

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

روز طهارت است و آن را غمی از آن
توبه بسیار است و اگر روز

۱۳۸۰ / ۹ / ۱۵

وزارت اطلاعات و امور علمی ایران
تیم ملی ایران

دانشگاه تربیت معلم

دانشکده علوم ریاضی و مهندسی کامپیوتر

پایان نامه کارشناسی ارشد

رشته آمار

عنوان:

محاسبه ماکسیمم آنترופی دیریکله

برای طرح ریزی داده‌ها

استاد راهنما:

014722

دکتر عین‌الله پاشا

نگارش:

نعمت مؤذن

مهر ۱۳۸۰

۳۷۹۷۵

بسمه تعالی

آگهی دفاع از پایان‌نامه کارشناسی ارشد آمار

عنوان:

محاسبه ماکسیمم آنترופی دیریکله برای طرح ریزی داده‌ها

استاد راهنما : آقای دکتر عین‌اله پاشا
داور خارجی : آقای دکتر غلامرضا محتشمی
داور داخلی : آقای دکتر علی‌اکبر رحیم‌زاده
دانشجو : آقای نعمت مؤذن
زمان : ساعت ۱۰ صبح روز شنبه مورخ ۸۰/۷/۱۴
مکان : دانشکده علوم ریاضی و مهندسی کامپیوتر دانشگاه تربیت معلم

خلاصه: اطلاع لگاریتمی که توسط شانون (۱۹۴۸) تعریف شد، کاربردهای زیادی در بخش‌های مختلف آمار پیدا کرده است. از جمله روش تشخیص توزیع نامعلوم مولد داده‌ها می‌باشد.

در این پایان‌نامه ابتدا به تعریف و بررسی بعضی خواص توابع اطلاع از قبیل آنترופی، چگالی آنترופی ماکسیمم، اطلاع، تمییز، قابلیت تمییز پذیری اطلاع (ID) و اطلاع متقابل می‌پردازیم. سپس مشخصه آنترופی ماکسیمم از خانواده پارامتری را با طرح پیشین دیریکله برای توزیع نامعلوم مولد داده‌ها ترکیب می‌کنیم که آن را روش آنترופی ماکسیمم دیریکله (MED) می‌نامیم. روش یافتن توزیع‌های پیشین و پسین MED برای آنترופی توزیع نامعلوم، پارامترهای گشتاورهای مدل تحت فرض، آنترופی مدل ME و شاخص ID با استفاده از شبیه‌سازی «مونت کارلو» برای تشخیص توزیع نامعلوم مولد داده‌ها، از مباحثی هستند که در این پایان‌نامه بررسی می‌شوند.

در این پایان‌نامه مقالات زیر مورد استفاده اصلی می‌باشد.

1. Soofi, E.S., N. Ebrahimi and M. Habibullah (1995), "Information Distinguishability with Application to Analysis of Failur Data", Journal of the American Statistical Association, 90, 657-668.
2. Mazzuchi, T. A., Soofi, E.S. and Soyer, R. (2000) "Computation of Maximum Entropy Dirichlet for Modeling Lifetime Data". Computational Statistics and Data Analysis, 32, 361-378.



تعالی

دانشکده علوم ریاضی و مهندسی کامپیوتر

تاریخ

شماره

پوست

واحد

صورتجلسه دفاع از پایان نامه کارشناسی ارشد

جلسه دفاع از پایان نامه آقای نعمت مؤذن دانشجوی دوره کارشناسی ارشد رشته ریاضی شاخه
آمار تحت عنوان:

محاسبه ماکسیم آنترپی دیریکله برای طرح ریزی داده‌ها

در روز شنبه مورخه ۸۵/۷/۱۴ در دانشکده علوم ریاضی و مهندسی کامپیوتر تشکیل گردید و نتیجه
آزمون به شرح زیر تعیین می‌گردد. نمره این آزمون ۱۸٫۵ (هجده و پنجم) می‌باشد.

- ۱- عالی
- ۲- بسیار خوب
- ۳- خوب
- ۴- قابل قبول
- ۵- غیر قابل قبول

داور داخلی
دکتر علی اکبر رحیم زاده

داور خارجی
دکتر غلامرضا محسنی

استاد راهنما
دکتر عین اله پارسا

اسماعیل بابلیان
رئیس دانشکده علوم ریاضی و
مهندسی کامپیوتر

تقدیم به :

تقدیم به مادر عزیز و مهربانم
که در تمام مراحل تحصیل مشوق من بوده است.
تقدیم به برادران و خواهران بزرگوارم
که زحمات زیادی را در طول نگارش پایان نامه
به همراه همسران گرامیشان متحمل شدند.

تقدیر و سپاس

لازم است در اینجا از همه کسانی که در تدوین این پایان نامه مرا یاری نمودند سپاسگزاری کنم. از استاد گرانقدرم جناب آقای دکتر پاشا که تدوین این پایان نامه با راهنمایی های ایشان صورت گرفت تشکر و قدردانی می نمایم. همچنین از اساتید محترم جناب آقای دکتر رحیم زاده و جناب آقای دکتر محتشمی که قبول زحمت نموده و داوری این رساله را به عهده گرفتند کمال تشکر را دارم. در پایان از دوستان کارشناسی ارشد نیز بخاطر همراهیشان در این تحقیق نهایت قدردانی را می نمایم.

چکیده

اطلاع لگاریتمی که توسط شانون (۱۹۴۸) تعریف شد، کاربردهای زیادی در بخش‌های مختلف آمار پیدا کرده است. از جمله روش تشخیص توزیع نامعلوم مولد داده‌ها می‌باشد.

در این پایان‌نامه ابتدا به تعریف و بررسی بعضی خواص توزیع اطلاع از قبیل آنتروپی، چگالی آنتروپی ماکسیمم، اطلاع تمیز، قابلیت تمیز پذیری اضلاع (ID) و اطلاع متقابل می‌پردازیم. سپس مشخصه آنتروپی ماکسیمم از خانواده پارامتری را با طرح پیشین دیریکله برای توزیع نامعلوم مولد داده‌ها ترکیب می‌کنیم که آن را روش آنتروپی ماکسیمم دیریکله (MED) می‌نامیم. روش یافتن توزیع‌های پیشین و پسین MED برای آنتروپی توزیع نامعلوم، پارامترهای گشتاوری مدل تحت فرض، آنتروپی مدل ME و شاخص ID با استفاده از شبیه سازی «مونت کارلو» برای تشخیص توزیع نامعلوم مولد داده‌ها، از مباحثی هستند که در این پایان‌نامه بررسی می‌شوند.

در این پایان‌نامه مقالات زیر مورد استفاده اصلی می‌باشد.

1. Soofi, E.S. , N. Ebrahimi and M. Habibullah (1995), "Information Distinguishability with Application to Analysis of Failure Data", Journal of the American Statistical Association , 90, 657-668.
2. Mazzuchi, T. A, Soofi, E. S. and Soyer, R.(2000) " Computation of Maximum Entropy Dirichlet for Modeling Lifetime Data", Computational Statistics and Data Analysis, 32, 361-378.

فهرست

| صفحه | عنوان |
|------|---------------------------------------|
| ح | پیشگفتار |
| ۱ | مقدمه و تاریخچه |
| ۵ | فصل اول: تعاریف و مقدمات آنروپی |
| ۵ | (۱.۱) آنروپی طرحهای منتهای، عدم حتمیت |
| ۱۰ | (۲.۱) ارتباط آنروپی و اطلاع |
| ۱۰ | ۱.۲.۱. شرح ارتباط آنروپی و اطلاع |
| ۱۲ | ۲.۲.۱. قضیه یکتایی |
| ۱۷ | ۳.۲.۱. آنروپی زنجیر مارکف |
| ۱۹ | (۳.۱) آنروپی شرطی و اطلاع متقابل |
| ۱۹ | ۱.۳.۱. آنروپی شرطی |
| ۲۱ | ۲.۳.۱. نتیجه های مهم |
| ۲۴ | ۳.۳.۱. اطلاع متقابل |
| ۲۵ | ۴.۳.۱. چند تعمیم |
| ۲۷ | ۵.۳.۱. جمع بندی مفاهیم |
| ۲۸ | (۴.۱) آنروپی متغیرهای تصادفی |
| ۲۸ | ۱.۴.۱. تعاریف |
| ۳۰ | ۲.۴.۱. آنروپی به عنوان امید ریاضی |
| ۳۱ | ۳.۴.۱. آنروپی توأم |

| | |
|----|--|
| ۳۱ | ۴.۴.۱. آنتروپی شرطی |
| ۳۱ | ۵.۴.۱. اطلاع متقابل |
| ۳۲ | ۶.۴.۱. برخی خواص آنتروپی |
| ۳۴ | ۷.۴.۱. چند تعمیم |
| ۳۵ | ۸.۴.۱. آنتروپی تبدیل متغیرهای تصادفی |
| ۳۸ | فصل دوم: روش آنتروپی ماکسیمم و توابع توزیع دیریکله |
| ۳۸ | (۱.۲) معرفی روش آنتروپی ماکسیمم |
| ۳۸ | ۱.۱.۲. مقدمه |
| ۳۹ | ۲.۱.۲. بیان روش |
| ۴۰ | ۳.۱.۲. قیدهایی به صورت امید ریاضی |
| ۴۰ | ۳.۱.۲. الف - متغیرهای تصادفی پیوسته |
| ۴۲ | ۳.۱.۲. ب - متغیرهای تصادفی گسسته |
| ۴۴ | (۲.۲) طرح دیریکله |
| ۴۴ | ۱.۲.۲. مقدمه |
| ۴۴ | ۲.۲.۲. توزیع دیریکله |
| ۴۶ | ۳.۲.۲. کاربردها |
| ۴۷ | ۳.۲.۲. الف - برآورد یک تابع توزیع |
| ۵۰ | فصل سوم: توابع اطلاع تمیز و خواص آنها |
| ۵۰ | (۱.۳) مقدمه |
| ۵۳ | (۲.۳) تمیز پذیری اطلاع |
| ۶۰ | (۳.۳) تشخیص آماره ها از روی خانواده‌های پارامتری |

| | | |
|----|-------|---|
| ۶۰ | | ۱.۳.۳. مقدمه |
| ۶۰ | | ۲.۳.۳. قابلیت تمییز پذیری ID نسبت به نرمال بودن |
| ۶۲ | | ۳.۳.۳. قابلیت تمییز پذیری ID نسبت به نمایی بودن |
| ۶۳ | | (۴.۳) آماره ID |
| ۶۷ | | (۵.۳) اطلاع تمییز و اطلاع متقابل |
| ۷۰ | | فصل چهارم: محاسبه ماکسیمم آنتروپی دیریکله برای طرح ریزی داده‌ها |
| ۷۰ | | (۱.۴) مقدمه |
| ۷۳ | | (۲.۴) پیشین MED و آنتروپی کمی شده |
| ۷۶ | | (۳.۴) الگوریتم محاسبه |
| ۸۴ | | (۴.۴) معرفی روش مونت کارلو |
| ۸۶ | | (۵.۴) جمع بندی نتایج |
| ۸۸ | | ضمائم |
| ۸۹ | | واژه نامه فارسی - انگلیسی |
| ۹۴ | | واژه نامه انگلیسی - فارسی |
| ۹۸ | | اسامی اشخاص |
| ۹۹ | | کتابنامه |

بیشگفتار

هدف این تحقیق ارائه روشی بر پایه آنتروپی برای استنتاج بیزی در مورد اینکه یک توزیع پارامتری به عنوان یک مدل برای داده‌ها مناسب است یا خیر، می‌باشد. در زیر مروری اجمالی بر مباحث بررسی شده در این پایان نامه خواهیم داشت.

فصل اول: تعاریف و مقدمات آنتروپی

در این فصل ابتدا در بخش اول طرح متناهی و عدم حتمیت آن را تعریف کرده و سپس ارتباط میان آنتروپی و اطلاع را در بخش دوم شرح می‌دهیم. با استفاده از یک قضیه مهم اندازه‌ای برای عدم حتمیت به دست می‌آوریم این اندازه در واقع همان اندازه‌ای است که شانون (۱۹۴۸) نخستین بار معرفی نمود. در بخش سوم آنتروپی شرطی و اطلاع متقابل روی طرحها یا فضاهای متناهی بحث می‌شود. بخش چهارم نیز به آنتروپی متغیرهای تصادفی گسسته و پیوسته اختصاص یافته است که در آن با استفاده از قضایا، برخی خواص آنتروپی مورد بحث و بررسی قرار گرفته است.

فصل دوم: روش آنتروپی ماکسیمم و توابع توزیع دیریکله

در بخش نخست این فصل ابتدا به معرفی روش آنتروپی ماکسیمم می‌پردازیم. سپس قضیه تابع چگالی ماکسیمم آنتروپی را با قیود گشتاوری داده شده بیان و اثبات می‌نماییم. در انتها جدول توابع چگالی آنتروپی ماکسیمم با قیود معلوم ارائه می‌شود. در بخش دوم به معرفی توابع توزیع دیریکله که در این پایان نامه استفاده شده است می‌پردازیم آنگاه به کاربرد آن در تعیین برآورد توزیع پیشین برای فرم‌های نامعلوم توابع توزیع خواهیم پرداخت.

فصل سوم: توابع اطلاع تمییز و خواص آنها

این فصل با هدف اندازه گیری تفاوت‌های کلی توزیع‌ها، روی تابع اطلاع «کالیک-لیبلر» بنا شده است. در بخش نخست به توضیح مقدمات استفاده از چگالی آنروپی ماکسیمم در توابع اطلاع توسط محققان مختلف می‌پردازیم. در بخش بعدی برای مقایسه توزیع‌ها در Ω_0 ، اختلاف اطلاع بین دو چگالی f (نامعلوم) و f^* (آنروپی ماکسیمم) مورد بررسی قرار گرفته است. تابع اطلاع کالیک - لیبلر به عنوان معروف‌ترین اندازه اطلاع نظری اختلاف بین توزیع‌ها شرح داده شده است. نامنفی بودن، جمع پذیری برای متغیرهای تصادفی مستقل از خواص این تابع می‌باشد. سپس شاخص ID توزیع‌ها، با استفاده از تابع اطلاع «کالیک-لیبلر» تعریف می‌شود که قابلیت تبعیص پذیری اطلاع را بیان می‌نماید و یک اندازه نرمال شده می‌باشد. به دست آوردن شاخص ID متناسب با حالت‌های نرمال و نمایی از دیگر قسمت‌های این بخش است. در بخش چهارم با معرفی آماره ID، برآورد MLE این شاخص ارائه می‌شود. در بخش آخر نیز ارتباط بین اطلاع تمییز و اطلاع متقابل بیان می‌شود.

فصل چهارم: محاسبه ماکسیمم آنروپی دیریکله برای طرح ریزی داده‌ها

در ابتدا کلاس گشتاوری مورد نظر و چگالی f^* در این کلاس معرفی شده سپس توابع اطلاع مورد نظر تعریف می‌شوند. در بخش دوم آنروپی کمی شده یک توزیع پیوسه f با افزایش نمودن خط حقیقی تعریف می‌شود. افزاز مفیدی با استفاده از سنگفرش‌های دیریکله ساخته می‌شود. برای تعیین توزیع F نامعلوم از یک طرح پیشین دیریکله استفاده می‌نماییم که یک توزیع کمی شده برای F به دست می‌آید. با استفاده از این توزیع، برآوردی برای آنروپی محاسبه می‌شود. در بخش سوم، آنروپی کمی شده، پارامترهای گشتاوری، مدل پارامتری و شاخص اطلاع ID با استفاده از پیشین دیریکله، برآورد شده و توزیع پیشین و پسین آنها با استفاده از یک الگوریتم شبیه‌سازی «مونت کارلو» به دست می‌آید.

مقدمه و تاریخچه

نظریه اطلاع برای اولین بار در سالهای ۴۸-۱۹۴۷ توسط "کلود شانون" مطرح شد. این نظریه در آغاز با بسیاری از مسائل ریاضی دشوار روبرو بود. طبیعی بود که شانون و اولین قوانینش که تمام هدف آنها محاسبه نتایج سودمند بود، نمی توانست دقت کافی برای این مسائل مشکل ریاضی ارائه کند.

در نتیجه در بسیاری از این تحقیقات، دانشمندان به منظور سهولت اثباتها، مجبور می شدند با استدلال از یک ماهیت غیرطبیعی یا مجموعه ای از موضوعات به طور مصنوعی (مانند، منابع، کانالها، کدها و غیره) استفاده کنند. بخش عمده ادبیات اولین سالهای نظریه اطلاع بناچار به محاسبات ناقص ریاضی که مخصوصاً آنرا برای ریاضی دانان بی نهایت مشکل می کرد، اختصاص یافت.

بعد یک کتاب درسی از نظریه اطلاع توسط "اس. گلدمن" منتشر شد که مثالهای رایجی را در آن بکاربرد. سپس مقالات زیادی نوشته شد که پایه های ریاضی و محاسباتی نظریه اطلاع را بنا نهادند. به عنوان اولین کارها باید از کار "مک میلان" نام برد که نظریه مفهومات اساسی منابع گسسته (منبع، کانال، کدو غیره) را به عنوان اولین تعاریف دقیق ریاضی بکار برد. مهمترین نتیجه این کار برای اثبات قضیه مشهور، باید بکار گرفته می شد که در آن هر منبع آرگودیک گسسته، ویژگی را که شانون به منابع نوع مارکف نسبت می داد دارا بود که این تقریباً همه محاسبات مجانبی نظریه اطلاع را ارائه می داد. این وضع به تمام قسمتهای نظریه اطلاع گسسته اجازه می داد که بدون محدودیت، همانند نظریه شانون، به منابع نوع مارکف ساخته شوند. "مک میلان" در ادامه مقاله اش سعی نمود قضیه اساسی شانون را روی کانالهای بانوفه روی اصل دقیقی پایه ریزی کند که در انجام آن معلوم شد که اثبات خلاصه وار که توسط

شانون داده شده بود دارای وقفه و نقص زیادی است که حتی در حالت منابع مارکف هنوز باقی مانده بود.

سپس لازم است که به کار " فین اشتین " توجه شود که او مثل " مک میلان " فرض کرد که قضیه شانون روی کانالهای بانوفه، متتهای نظریه کلی اطلاع گسسته باشد و متعهد به دادن اثباتی دقیق از این نظریه شد.

با پذیرفتن عملیات ریاضی " مک میلان " با اجتناب از پیروی مسیر اصلی شانون، اثباتی را بنا نهاد که در آن از یک عقیده، نتیجه بخش کاملاً جدید آشکار تحت عنوان " مجموعه قابل تمییز از دنباله ها " استفاده نمود.

هر چند " فین اشتین " اثبات آنرا برای مسائل و مسائلی که دارای بار عملی کمتری بودند بکار برد، که در آن سیگنالهای پی در پی منبع دویبدو مستقل هستند و حافظه کانال نیز صفر می باشد. در حالت کلی تر، فقط به طور خلاصه نشان داد که چگونه می توان استدلال لازم را برای مستقل بودن انجام داد. متأسفانه از لحاظ معنایی مشکلات زیادی باقی ماند.

کالیک و لیبیلر (۱۹۵۱) اندازه فاصله بین دو چگالی مختلف را تعریف نمودند که نزدیکی و اطلاع تمییز دو چگالی را نشان می داد. این تابع آنتروپی یک چگالی نسبت به چگالی دیگر نیز می باشد.

جینس (۱۹۵۷) اصل آنتروپی ماکسیمم را بیان نمود. این اصل چگالی آنتروپی ماکسیمم را با قیود گشتاوری داده شده مشخص می کرد و به کاربردهای زیادی در علوم و زمینه های مختلف از جمله مکانیک آماری، نجوم، هواشناسی، اقتصاد، جغرافیا، تجارت بین المللی، بانکداری، توزیع جمعیتی، پزشکی و غیره دست یافت.

کالیک (۱۹۵۹) تابع اطلاع تمییز بین دو چگالی را با استفاده از اصل آنتروپی ماکسیمم بیان نمود که نزدیکی چگالی نامعلوم و چگالی آنتروپی ماکسیمم را نشان می دهد این پایان نامه براساس تابع اطلاع کالیک لیبیلر (۱۹۵۹) بنا شده است و هدف آن تشریح توابع اطلاع و ارائه

روش‌های برای برآورد آنتروپی، توابع اطلاع، پارامترهای مدل و توزیع‌های پیشین و پسین آنها با بکارگیری «ماکسیمم آنتروپی دیریکله» می‌باشد.