



خوشه‌بندی زوایای تصادفی با مدل آمیخته توزیع فون میزس

سیما نوری جویریایی^۱، آناهیتا نودهی^۲ و موسی گل‌علی‌زاده^۳

کارشناس ارشد آمار^۱

دانشجوی دکتری آمار، گروه آمار، دانشگاه تربیت مدرس^۲

عضر هیئت علمی، گروه آمار، دانشگاه تربیت مدرس^۳

چکیده در تحقیقات علوم زیستی نشان داده شد که زوج زوایای وجود دارد که تا حد دقیقی ساختار هندسی و فضایی کامل یک پروتئین را در یک فضای سه بعدی توصیف می‌کنند. برای تشریح احتمالاتی بر اساس موقعیت اتمهای پروتئین و فضای فرارگیری زوایا نشان داده شد که چنبره است، مقادیر توام این دو زاویه دارای توزیعی به نام فون میزس دو متغیره هستند. با در نظر گرفتن یک مدل آمیخته از این توزیع می‌توان به مدل بندی احتمالی مجموعه ای از زوایای با وزن های متناسب پرداخت. به عبارتی دیگر، با این رویکرد امکان مدل بندی توزیع های آمیخته در حالت منهای چنگانه نیز وجود خواهد داشت. این موضوع زمینه مناسبی برای خوشه بندی مجموعه ای از پروتئین ها فراهم می‌کند. لذا، هدف اصلی مقاله حاضر بررسی خوشه بندی زوایای تصادفی بر اساس مدل آمیخته توزیع فون میزس دو متغیره، نمونه برآورد پارامترهای آنها و کاربست این مدل برای یک مثال واقعی با روش های است. واژه های کلیدی: زوایای تصادفی، توزیع فون میزس دو متغیره، مدل آمیخته، خوشه بندی.

کد موضوع بندی ریاضی (۲۰۱۰): 62H30, 62H11

۱ مقدمه

اگرچه آمار و احتمال نقش بی بدیلی در پیشرفت نظریه های کاربردی و نظری بر اساس متغیرهای تصادفی در فضای اقلیمسی ایفا کردند، اما پیشرفت تکنولوژی، پدیده های تصادفی جدیدی را پیش روی بشر قرار داد که توزیع های احتمالاتی (اقلیمسی) قادر به مدل بندی آنها نیستند. به عنوان مثال، در طی دهه های گذشته استفاده از زوایا توانسته جای پای محکمی در تحلیل آماری داده هایی که فضای رخداد آنها نااقلیمسی است، باز کند. نظریه آماری که به اینگونه مسائل می پردازد به آمار غیرخطی معروف است.

از نظر مطالعات سروری، پایریزی تئوری های احتمالاتی مربوط به زوج زوایا که مقادیرشان را در بازه $[0, 2\pi]$ اختیار می کنند، اولین

^۱تام ارائه دهنده مقاله: سیما نوری جویریایی، n.nour1@nodarwa.ac.ir

باز توسط **ماریا (۱۹۷۵)** با معرفی توزیع فون میوز دو متغیره^۱ با هشت پارامتر شروع شد. لازم به اشاره است مجموعه نقاط هندسی حاصل از تغییرات توأم این دو زاویه در بازه $[0, 2\pi]$ تشکیل چنبره می دهد. علاوه براین، در محافل زیستی این زوج زاویه به زوایای دوسطمی معروفند (**راماچاندران و همکاران (۱۹۶۳)**). هدف اصلی معرفی شیبه توزیع نرمال دو متغیره بود. سالها بعد، حالت های خاصی از توزیع فون میوز دو متغیره یا عنوان مدل سینوسی با پنج پارامتر توسط **سینگ و همکاران (۲۰۰۲)** معرفی شد. پس از آن با مطالعات **ماریا و همکاران (۲۰۰۳)** مدل دیگری به نام مدل کسینوسی با همان تعداد پارامتر در کارگاه آماری در دانشگاه لیزر پیشنهاد شد. سپس، **ماریا و همکاران (۲۰۰۷۸)** و **همکاران ماریا (۲۰۰۷۵)** خواص متوجهی از این مدل را مطالعه کردند. در ادامه این فعالیتها، **کنت و همکاران (۲۰۰۸)** به معرفی مدل فورگه^۲ از روی مدل های سینوسی و کسینوسی پرداختند. در همان زمان، **ماریا و همکاران (۲۰۰۸)** تصمیم چند متغیره مدل سینوس را ارائه دادند. اخیراً، بررسی تصمیم چندمتغیره این توزیع توسط **ماریا و واس (۲۰۱۳)** صورت گرفت. در کنار مسائل متنوع نظری احتمالاتی مرتبط با چنبره، مطالعه مدل های آماری و نیز مورد توجه محققین قرار گرفته است. به عنوان مثال، اخیراً **کنت و ماریا (۲۰۱۵)** درباره تعداد پیشش متعینها روی چنبره مطالعه کردند تا بتوانند از آن برای معرفی مدل آماری رگرسیونی مناسب استفاده کنند. با این حال ویژگیهای دیگری از این مدلها شایسته تحقیق و توسعه هستند که در پژوهش پیشنهادی حاضر به یکی از آنها پرداخته خواهد شد.

مطالعه زوایای دوسطمی^۳ با رویکرد مدل بندی در پیش گیری ساختار پروتئین ها از اهمیت زیادی برخوردار است. از سالیان قبل، دانشمندان علوم زیستی پراکتیکی نقاط مشاهده شده بر روی چنبره را در یک صفحه رسم می کردند که به افتخار پیشنهاد آن توسط **راماچاندران و همکاران (۱۹۶۳)** به آن، نمودار راماچاندران^۴ گفته می شود. در واقع نمودار راماچاندران وضعیت مجاز هر زاویه را برای ساختارهای پروتئین نشان می دهد. اگرچه نمایش تغییرات زوایا توسط نمودار راماچاندران از نظر شهودی آسان است. محققین را در مدل بندی احتمالاتی آن دچار اشتباه می کند. به عبارتی دیگر، توجه به نمایش واقعی نقاط روی چنبره می تواند انگیزه ای برای تفکر بیشتر در پایه ویزی مفاهیم متنوع آماری مانند رگرسیون بر روی این شکل هندسی شود. لذا، شکل ۱ (الف) نمودار راماچاندران پروتئینی خاص را نشان می دهد.

مقاله حاضر به اینصورت تدوین شده است که در بخش بعد جزئیاتی از توزیع فون میوز دو متغیره تشریح می شود. مدل بندی آمیختگی از توزیع فون میوز دو متغیره برای نیل به حوضه بندی در بخش ۳ می آید. تحلیل یک مثال واقعی مرتبط با مطالب مقاله در بخش ۴ خواهد آمد.

۲ توزیع فون میوز دو متغیره

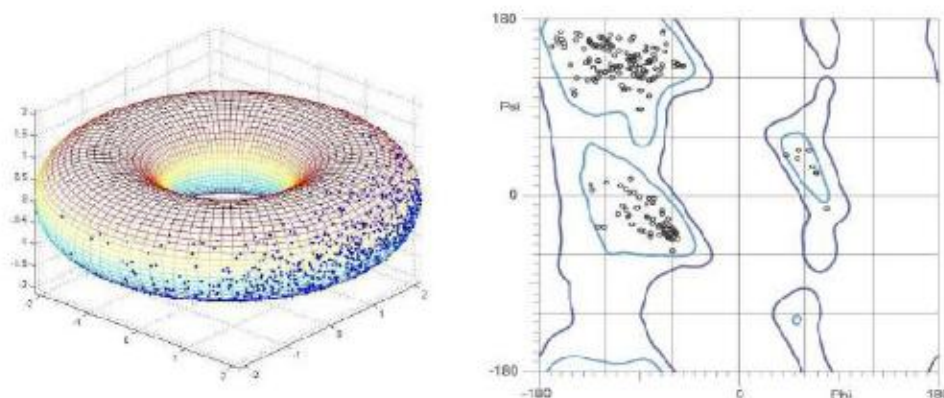
توزیع فون میوز یکی از توزیع های مفید و گارا برای مدل بندی داده های زاویهای است. تحقیقات وسیعی راجع به حالت یک متغیره این توزیع صورت گرفته است که **ماریا و چاپ (۲۰۰۰)** منبع مناسبی برای این منظور است. حالت دو متغیره آن اخیراً مورد توجه محققین آمار کاربردی بویژه آماردانان فعال در حوزه بیواتورماتیک قرار گرفته است. ویژگی های مدل خاصی از حالت دو متغیره این توزیع، نحوه برآورد پارامترها و الگوری تولید نمونه از آن توسط **نوری و گل علی زاده (۱۳۹۲)** صورت گرفته است.

^۱ Bivariate Von mises

^۲ Hybrid Model

^۳ Dihedral angles

^۴ Ramachandran



شکل ۱: (الف): نمودار با همپاندان زوایای در سطحی (ب): نمایش زوایای دو سطحی بر روی چتره

دو زاویه θ_1 و θ_2 را طوری که $-\pi \leq \theta_1, \theta_2 \leq \pi$ به عنوان دو متغیر زاویه‌ای در نظر بگیرید. حالت کلی تابع همگالی فون میزس دومتغیره که توسط **ماردیا (۱۹۷۵)** معرفی شده به صورت

$$f(\theta_1, \theta_2) = (c(k_1, k_2, A))^{-1} \exp \left\{ \kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) + [\cos(\theta_1 - \mu_1), \sin(\theta_1 - \mu_1)] A [\cos(\theta_2 - \mu_2), \sin(\theta_2 - \mu_2)]^T \right\} \quad (1.2)$$

است. بدینوسی که $\kappa_1, \kappa_2 > 0$ پارامترهای تمرکز و $-\pi \leq \mu_1, \mu_2 \leq \pi$ میانگین زاویه‌ای برای متغیرهای متناظر مربوطه هستند و $c(k_1, k_2, A)$ ثابت نرمال‌ساز است. در معادله (۱.۲) ماتریس $A = [a_{ij}]$ ماتریسی با بعد 2×2 است. اگر در ماتریس A قرار دهیم $a_{11} = \alpha$ و $a_{22} = \beta$ و $a_{12} = a_{21} = 0$ آنگاه داریم:

$$f_{\sin}(\theta_1, \theta_2) = (c(k_1, k_2, \lambda))^{-1} \exp \left\{ \kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) + \alpha \cos(\theta_1 - \mu_1) \cos(\theta_2 - \mu_2) + \beta \sin(\theta_1 - \mu_1) \sin(\theta_2 - \mu_2) \right\}.$$

حال با در نظر گرفتن $\lambda = \beta$ و $\alpha = 0$ تابع همگالی توزیع فون میزس دومتغیره به صورت

$$f_{\sin}(\theta_1, \theta_2) = (c(k_1, k_2, \lambda))^{-1} \exp \left\{ \kappa_1 \cos(\theta_1 - \mu_1) + \kappa_2 \cos(\theta_2 - \mu_2) + \lambda \sin(\theta_1 - \mu_1) \sin(\theta_2 - \mu_2) \right\} \quad (2.2)$$

خواهد شد که **سینگ و همکاران (۲۰۰۲)** آن را مدل سینوسی نامیدند و ثابت نرمال‌ساز را به صورت زیر بدست آوردند:

$$C_1 = c(k_1, k_2, \lambda) = \sqrt{\pi} \sum_{m=-\infty}^{\infty} \binom{\gamma m}{m} \left(\frac{\lambda}{\sqrt{k_1 k_2}} \right)^m I_m(k_1) I_m(k_2).$$

واضح است که پتا به (۶.۲) اگر $\lambda = 0$ آنگاه θ_1 و θ_2 از هم مستقل می‌شوند و علاوه بر آن هر کدام از متغیرهای زوایای θ_1 و θ_2 به صورت جداگانه دارای توزیع فون میزس تک‌متغیره خواهند بود.

اگر $\alpha = \beta = -\kappa_3$ آنگاه تابع چگالی مدل کسینوسی توزیع فون میزس دو متغیره به صورت

$$f_{\cos \theta_1, \theta_2}(\theta_1, \theta_2) = (c(k_1, k_2, k_3))^{-1} \exp \left\{ k_1 \cos(\theta_1 - \mu_1) + k_2 \cos(\theta_2 - \mu_2) - k_3 \cos(\theta_1 - \mu_1 - \theta_2 + \mu_1) \right\} \quad (۳.۲)$$

بندست می‌آید که در آن

$$c_2 = c(k_1, k_2, k_3) = (2\pi)^2 \left[I_0(k_1)I_0(k_2)I_0(k_3) + 2 \sum_{p=1}^{\infty} I_p(k_1)I_p(k_2)I_p(k_3) \right]$$

ثابت نرمال ساز است و $k_1 \geq k_3$ و $k_2 \geq k_3$ و پارامتر همبستگی است. واضح است که اگر در این مدل $\kappa_3 = 0$ آنگاه θ_1 و θ_2 از هم مستقل خواهند بود. علاوه بر این، اگر $\kappa_1 = \kappa_2 = \kappa_3 = 0$ آنگاه توزیع هر کدام از زوایا به توزیع یکنواخت روی دایره تبدیل می‌شود.

۳ مدل آمیخته توزیع فون میزس دو متغیره برای خوشه‌بندی زوایا

لاایل ذکر است که در مدل های سینوسی و کسینوسی معرفی شده احتمال انتخاب نقاط بر روی جنبه برای تمامی نقاط یکسان در نظر گرفته شده اما معرفی یک مدل آمیخته از این توزیع می تواند به احتمال انتخاب زوایای موجود در جنبه های متناسب با تراکم حضورشان دهنده که خود مبتنی متناسبی برای خوشه بندی مجموعه ای از زوایا خواهد بود. به زبانی ساده تر، ممکن است نمودار راماچاندوران برای زوج زوایای پیوندی پروتئین در تمام صفحه پراکنده نباشند و انباشتگی در بعضی از نقاط صفحه بیشتر از جاهای دیگر باشد. برای حل این مشکل ماریا و همکاران (۲۰۰۷۵) مدل آمیخته از توزیع فون میزس دو متغیره به صورت

$$f_{\text{mix}}(\phi, \psi, \Theta) = \sum_{j=1}^K \pi_j f_j(\phi, \psi, \theta_j) \quad (۱.۳)$$

پیشنهاد دادند. که در آن f_j تابع چگالی احتمال توزیع فون میزس دو متغیره برای پارامترهای $(k_j, \mu_j, \mu_j) = (\theta_j, k, k = 1, 2, 3, \mu_1, \mu_2)$ و $\theta_j = 1, 2, \dots, K$ و برای مدل کسینوسی و $(k_j, \mu_j, \mu_j) = (\theta_j, k, k = 1, 2, \lambda, \mu_1, \mu_2)$ و $\theta_j = 1, 2, \dots, K$ و همچنین $\sum_{j=1}^K \pi_j = 1$. واضح است که برآورد پارامترهای این توزیع آمیخته از طریق روش مستقیم ممکن نیست. مرسوم ترین روش برای این حال، به کارگیری الگوریتم EM است. آنچه که معمول است تشریح گام های این الگوریتم است.

گام های الگوریتم تا رسیدن به همگرایی در زیر آمده است:

گام اول: برآورد اعضای احتمال با استفاده از

(الف)

$$p_{ij} = \pi_j f_j(\phi_i, \psi_i, \theta_j)$$

برای هر $i = 1, 2, \dots, n$ و $z = 1, 2, \dots, K$

(ب) نرمال کردن $p_{iz} = p_{iz} / \sum_j p_{iz}$ برای $i = 1, 2, \dots, n$

گام سوم: برآورد ماکزیمم درستمایی (MLE) $\theta_j = (\lambda_j, \mu_{1j}, \mu_{2j})$ که با ماکزیمم کردن تابع درستمایی وزنی

$$\prod_{i=1}^n p_{iz} f_z(\phi_i, \psi_i, \theta_j)$$

برای $z = 1, 2, \dots, K$ بدست می‌آید.

گام سوم: بدست آوردن نسبت آمیخته شدن $\pi_z = \sum_i p_{iz}$

بنابراین **مارچیا و همکاران (۲۰۰۷)** انتقال داده‌ها $(\psi, -\phi) \rightarrow (\phi, \psi)$ در مدل سینوسی توزیع فون میزس دو متغیره مسبب همسانگردی با تغییر علامت پارامتر λ همراه است. در حالی که در مدل کسینوسی باعث جرخش در نمودار کانطور می‌شود. این انتقال برآزش بهتری برای این زوایای تصادفی فراهم می‌کند و با استفاده از این انتقال در گام دوم برآورد درستمایی برای هر z بدست می‌آید. سپس، تعداد خوشه با استفاده از معیار اطلاعاتی آکاتیک AIC بدست می‌آید.

۴ مطالعه یک مثال واقعی

برای تهیه مجموعه داده‌ها از پروتئین‌هایی که توسط NMR تعیین ساختار شده‌اند و تعداد متغیرهای آن برابر یا چهل متغیر بود استفاده شد. برای بدست آوردن اطلاعات ساختار دوم از برنامه DSSP استفاده و بعد در محیط مطلب اسیدهای آمینه موجود در ساختارهای پروتئینی بر اساس اطلاعات ساختار دوم در سه دسته قرار گرفتند. این پروتئین متشکل از تعدادی اسید آمینه و هر اسید آمینه با زوایای دو سطحی ϕ و ψ متصل می‌شوند. در پروتئین، ترتیب باقیمانده‌های اسید آمینه‌ها در زنجیره اصلی، تعیین‌کننده ساختار اول و تاخوردگی محلی ^۱ زنجیره‌ای از اسیدآمینه‌ها بیانگر ساختار دوم آن است. آلفا هلیکس^۲ و صفحات بتا بخش عمده‌ای از ساختارهای دوم را در پروتئین تشکیل می‌دهند. اما این ساختارهای منظم از طریق نواحی که ساختار منظمی ندارند به هم متصل می‌شوند که آنها را لوپ^۳ یا کویل^۴ می‌نامند. کویل‌ها نواحی هستند که معمولاً در سطح پروتئین قرار می‌گیرند. این نواحی معمولاً به صورت متصل‌کننده‌هایی بین دو ساختار منظم به حساب می‌آیند، اما می‌توانند از اهمیت ساختاری خاصی برخوردار باشند و حتی جایگاه فعال یا بخشی از عملکرد پروتئین را تشکیل دهند. در ساختار پروتئین مورد بررسی صفحات بتا و پیچ‌های آلفا وجود دارند که توسط کویل به هم متصل شده‌اند. خواننده علاقه مند برای اطلاع بیشتر می‌تواند به **راماچاندرا و همکاران (۱۹۶۳)** مراجعه کند.


برای شروع تحلیل آزمون همبستگی برای داده‌های بتا و مارپیچ آلفا و کویل بکار برده شد و مقدار آماری آزمون و نتایج حاصل از آن در جدول ۱ آمده است. لازم به ذکر است که فرضیه صفر در این آزمون عدم وجود همبستگی بین متغیرهای مورد بررسی است. با نگاهی به جدول ۱ - مقدار در جدول (۱) که برابر با ۱/۰۵۶ و ۰/۲۰۸ بدست آمده است می‌توان دریافت که فرضیه صفر در سطح ۰/۰۵ رد نمی‌شود و لذا مجموعه زوایای دو سطحی همبستگی معنی‌داری ندارند و در این صورت می‌توان نمونه‌ها را مستقل از هم در نظر گرفت. از نقطه نظر شهودی، به دلیل اینکه زوایای مورد مطالعه بر روی چنبره قرار دارد، از بین توزیع‌های موجود، توزیع فون میزس دو متغیره

^۱Local fold

^۲Helix

^۳Loop

^۴Coil



شکل ۲: نمودار راماجاندان داده‌ها بدستین

جدول ۱۱: نتایج آزمون همبستگی

داده	ρ -مقدار	مقدار همبستگی	مقدار آماره آزمون
ϕ	۰/۲۹۰	-۰/۵۹	۱/۰۵۶
ψ	۰/۸۳۳	۰/۰۱۲	-۰/۲۰۸

برای برازش مناسب‌تر بنظر می‌رسد. بنا به مطالب این مقاله و براساس نمایش راماجاندان مجموعه داده‌ها در شکل (۲)، مدل آمیخته‌ای از توزیع فونمیزس دو متغیره برای تحلیل بیشتر داده‌ها مدنظر قرار گرفته. با برازش مدل ۱-۳ توسط الگوریتم EM پارامترهای توزیع برآورد شدند که و نتایج عددی حاصل در جدول (۲) آمده است. برای نمایش هندسی مولفه‌ها در توزیع آمیخته، شکل (۳) رسم شد. تعداد خوشه‌های اولیه برای این الگوریتم ۵ خوشه برای داده‌های هلیکس، بنا و کوپل در نظر گرفته شد که مقدار احتمال ۳ خوشه بیشتر از همه بوده و بنابراین تعداد خوشه‌ها همانگونه که از ابتدا انتظار می‌رفت ۳ خوشه هلیکس، بنا و کوپل نشان داده می‌شود.

جدول ۲: برآورد EM پارامترهای مدل آمیخته

خوشه	μ_1	μ_2	μ_3	μ_4	μ_5	π
۱	۶/۲۳	۰/۲۲	-۳/۹	-۰/۸	۰/۹۳	۰/۲۳
۲	۱۱/۵۳	۱۵/۰۳	۸/۹۹	-۲/۸۵	۲/۹۹	۰/۱۵
۳	۶/۰۳	۱/۰۶	۰/۳۹	-۲/۱۳	-۰/۲۳	۰/۲۸

با فرض اینکه خوشه‌بندی مناسب این داده‌ها بوده و تعداد خوشه موجود ۳ هست، ترجیح داده شد از روش‌های موجود در خوشه‌بندی استفاده شود. روش k -means برای خوشه‌بندی این داده‌ها استفاده شد که درصد دقت روش خوشه‌بندی برابر با ۶۷۸ بدست

Proceedings of the Leeds Annual Statistical Research Conference, The Art and Science of Statistical Bioinformatics, Leeds University Press, Leeds , pp. 70-73.

Kent, J. T. and Mardia, K. V. (2015), The winding Number for Circular Data, In *Geometry-Driven Statistics and its Cutting Edge Applications: Celebrating Four Decades of Leeds Statistics Workshop.*, Eds. K.V. Mardia, A. Gusnanto, C. Nooney and J. Voss. Leeds University Press, 47-50.

Krishnan, T. H. R. I. Y. A. M. B. A. K. A. M., and McLachlan, G. J. (1997), *The EM algorithm and extensions*, John Wiley, New Jersey.

Mardia, K. V. (1975). Statistics of Directional Data, *Journal of the Royal Statistical Society, Series B*, 37, 349-393.

Mardia, K. V. and Jupp, P. (2000). *Directional Statistics*, John Wiley, New York.

Mardia, K. V., Taylor, C. C. and Subramanian, G. K. (2003), Applications of Circular Distribution to Conformational Angles in Proteins, In *Proceedings of the 22nd LASR Workshop*, edited by KV Mardia, RG Aykroyd and MJ Langdon, 149-152. Leeds University Press.

Mardia, K. V., Taylor, C. C. and Subramanian, G. K. (2007a), Protein Bioinformatics and Mixtures of Bivariate Von Mises Distribution for Angular Data, *Biometrics*, 63 , 502-512.

Mardia, K. V., Taylor, C. C. and Subramanian, G. K. (2007b), Bivariate Von Mises Densities for Angular Data with Application to Protein Bioinformatics, *Annals of Statistics*, 35, 166-180.

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. and Voss, J. (2014), Some Fundamental Properties of a Multivariate Von Mises Distribution, *Communications in Statistics-Theory and Methods*, 43, 1132-1144.

Ramachandran, G. N., Ramakrishnan, C., Sasisekharan, V. (1963), Stereochemistry of Polypeptide Chain Configurations, *Journal of Molecular Biology*, 7, 95-99.

Singh, H., Hnizdo, V. and Demchuk, E. (2002). Probabilistic Model for Two Dependent Circular Variable, *Bioinformatics*, 89, 719-723.