

بهبود عملکرد تحلیل ژئودزیک اصلی در تحلیل آمار شکل  
حمیدرضا فتوحی، موسی گل‌علی‌زاده  
گروه آمار، دانشگاه تربیت مدرس

تاریخ دریافت: ۱۳۹۱/۳/۱۸ تاریخ آخرین بازنگری: ۱۳۹۱/۹/۶

چکیده: یکی از هدف‌های تحلیل آماری شکل، علاوه بر دستیابی به برآورده از میانگین، برآورد واریانس شکل است، که از طریق تحلیل مولفه اصلی قابل حصول است. به دلیل محدودیت استفاده از روش تحلیل مولفه اصلی برای مجموعه داده‌هایی از فضای اقلیدسی، این روش برای داده‌های آمار شکل که ماهیتاً غیراقلیدسی هستند، قابل کاربرد نیست. در این حالت می‌توان از تحلیل ژئودزیک اصلی یا تقریب خطی آن به عنوان تعمیمی از تحلیل مولفه اصلی به فضای غیراقلیدسی استفاده نمود. از آنجا که اساس این روش مبنی بر الگوریتم گرادیان نزول است، در این مقاله با آشکار ساختن چند ضعف عمده آن، الگوریتم جدیدی معروفی می‌شود که هم منجر به برآورد استوار میانگین شکل و هم باعث حفظ ساختار هندسی شکل خواهد شد. سپس با ارائه جنبه‌های نظری روش تحلیل ژئودزیک اصلی، عملکرد آن در یک مطالعه شبیه‌سازی و یک مثال واقعی مورد ارزیابی قرار خواهد گرفت.

واژه‌های کلیدی: تحلیل مولفه اصلی، تحلیل ژئودزیک اصلی، الگوریتم گرادیان نزول، فضای غیراقلیدسی شکل.

آدرس الکترونیک مسئول مقاله: موسی گل‌علی‌زاده، golalizadeh@modares.ac.ir  
کد موضوع بندي رياضي (۲۰۰۵): ۳۲C۰۵، ۶۲P۱۰

پیشرفت‌های اخیر تکنولوژی موجب تسهیل مطالعه اشیاء از روی تصاویر هندسی آنها شده است. این موضوع علم آمار را با مسائل متفاوت و جدیدی مواجه کرده است که شکل شیء یک منع اطلاعاتی مناسب به شمار می‌رود. کنдал (۱۹۸۴) و بوک استاین (۱۹۸۶) از جمله کسانی بودند که به طور همزمان به مطالعه آماری اشیاء با در نظر گرفتن ساختار هندسی آنها پرداختند. حاصل زحمات آنها و محققین بعد از آنها، منجر به پیدایش شاخه جدیدی به نام آمار شکل گردیده است. یکی از جنبه‌های مهم تحلیل آماری شکل، برآورد ساختار تغییرات مربوط به شکل، از طریق نمونه تصادفی اخذ شده از اشیاء است. برای محاسبه واریانس شکل کوتز و همکاران (۱۹۹۲) و کنت (۱۹۹۴) برای اولین بار استفاده از تحلیل مولفه اصلی را در فضای مماس، که فضایی اقلیدسی است، به عنوان تقریبی از فضای شکل پیشنهاد کردند. این تقریب به این دلیل است که فضای شکل غیراقلیدسی است و استفاده مستقیم از تحلیل مولفه‌های اصلی در آن امکان‌پذیر نخواهد بود (درایدن و ماردیا، ۱۹۹۸).

پیروی از این روش ممکن است در بعضی موارد خاص قابل توجیه باشد، اما بهتر است واریانس شکل بدون تقریب و مستقیماً در همان فضای شکل محاسبه شود. لذا به نظر می‌رسد تعمیمی از تحلیل مولفه اصلی به فضای غیراقلیدسی، راه حل این مسئله باشد. یکی از تعمیم‌های تحلیل مولفه اصلی به فضای غیراقلیدسی تحلیل رئودزیک اصلی<sup>۱</sup> (PGA) است که اولین بار توسط فلتچر (۲۰۰۴) برای تحلیل تصاویر کامپیوتری پیشنهاد شد. اخیراً سامر و همکاران (۲۰۱۰) به ارزیابی این روش در چند مثال خاص پرداخته‌اند. مقاله حاضر با نگرشی اجمالی به این تحقیقات، الگوریتم جدیدی برای محاسبه میانگین استوار شکل با حفظ ساختار هندسی در مراحل نیل به میانگین ارائه می‌کند.

در بخش دوم این مقاله مطالعی مختصر از آمار غیراقلیدسی که در برگیرنده آمار شکل نیز است ارائه می‌شود. در بخش سوم دو معیار برای ارزیابی تغییرات

<sup>۱</sup> Principal Geodesic Analysis

داده‌های آمار شکل تشریح و عملکرد آنها در یک مثال کاربردی مورد مطالعه قرار می‌گیرد. در بخش چهارم به منظور بهبود عملکرد معیارهای ذکر شده، الگوریتم جدیدی پیشنهاد و کارآیی آن در یک مطالعه شبیه‌سازی و یک مثال واقعی با حالت استاندارد مورد مقایسه قرار می‌گیرد. سپس نتیجه‌گیری و پیشنهاداتی برای تحقیقات آتی در بخش پنجم ارائه خواهد شد.

## ۲ آشنایی با آمار غیراقلیدسی

در سال‌های اخیر مطالعه داده‌هایی که فضای رخداد آنها غیراقلیدسی هستند مورد توجه محققین قرار گرفته است (سامر و همکاران، ۲۰۱۰). دایره و کره مثال‌هایی از این قبیل هستند که ماردیا و جاپ (۲۰۰۰) از آنها به عنوان داده‌های سویی یاد می‌کنند. بر اساس مفاهیم توپولوژیکی، در منابع علمی چنین فضاهایی را منیفلد<sup>۲</sup> (M) می‌نامند. به زبانی ساده، منیفلد تعمیمی از رویه در فضاهای سه‌بعدی و بیشتر است. یکی از مهم‌ترین موضوعات آماری مربوط به مطالعه داده‌ها در منیفلدی خاص، نحوه محاسبه خلاصه‌های آماری است.

مشابه محاسبه میانگین داده‌ها در فضای اقلیدسی، پس از تعیین متر ریمانی مربوط به فضای منیفلد، که معمولاً آن را با  $d$  نمایش می‌دهند، با محاسبه مسئله کمینه‌سازی به صورت

$$\mu = \arg \min_{x \in M} \sum_{i=1}^N d(x, x_i) \quad (1)$$

و تعیین جواب آن در صورت وجود، میانگینی تحت عنوان میانگین ذاتی نتیجه می‌شود (پنس، ۱۹۹۹).

الگوریتم گرادیان نزول<sup>۳</sup> (GDA)، یکی از پرکاربردترین روش‌های محاسبات عددی برای نیل به این هدف است (کوشی، ۱۸۴۷؛ لئونبرگر، ۱۹۶۹؛ مزا، ۲۰۱۰). این الگوریتم در برگیرنده دو پارامتر تاثیرگذار، بهنام‌های خطای الگوریتم ( $\epsilon$ ) و اندازه گام برداری ( $\tau$ ) است و معمولاً توسط کاربر تعیین می‌شود.

<sup>۲</sup> Manifold

<sup>۳</sup> Gradient Descent Algorithm

محاسبه واریانس در فضاهای غیرآقلیدسی ارتباط تنگاتنگی با محاسبه میانگین در آن فضا دارد. به زبانی دقیق‌تر، واریانس نمونه‌ایی مشاهدات متعلق به یک فضای غیرآقلیدسی را می‌توان به عنوان مجموع توان‌های دوم فاصله ریمانی مشاهدات از میانگین ذاتی به صورت

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N d^2(\mu, x_i) = \frac{1}{N} \sum_{i=1}^N \| \log_\mu(x_i) \|^2,$$

تعریف کرد، که در آن  $\| \cdot \|$  نرم آقلیدسی، همچنین  $\log_\mu(x_i)$  بیانگر نگاشتی به منظور انتقال مشاهده  $x_i, i = 1, \dots, n$  از فضای غیرآقلیدسی به فضای مماس با مرکزیت  $\mu$  بوده و به نگاشت لگاریتمی معروف است (فلاتچر و همکاران، ۲۰۰۴). توجه کنید که نماد  $\exp_\mu(x_i)$  معکوس نگاشت لگاریتمی است و از آن به عنوان نگاشت نمایی یاد می‌شود.

ویژگی اصلی داده‌های آمار شکل این است که غیرآقلیدسی هستند، یعنی داده‌های حاصل از شکل ساختار هندسی اشکال دو بعدی، در یک ابر کره قرار دارند. در حالت خاص، اگر شیء مورد مطالعه مثلث باشد، کندال (۱۹۸۴) نشان داد فضایی که داده‌های برآمده از شکل در آن قرار دارند کره‌ای با شعاع نیم است.

### ۳ ارزیابی تغییرات داده‌های آمار شکل

پس از محاسبه میانگین، برآورد واریانس یکی از مسائل مورد علاقه در تحلیل آماری شکل است. برای دستیابی به این هدف، کنت (۱۹۹۴) استفاده از تحلیل مولفه اصلی در فضای مماس را پیشنهاد نمود.

فرض کنید  $n$  ماتریس  $(k+1) \times m$  به عنوان پیکره‌بندی  $X_1, \dots, X_n$  بعدی  $n$  شی مختلف در اختیار است. با پیش ضرب این ماتریس‌ها توسط زیر ماتریس هلمرت  $H$  با بعد  $(k+1) \times k$  و سپس تقسیم آنها به نرم آقلیدسی اشیاء مورد نظر به ماتریس‌های جدیدی می‌رسیم که نسبت به تبدیلات انتقال و مقیاس پایا هستند. آنها را به عنوان اطلاعات پیش شکل با نمایش ماتریسی  $Z_1, \dots, Z_n$  در نظر بگیرید. در این صورت مختصات متغیرهای شکل در فضای مماس با مرکزیت میانگین

شكل را می‌توان توسط رابطه

$$v_j = (I_{km-m} - Vec(\hat{\mu})Vec(\hat{\mu})^T)(Vec(Z_i\hat{\Gamma}_i)) \quad j = 3, \dots, k$$

تقریب زد، که  $Vec(\cdot)$  بیانگر عملگر برداری کننده،  $\hat{\mu}$  برآورد میانگین شکل به روش پروکراسنس تام و  $\hat{\Gamma}$  برآورد ماتریس دوران براساس انطباق بهینه پیش شکل‌ها به روش پروکراسنس تام است (کنت، ۱۹۹۴).

اکنون ماتریس کواریانس مختصات شکل در فضای مماس را به صورت  $S_v = \sum_{i=1}^n (v_i - \bar{v})(v_i - \bar{v})^T$  در نظر بگیرید. واضح است که به کمک  $S_v$  اعمال روش تحلیل مولفه اصلی در فضای مماس امکان پذیر خواهد بود. بهویژه، اثر زمین مولفه بر روی مشاهده  $i$  به صورت

$$x_{ij} = \gamma_j^T (v_i - \bar{v}) \quad i = 1, \dots, n; \quad j = 1, \dots, p \leq n$$

به دست می‌آید، که در آن  $p, \dots, 1, j = 1, \dots, n$  بردارهای ویژه ماتریس کواریانس  $S_v$  و  $\lambda$  مقدارهای ویژه متناظر با  $\gamma_j$  است. همچنین می‌توان با تقسیم زمین مولفه بر مقدار ویژه متناظرش، به اثر استاندارد شده زمین مولفه بر مشاهده  $i$  از طریق رابطه

$$\sigma_{ij} = x_{ij} / \lambda_j^{1/2}, \quad i = 1, \dots, n; \quad j = 1, \dots, p$$

دست یافت. حال با توجه به اینکه هر مولفه اصلی بیانگر درصدی از تغییرات کل می‌باشد، درصدی از عمدۀ تغییرات شکل، پیرامون میانگین جامعه، تحت هر مولفه قابل محاسبه است. بهویژه با محاسبه میانگین شکل، معمولاً تغییرات اصلی شکل تحت هر مولفه از طریق کمیت  $\gamma_j v + \sigma_{ij} \lambda_j^{1/2} = \bar{v} \pm \sigma_{ij}$  توصیف می‌شود.

هرچند می‌توان روش تحلیل مولفه اصلی را برای محاسبه واریانس در فضای شکل، که غیراقلیدسی است، مورد استفاده قرار داد اما یکی از مشکلات اساسی محدود بودن این روش به فضای اقلیدسی است. لذا استفاده مستقیم آن در فضای شکل امکان‌پذیر نبوده و همان‌گونه که کنت (۱۹۸۴) پیشنهاد نمود، باید فضای شکل را با فضای مماس، که اقلیدسی است، تقریب زد، سپس روش تحلیل مولفه اصلی را

به کار بست. پیروی از این روش ممکن است در بعضی موارد خاص قابل توجیه باشد، اما بهتر است واریانس شکل بدون تقریب و مستقیماً در فضای غیراقلیدسی شکل محاسبه شود.

PGA مشابه تحلیل مولفه اصلی، علاوه بر کاهش بعد داده‌ها روشی برآورده واریانس جامعه است. باید توجه داشت که برخلاف تحلیل مولفه اصلی که استفاده مستقیم آن محدودیتهایی را در بر دارد، می‌توان آن را زمانی که فضای مورد مطالعه غیراقلیدسی است به کار برد. به بیانی دیگر این روش تعییمی از تحلیل مولفه اصلی به فضای غیراقلیدسی است. لذا هنگام بکارگیری آن، با فرض غیراقلیدسی بودن فضای مورد مطالعه، هدف تصویر داده‌ها به داخل زیر فضایی با بعد کمتر است، طوری که داده‌های تصویر شده دارای بیشترین پراکندگی در اطراف میانگین باشند. محاسبه جهت‌های ژئودزیک اصلی در فضای شکل نیازمند محاسبه فرم کلی نگاشت لگاریتمی برای ابر کره با نقطه دلخواه  $\mu$  به عنوان نقطه شروع است. فتوحی و گل علی زاده (۲۰۱۲) نشان دادند که با تعیین معادله صفحه مماس روی کره‌ایی با ابعاد بالا ( $S^d, d > 3$ ، می‌توان شکل کلی نگاشت لگاریتمی نقطه  $\vec{x}$  با شروع از  $(x_0, \dots, x_d) \in S^d$

$$\log_{\vec{\mu}}(\vec{x}) = \frac{\theta}{\sin(\theta)} (\vec{x}_{[-d]}, 1) - \lambda \vec{\mu}$$

نوشت، که در آن  $\theta = \arccos(x_d)$  و

$$\lambda = \frac{\theta}{\sin(\theta)} (\vec{\mu}_{[-d]} \times \vec{x}_{[-d]}) + x_{0d} - 1$$

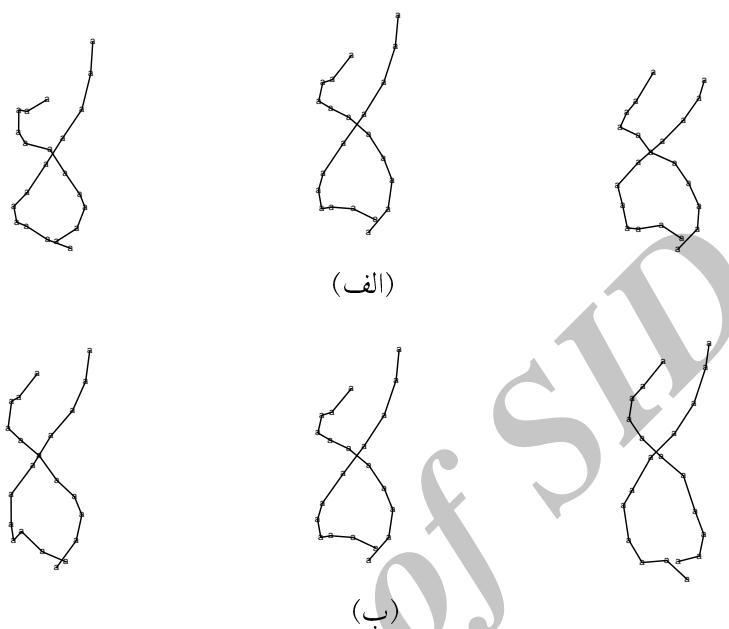
است، به قسمی که  $(\vec{x}_{[-d]} = (x_1, \dots, x_{d-1}), \vec{\mu}_{[-d]} = (x_{01}, \dots, x_{0d-1}))$  و  $\theta = \arccos(x_d)$  بیان این نکته ضروری است که این مقاله شامل دو سری مجموعه داده‌ها است. داده‌های اول مربوط به حرکت یک مولکول DNA در  $30^{\circ}$  زمان متفاوت می‌باشد، که اطلاعات مربوط به هر زمان در قالب ماتریسی با بعد  $3 \times 22$  ذخیره شده است. داده‌های مثال دوم، اطلاعات حاصل از تصاویر پزشکی مغز تعدادی از افراد است (درایدن و همکاران، ۲۰۰۲؛ فری و همکاران، ۲۰۰۱). این داده‌ها از طریق پایگاه الکترونیکی <http://cran.r-project.org/web/packages/shape> قابل دسترس است.

در این بخش برای بررسی عملکرد تحلیل مولفه اصلی و PGA، مجموعه داده‌های اول مدنظر قرار گرفته می‌شود. برای برآورد ساختار تغییرات مربوط به حرکت مولکول DNA، ابتدا فضای شکل با فضای مماس تقریب زده شده و دو مولفه اصلی اول در شکل ۱ رسم شده است که در آن ردیف اول بیانگر عمدۀ پراکندگی پیرامون میانگین شکل تحت اولین مولفه اصلی است. در واقع از روی این ردیف و با توجه به مقدار ویژه متناظر با اولین جهت اصلی، می‌توان نتیجه گرفت که در حدود  $44/2$  درصد از پراکندگی کل مربوط به نقاط شاخصی است که قسمت میانی بین دو شاخص مولکول و پیرامون آن را تشکیل می‌دهند. همچنین با توجه به ردیف دوم می‌توان دریافت که  $12/68$  درصد از تغییرات کل مربوط به قسمت‌های انتهایی شاخص‌های تشکیل دهنده مولکول است.

به منظور توصیف دقیق تر واریانس حرکت DNA در فضای واقعی شکل و بدون وجود محدودیت حاصل از به کار گیری تحلیل مولفه اصلی، از PGA برای ارزیابی تغییرات مربوط به حرکت مولکول بهره جسته و دو ژئودزیک تقریبی اول در شکل ۲ رسم شده است، ردیف اول بیانگر عمدۀ پراکندگی پیرامون میانگین شکل تحت اولین ژئودزیک اصلی است. در حقیقت از روی این ردیف و با توجه به مقدار ویژه متناظر با اولین جهت ژئودزیک اصلی، می‌توان نتیجه گرفت که در حدود  $79/9$  درصد از پراکندگی کل مربوط به میزان کشیدگی مولکول است. همچنین ردیف دوم این مطلب را بیان می‌کند که  $3/84$  درصد از تغییرات کل مربوط به نقاط شاخص میانی و نقاط انتهایی است. واضح است که تحقیق بیشتر در مورد حرکت مولکول DNA نیازمند لحاظ کردن نظر متخصصان زیست‌شناسی و در عین حال مدل‌بندی جامع‌تر است.

#### ۴ ارزیابی عملکرد الگوریتم گرادیان نزول

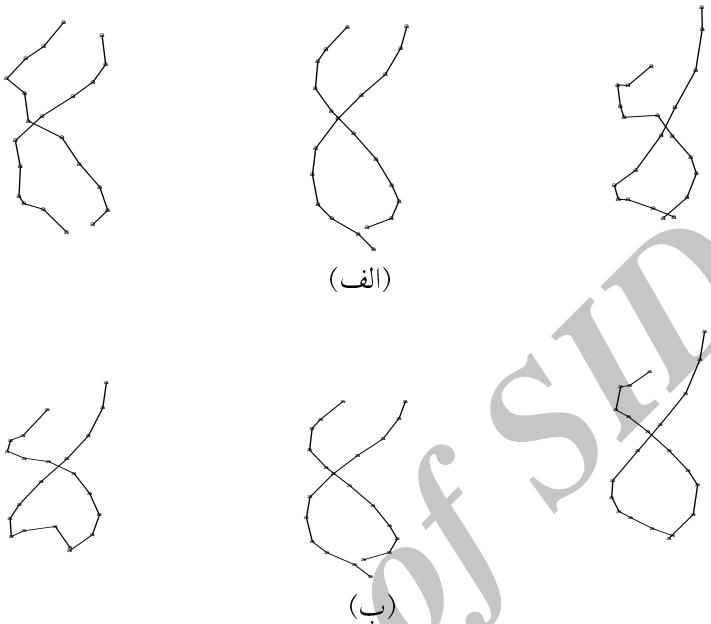
با مطالعه چگونگی دستیابی به میانگین ذاتی شکل می‌توان دریافت که GDA نقش اساسی را در فرآیند تکراری بازی می‌کند. با توجه به ماهیت این الگوریتم، هنگام استفاده از تحلیل ژئودزیک اصلی، ممکن است زمان رسیدن به میانگین ذاتی شکل



شکل ۱: واریانس ساختار مولکول DNA حول میانگین (نمودار وسط) با  $\pm 3$  انحراف استاندارد (نمودار چپ و راست). تغییرات توصیف شده توسط اولین مولفه (نمودار الف) ۴۴/۲ درصد و دومین مولفه (نمودار ب) ۱۲/۶۸ درصد

طولانی شود یا اساساً منجر به نتیجه مطلوبی نشود. برای روشن شدن این مطلب و بیان جزئیات بیشتر در این خصوص، ابتدا به بررسی تاثیر  $\tau$  در عملکرد الگوریتم مطرح شده پرداخته و سپس با استفاده از داده های واقعی آمارشکل، نقش آن در ایجاد ضعف برای GDA نشان داده خواهد شد. بنا به محاسبات شبیه سازی و تجربیات نویسندهای این مقاله، باید به این نکته اشاره کرد که انتخاب مقدار مناسب  $\tau$  تا حدودی سلیقه ای است و آنچه تاثیر بیشتری در عملکرد الگوریتم دارد پارامتر  $\tau$  است. از این رو بیشتر به نقش  $\tau$  معطوف خواهد شد، اما در بخش مثال واقعی با انتخاب چند مقدار مختلف برای  $\tau$  نقش این پارامتر در دستیابی به میانگین ذاتی شکل نیز نشان داده خواهد شد.

در این قسمت عملکرد GDA در یک مثال کاربردی، مربوط به تصاویر پزشکی مغز تعدادی از افراد مورد بررسی قرار می گیرد و نشان داده خواهد شد GDA از



شکل ۲: واریانس ساختار مولکول DNA حول میانگین (نمودار وسط) با  $\pm 3$  انحراف استاندارد (نمودار چپ و راست). تغییرات توصیف شده توسط اولین رئوذیک (نمودار الف) ۷۹/۹ درصد و دومین رئوذیک (نمودار ب) ۳/۸۴ درصد

چند ضعف عمدیه برخوردار است. سپس الگوریتم پیشنهادی جدیدی برای بهبود آن ارائه می‌شود.

بنا به توضیحات مربوط به GDA، ضروری است مقادیر  $\epsilon$  و  $\tau$  از قبیل مشخص شوند. از آنجا که هدف بررسی تاثیر این دو پارامتر بر عملکرد آن است،  $\epsilon$  برای بروز اختیار شده است. به علاوه  $\epsilon$  و  $\tau$ ،  $1,0 / 4,0 / 7,1$  و  $1,0 / 0,6 / 0,1$  میانگین حسابی همه ماتریس‌های پیکربندی موجود به عنوان نقطه شروع اولیه برای الگوریتم در نظر گرفته شده است. برای مقادیر  $\epsilon$  و  $\tau$  میانگین ذاتی شکل محاسبه و تعداد تکرارهای ممکن تا رسیدن به همگرایی در قالب جدول ۱ رائی شده‌اند. البته در بعضی از موارد که الگوریتم واگرا است به جای تعداد تکرار، کلمه "واگرا" یادداشت شده است.

بنابراین جدول ۱، به جز برای  $\varepsilon = 0/6$  و قیمت مقدار  $\tau$  به ۱ می‌رسد GDA واگرا می‌شود. این موضوع برای  $\varepsilon = 0/0$  حتی برای مقادیر کم  $\tau$  نیز اتفاق می‌افتد. نکته دیگر همگرایی GDA در تکرارهای دوم برای مقادیر  $\tau$  غیر از  $0/1$  و  $0/4$  است. پیش بینی می‌شود برای  $\varepsilon$  های بزرگ‌تر، تعداد تکرار تا رسیدن به همگرایی عددی بیشتر از ۲ باشد. نتیجه کلی این جدول، به نوعی بیانگر عدم ثبات رفتار توسط الگوریتم برای مقادیر متفاوت  $\varepsilon$  و  $\tau$  است. بهویژه در موضعی که این روش همگرایی نمی‌شود، نقش این دو پارامتر بر جسته تراز وضعیت‌هایی است که روش به همگرایی می‌رسد.

جدول ۱: تعداد تکرار در اجرای GDA تا رسیدن به همگرایی.

		$\varepsilon$					
		$0/01$	$0/06$			$0/1$	$0/6$
				$\tau$			
		۱	۱	۱	۱	۰/۱	
واگرا	۲			۱	۱		$0/4$
واگرا	۲			۲	۲		$0/7$
واگرا	واگرا			۲	۱		

برای بررسی وضعیت ساختار هندسی شکل حاصل از گام‌های مختلف این روش، میانگین پروکراسیس که به آسانی قابل محاسبه است به عنوان ملاک ارزیابی، مورد استفاده قرار گرفته است. از این‌رو از ملاک OPA<sup>۴</sup> برای مقایسه دو ساختار هندسی استفاده شده است (فتوحی و گل‌علیزاده، ۲۰۱۲).

براساس این ملاک دو ساختار هندسی طوری روی هم‌دیگر منطبق می‌شوند که کمترین اختلاف ممکن را از یگدیگر داشته باشند. جزئیات بیشتر در زمینه انطباق بهینه در درایدن و ماردیا (۱۹۹۸) موجود است. برای مثال ذکر شده، ساختار هندسی اول، میانگین پروکراسیس شکل و ساختار هندسی دوم، ماتریس پیکره‌بندی خروجی حاصل از هر مرحله الگوریتم در نظر گرفته شد. مقدار  $\tau$  همان مقادیر فوق و  $\varepsilon$  برابر  $0/6$  در نظر گرفته شد و برای هر حالت کمیت OPA محاسبه شده

<sup>۴</sup> Ordinary Procrustes Analysis

است. نتایج حاصل، همراه با نمایش هندسی دو میانگین پروکراستس و ذاتی در شکل ۳ نمایش داده شده است. همان‌گونه که ملاحظه می‌شود با افزایش  $\tau$  کمیت OPA نیز افزایش می‌یابد. در نتیجه اختلاف بین دو میانگین بیشتر می‌شود، و تعییر آن این است که ساختار هندسی میانگین ذاتی شکل خیلی دورتر از میانگین پروکراستس شکل خواهد شد. به عبارتی دیگر ناپایداری در ساختار هندسی بیشتر شده و میانگین حاصل از الگوریتم ذکر شده معتبر نخواهد بود.

نتایج کلی این بخش به ما کمک می‌کند تا الگوریتم جدیدی را که به طریقی درس‌گیرنده تعامل مناسبی از پارامترهای بهینه‌سازی و معیارهای آمار شکل است، در بخش بعد پیشنهاد نماییم.

#### ۱.۴ الگوریتم گرادیان نزول استوار

در این بخش برای رفع ضعف بیان شده در بخش قبل، الگوریتم جدیدی پیشنهاد می‌شود. چون در آمارشکل، حفظ هندسه اشکال از اهمیت بسیاری برخوردار است، الگوریتم طوری طراحی می‌شود که تحت تغییر عوامل موثر مانند  $\tau$  و  $\epsilon$  استوار باشد. به همین دلیل الگوریتم گرادیان نزول استوار<sup>۵</sup> (RGDA) نامیده می‌شود.

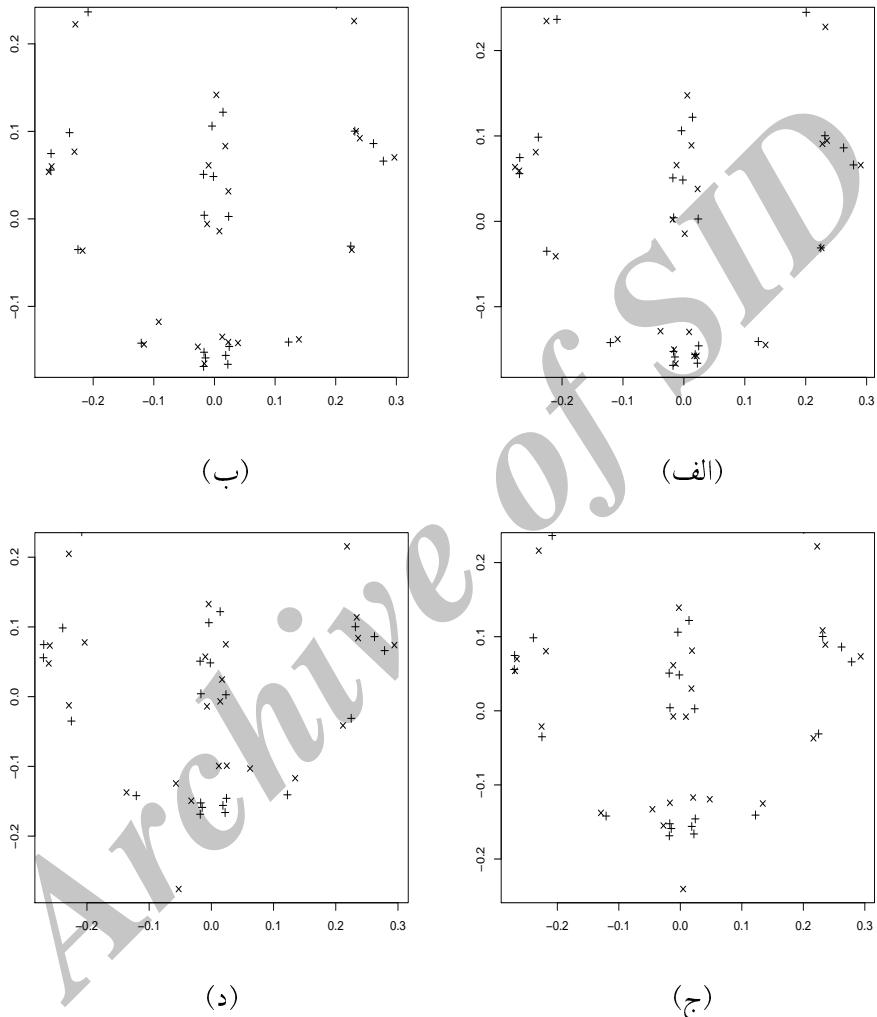
یکی از مزیت‌های آن این است که در هر مرحله از الگوریتم، میزان انحراف هندسی خروجی از مقدار واقعی، براساس معیار میانگین مجموع توان‌های دوم عادی<sup>۶</sup> (MOPA) بررسی می‌شود. محاسبه این ملاک به این ترتیب است که با استفاده از انطباق بهینه به روش پروکراستس، در هر مرحله از اجرای الگوریتم استاندارد، اختلاف بین ساختار هندسی خروجی الگوریتم و هر یک از ماتریس‌های پیکره‌بندی مشاهدات را محاسبه کرده، سپس میانگین حسابی این اختلاف‌ها به عنوان ملاکی برای ارزیابی میزان انحراف از ساختار هندسی، استفاده شود.

بنابراین با توجه به این ملاک می‌توان الگوریتم مورد مطالعه در این مقاله را به گونه‌ای تعمیم داد که هندسه شکل در هر مرحله مورد بازبینی قرار گیرد. سپس

<sup>۵</sup> Robust Gradient Descent Algorithm

<sup>۶</sup> Mean of Ordinary Procrustes Analysis

## کاربست PGA در فضای شکل ۲۳°



شکل ۳: میانگین پروکراسس (+) و ذاتی (×) ساختار هندسی مغز از طریق اجرای GDA. الف:  $\text{OPA} = 0^\circ / 0^\circ 561$ ,  $\tau = 0^\circ / 4^\circ 127$ , ب:  $\text{OPA} = 0^\circ / 0^\circ 561$ ,  $\tau = 0^\circ / 1^\circ 127$ , ج:  $\text{OPA} = 0^\circ / 0^\circ 561$ ,  $\tau = 1^\circ 127$  و د:  $\text{OPA} = 0^\circ / 1^\circ 072$ ,  $\tau = 0^\circ / 7^\circ 127$

براساس حفظ یا از بین رفتن هندسه شکل تعیین شود. به این ترتیب که اگر هندسه شکل در هر مرحله حفظ شد، الگوریتم فرایند عادی مربوط به خود را طی کند، اما اگر هندسه شکل از بین رفت، الگوریتم گرادیان نزول طوری طراحی شود که میانه میانگین‌های به دست آمده در مرحله قبلی و اخیر را به دست آورده و با در نظر گرفتن آن به عنوان نقطه شروع جدید فرایند مرحله قبل را طی کند.

#### ۲.۴ ارزیابی عملکرد RGDA

در این بخش با اجرای الگوریتم پیشنهاد شده روی داده‌های مغز و محاسبه میانگین ذاتی شکل به ازای مقادیر  $\tau$  متعلق به بازه  $[1/0, 0/1]$ ، علاوه بر مطالعه برخی ویژگی‌های کلیدی آن، عملکردش در مقابل حالت استاندارد مورد ارزیابی قرار می‌گیرد. روش انجام آزمایش مشابه بخش قبل است.

تعداد تکرارهای لازم تا رسیدن به همگرایی توسط RGDA در جدول ۲ آمده است. نکته قابل تأمل عدم واگرایی این روش به ازای کلیه ترکیب‌های در نظر گرفته برای  $\tau = 0$  است. این مطلب خود به نوعی ارجحیت روش پیشنهادی را نشان می‌دهد. به علاوه، ملاحظه می‌شود که برای هر مقدار ثابت  $\tau$  با افزایش  $\epsilon$  تعداد تکرار نیز افزایش می‌یابد و یک روند معکوس برای تعداد تکرارها با افزایش  $\epsilon$  به ازای مقادیر ثابت  $\tau$  قابل مشاهده است. این نتایج تاییدی بر ادعای مطرح شده در بخش قبل مبنی بر بهبود GDA با اختیار مقادیر بزرگ  $\epsilon$  و مقادیر کوچک  $\tau$  است.

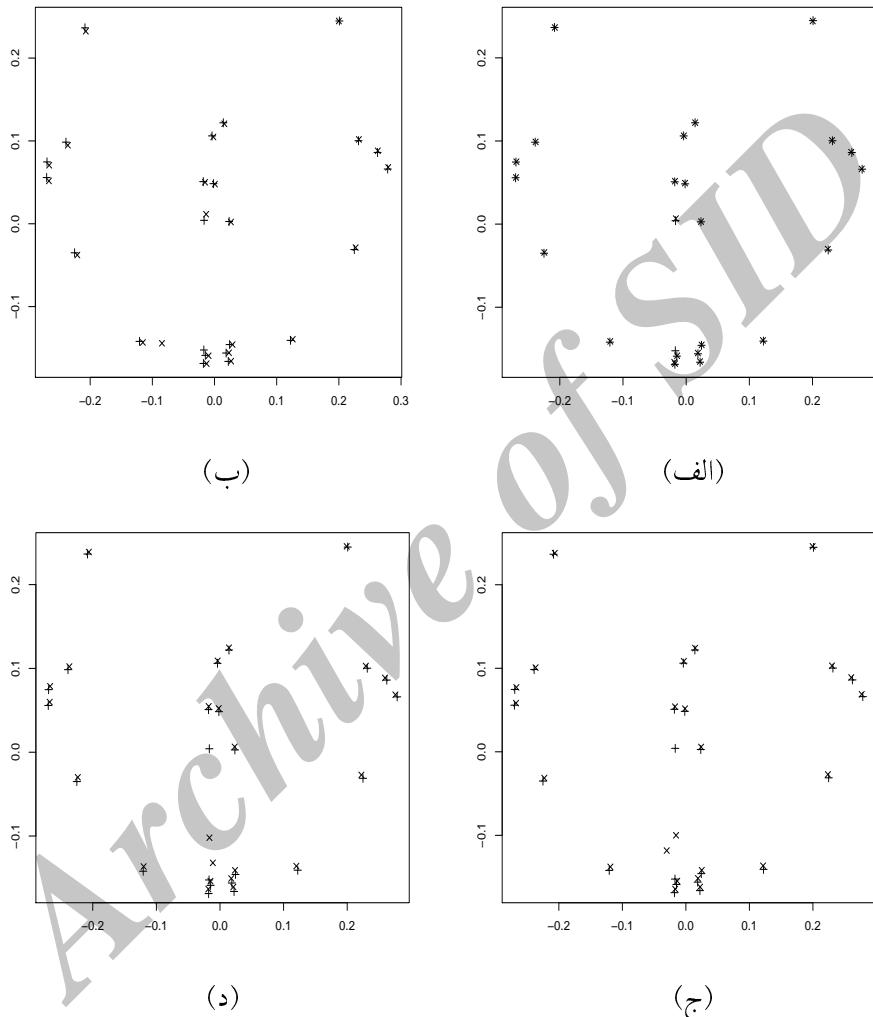
جدول ۲: تعداد تکرار در اجرای روش RGDA تا رسیدن به همگرایی.

$\epsilon$					$\tau$
$0/01$	$0/06$	$0/1$	$0/6$		
۴	۱	۱	۱	۰/۱	
۵	۲	۱	۱	۰/۴	
۵	۲	۲	۱	۰/۷	
۷	۴	۵	۳	۱	

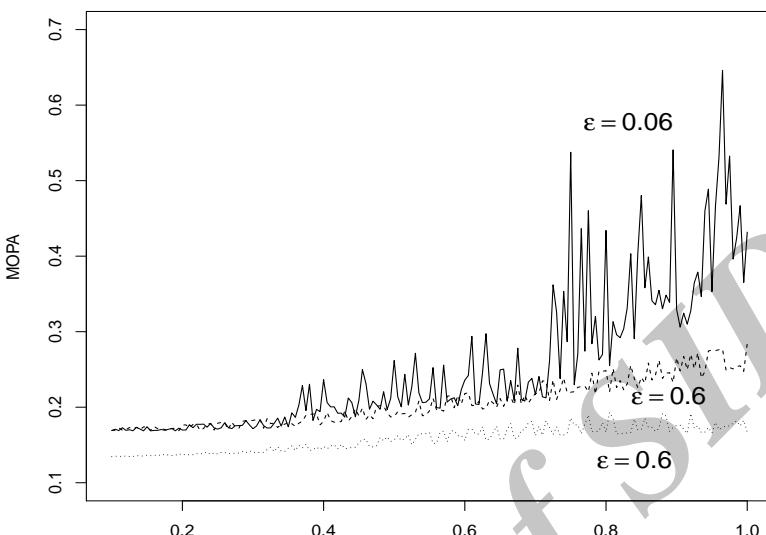
اکنون با ثابت نگهداشتن  $\epsilon$  در مقدار  $6/0\%$  به بررسی پایداری ساختار هندسی میانگین ذاتی به ازای مقادیر  $\tau$  پرداخته می‌شود. نتایج حاصل به صورت نموداری با مختصات دکارتی میانگین ذاتی شکل همراه با کمیت OPA به ازای مقادیر متفاوت  $\tau$  در شکل ۴ نمایش داده شد. به علاوه مقایسه عینی میانگین پروکراستس نیز در نمودار گنجانده شده است. روند نزولی کمیت OPA برای وقتی که  $\tau$  افزایش می‌یابد همانند روند مشابه در بخش قبل است. اما نکته حائز اهمیت کاهش این مقادیر برای حالت متناظر آن با استفاده از GDA است. این نتیجه نشان می‌دهد که عملکرد الگوریتم ارائه شده به مراتب بهتر از حالت استاندارد است. در نهایت برای دو مقدار  $\epsilon$  برابر  $6/0\%$  و  $0/0\%$  ملاک MOPA به ازای تمامی مقادیر  $\tau$  در بازه  $[1/0]$ ، محاسبه و نتایج حاصل در شکل ۵ نشان داده شده است. ملاحظه می‌شود که با افزایش  $\tau$  این ملاک نیز افزایش می‌یابد. اما این روند افزایشی برای عهای بزرگ به مراتب کمتر از عهای کوچک است و در سراسر حوزه تغییرات  $\tau$ ، مقدار آن برای الگوریتم جدید همواره کمتر از استاندارد است. نتیجه کلی این است که با استفاده از RGDA نه تنها معیارهای اختلاف کمتر شده، بلکه پایداری ساختار هندسی برای میانگین ذاتی شکل نیز بیشتر شده است. اضافه بر این با استفاده از آن وجود میانگین ذاتی شکل همواره تضمین می‌شود.

## بحث و نتیجه‌گیری

در این مقاله با تعمیم تحلیل ژئودزیک اصلی به فضای شکل، واریانس مولکول DNA محاسبه و با نتایج تحلیل مولفه اصلی مورد مقایسه قرار داده شد. پایداری هندسه میانگین شکل براساس پارامترهای الگوریتم گرادیان نزول برای توسعی تحلیل ژئودزیک اصلی به فضای شکل ضروری است. لذا براساس داده‌های پژوهشی مغز انسان، اثر نامطلوب آنها مورد بررسی و مطالعه قرار گرفت. سپس با ارائه ملاک مناسب برای تعیین ساختار هندسی اشیاء، الگوریتم استوارتری نسبت به حالت استاندارد پیشنهاد شد. به علاوه با اجرای الگوریتم پیشنهادی روی داده‌های مغز، ارجحیت آن در بهبود عملکرد تحلیل ژئودزیک اصلی نشان داده شد.



شکل ۴: میانگین پروکراسیس (+) و ذاتی (×) ساختار هندسی مغز از طریق اجرای RGDA. الف:  $\tau = ۰/۱$ ,  $OPA = ۰/۰۰۰۲۱$ , ب:  $\tau = ۰/۴$ ,  $OPA = ۰/۰۰۰۴۸$ , ج:  $\tau = ۱/۷$ ,  $OPA = ۰/۰۱۳۰$ , د:  $\tau = ۷/۱۷۸$ ,  $OPA = ۰/۰۱۷۸$



شکل ۵: مقایسه میزان حاصل از RGDA به ازای خطای ثابت  $\epsilon$  ( نقطه چین ) با حالت استاندارد به ازای خطاهای  $6^{\circ}$  (خط چین) و  $0^{\circ}$  (خط ممتد) جهت برآورد میانگین ذاتی شکل

### تقدیر و تشکر

نویسنده‌گان از داوران محترم که پیشنهادهای سازنده‌ای برای بهبود این مقاله ارائه کردند تقدیر و تشکر می‌نمایند.

### مراجع

- Bookstein, F. L. (1986), Size and Shape Spaces for Landmark Data in Two Dimensions (with discussion), *Statistical Science*, **1**, 181-242.
- Buss, S. R. and Fillmore, J. P. (2001), Spherical Averages and Application to Spherical Splines and Interpolation, *ACM Transaction on Graphics*, **20**, 95-126.
- Cauchy. A. (1847), Methodes Generales Pour La Resolution Des Systemes Dequations Simultanees. *Compte Rendu Academie des Sci-*

- ences. *Paris*, **25**, 536-538.
- Cootes, T. F., Taylor, C. J., Cooper, D. H., and Graham. J. (1992), Training Models of Shape from Sets of Examples, In Hogg, D. C. and Boyle, R. D. (eds), *British Machine Vision Conference*, 9-18, Springer-Verlag, Berlin.
- Dryden, I. and Mardia, K. (1998), *Statistical Shape Analysis*. New York, Wiley.
- Dryden, I., Kume, A., Le, H., Wood, A. T. and Laughton, C. (2002), Size-and-Shape Analysis of DNA Molecular Dynamics Simulations, *In Proceedings of Statistics of Large Datasets, LASR2002, University of Leeds, Leeds*, 23-26.
- Fotouhi, H. and Golalizadeh, M. (2012). Exploring Variability of DNA Molecules via Principal Geodesic Analysis on the Shape Space. *Journal of Applied Statistics*, **39**, 2199-2207.
- Fletcher, P. (2004). *Statistical Variability in Nonlinear Spaces: Application to Shape Analysis and DT-MRI*, Ph.D Thesis, University of North Carolina at Chapel Hill.
- Fletcher, P., Lu, C., Pizer, S., Joshi, S. (2004), Principal Geodesic Analysis for the Study of Nonlinear Statistics of Shape, *Medical Imaging, IEEE Transactions*, **23**, 995-1001.
- Free, S. L., O'Higgins, P., Maudgil, D. D., Dryden, I. L., Lemieux, L., Fish, D. R. and Shorvon, S. D. (2001), Landmark-Based Morphometrics of the Normal Adult Brain Using MRI. *Neuroimage*, **13**, 801-813.

- Kendall, D. G. (1984), Shape Manifolds, Procrustean Metrics and Complex Projective Spaces, *Bulletin of the London Mathematical Society*, **16**, 81-121.
- Kent, J. T. (1994), The Complex Bingham Distribution and Shape Analysis, *Journal of the Royal Statistical Society. Series B*, **56**, 285-299.
- Luenberger, D. G. (1969), *Optimization by Vector Space Method*. New York, Wiley.
- Mardia, K. and Jupp, P. (2000), *Directional Statistics*, New York, Wiley.
- Meza, J. C. (2010), Steepest Descent, *Wiley Interdisciplinary Review: Computational Statistics*, **2**, 719-722.
- Pennec, X. (1999), Probabilities and Statistics on Riemannian Manifolds: Basic Tools for Geometric Measurements, *IEEE Workshop on Non-linear Signal and Image Processing*, Antalya, Turkey.
- Sommer, S., Lauze, F., Hauberg, S. and Nielson, M. (2010), Manifold Valued Statistics, Exact Principal Geodesic Analysis and the Effect of Linear Approximations, *Lecture Notes in Computer Science*, **63**, 43-56.