

مجله علوم آماری، بهار و تابستان ۱۳۹۳

جلد ۸، شماره ۱، ص ۱۱۱-۱۲۷

ویژگی‌های توزیع آماری برای زوایای دوستحی

آناهیتا نودهی، موسی گل‌علی‌زاده

گروه آمار، دانشگاه تربیت مدرس

تاریخ دریافت: ۱۳۹۲/۸/۱۹ تاریخ آخرین بازنگری: ۱۳۹۳/۴/۲۵

چکیده: مدل کسینوسی توزیع ون میسر دو متغیره، که تا حدودی رفتاری مشابه توزیع نرمال دو متغیره دارد، برای نمایش تغییرات احتمالاتی توان زوایای دوستحی پیشنهاد شده است. از ویژگی‌های بارز این توزیع داشتن چگالی شرطی ون میسر یک متغیره است. اما توزیع حاسیه‌ای آن بسته به پaramترهای درگیر مسئله صورت‌های متفاوتی به خود می‌گیرد و به طور کلی شکل بسته‌ای ندارد. این موضوع استنباط آماری راجع به پaramترهای توزیع را با مشکلات خاصی همراه می‌کند. در مقاله حاضر توزیع مورد اشاره و ویژگی‌های آماری آن مطالعه و سپس نحوه نمونه‌گیری از آن با الگوریتم رد و پذیرش تشریح می‌شود. به دلیل محدودیت دوره‌ای بودن توان زوایای دوستحی، مشکلات مربوط به انتخاب توزیع‌های کاندید مناسب مطرح و از ویژگی‌های چگالی شرطی آن برای رفع این معضل بهره‌گرفته می‌شود.

واژه‌های کلیدی: آمار دایره‌ای، توزیع ون میسر، زوایای دوستحی، چنبره، الگوریتم رد-پذیرش

۱ مقدمه

از جمله کاربردهای آمار در سایر علوم، استفاده از اطلاعات و منابع موجود برای مدل‌بندی و تحلیل نتایج است. فرض اساسی بسیاری از روش‌های آماری که برای مدل‌بندی داده‌ها و پیش‌بینی نتایج حاصل از آن مورد استفاده قرار می‌گیرد این است که داده‌های مورد مطالعه متعلق به فضای اقلیدسی‌اند. توانایی پیشر در عصر جدید او را قادر به اخذ داده‌هایی کرده است که ماهیتی ناآقلیدسی دارند. جهت‌ها مثالی از داده‌های ناآقلیدسی هستند. یک مجموعه از چنین مشاهداتی که با لحاظ نمودن جهت‌شان مشخص می‌شوند را داده‌های سویی^۱ می‌نامند. ویژگی اصلی این گونه داده‌ها داشتن دور یا جهت خاص است. مشاهداتی که از این نوع متغیرها ناشی می‌شوند در علومی مانند زیست‌شناسی، زمین‌شناسی، جغرافیا و ... به وفور دیده می‌شوند (ماردیا، ۱۹۷۵). به نظر می‌رسد به کارگیری نتایج مفاهیم موجود در فضای اقلیدسی برای این داده‌ها نتایج صحیحی به همراه نداشته باشد.

یکی از زیر شاخه‌های مهم آمار سویی آمار دایره‌ای^۲ است که در چند دهه اخیر بسط و گسترش فراوانی یافته است (ماردیا و جاپ، ۲۰۰۰). اگرچه مسائل مربوط به جهت‌های یک بعدی تا حد زیادی آسان و سرراست هستند، اما موضوعات آماری راجع به جهت‌های دو بعدی دو بعدی از پیچیده‌گی‌های خاصی برخوردار است. اندازه‌گیری حاصل از جهت‌های دو بعدی معمولاً به صورت زوایا نشان داده می‌شوند. به طور کلی، اندازه‌گیری جهت‌ها بر اساس جهت صفر^۳ (نقطه‌ی شروع) و حالت دوران^۴ (موافق یا مخالف جهت حرکت عقربه‌های ساعت) مشخص می‌شود. با این حال، باید توجه داشت که نتایج تحلیل‌های آماری شامل خلاصه‌سازی و استنباط نباید وابسته به مقادیر دلخواه مبدا و حالت دوران باشند. به زبان ساده، باید محاسبات آماری طوری تعديل شوند تا متأثر از پارامترهای مزاحم این گونه داده‌ها شامل نقطه‌ی مبدأ، وضعیت دوران و ویژگی‌های دوره‌ای زوایا نباشد. این نکته و جنبه‌های متفاوت آماری دیگر مربوط به جهت‌ها در منابع استاندارد مثل ماردیا (۱۹۷۲)، ماردیا و جاپ (۲۰۰۰) و جامال‌اماداکا و سن گوپتا (۲۰۰۱) مورد مطالعه قرار گرفته است.

وضعیت‌هایی متفاوت از پدیدهای تصادفی مربوط به آمار دایره‌ای وجود دارد که داده‌های حاصل دو یا چند متغیره هستند. به عنوان مثال، چسین حالتی در مطالعه جفت زوایای دو

^۱ Directional Data

^۲ Circular data

^۳ Zero direction

^۴ Rotation

سطحی^۵ برای چند پروتئین اتفاق می‌افتد. می‌توان حدس زد که تعمیم نتایج حاصل از آمار دایره‌ای تک متغیره و هم‌چنین لحاظ فضای توپولوژیکی که جفت زوایا در آنجا قرار می‌گیرند نیازمند توجه خاصی است. بهویژه، ماردیا و همکاران (۲۰۰۷) نشان دادند زوایای دو سطحی بر روی یک چنبه قرار دارند. اخیراً تعیین ساختار دینامیکی و کارکرد مولکول‌های زیستی در فضای میکروسکوپی باعث گشودن زمینه تحقیقاتی جدیدی برای محققین آماری علاقه‌مند به ویژگی‌های هندسی مثلاً با رویکرد احتمالات هندسی شده است طوری که هدف اصلی این فعالیت‌ها تعیین ساختار پروتئین است (درایدن و همکاران، ۲۰۰۵). نکته قابل تأمل در این حوزه که نقش مطالعات آماری را پررنگ‌تر می‌کند این است که می‌توان با دراختیار داشتن زوایای دوسرطحی بین زوج اتم‌های متوالی یک پروتئین ساختار هندسی آن را به‌طور منحصر‌بفرد به‌دست آورد (الماسی و بُری، ۱۹۹۹). بنابراین شناخت بیشتر توزیع احتمالاتی این زوایا و نحوه نمونه‌گیری از آن می‌تواند برای نیل به حل پاره‌ای از مشکلات موجود در بیان‌فورماتیک به‌خصوص تعیین ساختار پروتئین‌ها مدد نظر قرار گیرد.

فعالیت‌های علمی برای معرفی و مطالعه توزیع دایره‌ای دو متغیره توسط ماردیا (۱۹۷۵) شروع شد که آنرا ون میسز دو متغیره نامید. او بیان داشت که چنین توزیعی بسیار شبیه توزیع نرمال دو متغیره‌ای است که بر روی چنبره قرار می‌گیرد. یکی از نگرانی‌ها در مورد آن توزیع وجود ۸ پارامتر بود در حالی که انتظار می‌رفت تنها ۵ پارامتر (با به ماهیت توزیع نرمال دو متغیره) برای این امر نیاز باشد. برای رفع این مشکل، ریوست (۱۹۸۸) همان توزیع را طوری تعدل نمود که تعداد پارامترهای مدل به ۶ کاهش یافت. برای استفاده از این توزیع ۶ پارامتری در مثال‌های کاربردی مربوط به پروتئین‌ها، سینگ و همکاران (۲۰۰۲) سه زیر مدل به نام‌های سینوس، کسینوس با اثرات متقابل مثبت و منفی را معرفی کردند. اما جزئیات بیشتر در مورد دو زیر مدل آخر بسته‌بیب توسط ماردیا و همکاران (۲۰۰۷) و کمنت و همکاران (۲۰۰۸) تشریح شد. در هر دو فعالیت بطور گذرا به نحوه اخذ نمونه‌های تصادفی از توزیع‌های مربوطه اشاره شد ولی جزئیات الگوریتم مناسب و مشکلات مبتلا به آن مد نظر قرار نگرفت. بیان این نکته ضروری است که اخیراً، ماردیا (۲۰۱۰) با رویکرد بیزی توزیع ون میسز دو متغیره را مورد مطالعه قرار داد.

به دلیل اهمیت توزیع ون میسز دو متغیره در مدل‌بندی جفت زوایای دوسرطحی و بهویژه تعیین ساختارهای متفاوت زنجیره اصلی پروتئین‌ها، که از مسائل پر اهمیت علوم زیستی است، توجه این مقاله معطوف به این توزیع شده است. به‌طور دقیق‌تر، نحوه اخذ نمونه‌های

^۵ Dihedral angles

تصادفی از آن‌ها (همراه با جزئیات مورد نیاز) تشریح می‌شود. برای این منظور توزیع‌های حاشیه‌ای و شرطی‌های مورد نیاز محاسبه و در الگوریتم رد و پذیرش مورد استفاده فرار می‌گیرد. نتایجی از شبیه‌سازی‌های صورت گرفته نمایش داده خواهد شد. نکته حائز اهمیت این است که با شناخت توزیع‌های احتمالاتی مرتبط با توزیع ون میسر دو متغیره و بهویژه اخذ مشاهداتی از آن می‌توان به استنباط آماری راجع به پارامترهای توزیع پرداخت.

در بخش ۲ خلاصه‌ای از آمار دایره‌ای و توزیع ون میسر تشریح می‌شود. سپس، توزیع‌های آماری مناسب بر روی چنبره و ویژگی‌های آماری مهم آن‌ها در بخش ۳ ارائه می‌شود. بخش ۴ در برگیرنده نحوه شبیه‌سازی از مدل کسینوسی توزیع ون میسر دو متغیره و نمایش هندسی نمونه‌های تولید شده است. مقاله با بحث و نتیجه‌گیری کلی خاتمه می‌یابد.

۲ آمار دایره‌ای و توزیع‌های روی آن

معمولًاً داده‌های زاویه‌ای به صورت زوایا یا نقاط بر روی محیط دایره‌ی واحد نمایش داده می‌شوند. به طور کلی، موقعیت جهت‌ها را می‌توان به صورت یکتا از طریق مختصات دو بعدی تعیین کرد. برای این منظور می‌توان از مختصات دکارتی استفاده نمود که به این ترتیب، هر نقطه مانند p به صورت (x, y) که در مختصات قطبی به صورت (r, α) که در آن r فاصله نقطه از نقطه مرکز o و α جهت آن‌هاست، نمایش داده می‌شود. مختصات قطبی و دکارتی با استفاده از توابع مثلثاتی سینوس و کسینوس به صورت $x = r \cos \alpha$ و $y = r \sin \alpha$ قابل تبدیل به یکدیگر هستند. از آنجایی که در تحلیل زاویه‌ای محقق علاقه‌مند به بررسی جهت‌ها به جای مقادیر بردارها است و طبق قرارداد این بردارها دارای اندازه واحد هستند پس هرجهت متناظر با یک نقطه بر روی محیط دایره واحد است. به زبان ریاضی می‌توان نوشت:

$$(1, \alpha) \Leftrightarrow (x = \cos \alpha, y = \sin \alpha).$$

در واقع دیدگاه کلی در آمار دایره‌ای مبتنی بر زاویه α براساس بردار متناظرش یعنی (x, y) بر روی دایرة واحد است. برخلاف دامنه دوره‌ای در α ، بردارهای (x, y) در فضای خطی و میانگین و فاصله‌ها همانند فضای اقلیدسی تعریف می‌شوند. به علاوه، استفاده از بردارها باعث سادگی محاسبات می‌شود و در پی آن به کارگیری بسیاری از ابزارهای آمار خطی^۶ میسر می‌گردد.

^۶ Linear statistics

برای متغیر تصادفی دایره‌ای X ، با فضای نمونه S ،تابع توزیع $(x) F_X$ علاوه بر خواص مرسوم بایستی دارای ویژگی‌های زیر باشد:

$$F_X(x) = Pr(0 < \theta \leq x), \quad 0 \leq x \leq 2\pi,$$

$$F_X(x + 2\pi) - F_X(x) = 1, \quad -\infty < x < +\infty$$

رابطه آخر بیان می‌کند که احتمال طول کمان 2π برابر یک است. برای هر تابع توزیع متغیر دایره‌ای، تابع چگالی متناظر با آن به کمک روابط آمار خطی به دست می‌آید. در حالت پیوسته تابع چگالی احتمال به ازای هر عدد صحیح k در تسلوی $f(\theta + 2k\pi) = f(\theta) + 2k\pi$ صدق می‌کند (جامال‌اماداکا و سن گوپتا، ۲۰۰۱).

توزیع ون میسز یک توزیع دایره‌ای است که نقشی مشابه توزیع نرمال در فضای اقلیدسی دارد (ماردیا، ۱۹۷۵). تا قبل از کشف ایزوتوپ‌ها در اتم تصور می‌شد که وزن اتمی عناظر عددی صحیح است. با در نظر گرفتن بخش اعشاری وزن ۲۴ عنصر سبک ریچارد ون میسز (۱۹۱۸) نشان داد که قسمت کسری مربوطه می‌تواند به عنوان متغیر تصادفی بر روی دایره تلقی شود. ایشان با نمایش هندسی و بررسی علمی آن سبب ایجاد تحول شگرفی در فیزیک اتمی گشت. به همین دلیل توزیع پیشنهادی ایشان به افتخار وی به توزیع ون میسز معروف شد. البته، بنا به اعتقاد جمال‌اماداکا و سن گوپتا (۲۰۰۱) قبیل از ون میسز پل لانجوین (۱۹۰۵) از این توزیع در برخی مباحث فیزیکی استفاده کرده بود. گذر تاریخی این توزیع به همین جا ختم نمی‌شود. بلکه در پی سالیان متمادی با بسط آن در بعدهای بالاتر اهمیت آن بیش از پیش مشخص شد (ماردیا و جاب، ۲۰۰۰).

اگر θ دارای توزیع ون میسز با پارامترهای μ و κ باشد که با نماد $(\mu, \kappa) VM$ نمایش داده می‌شود، آنگاه تابع چگالی احتمال آن به صورت

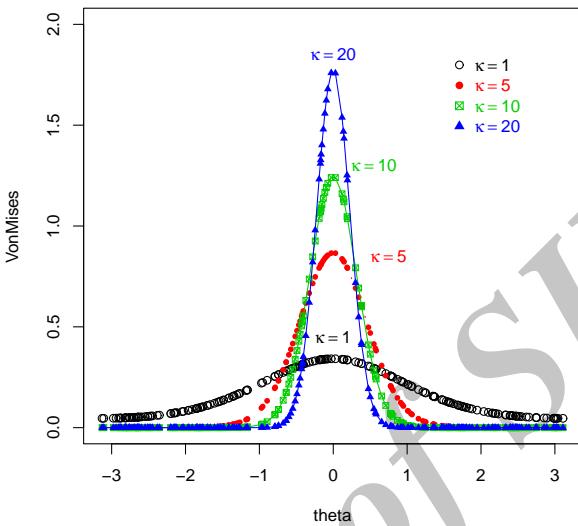
$$f(\theta) = \frac{1}{2\pi I_{\circ}(\kappa)} e^{\kappa \cos(\theta - \mu)}, \quad -\pi \leq \theta \leq \pi, \quad (1)$$

نوشته می‌شود، که در آن پارامتر μ میانگین توزیع، κ پارامتر تمرکز^۷ و $I_{\circ}(\kappa)$ تابع پیش از مرتبه صفر به صورت

$$I_{\circ}(k) = \frac{1}{2\pi} \int_0^{2\pi} e^{\kappa \cos(\theta)} d\theta = \sum_{r=0}^{\infty} \left(\frac{\kappa}{2}\right)^r \left(\frac{1}{r!}\right)^2$$

است (آبراموویچ و استگان، ۱۹۶۵). توزیع ون میسز، متقارن و تک مدی در نقطه میانگین μ است. هنگامی که $\kappa = 0$ توزیع ون میسز به توزیع یکساخت تبدیل خواهد شد. اما اگر κ

^۷ Concentration parameter



شکل ۱: رفتار توزیع ون میسز به ازای مقادیر متفاوت پارامتر تمرکز

افزایش یابد، جرم توزیع ون میسز حوالی μ متراکم شده و به همین دلیل به κ پارامتر تمرکز گفته می‌شود. شکل ۱ رفتار این توزیع را به ازای مقادیر متفاوت پارامتر تمرکز نشان می‌دهد.

۳ چنبره و توزیع‌های آماری بر روی آن

در هندسه، چنبره یکی از اشکال سه بعدی است که از چرخاندن یک دایره در فضای سه بعدی حول محوری هم صفحه ولی غیرمماس با آن دایره به وجود می‌آید. از نقطه نظر توپولوژی، چنبره همانند دستگاه مختصات دکارتی است که از ضرب دو دایره به دست می‌آید یعنی اگر S^1 نمایانگر دایره و T^2 نمایانگر چنبره باشد آنگاه $S^1 \times S^1 = T^2$. به علاوه، چنبره را می‌توان به صورت پارامتری توسط روابط

$$X = (R + r \cos \theta_1) \cos \theta_2, \quad Y = (R + r \cos \theta_1) \sin \theta_2, \quad Z = r \sin \theta_1.$$

نوشت، که در آن $\theta_1, \theta_2 \in [-\pi, \pi]$ و با توجه به اینکه چنبره از ضرب دو دایره به دست آمده است، R شعاع دایره بزرگتر و r شعاع دایره کوچکتر در چنبره است (هاچر، ۲۰۰۲).

در دستگاه مختصات دکارتی معادله چنبره به صورت

$$(\sqrt{X^2 + Y^2} - R)^2 + Z^2 = r^2.$$

است که آن را می‌توان به طور هم‌ارز به صورت

$$(X^2 + Y^2 + Z^2 + R^2 - r^2) = 4R^2(X^2 + Y^2)$$

نوشت. لازم به ذکر است که در تحلیل داده‌های ناقصیلیدسی فضای توپولوژیکی فرارگیری داده‌ها مبنای استنباط و مدل‌بندی آماری است و از آنجایی که زوایای دو سطحی بر روی چنبره استاندارد ($R = 1, r = 2$) قرار دارند (ماردیا و همکاران، ۲۰۰۷)، تمام تحلیل‌ها و استنباط آماری این زوایا بر روی این حالت خاص از چنبره انجام گرفته است. فرض کنید که در سراسر این بخش تکیه گاه چنین متغیرهای زاویه‌ای $[\pi, -\pi]$ است. ماردیا (۱۹۷۵) تابع چگالی احتمال توان آن‌ها را به صورت

$$f(\theta_1, \theta_2) = \exp \{ [\cos(\theta_1 - \mu_1), \sin(\theta_1 - \mu_1)] A [\cos(\theta_2 - \mu_2), \sin(\theta_2 - \mu_2)]^T + \kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) \} \{ C(\cdot) \}^{-1}, \quad (2)$$

پیشنهاد داد که در آن $\kappa_2 \geq \kappa_1$ ، $\mu_1, \mu_2 \in [-\pi, \pi]$ ، مقداری ثابت و معیارهایی از تمرکز توزیع، پارامترهای $A = [a_{ij}]$ یک ماتریس 2×2 و معیاری از پراکندگی توزیع هستند. همان‌گونه که از رابطه (۲) ملاحظه می‌شود چگالی حاصل ۸ پارامتر دارد. ریوست (۱۹۸۸) زیر مدلی از این توزیع را به صورت

$$f(\theta_1, \theta_2) = \exp \{ \alpha \cos(\theta_1 - \mu_1) \cos(\theta_2 - \mu_2) + \beta \sin(\theta_1 - \mu_1) \sin(\theta_2 - \mu_2) + \kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) \} \{ C(\cdot) \}^{-1}, \quad (3)$$

معرفی کرد که دارای ۶ پارامتر است. سالیان بعد، سینگ و همکاران (۲۰۰۲) با الگوبرداری از توزیع نرم‌مال دو متغیره حالت‌های خاصی از این زیرمدل را مورد مطالعه قرار دادند و آن‌ها را در چند مثال کاربردی به کار برداشتند. سه زیر مدل پیشنهادی توسط آن‌ها به نام‌های مدل سینوسی، کسینوسی با اثرات متقابل مثبت و مدل کسینوسی با اثرات متقابل منفی معروف است.

اگر مولفه‌های ماتریس $A = [a_{ij}]$ در معادله (۲) با مقادیر $a_{11} = a_{12} = a_{21} = 0$ و $a_{22} = \eta$ جایگزین شود، آنگاه مدل سینوسی دارای تابع چگالی به صورت

$$f(\theta_1, \theta_2) = \frac{e^{\kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) + \eta \sin(\theta_1 - \mu_1) \sin(\theta_2 - \mu_2)}}{C(\kappa_1, \kappa_2, \eta)} \quad (4)$$

خواهد بود، که در آن $\infty < \eta < \infty$ معیاری از وابستگی بین θ_1 و θ_2 است. در این حالت اگر $\eta = \theta_1 = \theta_2$ مستقل بوده و هر کدام دارای توزیع ون میسز تک متغیره خواهد بود. توجه کنید که با قرار دادن $\eta = \alpha, \beta = \beta$ در رابطه (۳) نیز مدل سینوسی (۴) به دست خواهد آمد. سینگ و همکاران (۲۰۰۲) مقدار ثابت نرمال ساز در مدل سینوس را به صورت

$$C(\kappa_1, \kappa_2, \eta) = \{4\pi^2 \sum_{m=0}^{\infty} \left(\frac{2m}{m} \right) (\frac{\eta}{2})^m m \kappa_1^{-m} I_m(\kappa_1) \kappa_2^{-m} I_m(\kappa_2)\}^{-1}$$

به دست آورده است، که در آن $I_r(\kappa)$ تابع بسل نوع اول از مرتبه r است. آنها همچنین نشان دادند که توزیع‌های شرطی از توزیع (۴)، و ن میسز و توزیع‌های حاشیه‌ای، متقاضان در میانگین دایره‌ای هستند. توزیع‌های حاشیه‌ای هم می‌توانند تک مدلی دو مدلی باشند و با ایجاد شرایطی در پارامترها توزیع شکل خاصی به خود می‌گیرند. در توزیع‌های تک مدلی، هنگامی که پارامترهای تمرکز کوچک باشند، حاشیه‌ها تقریباً از توزیع ون میسز پیروی خواهند کرد.

ماردیا و همکاران (۲۰۰۷) با قرار دادن $\kappa_2 = -\beta$ در رابطه (۳) مدل کسینوس با

اثرات متقابل مثبت با تابع چگالی به صورت

$$f_{\cos PI}(\theta_1, \theta_2) \propto e^{\kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) - \kappa_2 \cos(\theta_1 - \mu_1 - \theta_2 + \mu_2)}.$$

معرفی کردند. کنت و همکاران (۲۰۰۸) تابع چگالی دیگری پیشنهاد کردند که مدل کسینوسی با اثرات متقابل منفی را به نمایش می‌گذارد. آن تابع چگالی به صورت

$$f_{\cos NI}(\theta_1, \theta_2) \propto e^{\kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) - \kappa_2 \cos(\theta_1 - \mu_1 + \theta_2 - \mu_2)}$$

است، که در آن $\kappa_1 > \kappa_2 > 0$ و $\kappa_3 > \kappa_2 > \kappa_1$. این توزیع هنگامی که نوسانات در متغیر دایره‌ای کوچک باشد، تقریباً نرمال دو متغیره است. توجه کنید که تابع چگالی مدل کسینوس با اثرات متقابل منفی با قرار دادن $\kappa_2 = -\beta$ در رابطه (۳) به دست می‌آید. ماردیا (۲۰۰۹) مقدار ثابت نرمال ساز در این مدل را به صورت

$$C(\kappa_1, \kappa_2, \kappa_3) = \{4\pi^2 [I_o(\kappa_1) I_o(\kappa_2) I_o(\kappa_3) + 2 \sum_{p=0}^{\infty} I_p(\kappa_1) I_p(\kappa_2) I_p(\kappa_3)]\}^{-1}.$$

پیشنهاد کرد. برخی از ویژگی‌های مدل‌های سینوسی و کسینوسی عبارتند از:

الف) هر دو مدل سینوسی و کسینوسی متقارن‌اند، یعنی $f(\theta_1, \theta_2) = f(-\theta_1, -\theta_2)$.
ب) در بیشتر موقعی، اختلاف اندکی مابین مدل‌های سینوسی و کسینوسی وجود دارد.
به علاوه، هنگامی که پارامتر تمکر زیاد باشد، هر دو مدل معادل برآش توزیع نرمال دو متغیره در صفحه مماسی در نقطه میانگین (μ_1, μ_2) است.

ج) هنگامی که $|\eta|$ در مدل سینوسی افزایش یابد، چگالی آن دو مدد خواهد شد در حالی که در مدل کسینوسی با افزایش مقادیر مثبت κ_1 و منفی κ_2 این اختلاف خواهد افتاد (شکل ۲). در شبیه‌سازی از توزیع دو متغیره ون میسز، توابع چگالی شرطی و حاشیه‌ای نقشی اساسی ایفا می‌کنند. با پیروی از ماردیا و همکاران (۲۰۰۷) و با فرض اینکه $\mu_1 = \mu_2 = 0$ ، توابع چگالی احتمال مدل سینوسی و کسینوسی با اثرات متقابل مثبت و منفی، به ترتیب، به فرم

$$\begin{aligned} f_{\sin}(\theta_1, \theta_2) &= C(\kappa_1, \kappa_2, \eta) \exp\{\kappa_1 \cos \theta_1 + \kappa_2 \cos \theta_2 + \eta \sin \theta_1 \sin \theta_2\} \\ f_{\cos PI}(\theta_1, \theta_2) &= C(\kappa_1, \kappa_2, \kappa_3) \exp\{\kappa_1 \cos \theta_1 + \kappa_2 \cos \theta_2 - \kappa_3 \cos(\theta_1 - \theta_2)\} \\ f_{\cos NI}(\theta_1, \theta_2) &= C(\kappa_1, \kappa_2, \kappa_3) \exp\{\kappa_1 \cos \theta_1 + \kappa_2 \cos \theta_2 - \kappa_3 \cos(\theta_1 + \theta_2)\} \end{aligned} \quad (5)$$

هستند. برای محاسبه توزیع‌های حاشیه‌ای و شرطی، پارامترهای جدید $\alpha(\theta_1)$ و $\beta(\theta_1)$ را که به اختصار با α و β نمایش داده طوری تعریف می‌شود که در روابط $\kappa_2 = \alpha \cos \beta$ و $\kappa_3 = \alpha \sin \beta$ صدق کنند. بنابراین

$$\alpha = (\kappa_1^2 + \eta^2 \sin^2 \theta_1)^{\frac{1}{2}}, \quad \beta = \arctan\left(\frac{\eta}{\kappa_1} \sin \theta_1\right).$$

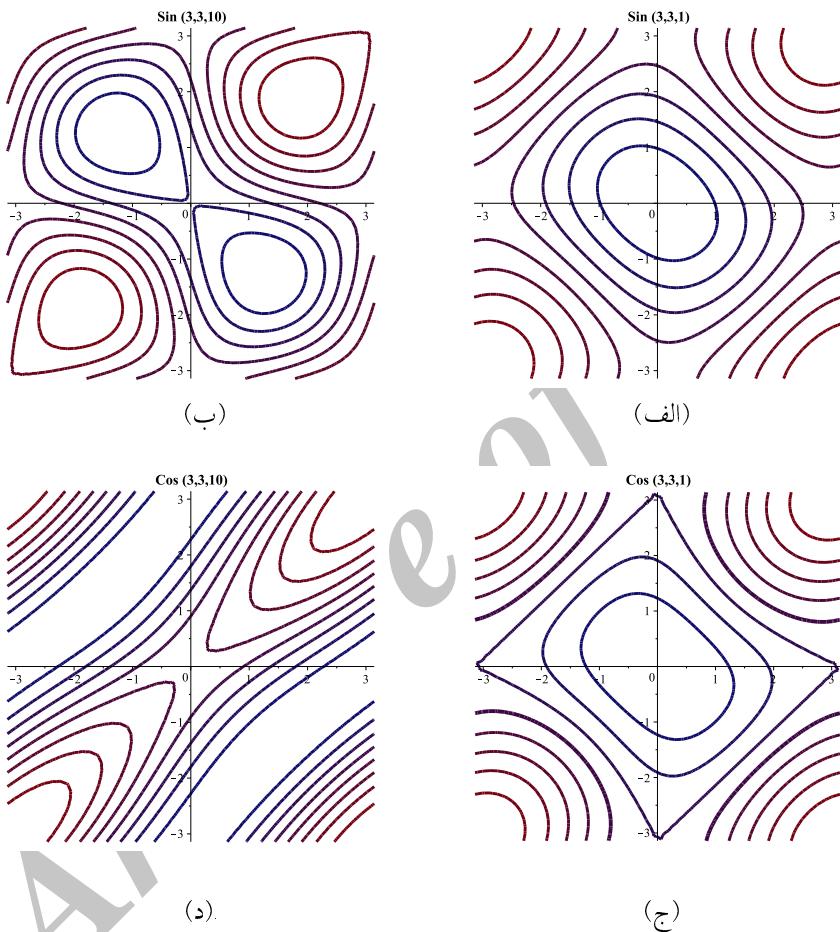
حال برای محاسبه تابع چگالی احتمال حاشیه‌ای θ_1 در مدل سینوسی داریم:

$$\begin{aligned} f_{\sin}(\theta_1) &= \int_{-\pi}^{\pi} f_{\sin}(\theta_1, \theta_2) d\theta_2 \\ &= C(\kappa_1, \kappa_2, \eta)^{-1} 2\pi I_0(\alpha(\theta_1)) \exp\{\kappa_1 \cos \theta_1\}, \end{aligned}$$

که در آن $I_0(\cdot)$ تابع بیسل از مرتبه صفر است. ملاحظه می‌شود این تابع چگالی شباهتی با توزیع‌های معمول بر روی دایره ندارد (ماردیا و جاپ، ۲۰۰۰).

با توجه به محاسبه توزیع‌های حاشیه‌ای و تئوری احتمالات، محاسبه توزیع‌های شرطی ساده خواهد بود. به زبانی دقیق‌تر، تابع چگالی شرطی θ_2 به شرط $\theta_1 = \theta_1$ برابر

$$\begin{aligned} f_{\sin}(\theta_2 | \theta_1) &= \frac{f_{\sin}(\theta_1, \theta_2)}{f_{\sin}(\theta_1)} \\ &= \frac{1}{2\pi I_0(\alpha(\theta_1))} \exp\{\alpha(\theta_1) \cos(\theta_2 - \beta(\theta_1))\}, \end{aligned}$$



شکل ۲: نمودار تراز لگاریتم تابع چگالی مدل سینوس با مقادیر پارامتر (الف):
 (۱، ۳، ۳) و (ب): (۳، ۳، ۱۰). نمودار تراز لگاریتم تابع چگالی مدل کسینوس با
 مقادیر پارامتر (ج): (۱، ۳، ۳) و (د): (۳، ۳، ۱۰).

خواهد شد. می‌توان ملاحظه کرد کهتابع چگالی شرطی $\theta_2 = \theta_1$ دارای توزیع ون میسز با پارامتر تمرکز $(\alpha(\theta_1), \beta(\theta_1))$ و میانگین زاویه‌ای است. برای محاسبه تابع چگالی حاشیه‌ای و شرطی مدل کسینوسی پارامترهای جدید $(\alpha(\theta_2), \beta(\theta_2))$ به صورت

$$\begin{aligned}\alpha(\theta_2) &= \sqrt{(\kappa_1^2 + \kappa_2^2 - 2\kappa_1\kappa_2 \cos \theta_2)}, \\ \beta(\theta_2) &= \arctan\left(\frac{-\kappa_2 \sin \theta_2}{\kappa_1 - \kappa_2 \cos \theta_2}\right)\end{aligned}$$

تعریف می‌شود. با بررسی تابع حاشیه‌ای و شرطی مدل کسینوسی با اثرات متقابل مثبت داریم:

$$\begin{aligned}f_{\cos}(\theta_2) &= \int_{-\pi}^{\pi} f_{\cos}(\theta_1, \theta_2) d\theta_1 \\ &= C(\kappa_1, \kappa_2, \kappa_3)^{-1} 2\pi I_0(\alpha(\theta_2)) \exp\{\kappa_2 \cos \theta_2\}. \quad (6)\end{aligned}$$

اکنون با توجه به توزیع توام مدل کسینوسی و توزیع حاشیه‌ای حاصل در (6) توزیع چگالی شرطی مدل کسینوسی به آسانی به صورت

$$\begin{aligned}f_{\cos}(\theta_1 | \theta_2) &= \frac{f_{\cos}(\theta_1, \theta_2)}{f_{\cos}(\theta_2)} \\ &= \frac{1}{2\pi I_0(\alpha(\theta_2))} \exp\{\alpha(\theta_2) \cos(\theta_1 - \beta(\theta_2))\}\end{aligned}$$

قابل محاسبه است. همان طور که ملاحظه می‌شود توزیع ون میسز با پارامتر تمرکز $(\alpha(\theta_2), \beta(\theta_2))$ و میانگین زاویه‌ای θ_2 خواهد بود.

۴ شبیه‌سازی از مدل کسینوسی توزیع ون میسز دو متغیره

در علوم زیستی و به‌ویژه در بیوانفورماتیک تولید پروتئین‌ها با ویژگی‌های متفاوت بسیار پرهزینه است. از نقطه‌نظر آماری نیز در خیلی از مواقع دسترسی به هر حجمی از داده‌های واقعی غیرممکن بنظر می‌رسد (اشمیت و تیلور، ۱۹۷۵). در عوض انجام شبیه‌سازی از مدل‌ها یا ساختارهای تصادفی کمک شایانی در این موضوع می‌کند. به علاوه، معمولاً با شبیه‌سازی می‌توان به راحتی و با صرف هزینه کم به حجم قابل توجهی از داده‌ها دست یافت. در نهایت از شبیه‌سازی داده‌ها می‌توان برای مدل‌بندی و یا پیش‌بینی اینکه چگونه تغییرات حجم داده‌ها بر روی نتایج حاصل از استنباط آماری تأثیر می‌گذارد، استفاده کرد. لذا، در این بخش نمونه‌های تصادفی که نقش مشاهدات زاویه‌ای بر روی چنبره را بازی می‌کنند، تولید می‌شود.

با نگاه به توزیع کسینوسی با اثرات متقابل مشبّت معرفی شده در بخش ۳ ملاحظه می‌شود که چگالی مربوطه فرم بسته‌ای ندارد و لذا شبیه‌سازی مستقیم از آن آسان نخواهد بود. با این حال چون چگالی شرطی $\theta_2 \leq f(\theta_2)$ توزیع ون میسز است که شبیه‌سازی از آن به وسیله کتابخانه Circular در نرم‌افزار آماری R میسر خواهد بود. می‌توان شبیه‌سازی از این چگالی شرطی را با شبیه‌سازی از توزیع حاشیه‌ای θ_2 در هم آمیخت و زوج نمونه‌های (θ_1, θ_2) را به دست آورد.

با دقت در توزیع حاشیه‌ای θ_2 در توزیع ون میسز دو متغیره مدل کسینوسی در می‌یابیم شبیه‌سازی مستقیم از آن نیز میسر نیست. اما می‌توان از الگوریتم‌های مختلفی از جمله الگوریتم رد و پذیرش، برای تولید نمونه تصادفی از این توزیع حاشیه‌ای استفاده نمود. برای این منظور باید توجه شود که توزیع کاندید را باید طوری در نظر گرفت که هم رفتار و دارای تکیه‌گاه یکسان با توزیع مورد نظر باشد (رابرت و کسلا، ۲۰۰۴). برای تعیین توزیع نامزد با دقت در فرم توزیع حاشیه‌ای θ_2 در توزیع ون میسز دو متغیره مدل کسینوسی و مقایسه آن با رابطه (۱) ملاحظه می‌شود که قسمت نمایی آن‌ها بسیار به هم شبیه بوده بنابراین میانگین توزیع را صفر و پارامتر تمکز $f(\theta_2)$ را طوری در نظر گرفته که توزیع نامزد، توزیع حاشیه‌ای را در سراسر دامنه تغییرات θ_2 پوشش^۸ دهد.

گام‌های الگوریتم رد و پذیرش پشنهدای برای تولید نمونه از توزیع کسینوسی با اثرات متقابل مشبّت به صورت زیر است:

گام ۱ : از توزیع کاندید $VM(0, 0/5) = h(\theta_2)$ داده تولید کنید.

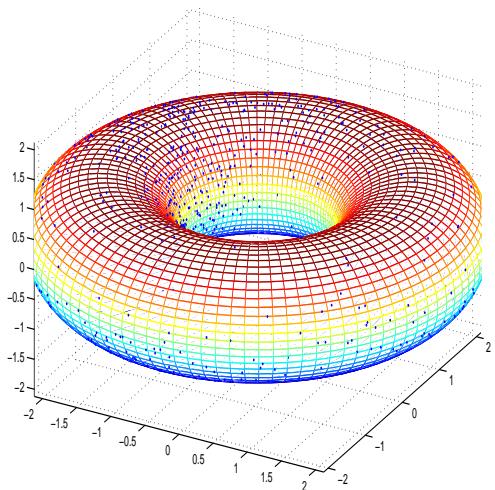
گام ۲ : ثابت L طوری در نظر گرفته شود که به ازای هر θ_2 در شرایط $L = \max \left\{ \frac{f(\theta_2)}{h(\theta_2)}, 1 \right\} < L \times h(\theta_2)$ صدق کند.

گام ۳ : از توزیع $(1, 0) U$ داده تولید کنید.

گام ۴ : اگر شرط $\frac{f(\theta_2)}{L \times h(\theta_2)} < U$ برقرار باشد، مقدار θ_2 به عنوان مقدار تصادفی از توزیع موردنظر $f(\theta_2)$ پذیرفته شود و در غیر این صورت به گام ۱ برگردید.

با داشتن θ_2 ، برای تولید متغیر تصادفی $\theta_1 = f(\theta_1|\theta_2)$ از توزیع شرطی $f(\theta_1|\theta_2)$ که دارای توزیع ون میسز با پارامترهای $\{\mu = \beta(\theta_2), \kappa = \alpha(\theta_2)\}$ است، با استفاده از بسته آماری Circular (در نرم‌افزار R) میسر است.

^۸ Dominate



شکل ۳: نمودار داده‌های شبیه‌سازی شده مدل کسینوسی از توزیع ون میسر دو متغیره بر روی چنبره

برای مدل کسینوسی با اثرات متقابل مثبت پارامترهای توزیع به صورت $\kappa_1 = 1/5$, $\kappa_2 = 1/7$, $\kappa_3 = 1/3$ درنظر گرفته شد و نمونه‌ای به حجم ۱۰۰۰ از این توزیع تولید شده و فرم هندسی آن در شکل ۳ نشان داده شده است.

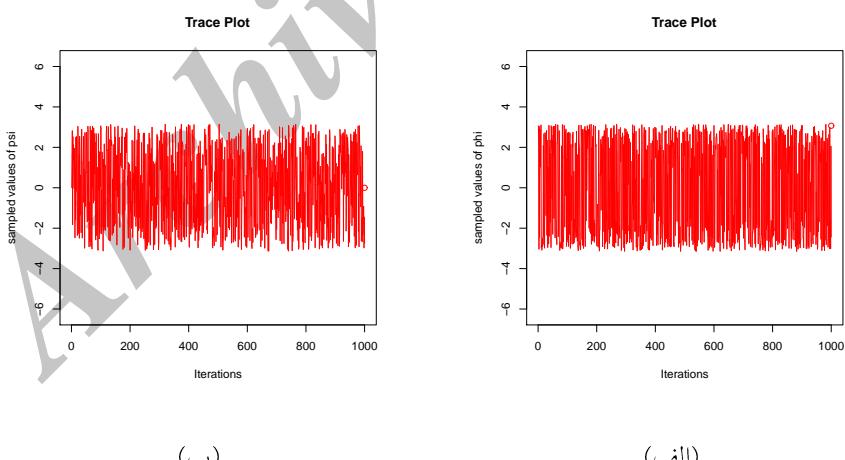
یکی از جنبه‌های مورد توجه نمونه‌های تولید شده بررسی دامنه تغییرات آن‌هاست به این مفهوم که آیا در بازه خودشان حضور دارند یا خیر. علاوه بر این، بررسی روند تغییرات آن‌ها در طی گام‌های شبیه‌سازی روند آمیختن^۹ نمونه‌های تولید شده را نمایان خواهد ساخت. برای این منظور، در شکل ۴ - الف نمودار اثر نمونه‌های تولید شده ازتابع چگالی حاشیه‌ای مدل کسینوس با استفاده از الگوریتم رد و پذیرش با توزیع کاندید ذکر شده در گام ۱ رسم شده است. قابل ذکر است که درصد پذیرش نمونه‌ها در کل شبیه‌سازی ۴۹ درصد بود. همچنین، در شکل ۴ - ب نمونه‌های تولید شده از توزیع شرطی θ_1 به شرط θ_2 با پارامترهای (μ, κ) نمایش داده شده است. یکی از موارد استفاده از این نمونه‌های شبیه‌سازی شده کاربردشان در مبحث استیباط آماری است. موضوع برآورد پارامترهای این توزیع از مباحث

^۹ Mixing

نوین تحقیق در آمار دایره‌ای است که هاملریک و همکاران (۲۰۱۲) به بخشی از آن اشاره کردند. بهویژه، آن‌ها تاکید کردند که محاسبه برآوردهای ماکسیمم درستنمایی مستلزم حل تعداد زیادی روابط غیرخطی است در حالی که برآوردهای گشتاوری ساختاری ساده‌تر دارند. اما باید توجه داشت که اولی جواب‌های دقیق‌تری از دومی خواهد داد. محاسبه برآوردهای گسترده‌ای ماکسیمم درستنمایی امری بسیار دشوار بوده که ترجیح داده شد در این مقاله به آن پرداخته نشود. اما با ۱۰۰ بار تکرار فرایند شبیه‌سازی، برآوردهای تجربی گشتاوری پارامترها همراه با خطای برآورد آنها به صورت

$$\hat{\kappa}_1 = 1/204(0/084), \hat{\kappa}_2 = 1/627(0/064), \hat{\kappa}_3 = 1/44(0/104)$$

به دست آمده است. همان‌طور که ملاحظه می‌شود محاسبه بازه‌های اطمینان تقریبی در برگیرنده مقادیر اولیه در نظر گرفته شده برای پارامترها نیست. این موضوع به نوعی تاییدی بر عدم اعتبار برآوردهای گشتاوری، همان‌طوری که هاملریک و همکاران (۲۰۱۲) اشاره کردند، است.



شکل ۴: نمودار نمونه‌های تولید شده از الف: چگالی $f_{\cos}(\theta_2)$ با استفاده از الگوریتم رد و پذیرش و ب: توزیع ون میسر $(\beta(\theta_2), \alpha(\theta_2))$

بحث و نتیجه‌گیری

در این مقاله ضمن معرفی داده‌های زاویه‌ای که ماهیت نااقلیدسی داشته و کاربرد فراوانی در مسائل کاربردی دارند، به تحلیل آن‌ها پرداخته و روش شبیه‌سازی از این گونه داده‌ها توضیح داده شد. نادیده گرفتن خاصیت زاویه‌ای بودن چنین متغیرهایی و اعمال روش‌های آمار خطی بر روی آن‌ها منجر به نتایج نادرست می‌گردد. بنابراین با مدنظر قرار دادن فضای نااقلیدسی این داده‌ها و تعییم توزیع‌ها و روش‌های آمار خطی در این فضای سعی در پاسخگویی به سوالات متدالوی بهخصوص در حوزه آمار غیرخطی شده است.

از نقطه نظر تئوری، پیشفرفت‌های خوبی در حوزه آمار دایره‌ای و آمار روی چنبره صورت گرفته است ولی بسته‌های نرم‌افزاری کمتری در این زمینه موجود است. در نرم افزار Matlab بسته‌ای برای شبیه‌سازی از توزیع‌های آماری روی دایره و درحال تک متغیره وجود دارد و در نرم افزار R بسته‌های CircStat و Circular برای این منظور موجودند. ولی در حال حاضر و با بررسی‌های صورت گرفته توسط نویسنده‌گان این مقاله ملاحظه شد که در حالت دو یا چندمتغیره بسته آماری خاصی موجود نیست.

از نقطه نظر کاربردی، می‌توان از این زوایا در حوزه بیوانفورماتیک بهخصوص تعیین ساختار پروتئین‌ها استفاده نمود. اما باید توجه داشت که پیچیدگی‌های منحصر به‌فرد ساختار پروتئین‌ها تنها با کمک توزیع‌های مورد اشاره در این مقاله و منابع آن قابل حل نیستند. در عوض، مدل‌بندی جامعی که شامل علوم زیستی، فیزیکی، کامپیوتري و آماري هستند می‌توانند مسیری را برای پاسخ به بخشی از مشکلات مورد اشاره هموار نمایند. بومسا و همکاران (۲۰۰۸) و مارديا (۲۰۱۰) به گوشاهی از این مسائل در بررسی تعیین ساختار پروتئین‌ها اشاره کرده‌اند. مارديا و همکاران (۲۰۰۸) به بررسی حالت چند متغیره توزیع ون میز پرداخته و به کاربرد آن را در بیوانفورماتیک پرداخته‌اند. اخیرا، این حوزه از علم در علوم دیگر بسیار مطرح شد. اما پرداختن به این موضوع کمتر در منابع علمی آماری به‌چشم می‌خورد. امید است مقاله حاضر انگیزه‌ای برای محققین آمار غیرخطی که مایل به مطالعه داده‌های زاویه‌ای و استنباط آماری آن‌ها در حالت دو متغیره‌اند، فراهم کرده باشد.

تقدیر و تشکر

نویسنده‌گان از مسئولان مجله علوم آماری در فراهم کردن زمینه مشارکت علمی برای موضوعات جدید آماری تقدیر و از داوران محترم برای ارائه پیشنهادات مفید در بهبود این مقاله سپاسگزاری می‌نمایند.

مراجع

- Abramowitz, M. and Stegun, I. A. (1965), *Handbook of Mathematical Functions*, Dover Publications, New York.
- Boomsma, W., Mardia, K. V., Taylor, C. C., Ferkinghoff-Borg, J., Krogh, A. and Hamelryck, T. (2008), A Generative, Probabilistic Model of Local Protein Structure, *Proceedings of the National Academy of Sciences of USA*, **105**, 8932-8937.
- Dryden, I. L., Mian, S., Browne, W. J., Handley, K., di Nisio, R. and Rees, R. (2005), Statistical Analysis of SELDI Protein Chip Data from Breast Cancer Cell Lines Exposed to Chemotherapeutic Agents, In *S. Barber, P.D. Baxter, K.V. Mardia and R.E. Walls (Ed.), LASR 2005 - Quantitative Biology, Shape Analysis, and Wavelets*, University of Leeds, UK.
- Elmaci, N. and Berry, R. S. (1999), Principal Coordinate Analysis on a Protein Model, *Journal of Chemistry-Physics*, **110**, 10606-10622.
- Hamelryck, T., Mardia, K. V. and Ferkinghoff-Borg, J. (2012), *Bayesian Methods in Structural Bioinformatics*, Springer, Berlin.
- Hatcher, A. (2002), *Algebraic Topology*, Cambridge University Press, Cambridge.
- Jammalamadaka, S. R. and Sengupta, A. (2001), *Topics in Circular Statistics*, World Scientific Publishing Co., Inc, Singapore.
- Kent, J. T., Mardia, K. V. and Taylor, C. C. (2008), Modelling Strategies for Bivariate Circular Data, In Gusnanto A., Barber, S., Baxter, P. D. and Mardia, K. V. editors, *The Art and Science of Statistical Bioinformatics*, University of Leeds Press, UK.
- Langevin, P. (1905), Magnetisme et Theorie des Electrons, *Annual of Chemistry Physics*, **5**, 71-127.
- Mardia, K. V. (1972), *Statistics of Directional Data*, Academic Press, London.

- Mardia, K. V. (1975), Statistics of Directional Data (with discussion), *Journal of Royal Statistical Society, B*, **37**, 349-393.
- Mardia, K. V. and Jupp, P. E. (2000), *Directional Statistics*, John Wiley, Chichester.
- Mardia, K. V., Taylor, C. C. and Subramaniam, G. K. (2007), Protein Bioinformatics and Mixture of Bivariate Von Mises Distributions for Angular Data, *Biometrics*, **63**, 505-512.
- Mardia, K. V., Hughes, G., Taylor, C. C. and Singh, H. (2008), A Multivariate Von Mises Distribution with Applications to Bioinformatics, *Canadian Journal of Statistics*, **36**, 99-109.
- Mardia, K. V. (2009), Statistical Complexity in Protein Bioinformatics, In Mardia, K. V., Gusnanto, A. and Fallaize, C. J. Editors, *Statistical Tools for Challenges in Bioinformatics*, University of Leeds Press, UK.
- Mardia, K. V. (2010), Bayesian Analysis for Bivariate Von Mises Distributions, *Journal of Applied Statistics*, **37**, 515-528.
- Robert, C. P., and Casella, G. (2004), *Monte Carlo Statistical Methods*, Springer, New York.
- Rivest, L. P. (1988), A Distribution for Dependent Unit Vectors, *Communications in Statistics*, **17**, 461-483.
- Schmidt, J. W. and R. E. Taylor, (1970), *Simulation and Analysis of Industrial Systems*, Richard D. Irwin, Homewood, Illinois.
- Singh, H., Hnizdo, V. and Demchuk, E. (2002), Probabilistic Model for Two Dependent Circular Variables, *Biometrika*, **89**, 719-723.
- Von Mises, R. (1918), Über die "Ganzzahligkeit" der Atomgewichte und Verwandte Fragen, *Physikal*, **19**, 490-500.