در این پژوهش، براساس قانون زیپف-ماندل بروت - پرتو نشان داده شد که رابطه بین رتبه افراد و میزان مشارکت آنها در نوشتمن مقاله براساس یک توزیع توائی است.

مطالعه در زمینه قوانین تجربی یادشده، صرفاً محدود به حوزه‌های سنجشی مربوط به علوم اطلاعات و دانش‌شناسی نیست. مثلاً در زمینه زیپف که مبدأ آن زبان‌شناسی است، از همان ابتدا تاکنون در مباحث زبانی به آن توجه شده است. یکی از کارهای دهه ۵۰ میلادی مربوط به میلر و نیومن^۷ (۱۹۵۸) است که به توضیح آماری رابطه بین رتبه و فراوانی واژه‌ها در متون انگلیسی توجه کردند. این نوع مطالعات هنوز ادامه دارد. گلبوخ و سیدورف^۸ (۲۰۰۱) ضرایب قوانین زیپف و هیپ را مطالعه کردند. در حوزه‌های دیگر نیز این قوانین بسط یافته است، مانند حوزه نظریه اطلاعات (هارمویز و تاپسوی^۹، ۲۰۰۵)، جمعیت شهرها (مالاکارنی^{۱۰} و همکاران، ۲۰۰۲)، ترافیک وب (ژوهانسون و سورنتی^{۱۱}، ۲۰۰۰)، امور مالی و تجارت (آکستل^{۱۲}، ۲۰۰۱)، و بسیاری موضوعات دیگر.

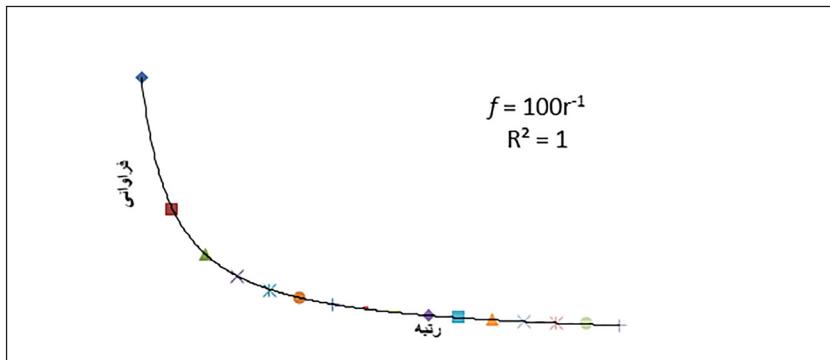
روش شناسی

مطالعه حاضر توصیفی و از لحاظ هدف، کاربردی و از جنبه ابزار و منبع داده‌های مورد نیاز از پژوهش‌های سندی-تحلیلی محسوب می‌شود. برای انجام این پژوهش، آثار مرتبه اصلی که توسط کاشفان قوانین مورد نظر نوشته شده، و نیز آثاری که توسط دیگران درباره این قوانین نگاشته شده، و در انتهای، پژوهش‌هایی که از این قوانین در آنها بهره گرفته شده است مطالعه و بررسی شد. با توجه به اهداف ویژه، این مطالعات و بررسی‌ها از زاویه شکل اولیه داده‌ها، تعداد دسته‌ها، نحوه دسته‌بندی و توابع و ضرایب حاصل از این دسته‌بندی‌ها، و نحوه تعمیم آنها در هریک از توزیع‌ها انجام شد. علاوه بر آن، منابعی که به توابع رگرسیونی، به ویژه توابع نمایی و توانی، از نگاه قوانین تجربی و توزیع فراوانی پرداخته‌اند، بررسی شدند.

یافته‌ها

۱. شکل اولیه داده‌ها

اولین گام عملی در هریک از این توزیعات (زیپف، برادرفورد، لوتنکا، و پرتو) را می‌توان روی یک محور مختصات دو بعدی نشان داد. در محور افقی، همیشه رتبه و در محور عمودی، فراوانی قرار دارد. اگر به ریشه تاریخی هریک از این قوانین نگاه کنیم موجودیتی که بررسی می‌شود متفاوت است. موجودیت‌های مورد توجه در این چهار قانون به این صورت است: قانون زیپف به واژه‌های یک متن، قانون لوتنکا به نویسندهای در یک مجموعه، قانون برادرفورد به مدارک مرتبط با یک موضوع در نشریات، و قانون پرتو به افراد جامعه از نظر ثروت و دارایی می‌پردازد. نکته دیگر این است که همیشه موجودیت‌هایی که فراوانی آنها سنجیده شده است از زیاد به کم در یک ستون تنظیم می‌شوند. این فرایند سبب می‌شود که توزیع همیشه شبیه منفی داشته باشد.



نمودار ۱. نمونه‌ای از یک توزیع توانی

در این چهار توزیع، اگر سه ستون داده داشته باشیم، ستون اول حاوی رتبه هر موجودیت براساس فراوانی ویژگی مورد مطالعه است. در این ستون، رتبه نشریه براساس مقالات مرتبط (در قانون برادرفورد)، رتبه نویسنده براساس میزان مشارکت در نوشتن مقاله (در قانون لوتكا)، رتبه واژه براساس تکرار در متن (در قانون زیپف)، و رتبه فرد براساس میزان دارایی (در قانون پرتو) آورده می‌شود. ستون دوم، حاوی مقدار فراوانی مطلق ویژگی موجودیت مربوط است. ستون سوم، فراوانی را به صورت تراکمی نشان می‌دهد. بنابراین، شباهت توزیع‌های لوتكا، برادرفورد، زیپف، و پرتو عجیب نیست. این توزیع‌ها برپایه رتبه و فراوانی (یا رابطه رتبه-مقدار) قرار دارند که موجودیت‌ها پس از طبقه‌بندی رتبه‌بندی می‌شوند (اوکنور و ووس، ۱۹۸۱).

جدول ۱. شکل اولیه داده‌ها براساس توزیع آماری

| فراوانی تراکمی ویژگی | فراوانی مطلق ویژگی (محور عمودی) | رتبه موجودیت (محور افقی) |
|----------------------|------------------------------------|-----------------------------|
| ۹۳ | ۹۳ | ۱ |
| ۱۷۹ | ۸۶ | ۲ |
| ۲۳۵ | ۵۶ | ۳ |
| ۲۸۳ | ۴۸ | ۴ |
| ۳۲۹ | ۴۶ | ۵ |
| ۳۶۴ | ۲۵ | ۶ |

سنجدیدن رابطه بین ستون اول (رتبه) و دوم (فراوانی) در بسیاری از موارد به یک توزیع توانی با توان منفی منجر خواهد شد که تابع آن از فرمول زیر پیروی می‌کند:

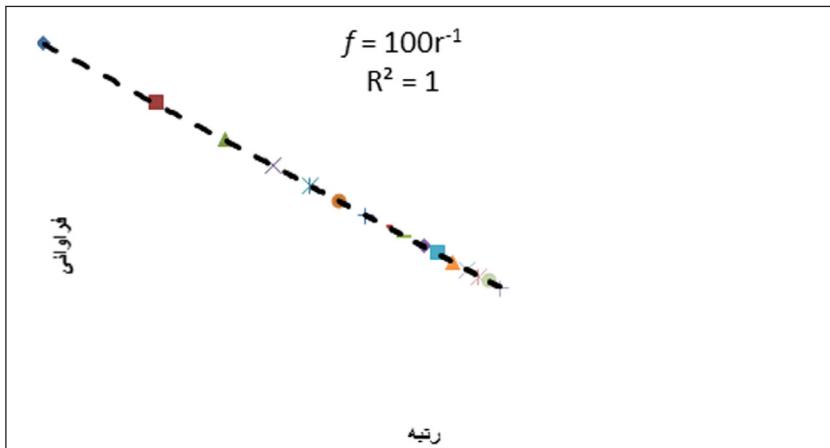
$$f = cr^p$$

فرمول ۱. تابع توزیع توانی

f مقدار فراوانی موجودیت در ویژگی مورد نظر (مقدار فراوانی قابل انتظار) است؛ c یک عدد ثابت است و نشان می‌دهد که اگر رتبه، صفر باشد مقدار فراوانی چقدر است؛ r رتبه هر موجودیت از نظر فراوانی ویژگی مورد نظر را نشان می‌دهد؛ و p عددی منفی و توان توزیع است. به این ترتیب، براساس این تابع می‌توان پیش‌بینی کرد که فراوانی ویژگی موجود نظر برای هر رتبه چقدر است. براساس خاصیتی که توزیع توانی منفی دارد، با تنزل رتبه یک

1. O'connor & Voos

موجودیت، فراوانی ویژگی مورد نظر در آن متناسب با رتبه کاهش می‌یابد. در این نوع توزیع، اگر بخواهیم تصویر نمودار را به جای خط منحنی به صورت خط صاف نمایش دهیم باید هر دو محور افقی و عمودی را به صورت لگاریتمی درجه‌بندی کنیم که این کار توسط نرم‌افزارهایی مانند اکسل به سادگی میسر است؛ از این‌رو، به این‌نوع توزیع Log-log نیز گفته می‌شود. نیomon¹ (۲۰۰۵) بیان می‌دارد: "برای اینکه شکل توزیع فراوانی را نشان دهیم، بهتر است آن را روی نمودار قرار دهیم و محور عمودی و افقی را به صورت لگاریتمی در بیاوریم. وقتی چنین کاری انجام شد، رابطه به صورت یک خط مستقیم نشان داده می‌شود. این کار باعث می‌شود که بتوان مشاهده کرد کدام بخش از داده‌ها بر این توزیع منطبق نیست. مثلاً ممکن است در بعضی موارد، دنباله نمودار بر آن خط صاف منطبق نباشد. در این حالت، یکی از گزینه‌های تواند کنار گذاشتن داده‌های انتهایی باشد. اما مشکل اینجاست که گاهی اطلاعات سودمندی وجود دارد که ممکن است از دست برود. به علاوه، بسیاری از داده‌ها در دنباله نمودار دارای توزیع توانی هستند. این خطر وجود دارد که ما بچه را همراه با آب تشست بیرون بیندازیم". در توزیع‌های نمایی اگر محور افقی و در توزیع‌های لگاریتمی اگر محور عمودی به صورت لگاریتمی درجه‌بندی شوند، چنین خط صافی حاصل می‌شود. از این‌رو، به توزیع‌های نمایی Log-normal و به توزیع لگاریتمی Normal-log نیز اطلاق می‌شود.



نمودار ۲. نمایش یک توزیع توانی به صورت Log-log

در توزیع برادرفورد، ستون اول حاوی رتبه هر نشریه از نظر فراوانی مقالات مرتبط با یک

1. Newman موضع خاص و ستون دیگر، فراوانی مطلق مقالات مرتبط به موضوع مورد نظر در هر نشریه

است. بنابراین، مقادیر مرتبط با هریک از متغیرهای فرمول ۱ چنین است: f فراوانی مقالات مرتبط با یک موضوع خاص در یک نشریه است، c یک عدد ثابت که معمولاً مقدار آن نزدیک به فراوانی مقالات آن نشریه‌ای است که از همه نشریات دیگر مقالات مرتبط بیشتری داشته، p همان رتبه نظریه از نظر فراوانی مقالات مرتبط، و n عددی منفی و توان توزیع است. در توزیع پرتو، ستون اول رتبه هر شخص از نظر دارایی و ثروت، و ستون دیگر میزان ثروت هر فرد، c یک عدد ثابت و نزدیک به دارایی ثروتمندترین فرد، p رتبه وی، و n توان توزیع است. در توزیع لوتكا، ستون اول، رتبه هر نویسنده از نظر تعداد مقالات و ستون دوم، فراوانی مطلق تعداد مقالات وی است. بنابراین، در فرمول ۱، f فراوانی مقالات هر فرد، c یک عدد ثابت نزدیک به فراوانی مقالات پرکارترین نویسنده، p رتبه نویسنده، و n توان توزیع است. در توزیع زیپف، ستون اول، رتبه هر واژه از لحاظ فراوانی و ستون دیگر، فراوانی مطلق آن واژه در متن است. در این حالت، f فراوانی واژه، p رتبه آن واژه از نظر فراوانی، c یک عدد ثابت نزدیک به پرسامدترین واژه در متن، و n توان توزیع است.

۲. تعداد دسته‌ها

کاری که عملاً برپایه این قوانین صورت می‌گیرد، طبقه‌بندی یا دسته‌بندی موجودیت‌ها براساس توزیع فراوانی آنهاست. در هریک از این قوانین، موجودیت‌ها براساس میزان فراوانی در ویژگی مورد نظر به چند دسته تقسیم می‌شوند: پرتو (۲ دسته)، برادرورد (۳ دسته)، لوتكا (به تعداد حداقل فراوانی یا همان C در فرمول ۱)، و زیپف (به تعداد واژگان متن). علاوه بر تعداد دسته‌ها، تفاوت دیگر این قوانین در نحوه دسته‌بندی موجودیت‌هاست که هریک از آنها روش خاصی را به کار می‌برند. اما در هر صورت، مبنای این تقسیم‌بندی‌ها، فراوانی است. به این صورت که باید حاصل جمع ستون فراوانی مطلق بر یک عدد تقسیم یا در یک عدد ضرب شود تا تعداد اعضای هر دسته به دست آید.

در توزیع پرتو، تعداد افراد دسته اول برابر با آن ردیفی است که مقدار فراوانی تراکمی آن برابر با حاصل جمع فراوانی مطلق، ضرب در عدد $1/n$ باشد، یعنی تعداد افراد دسته اول برابر است با شماره ردیفی که مقدار فراوانی تراکمی آن برابر با X باشد:

$$X = n / \sum_{i=1}^n f_i$$

فرمول ۲. تعیین تعداد اعضای دسته اول در توزیع پرتو

تعداد موجودیت‌های دسته دیگر برابر است با تعداد کل ردیف‌ها، منهای شماره ردیفی که مقدار فراوانی تراکمی آن برابر با X است. مثلاً اگر تعداد کل ردیف‌ها ۱۰۰ و شماره ردیفی که فراوانی تراکمی آن X است، برابر با ۲۰ باشد، تعداد افراد دسته دوم $80 = 80 \times 100 - 20$ نفر می‌شود. به عبارتی، از نظر ثروت و دارایی ۲۰ نفر اول در دسته اول و ۸۰ نفر بعدی در دسته دوم قرار می‌گیرند. البته، این توزیع در حالت‌های دیگر مانند $30 = 70 - 40$ یا $40 = 60 - 20$ (یعنی $100 - 60 = 40$) وغیره هم می‌تواند نمود پیدا کند. به هر حال، مجموع باید برابر ۱۰۰ باشد. در هریک از این حالت‌ها برای محاسبه X باید به جای $0/8$ به ترتیب، عده‌های $7/0$ ، $0/6$ وغیره را قرار داد.

در توزیع برادفورد، تعداد نشریات دسته اول برابر است با شماره ردیفی که فراوانی تراکمی آن تقریباً به اندازه حاصل جمع ستون فراوانی مطلق، ضرب در یک‌سوم باشد. یعنی تعداد نشریات دسته اول برابر است با شماره ردیفی که مقدار فراوانی تراکمی آن برابر با X باشد:

$$X = (1 \div 3) \times \text{حاصـل جـمـع سـتوـن فـراـوانـي}$$

فرمول ۳. تعیین تعداد اعضاً دسته اول در توزیع برادفورد

اگر شماره ردیفی که فراوانی تراکمی آن دو برابر X است از شماره ردیفی که فراوانی تراکمی آن برابر با X است کم شود، تعداد نشریات دسته دوم به دست می‌آید. تعداد نشریات دسته سوم برابر است با تعداد کل ردیف‌ها، منهای شماره ردیفی که مقدار فراوانی تراکمی آن برابر با $2X$ است.

در توزیع لوتكا، تعداد دسته‌ها برابر با بزرگترین عدد موجود در ستون فراوانی مطلق است. هر دسته حاوی نویسنده‌گانی است که فراوانی مقالات‌شان شبیه هم است (فقط اولین نویسنده در نظر گرفته می‌شود). به طور مثال، اگر بزرگترین عدد در ستون فراوانی مطلق ۲۰ و فراوانی مقالات فقط یک نفر 20 باشد، تعداد افراد دسته اول یک نفر خواهد بود. قاعده‌تاً باید با افزایش شماره دسته، تعداد افراد درون آن نیز به ترتیب افزایش یابد. در توزیع زیپف، عملاً تعداد دسته‌ها برابر با تعداد ردیف‌ها یا همان واژه‌های به کاررفته در متن است. از این رو، می‌توان گفت که واژه‌ها عملاً دسته‌بندی شده‌اند و نیاز به عمل خاصی برای دسته‌بندی آنها نیست.

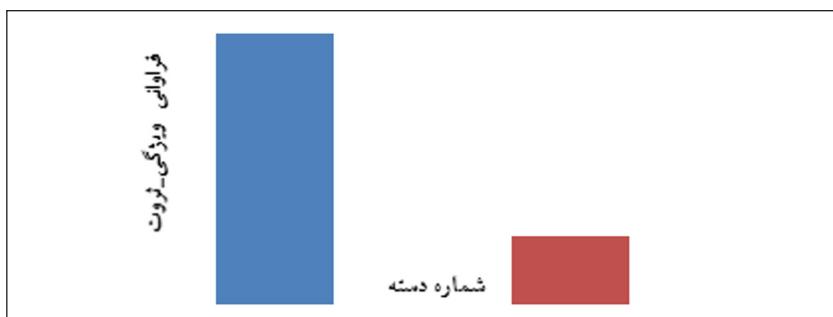
۳. نحوه دسته‌بندی

در عمل، آنچه تحت عنوان قوانین چهارگانه یاد می‌شود نحوه دسته‌بندی موجودیت‌ها

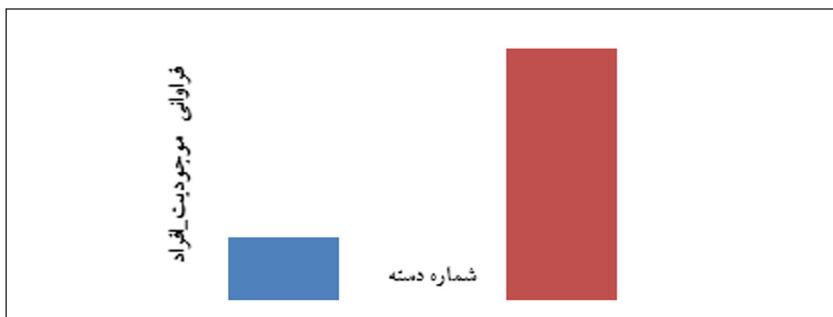
و تعیین تعداد موجودیت‌های درون هر دسته است. به عبارتی، در هر قانون گفته می‌شود که فراوانی موجودیت‌های هر دسته با دسته‌های قبل از خود چقدر تفاوت دارد. یکی از کارکردهای این قوانین این است که نشان می‌دهند تفاوت بین فراوانی دسته‌ها تابع یک توزیع مشخص است، یعنی اگر شماره دسته را در محور افقی و فراوانی موجودیت‌های هر دسته را در محور عمودی قرار بدهیم، یک توزیع ریاضی به دست خواهد آمد.

در توزیع پرتو، فراوانی تعداد موجودیت‌های دسته دوم، چهار برابر فراوانی دسته اول است. به عبارت دیگر، فراوانی ویژگی‌های دسته دوم یک‌چهارم دسته اول است، یعنی 20% درصد مردم که در دسته اول قرار می‌گیرند 80% درصد ثروت را در اختیار دارند و 80% درصد مردم که در دسته دوم قرار می‌گیرند، 20% درصد ثروت را در اختیار دارند.

نتیجه این دسته‌بندی را می‌توان به دو شکل نشان داد: (الف) فراوانی ویژگی که در نظریه پرتو همان ثروت است؛ و (ب) فراوانی موجودیت که در نظریه پرتو همان افراد جامعه است. اگر به شکل اول نمایش داده شود، مقدار دسته اول 80% درصد و مقدار دسته دوم 20% درصد کل فراوانی است (نمودار ۳). اما در شکل دوم، مقدار دسته اول 20% درصد و دسته دوم 80% درصد کل فراوانی را دربرمی‌گیرد (نمودار ۴).

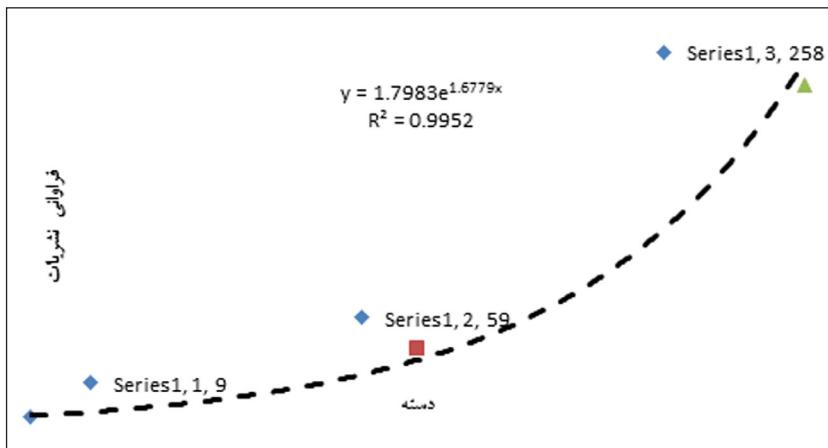


نمودار ۳. فراوانی ویژگی‌ها در قانون پرتو



نمودار ۴. فراوانی موجودیت‌ها در قانون پرتو

در توزیع برادفورد، اگر رابطه بین شماره دسته و فراوانی نشریات درون هر دسته محاسبه شود، یک توزیع نمایی حاصل می شود. براساس خاصیت توزیع نمایی برای به دست آوردن فراوانی نشریات هر دسته باید فراوانی دسته قبل از خود را در عددی ثابت ضرب کرد.



نمودار ۵. توزیع موجودیت‌ها براساس قانون برادفورد

در فرمولی که از تابع نمودار ۵ به دست آمده است، y برابر با تعداد نشریات، e همان $2/718281$ است که لگاریتم طبیعی آن 1 می شود و X شماره دسته است. اگر e را به توانی که بالای آن است برسانیم، عددی حاصل می شود که نشان می دهد فراوانی هر دسته چند برابر دسته قبل از خود است. این فرایند به توضیح ریاضی Leimkuhler¹ در سال ۱۹۶۷ شباهت دارد. قبل از آن، برادفورد این مسئله را به صورت $n:nc:nc^2$ بیان کرده بود. در این حالت، n فراوانی نشریات دسته اول و c برابر با e به توان عدد بالای آن است که در مورد نمودار ۵ این توان برابر با $1/6779$ است. از این رو، در پژوهش برادفورد برای موضوع رئوفیزیک، ضریب c برابر با $2/718281$ به توان $1/6779$ است که عددی مساوی با $5/72$ می شود.

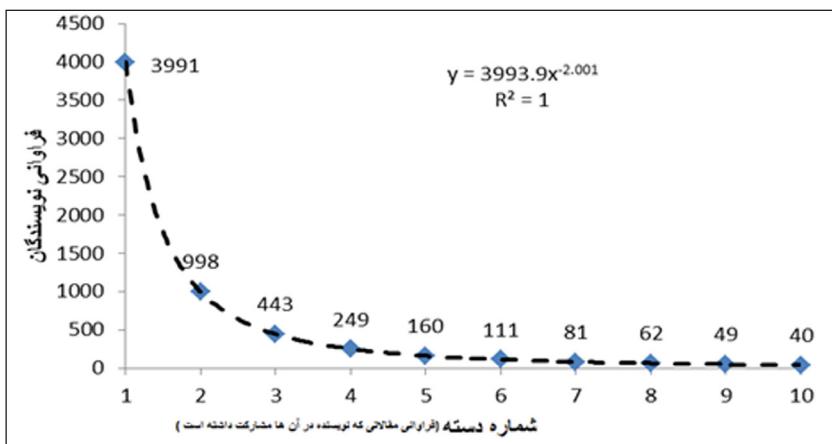
در توزیع لوتكا، شماره‌گذاری دسته‌ها از پایین به بالاست، یعنی دسته آخری شماره 1 ، ماقبل آخر 2 و به همین منوال، دسته ابتدایی آخرین شماره را می گیرد. ستون اول، همان فراوانی مطلق ویژگی در جدول اولیه (جدول ۱) و ستون دوم، تعداد موجودیت‌هایی است که آن میزان فراوانی را به خود اختصاص داده‌اند.

1. Leimkuhler

جدول ۲. توزیع فرانانی موجودیت‌ها در قانون لوتكا

| فرانانی موجودیت‌های دارای آن فرانانی | فرانانی مطلق ویژگی (شماره دسته) |
|--------------------------------------|---------------------------------|
| ۴۰ | ۱۰ |
| ۴۹ | ۹ |
| ۶۲ | ۸ |
| ۸۱ | ۷ |
| ۱۱۱ | ۶ |
| ۱۶۰ | ۵ |
| ۲۴۹ | ۴ |
| ۴۴۳ | ۳ |
| ۹۹۸ | ۲ |
| ۳۹۹۱ | ۱ |

اگر رابطه بین دو ستون در جدول ۲ را بسنجیم، یک توزیع توانی حاصل می‌شود که توان آن تقریباً برابر با ۲- است.



نمودار ۶. تابع توزیع قانون لوتكا

همان‌گونه که نمودار ۶ نشان می‌دهد، تابع توزیع لوتكا یک تابع توانی است که در آن y فرانانی نویسنده و x شماره دسته است. شماره هر دسته نشانگر تعداد مدارکی است که هریک از نویسنده‌گان آن دسته نوشته‌اند. به طور مثال، به طور مثال، ۳۹۹۱ نویسنده از مجموع کل

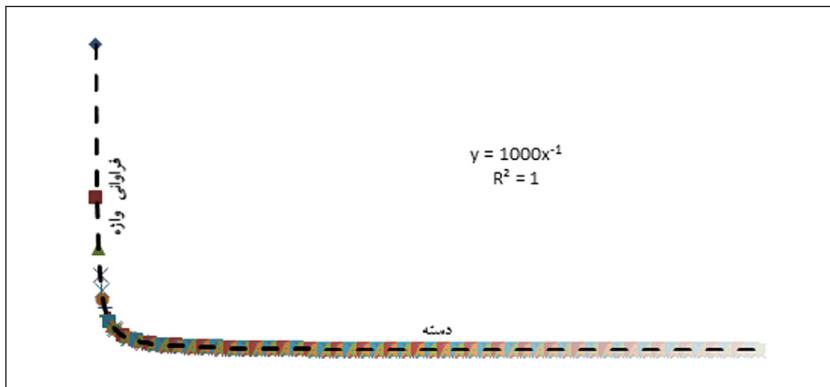
نویسنده‌گان فقط در نوشتمن یک مدرک مشارکت داشته‌اند. به عبارتی، فراوانی نویسنده‌گان هر دسته برابر با شماره آن دسته به توان ۲- است. اگر بخواهیم این توزیع را به زبان برادرافورد بیان کنیم، به این صورت خواهد شد:

$$n1^2 : n2^2 : n3^2 : n4^2 : n5^2 : n6^2 : n7^2 : n8^2 : n9^2 : n10^2$$

فرمول ۴. توزیع لوتكا طبق حالت بیان شده در توزیع برادرافورد

برای تعمیم این نکته می‌توان گفت که فراوانی نویسنده‌گان هر دسته در توزیع لوتكا برابر با nc^p است که در آن n تعداد افراد دسته اول، C شماره دسته، و p توان ثابت است که در این توزیع برابر با $2-p$ می‌شود.

در توزیع زیپف، عملاً برای دسته‌بندی کاری انجام نمی‌شود و اساس، همان جدول اولیه (مانند جدول ۲) است. به همین دلیل، توزیعات سه‌گانه بالا را عملاً شکل تغییریافته‌ای از زیپف می‌دانند، یعنی در همه آنها باید ابتدا زیپف هر موجودیت را از نظر فراوانی از زیاد به کم تنظیم کرد. در این صورت، توزیعی شبیه توزیع توانی حاصل خواهد شد. از آنجا که توزیع زیپف ابتدا برای توزیع فراوانی واژگان یک متن در زبان انگلیسی ارائه شد، آن را می‌توان توزیع فراوانی واژه‌های یک متن دانست. توان این توزیع برای زبان انگلیسی ۱- برآورده شده است.



نمودار ۷. توزیع فراوانی واژه‌های یک متن براساس توزیع زیپف

در نمودار ۷ تعداد واژه‌ها ۵۹۴ مورد فرض شده است که همان تعداد واژگان تشکیل‌دهنده یک متن فرضی است. در ادبیات مربوط به توزیع زیپف به جای اصطلاح دسته،

از واژه "رتبه" استفاده می‌شود. در تابع این نمودار y فراوانی واژه و x رتبه آن واژه از نظر فراوانی است. از این رو، می‌توان توزیع زیپف را به صورت n^{-c} ^۱ بیان کرد. n فراوانی واژه‌ای است که دارای بیشترین فراوانی و c رتبه واژه است. با توجه به اینکه توان -1 است، می‌توان به طور ساده‌تر گفت که توزیع زیپف برابر با n^{-c} است؛ زیرا می‌توان توزیع توانی منفی را به این صورت محاسبه کرد:

$$f = \frac{n}{c^p}$$

در این فرمول، منظور از p همان توان تابع است که چون در مخرج قرار گرفته، علامت آن مثبت شده است.

۴. تعمیم‌پذیری

علم اطلاعات پراز توزیع‌هایی است که "توانی" خوانده می‌شوند، مانند بهره‌وری پدیدآورندگان، دریافت استناد توسط مقالات، توزیع ادبیات علمی، و همکاری در نویسنده‌گی. این موارد جزوی از توزیع‌های تجربی هستند که توزیع توانی دارند (Milojević^۱, ۲۰۱۰). مدت زیادی است که توزیع‌های توانی و نمایی در حوزه‌های دیگر مانند اقتصاد، زیست‌شناسی، و علوم رایانه راه یافته‌اند (Mitzenmacher, ۲۰۰۴). بر این اساس، یکی دیگر از کارکردهای قوانین چهارگانه در این است که می‌توان آنها را به موجودیت‌ها و ویژگی‌های مختلف تعمیم داد. گرچه این قوانین بر اثر مطالعه فراوانی موجودیت‌های خاصی از نظر یک ویژگی کشف شده‌اند، این توانایی را دارند تا موجودیت‌های دیگر را براساس توزیع فراوانی در یک ویژگی خاص دسته‌بندی کنند. موجودیتی که پرتو نخستین بار مورد توجه قرار داد، افراد جامعه در ایتالیا بود که از نظر ویژگی ثروت به دسته‌بندی آنها پرداخت. برادر فوردنشریات را از نظر تعداد مقالات مرتبط به یک موضوع بررسی و آنها را به سه دسته تقسیم کرد. لو تکانویسنده‌گان را از نظر ویژگی تعداد مقاله و مدارکی که نوشته‌اند دسته‌بندی کرد. زیپف به واژه‌های یک متن از نظر دفعات تکرار در متن پرداخت. با توجه به ویژگی تعمیم‌پذیری، بسیاری از موجودیت‌های دیگر را می‌توان براساس توزیع پرتو دسته‌بندی کرد. به طور مثال، مجموعه کتاب‌های یک کتابخانه را از نظر میزان امانت می‌توان به دو دسته تقسیم کرد: دسته اول متشکل از ۲۰ درصد کتاب‌های است که توسط ۸۰ درصد مراجعت به امانت رفته‌اند و دسته دوم را ۸۰ درصد بقیه کتاب‌های را تشکیل می‌دهند که توسط ۲۰ درصد اعضا به امانت رفته‌اند. به همین ترتیب، می‌توان ویگاه‌های را از لحاظ تعداد بازدید و مقالات یک حوزه را از نظر استناد شدن به دو دسته تقسیم کرد. نمونه‌های بیشتری نیز می‌توانیم در اطراف خودمان ببینیم که این توزیع را می‌توان به آنها تعمیم داد. بسیاری از

1. Milojević
2. Mitzenmacher

موجودیت‌های دیگر را می‌توان براساس توزیع‌های دیگر دسته‌بندی کرد. گام اول در این مطالعات، انتخاب یک موجودیت برای مطالعه و تعیین فراوانی یک ویژگی در آنهاست. سپس می‌توان همانند آنچه کاشفان این قولانی انجام داده‌اند و شرح آن در بالا آمد، عمل کرد.

نتیجه گیری

در این پژوهش، تصویری کلی از قولانی تجربی معروف در علم سنجی بر مبنای قاعده توانی ارائه شد. نتایج پژوهش نشان می‌دهد که شکل اولیه داده‌ها در این چهار توزیع، حاوی رتبه هر موجودیت، فراوانی ویژگی مورد مطالعه، و مقدار فراوانی مطلق آن ویژگی در آن موجودیت است. نتایج مرتبط با نحوه دسته‌بندی موجودیت‌ها و تعیین تعداد موجودیت‌های درون هر دسته حاکی از آن است که تفاوت بین فراوانی دسته‌ها تابع یک توزیع مشخص است. ویژگی تعمیم‌پذیری این قولانی، راه را برای مطالعات بیشتر به منظور دسته‌بندی موجودیت‌های براساس توزیع فراوانی باز می‌کند. این نوع مطالعات، عملاً با تطبیق توزیع فراوانی یک موجودیت براساس یک ویژگی خاص می‌کوشند تا امکان دسته‌بندی موجودیت‌های مورد مطالعه را با رویکردهای به کار رفته در این قولانی بررسی کنند. به عبارتی، می‌خواهند دریابند که آیا توزیع موجودیت مورد مطالعه بر یافته‌های به کار رفته در قولانی تجربی کتاب سنجی منطبق است یا خیر، و یا چقدر نزدیک است.

در فرایند تطبیق باید به چند نکته توجه کرد: اول اینکه ممکن است تعداد دسته‌ها براساس یکی از این قولانی باشد؛ اما فاصله بین فراوانی دسته‌ها از توزیع مورد نظر تبعیت نکند. مثلًا ممکن است بتوان نویسنده‌گان را از نظر ویژگی فراوانی دریافت استناد به سه دسته تقسیم کرد که فراوانی تعداد استنادهای دریافتی هر دسته، همانند توزیع برادرفورد، یک‌سوم کل استنادهای دریافتی باشد؛ اما توزیع تعداد نویسنده‌گان در این دسته‌ها به صورت نمایی نباشد و از توزیع توانی پیروی کند. حتی ممکن است بتوان تعداد دسته‌ها را در توزیع برادرفورد افزایش داد. در مواردی حتی ممکن است بتوان دسته‌بندی را براساس بیش از یک توزیع انجام داد، مثلًا یک توزیع همزمان بر دو توزیع برادرفورد و زیپف منطبق باشد. این حالت از آنجا پیش می‌آید که در اساس، توزیع فراوانی ویژگی‌های یک موجودیت تا حدودی از یک توزیع توانی پیروی می‌کند. نتایج حاصل همگام با نتایج ویلسون (Wilson) در ARIST (1999) است که به موضوع اطلاع‌سنجی پرداخته و نشان داده است که بین سه قانون زیپف، لوتكا، و برادرفورد ارتباط وجود دارد.

ماخذ

- Ausloos, M. (2014). Zipf–Mandelbrot–Pareto model for co-authorship popularity. *Scientometrics*, 101 (3), 1565–1586.
- Axtell, R. L. (2001). Zipf distribution of US firm sizes. *Science*, 293 (5536), 1818–1820.
- Bradford, S. C. (1934). Sources of information on specific subjects. *Engineering: an Illustrated Weekly Journal (London)*, 137 (3550), 85–86.
- Bradford, S. C. (1985) Sources of information on specific subjects. *Journal of Information Science*, 10 (4), 173–180
- Broadus, R. N. (1987). Toward a definition of ‘bibliometrics’. *Scientometrics*, 12 (5–6), 373–379.
- Clauset, A., Shalizi, C. R., & Newman, M. E. (2009). Power-law distributions in empirical data. *SIAM Review*, 51 (4), 661–703.
- Drott, M. C. (1981). Bradford’s Law: Theory, empiricism and the gaps between. *Library Trends*, 30 (1), 41–52.
- Franceschet, M. (2008). Frozen footprints. *arXiv preprint arXiv:0811.4603*. Retrieved Sep. 05, 2015, from <http://arxiv.org/abs/0811.4603>
- Gelbukh, A., & Sidorov, G. (2001). Zipf and Heaps Laws’ coefficients depend on language. *Computational Linguistics and Intelligent Text Processing*. Berlin Heidelberg: Springer.
- Harremoës, P., & Topsøe, F. (2005). Zipf’s law, hyperbolic distributions and entropy loss. *Electronic Notes in Discrete Mathematics*, 21 (1), 315–318.
- Hertzel, D. H. (1987). History of the development of ideas in bibliometrics. Kent, A. (Ed.), *Encyclopedia of library and information sciences* (Vol. 42, pp. 144–219). New York: Marcel Dekker.
- Hood, W. W., & Wilson, C. S. (2001). The literature of bibliometrics, scientometrics, and informetrics. *Scientometrics*, 52 (2), 291–314.
- Leimkuhler, F. F. (1967). The Bradford distribution. *Journal of documentation*, 23 (3), 197–207.
- Lotka, A. J. (1926). The frequency distribution of scientific productivity. *Journal of the Washington Academy of Sciences*, 16 (12), 317–323.

- Malacarne, L. C., Mendes, R. S., & Lenzi, E. K. (2002). Q-exponential distribution in urban agglomeration. *Physical Review*, 65(1), 17-26.
- Mayr, P. (2013). Relevance distributions across Bradford Zones: Can Bradfordizing improve search? Retrieved Nov. 14, 2015, from <http://arxiv.org/abs/1305.0357>
- Milojević, S. (2010). Power law distributions in information science: Making the case for logarithmic binning. *Journal of the American Society for Information Science and Technology*, 61 (12), 2417-2425.
- Mitzenmacher, M. (2004). A brief history of generative models for power law and lognormal distributions. *Internet Mathematics*, 1 (2), 226-251.
- Newman, M. E. (2005). Power laws, Pareto distributions and Zipf's law. *Contemporary Physics*, 46 (5), 323-351.
- O'Connor, D. O., & Voos, H. (1981). Empirical laws, theory construction and bibliometrics. *Library Trends*, 30 (1), 9-20.
- Pareto, V. (1964). *Cours d'Économie Politique*: Nouvelle édition par G.-H. Bousquet et G. Busino. Geneve: Librairie Droz.
- Pritchard, A. (1969). Statistical bibliography or bibliometrics? *Journal of Documentation*, 25 (4), 348-349.
- Van Raan, A. F. (2001). Two-step competition process leads to quasi power-law income distributions: Application to scientific publication and citation distributions. *Physica A: Statistical Mechanics and its Applications*, 298 (3), 530-536.
- Wilson, C. S. (1999). *Informetrics. Annual Review of Information Science and Technology (ARIST)*, 34 (1), 107-247.
- Zipf, G. K. (1932). *Selected studies of the principle of relative frequency in language*. Cambridge (Mass): Harvard University Press.

استناد به این مقاله:

توکلیزاده راوری، محمد؛ سهیلی، فرامرز (۱۳۹۵). ویژگی‌های مشترک قوانین تجربی معروف در علم سنجی: نگاهی از زاویه دسته‌بندی داده‌ها براساس توزیع فراوانی. *مطالعات ملی کتابداری و سازماندهی اطلاعات*، ۲۷ (۱)، ۲۵-۴۲.