

Population structure identification of Turkmen and Darehshori horses using PCA, DAPC, and SPC methods

Ghazaleh Javanmard 

MSc Student, Department of Animal Science, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail address: gh.javanmard@ut.ac.ir

Mohammad Moradi Shahrbabak 

Professor, Department of Animal Science, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail address: moradim@ut.ac.ir

Hossein Moradi Shahrbabak 

*Corresponding author. Assistant Professor, Department of Animal Science, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail address: hmoradis@ut.ac.ir

Javad Rahmaninia 

Assistant Professor, Animal Sciences Research Institute of Iran, Agricultural Research, Education and Extension Organization (AREEO), Karaj, Iran. E-mail address: javad_rahmaninia@yahoo.com

Mahdi Abbasi Firoozjaei 

MSc Student, Department of Animal Science, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail address: mahdiabbasi@alumni.ut.ac.ir

Mohammad Bagher Zandi 

Assistant Professor, Department of Animal Science, Faculty of Agriculture, University of Zanjan, Zanjan, Iran. E-mail address: mbzandi@znu.ac.ir

Abstract

Objective

Conservation of the genetic diversity of indigenous animals is very important. For the sustainable use of genetic resources, it is necessary to first study the genetic structure of populations. The main goals of this research were to identify the population structure of Turkmen and Darehshori horses using dense SNP markers and to compare the effectiveness of PCA, DAPC, and SPC methods in clustering these populations.

Materials and methods

For this purpose, 67 Turkmen and 39 Darehshori horses were genotyped using Illumina EquineSNP70 BeadChip. After applying quality control steps, five Turkmen horses and one Darehshori horse were removed. Then, the structure of populations was identified by three methods of principal component analysis (PCA), discriminant analysis of principal components

(DAPC), and superparamagnetic clustering (SPC). These methods do not depend on previous assumptions and make it possible to analyze very large genome databases without prior knowledge of individual ancestry. These methods are also very fast and efficient.

Results

This study compared the efficiency of these three clustering methods in identifying population structures. All three methods were successful in separating the two breeds, and Turkmen and Darehshori breeds were grouped into separate genetic groups. The difference is that the DAPC method only separated the two main populations, but the PCA and SPC methods could identify several subpopulations in each breed. The results of this study showed that the SPC method for studying the population structure of indigenous breeds with unknown information can be more useful than other methods. Therefore, using this method, a suitable program can be designed to conserve and use genetic resources.

Conclusions

PCA, DAPC, and SPC methods were able to successfully identify the genetic structure of Turkmen and Darehshori breeds, and in general, it can be said that the information obtained from dense SNP markers can be a powerful tool for identifying the population structure of indigenous breeds.

Keywords: Discriminant analysis of principal components, Principal component analysis, Subpopulation, Superparamagnetic clustering

Paper Type: Research Paper.

Citation: Javanmard G, Moradi Shahrabak M, Moradi Shahrabak H, Rahmaninia J, Abbasi Firoozjaei M, Zandi MB (2022) Population structure identification of Turkmen and Darehshori horses using PCA, DAPC, and SPC methods. *Agricultural Biotechnology Journal* 14 (4), 200-220.

Agricultural Biotechnology Journal 14 (4), 200-220. DOI: 10.22103/jab.2022.18795.1372

Received: October 23, 2022.

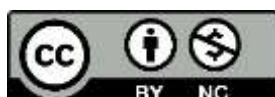
Received in revised form: November 23, 2022.

Accepted: November 24, 2022.

Published online: November 30, 2022

Publisher: Faculty of Agriculture and Technology Institute of Plant Production, Shahid Bahonar University of Kerman-Iranian Biotechnology Society.

© the authors



غزاله جوانمرد

دانشجوی کارشناسی ارشد، گروه علوم دامی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانame:
gh.javanmard@ut.ac.ir

محمد مرادی شهربابک

استاد، گروه علوم دامی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانame:
moradim@ut.ac.ir

حسین مرادی شهربابک

*نویسنده مسئول: استادیار، گروه علوم دامی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانame:
hmoradis@ut.ac.ir

جواد رحمانی نیا

استادیار پژوهشی، موسسه تحقیقات علوم دامی کشور، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران. رایانame:
javad_rahmaninia@yahoo.com

مهدى عباسی فیروزجایی

دانشجوی کارشناسی ارشد، گروه علوم دامی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانame:
mahdiabbasi@alumni.ut.ac.ir

محمدباقر زندی

استادیار، دانشگاه زنجان، دانشکده کشاورزی، گروه علوم دامی، زنجان، ایران. رایانame:
mbzandi@znu.ac.ir

تاریخ دریافت: ۱۴۰۰/۱۱/۱۹ تاریخ دریافت فایل اصلاح شده نهایی: ۱۴۰۰/۱۲/۱۶ تاریخ پذیرش: ۱۴۰۰/۱۲/۱۷

چکیده

هدف: حفاظت از تنوع ژنتیکی حیوانات بومی، امر بسیار مهمی است. برای استفاده پایدار از منابع ژنتیکی، باید ابتدا به مطالعه ساختار ژنتیکی جمعیت‌ها پرداخت. اهداف اصلی این پژوهش، شناسایی ساختار جمعیتی اسبهای نژاد ترکمن و دره‌شوری با استفاده از نشانگرهای متراکم SNP و مقایسه کارایی روش‌های PCA، DAPC و SPC در خوش بندی این جمعیت‌ها بود.

مواد و روش‌ها: برای این منظور، ۶۷ راس اسب از نژاد ترکمن و ۳۹ راس اسب از نژاد دره‌شوری با استفاده از تراشه K ۷۰ شرکت ایلومینا (Illumina EquineSNP70 BeadChip) تعیین ژنتیک شدند. پس از اعمال مراحل کنترل کیفیت، پنج راس اسب ترکمن و یک راس اسب دره‌شوری حذف شدند. سپس با استفاده از سه روش تجزیه و تحلیل مولفه‌های اصلی (PCA)، تجزیه و تحلیل تفکیکی مولفه‌های اصلی (DAPC) و خوشبندی فوق پارامغناطیسی (SPC) شناسایی ساختار جمعیت‌ها انجام شد. این روش‌ها به مفروضات پیشین وابسته نیستند و در نتیجه، تجزیه و تحلیل مجموعه داده‌های ژنومی بسیار حجمی را بدون دانش قبلی درباره انساب افراد، امکان‌پذیر می‌کنند. همچنین این روش‌ها بسیار سریع و کارآمد هستند.

نتایج: در این پژوهش، کارایی سه روش خوشبندی یادشده در تشخیص ساختارهای جمعیتی مقایسه شد. هر سه روش در تفکیک دو نژاد موفق بودند و نژادهای ترکمن و دره‌شوری در گروههای مجزای ژنتیکی قرار گرفتند؛ با این تفاوت که روش DAPC صرفاً دو جمعیت اصلی را از هم تفکیک کرد اما روش‌های SPC و PCA زیرجمعیت‌های متعددی را نیز در هر نژاد شناسایی کردند. نتایج این پژوهش نشان داد روش SPC برای مطالعه ساختار جمعیت نژادهای بومی با اطلاعات ناشناخته، می‌تواند مفیدتر از سایر روش‌های مورد بررسی باشد. بنابراین، با استفاده از این روش می‌توان برنامه مناسبی برای حفظ و استفاده از منابع ژنتیکی طراحی کرد.

نتیجه‌گیری: روش‌های PCA، DAPC و SPC توانستند ساختار ژنتیکی نژادهای ترکمن و دره‌شوری را با موفقیت شناسایی کنند و به طور کلی می‌توان گفت اطلاعات به دست آمده از نشانگرهای متراکم SNP می‌تواند ابزار قدرتمندی برای شناسایی ساختار جمعیتی نژادهای بومی باشد.

کلیدواژه‌ها: تجزیه تفکیکی مولفه‌های اصلی، تجزیه مولفه‌های اصلی، خوشبندی فوق پارامغناطیسی، زیرجمعیت.

نوع مقاله: پژوهشی.

استناد: جوانمرد غزاله، مرادی شهربابک محمد، مرادی شهربابک حسین، رحمانی نیا جواد، عباسی فیروزجایی مهدی، زندی محمدباقر (۱۴۰۱) شناسایی ساختار جمعیتی اسب‌های ترکمن و دره‌شوری با استفاده از روش‌های PCA، DAPC و SPC. مجله بیوتکنولوژی کشاورزی، ۱۴(۴)، ۲۰۱-۲۲۰.

Publisher: Faculty of Agriculture and Technology Institute of Plant Production, Shahid Bahonar University of Kerman-Iranian Biotechnology Society.

© the authors



مقدمه

سرزمنی پهناور ایران، خاستگاه نژادهای مختلف اسب است. اسب‌های عرب در مناطق جنوب و جنوب غربی، اسب‌های کرد در مناطق غربی و مرکزی، اسب‌های قره باغ در مناطق شمال غربی، اسب‌های ترکمن در مناطق شمال شرقی و اسب‌های دره شوری در مناطق مرکزی و جنوب غربی کشور پرورش می‌یابند (Hedayat-Evrigth et al. 2018). در دو دهه اخیر، واردات اسب‌های خارجی به کشور افزایش قابل توجهی داشته است. از دلایل این امر می‌توان به تغییر رویه در واردات کشور، افزایش توجه به ورزش سوارکاری و افزایش حضور بخش خصوصی در این عرصه اشاره کرد (Moladoust et al. 2020). واردات مداوم اسب‌های خارجی و آمیزش‌های کنترل نشده بین نژادی، خلوص ژنتیکی نژادهای بومی را کاهش می‌دهد (Khadka 2010; Hassan et al. 2019). برای حفاظت از منابع ژنتیکی، به برنامه‌ی مدیریت ژنتیکی مناسب، نیاز است و لازمه تدوین این برنامه، مطالعه ساختار ژنتیکی و تنوع ژنتیکی جمعیت‌ها است (Jemaa et al. 2015; Laliotis & Avdi 2017). استنباط ساختار جمعیت از داده‌های ژنتیکی، اغلب برای درک فرایندهای تکاملی و جمعیت شناختی، مورد استفاده قرار می‌گیرد و یک جنبه مهم در بسیاری از مطالعات ژنتیکی است. چنین استنباطی عمدها توسط خوشبندی افراد در گروههایی به نام زیرجمعیت انجام می‌شود. ارزیابی ساختار ژنتیکی، اجازه استنتاج در مورد الگوهای مهاجرت و پیامدهای ژنتیکی آن‌ها را می‌دهد (Greenbaum et al. 2016). پیشرفت در فناوری‌های تعیین توالی DNA، فرصت استفاده از تعداد زیادی چند شکلی تک نوکلئوتیدی (SNP) را برای بررسی ساختار ژنتیکی و تنوع گونه‌های دام، مانند گاو (Neuditschko 2011; Karimi et al. 2016), گوسفند (Kijas Petersen et al. 2013; Petersen et al. 2016; Colli et al. 2012) و اسب (Visser et al. 2018) (et al. 2012) فراهم کرده است. استفاده از تکنیک‌های مولکولی در سال‌های اخیر جهت مطالعه موجودات بومی و حفاظت شده، کاربرد گسترده‌ای یافته است (Askari et al. 2010; Mohammadabadi 2017). میزان اطلاعات به دست آمده از این تکنیک‌های ژنتیکی، یکی از پارامترهای قابل ارزیابی برای مطالعه جمعیت‌های مختلف و درک تفاوت‌های ژنتیکی بین گروه‌های مختلف با استفاده از تکنیک‌های مولکولی، بسیار مهم و برای طبقه‌بندی آن‌ها مفید است (Mohammadabadi et al. 2017). حفاظت باید بر اساس دانش عمیقی از منابع ژنتیکی نژادهای خاص باشد، بنابراین، تلاش برای شناسایی و تعیین خصوصیات ژنتیکی نژادهای مختلف بسیار اهمیت دارد (Ghasemi et al. 2010; Mohammadabadi et al. 2021) تنوع ژنتیکی یک عنصر اساسی برای پیشرفت ژنتیکی، حفظ جمعیت‌ها، تکامل و سازگاری با شرایط محیطی متغیر و مختلف است (Askari et al. 2008; Mohammadifar and Mohammadabadi 2011). تجزیه و تحلیل داده‌های حجمی و شناسایی ساختار جمعیت بدون اطلاع از نسب افراد می‌تواند یک چالش بزرگ باشد؛ اما می‌توان این مسئله را با به کارگیری روش‌های خوشبندی بدون نظارت حل کرد (Neuditschko 2011).

2011). بدین جهت در این پژوهش، برای شناسایی ساختار ژنتیکی اسبهای نژاد ترکمن و دره‌شوری، روش‌های تجزیه و تحلیل مولفه‌های اصلی (PCA)، تجزیه و تحلیل تفکیکی مولفه‌های اصلی (DAPC) و خوشه‌بندی فوق پارامغناطیسی (SPC) مورد استفاده قرار گرفتند. PCA یک روش مبتنی بر فاصله برای تجزیه و تحلیل مجموعه داده‌هایی با ابعاد بزرگ است. این روش، مجموعه داده‌ی مت Shank از تعداد زیادی متغیر همیسته را به مجموعه کوچکی از متغیرهای غیر همبسته تبدیل می‌کند. اعضای این مجموعه جدید، مؤلفه‌های اصلی (PCs) نامیده می‌شوند (Jolliffe 2003; Reich et al. 2008). هر PC، ترکیبی خطی از متغیرهای اولیه است (Lavine & Mirjankar 2006). برای شناسایی ساختار جمعیت، معمولاً PCA به همراه الگوریتم خوشه‌بندی k-means اعمال می‌شود (Liu & Zhao 2006). DAPC یک روش مبتنی بر فاصله برای شناسایی و توصیف خوشه‌ها در مجموعه داده‌های بزرگ است (Campoy et al. 2016). روشن DAPC توسط Jombart et al. (2010) پیشنهاد شد (Jombart et al. 2010). این روش یک رویکرد چند متغیره است که ترکیبی از تجزیه و تحلیل مولفه‌های اصلی (PCA) و SPC. (García-Girón et al. 2019) برای خلاصه کردن تمایز ژنتیکی بین گروه‌ها است (Blatt et al. 1996). در مطالعات پیشین، ساختار جمعیتی اسبهای بومی ایران با استفاده از ژنوم میتوکندریال (Seyedsharifi et al. 2019a; Seyedsharifi et al. 2019b; Moridi et al. 2012) SNP و نشانگرهای ریز ماهواره (Hedayat-Evigh et al. 2020; Khamisabad et al. 2020; Abdoli et al. 2021) اسب بومی ایران (عرب، ترکمن، دره‌شوری، کرد و کاسپین) بررسی شد و نتایج حاکی از آن بود که نژادهای کاسپین و کرد دارای تشابه ژنتیکی بیشتری بوده و در یک گروه نژادی واقع شده‌اند و نژادهای ترکمن، عرب و دره‌شوری در گروه‌های مجزای ژنتیکی قرار گرفتند (Abdoli et al. 2021). در مطالعه دیگری، تنوع ژنتیکی در اسبهای عرب و رابطه ژنتیکی این نژاد با نژادهای ترکمن، دره‌شوری، کرد و خزر بررسی شد و نتایج نشان داد اسبهای عرب را می‌توان به سه خوشه تقسیم کرد؛ همچنین ساختار جمعیتی متمایزی بین نژادهای عرب، ترکمن و خزر مشاهده شد، درحالی‌که بین اسبهای عرب، کرد و دره‌شوری همپوشانی وجود داشت (Sadeghi et al. 2019). اهداف این پژوهش، بررسی ساختار ژنتیکی جمعیت‌های اسب ترکمن و دره‌شوری و همچنین مقایسه عملکرد روش‌های SPC و DAPC، PCA در خوشه‌بندی این جمعیت‌ها بود.

مواد و روش‌ها

نمونه‌گیری، استخراج DNA و تعیین ژنوتیپ SNP‌ها: در این بخش، نمونه خون از ۶۷ راس اسب نژاد ترکمن ۴۸) راس مادیان و ۱۹ راس نریان) از شهرهای گنبدکاووس، بندر ترکمن، آق‌قلاء، گرگان و کلاله و همچنین ۳۹ راس اسب نژاد

درهشوری (۲۸ راس مادیان و ۱۱ راس نریان) از شهرهای شیراز، خان زنیان، کازرون، کوار، استهبان، نی‌ریز، زروان و مرودشت توسط شرکت دانش‌بنیان ساینا گستر البرز تهیه شد. در این پژوهش سعی شد نمونه‌گیری از حیواناتی به عمل آید که رابطه خویشاوندی با یکدیگر نداشته و از لحاظ مورفولوژیکی و فنتوپیپی دارای حداقل خصوصیات نژادی باشند. استخراج DNA از خون به روش کلرفرم در آزمایشگاه بیوتکنولوژی علوم دامی پردیس کشاورزی و منابع طبیعی دانشگاه تهران انجام شد. سپس نمونه‌ها در پلت مخصوص، جایگذاری و برای تعیین ژنوتیپ به دانشگاه کنتاکی آمریکا ارسال شدند. پس از اطمینان از کمیت و کیفیت DNA استخراج شده تو سط دستگاه پیکوگرین، نمونه‌ها با استفاده از آرایه‌های شرکت ایلومینا (Illumina EquineSNP70 BeadChip) تعیین ژنوتیپ شدند.

کنترل کیفیت داده‌ها: مراحل کنترل کیفیت داده‌ها توسط نرم‌افزار PLINK(1.07) (Purcell et al. 2007) اعمال شد. در این فرایند، فقط نشانگرهایی با فراوانی آلل حداقل (Minor Allele Frequency) بیش از ۱٪ و نرخ فراخوانی (call rate) بیش از ۹۵٪ حفظ شدند. در معیار تعادل هاردی-واینبرگ نیز جایگاه‌هایی که $P\text{-value}$ آزمون کای اسکور آن‌ها کمتر از 10^{-6} بود حذف شدند.

خوشه‌بندی با روش PCA به همراه الگوریتم k-means: با هدف ارزیابی ساختار جمعیت، یک مسیر دو مرحله‌ای انتخاب گردید. ابتدا از روش PCA برای کاهش ابعاد داده‌ها و سپس برای خوشه‌بندی داده‌های کاهش یافته، از الگوریتم k-means استفاده شد (Ding & He 2004). در مرحله نخست، برای یافتن تعداد PC‌های معنادار، از تجزیه و تحلیل موازی PCA استفاده کردیم که توسط بسته نرم‌افزاری paran در محیط R اجرا شد (Dinno & Dinno 2018). سپس روش PCA توسطتابع prcomp روی ماتریس داده‌ها اجرا شد (Holland 2008). در مرحله دوم، از الگوریتم خوشه‌بندی k-means تخمین تعداد خوشه‌ها (k) و سپس اختصاص افراد به این خوشه‌ها استفاده شد. با استفاده از روش‌های آرنج (Elbow) و نیمرخ (Silhouette) شناسایی تعداد بهینه خوشه برای الگوریتم k-means انجام شد. هر دو روش توسط تابع fviz_nbclust بسته factoextra در محیط R اجرا شدند (Kassambara & Mundt 2017). روش آرنج، الگوریتم k-means را به ازای محدوده‌ای از مقادیر k (به طور مثال با در نظر گرفتن مقدار k در بازه ۱ تا ۱۵) محاسبه می‌کند و سپس برای هر مقدار k، مجموع مربعات داخل خوشه (WSS) را محاسبه می‌کند و منحنی WSS را بر حسب مقادیر مختلف k رسم می‌کند. محل خمیدگی (آرنج) در نمودار، به عنوان شاخص تعداد بهینه خوشه‌ها در نظر گرفته می‌شود (Jeon et al. 2016). روش نیمرخ، الگوریتم k-means را به ازای محدوده‌ای از مقادیر k اجرا می‌کند و ضریب نیمرخ هر یک از مشاهدات را به دست می‌آورد (رابطه ۱) و سپس میانگین آن‌ها را محاسبه می‌کند (رابطه ۲) و مقدار میانگین عرض نیمرخ بر حسب مقادیر مختلف k را در یک نمودار به تصویر می‌کشد. نقطه ماکزیمم نمودار رسم شده، تعداد بهینه خوشه‌ها را نشان می‌دهد (Kassambara 2017). مقدار ضریب نیمرخ برای هر مشاهده طبق (رابطه ۱) به دست می‌آید (Reddy 2018).

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (رابطه ۱)$$

$s(i)$ ضریب نیمرخ داده i است: $a(i)$ میانگین فاصله بین نقطه i و سایر نقاط خوش‌های است که i به آن تعلق دارد و $b(i)$ میانگین فاصله از نقطه i تا تمام خوش‌های است که i به آن‌ها تعلق ندارد (Reddy 2018). $s(i)$ در محدوده بین ۱ تا -۱ است (Kaufman & Rousseeuw 2009). میانگین ضرایب نیمرخ تمام نقاط (میانگین عرض نیمرخ) توسط (رابطه ۲) محاسبه می‌شود. هرچه میانگین عرض نیمرخ مجموعه داده بالاتر باشد، خوش‌بندی بهتر انجام شده است (Reddy 2018).

$$S = \frac{\sum_{i=1}^N \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}}{N} \quad (رابطه ۲)$$

خوش‌بندی با روش DAPC: روش DAPC با استفاده از بسته نرم‌افزاری adegenet 2.0.0 در محیط R انجام شد (Jombart et al. 2018). نیاز دارد گروه‌ها از پیش تعیین شده باشند، بنابراین از الگوریتم k-means تعیین تعداد خوش‌ها استفاده کردیم. تعیین خوش‌ها توسطتابع find.clusters انجام شد (Jombart et al. 2018). این تابع، الگوریتم k-means را مرتب با افزایش مقادیر k اجرا می‌کند و حالت‌های مختلف خوش‌بندی را با استفاده از معیار اطلاعات بیزی (BIC) مقایسه می‌کند. بهترین تعداد خوش، اغلب با یک آرنج در منحنی مقادیر BIC به عنوان تابعی از k نمایان می‌شود (Jombart & Collins 2015). سپس برای ارزیابی تعداد بهینه مولفه‌های اصلی حفظ شده، از روش اعتبارسنجی متقابل که توسط تابع xvalDapc اجرا می‌شود، استفاده کردیم و در نهایت تجزیه و تحلیل DAPC توسط تابع daptc اجرا شد (Jombart et al. 2018).

خوش‌بندی با روش SPC: الگوریتم خوش‌بندی SPC در بسته نرم‌افزاری SPIN پیاده‌سازی شده است (Tsafrir et al. 2005). ورودی‌های این الگوریتم عبارتند از: ماتریس فواصل (D)، k نزدیک‌ترین همسایگان (k -NN)، یک متغیر اسپین (s) که مقادیر صحیح ۱ تا q را به خود می‌گیرد: $s = (s_1, s_2, \dots, s_q)$. در معیار k -NN هر فرد به k نزدیک‌ترین همسایگان خود متأصل می‌شود. بنابراین، عملکرد خوش‌بندی SPC به شدت به تعداد k -NN و بسته است، به عنوان مثال با کاهش k -NN تعداد خوش‌ها افزایش می‌یابد (Neuditschko et al. 2010). با توجه به ماتریس D، هر نقطه (داده) با یک متغیر Pott spin s مرتبط می‌شود. نتیجه خوش‌بندی نسبت به انتخاب q حساس نیست و ما با مقدار معمول $q = 20$ کار کردیم (Neuditschko 2011). پس از مرتبط شدن Pott spin‌ها، خوش‌بندی در یک محدوده دمایی (ΔT) انجام می‌شود که تعاملات را به تعداد معینی از k -NN محدود می‌کند (Tsiafouli et al. 2017). برای ارزیابی کیفیت زیر شبکه‌ها و تعیین تعداد بهینه k -NN از پارامتری به نام مدولاریته (Q) استفاده کردیم، محدوده مدولاریته از ۰ تا ۱ متغیر است و هر چه مقدار آن بیشتر

باشد، تقسیم بندی جامعه بهتر بوده است (Newman 2006). بسته نرم افزاری SPIN برای ارزیابی عملکرد خوشه بندی SPC در یک فضای چند بعدی، از یک تابع هزینه استفاده می کند. تابع هزینه اعمال شده برای SPC، مدل پاتس همیلتونی فرو مغناطیس ناهمگن است که با (رابطه ۳) محاسبه می شود (Neuditschko et al. 2010).

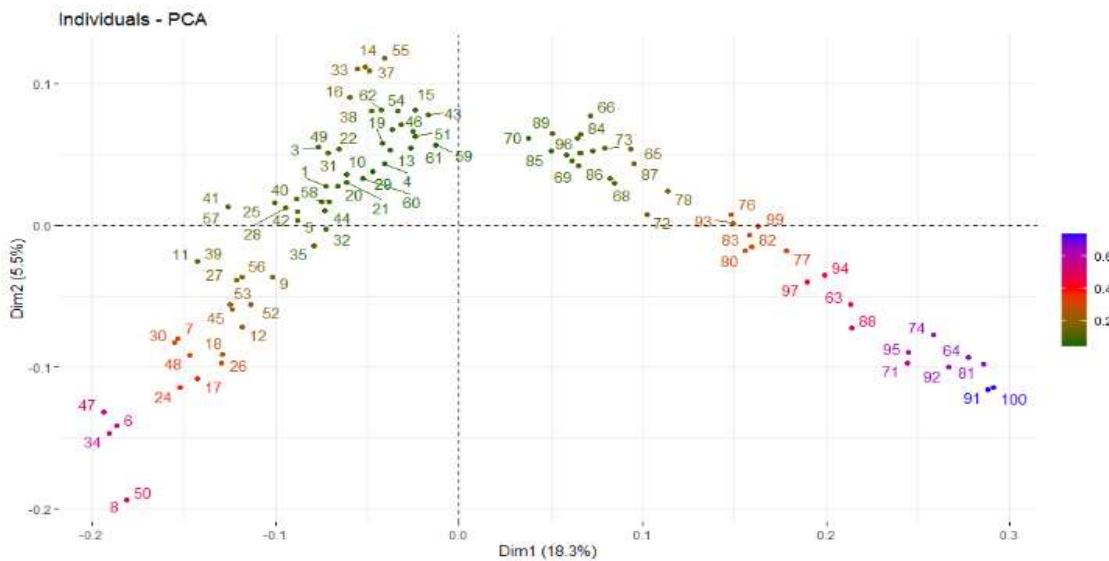
$$H[\{s\}] = \sum_{i,j} J_{ij} [1 - (\delta_{si,sj})] \quad \text{رابطه ۳}$$

طبقه بندی $\{s\}$ توسط تابع همیستگی اسپین-اسپین ($\delta_{si,sj}$) و اثر متقابل نزدیک ترین همسایه j تعیین می شود، که تابعی کاهشی و مثبت از فواصل بین نقاط همسایه i و j است. مدل های پاتس فرومغناطیسی در دنباله ای از دما با یک ΔT ثابت، شبیه سازی می شوند، به طوری که خوشه بندی می تواند در هر سطحی از T بیان شود (Neuditschko et al. 2010). این فرایند از $T = 0$ شروع می شود، یعنی زمانی که همه نقاط داده، یک خوش را تشکیل داده اند. این خوشه بندی اولیه فرضی، پی در پی در یک شبیه دمایی پیوسته، انشعاب می یابد؛ به عبارت دیگر، الگوریتم SPC شروع به تقسیم دورترین داده های ترکیب شده می کند و بدین ترتیب یک ساختار سلسله مراتبی از خوشه ها ایجاد می شود. بنابراین، محدوده دمایی $T_2 - T_1 = \Delta T$ که یک خوشه از خوشه های بالادستی جدا می شود به عنوان معیاری برای ثبات و اهمیت خوشه استفاده می شود. هرچه ثبات خوشه بیشتر باشد، محدوده ΔT بزرگ تر است (Neuditschko 2011).

نتایج و بحث

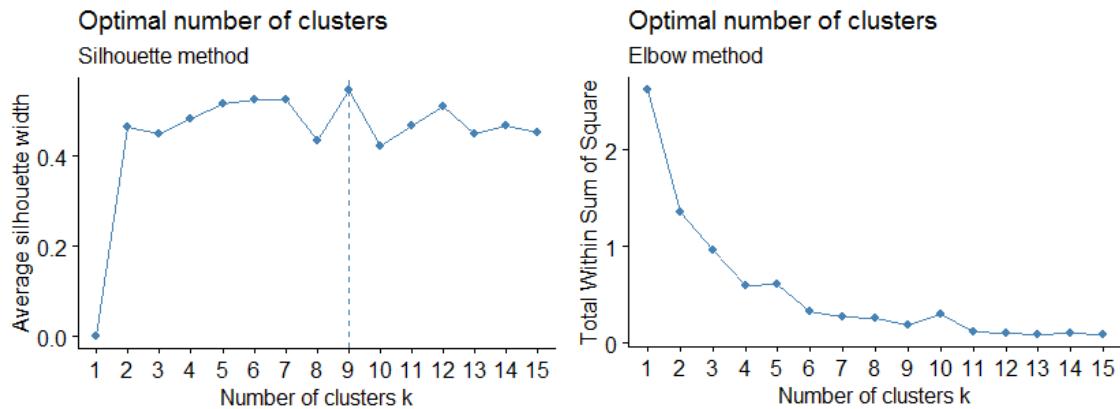
کنترل کیفیت داده ها: در حین مراحل کنترل کیفیت، شش حیوان از بررسی ها حذف شدند و ۱۰۰ حیوان باقی ماندند که از این تعداد، ۶۲ راس متعلق به نژاد ترکمن و ۳۸ راس متعلق به نژاد دره شوری بودند. تعداد ۵۶۹۰۸ جایگاه در این حیوانات حفظ شدند.

خوشه بندی با روش PCA به همراه الگوریتم k-means: با به کار گیری تجزیه و تحلیل موازی Horn، تعداد سه مؤلفه اصلی حفظ شدند. در این فرایند، واریانس موجود در داده ها به مؤلفه هایی تجزیه می شود به این صورت که اولین مؤلفه علت بیشترین واریانس موجود در داده ها باشد، دومین مؤلفه علت بیشترین واریانس ممکن پس از مؤلفه اول باشد و ال آخر. سه مؤلفه اصلی ابتدایی به ترتیب ۱۸,۳٪، ۵,۵٪ و ۵٪ از کل واریانس را توجیه کردند، سپس ابعاد داده ها توسط روش PCA کاهش یافت و پردازش داده ها در یک نمودار دو بعدی به نمایش درآمد، به طوری که فواصل هندسی بین افراد، منعکس کننده فاصله ژنتیکی بین آن ها است (شکل ۱). در تعیین تعداد بهینه خوشه ها، نتیجه روش آرنج ابهام آمیز بود اما روش نیمرخ تعداد ۹ خوشه را پیشنهاد کرد (شکل ۲).



شکل ۱. نحوه توزیع نمونه‌ها در دو بعد. اعداد ۱ تا ۶۲ متعلق به نمونه‌های نژاد ترکمن و اعداد ۶۳ تا ۱۰۰ متعلق به نمونه‌های نژاد دره‌شوری است

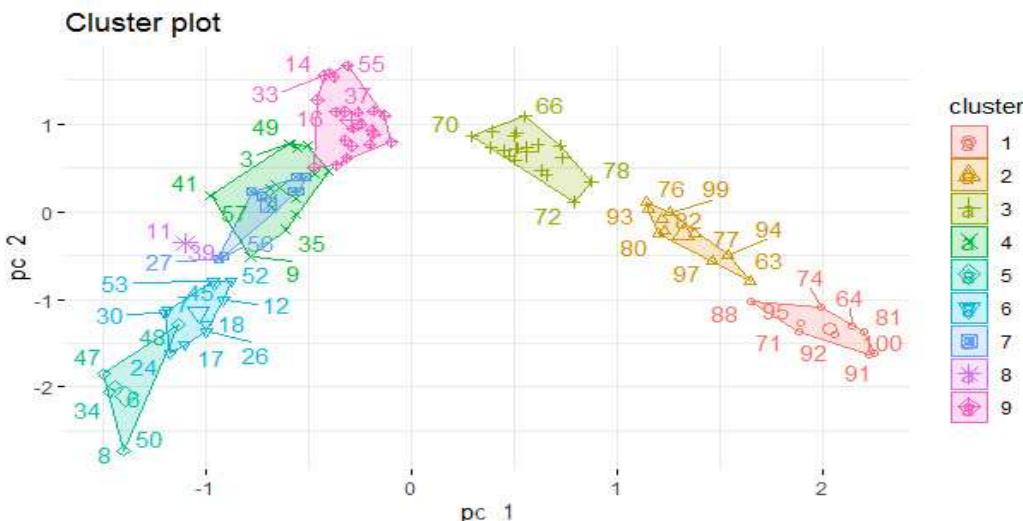
Figure 1. The distribution of the first two dimensions. The numbers 1 to 62 belong to the Turkmen breed and the numbers 63 to 100 belong to the Darehshori breed



شکل ۲. تعیین تعداد بهینه خوشها با روش آرنج (سمت راست) و نیمرخ (سمت چپ). نتیجه روش آرنج مبهم بود اما روش نیمرخ تعداد ۹ خوش را پیشنهاد کرد

Figure 2. Determining the optimal number of clusters by Elbow (right) and Silhouette (left) methods. The result of the Elbow method was ambiguous, but the Silhouette method suggested the number of 9 clusters

بنابراین الگوریتم k-means با تعداد ۹ خوش اجرا شد. در نتیجه، نمونه‌های متعلق به نژاد ترکمن (۶۲ راس) در شش خوش و نمونه‌های متعلق به نژاد دره‌شوری (۳۸ راس) در سه خوش جای گرفتند. بین نمونه‌های دو نژاد هیچگونه اختلاط و همپوشانی وجود نداشت و کاملا از هم تفکیک شدند. (شکل ۳)



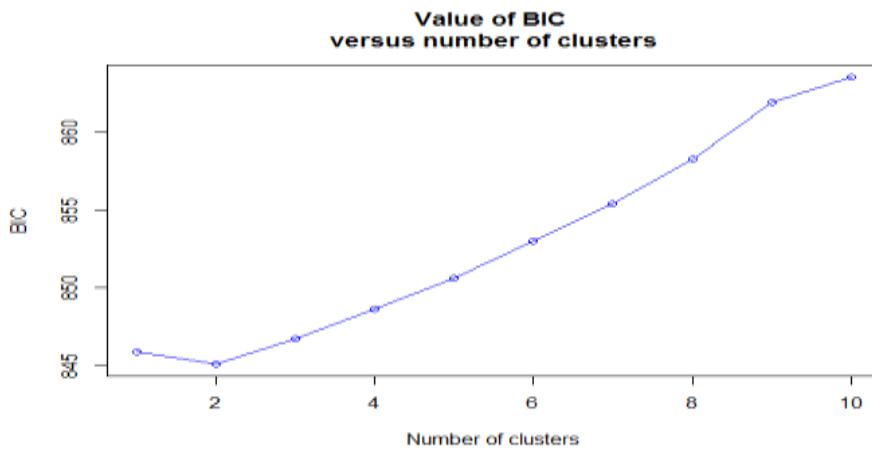
شکل ۳. محور x مولفه اصلی اول و محور y مولفه اصلی دوم را نشان می‌دهد. نقاط، نشانگر افراد هستند و خوشه‌ها با رنگ‌های مختلف نمایش داده شده است. خوشه‌های ۱، ۲ و ۳ نمونه‌های نژاد دره‌شوری هستند و خوشه‌های ۴، ۵، ۶، ۷، ۸ و ۹ نمونه‌های نژاد ترکمن هستند

Figure 3. The x-axis represents the first principal component and the y-axis represents the second principal component. The dots represent the samples and the clusters are displayed in different colors. Clusters 1, 2, and 3 are samples of the Darehshori breed, and clusters 4, 5, 6, 7, 8, and 9 are samples of the Turkmen breed

خوشبندی با روش DAPC: با اجرای الگوریتم k-means، با استفاده از معیار اطلاعات بیزی (BIC) تعداد دو خوشه به عنوان تعداد بهینه خوشه‌ها انتخاب شد (شکل ۴). برای تعیین تعداد PC‌های حفظ شده برای انجام تجزیه تحلیل تفکیکی، روش اعتبار سنجی متقابل به کار برد شد. در شکل ۵ تعداد PC با کمترین خطای جذر میانگین مربعات (RMSE) به عنوان تعداد بهینه PC حفظ شده در نظر گرفته شد (Jombart & Collins 2015) که در اینجا ۴۰ عدد است. روش DAPC با در نظر گرفتن ۴۰ مولفه اصلی ابتدایی و یکتابع تفکیکی اجرا شد و نمونه‌ها در دو خوشه جای گرفتند. نمونه‌های نژاد ترکمن و دره‌شوری کاملاً از هم تفکیک شدند و فاصله نسبتاً زیادی از هم دارند (شکل ۶).

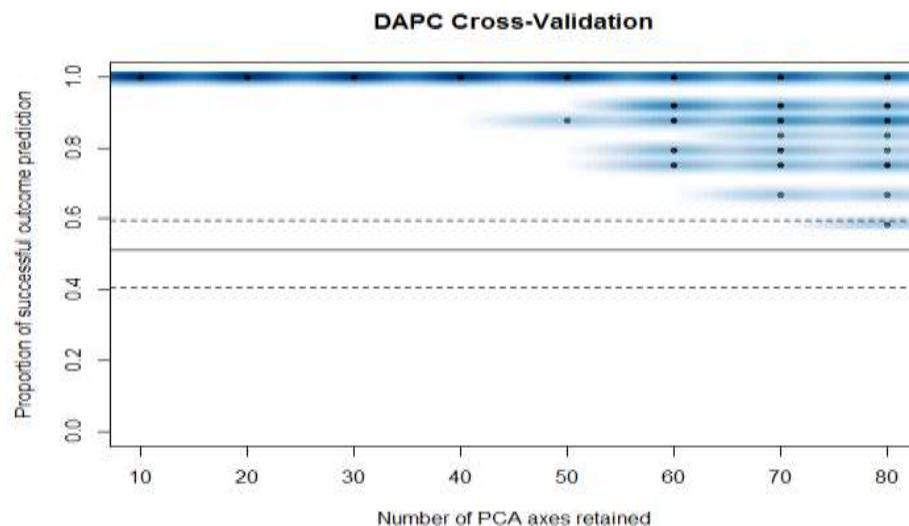
خوشبندی با روش SPC: برای تعیین مقدار بهینه k-NN، ابتدا مقداری به k-NN تعلق می‌گیرد که در آن، همه نمونه‌ها در یک خوشه قرار می‌گیرند. این مقدار برای داده‌های ما، برابر $k\text{-NN} = 33$ بود. سپس مقدار $k\text{-NN}$ به تدریج کاهش یافت و در $k\text{-NN} = 2$ تعداد ۱۶ خوشه حاصل شد. این فرایند در شکل ۷ به نمایش درآمده است. با توجه به (شکل ۸) حداقل میزان مدولاریته در $k\text{-NN} = 2$ حاصل شد (0.807642) و اجرای نهایی الگوریتم SPC با این مقدار $k\text{-NN}$ انجام پذیرفت (شکل ۹). در سطح $k\text{-NN} = 2$ تعداد ۱۶ خوشه حاصل شد؛ حیوانات متعلق به نژاد ترکمن از ۱۲ زیرجمعیت و حیوانات متعلق به

نژاد دره شوری از ۴ زیر جمعیت تشکیل شده اند و اختلاطی بین دو نژاد مشاهده نشد. این ۱۶ خوشه از دو خوشه اصلی انشعاب یافته اند. در (شکل ۹) تفکیک دو نژاد، به وضوح مشخص است.



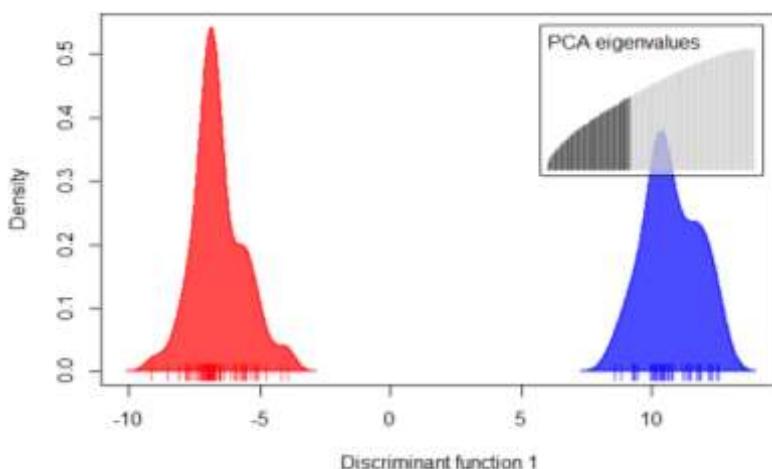
شکل ۴. استنباط تعداد خوشه بهینه با استفاده از معیار اطلاعات بیزی (BIC)

Figure 4. Inferring the number of optimal clusters using the Bayesian information criterion (BIC)



شکل ۵. اعتبارسنجی متقابل DAPC: تعداد PCهای حفظ شده در محور x است و نسبت موفقیت پیش‌بینی نتایج در محور y است. تکرارهای جداگانه به صورت نقاط، ظاهر شده و تراکم آن نقاط در مناطق مختلف شکل با رنگ آبی نشان داده شده است

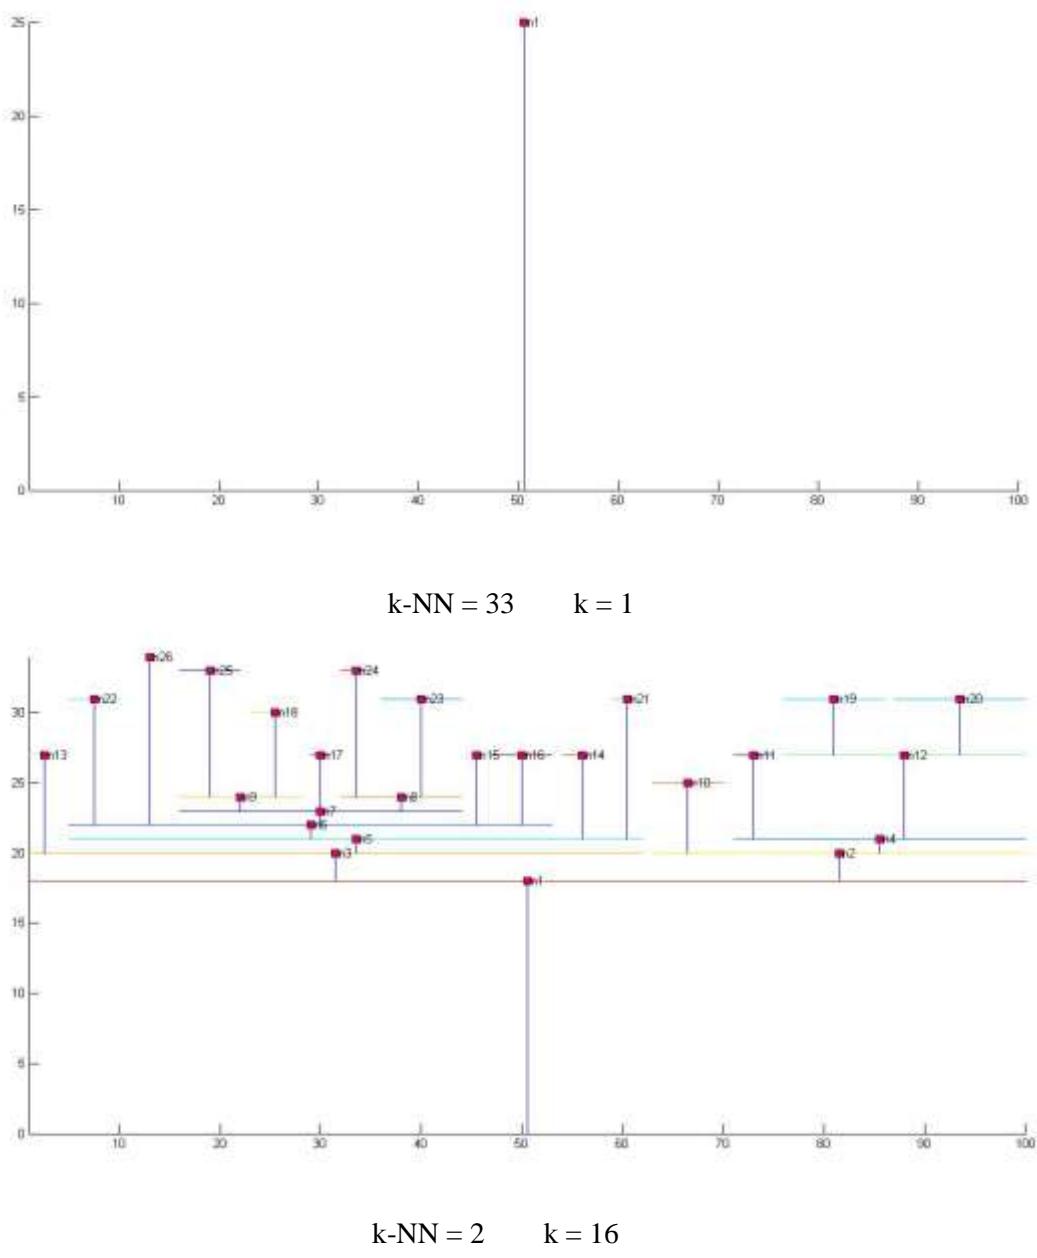
Figure 5. DAPC cross-validation. The number of PCs retained is on the x-axis, and the proportion of successful outcome prediction is on the y-axis. Single repetitions appear as dots, and the density of those dots in different areas is shown in blue



شکل ۶. نتیجه DAPC. نژاد ترکمن با رنگ قرمز و نژاد دره‌شوری با رنگ آبی نمایش داده شده است. هیستوگرام سمت راست بالا، میزان واریانس توجیه شده توسط مولفه‌های اصلی حفظ شده را نشان می‌دهد
($\text{PCs} = 40$)

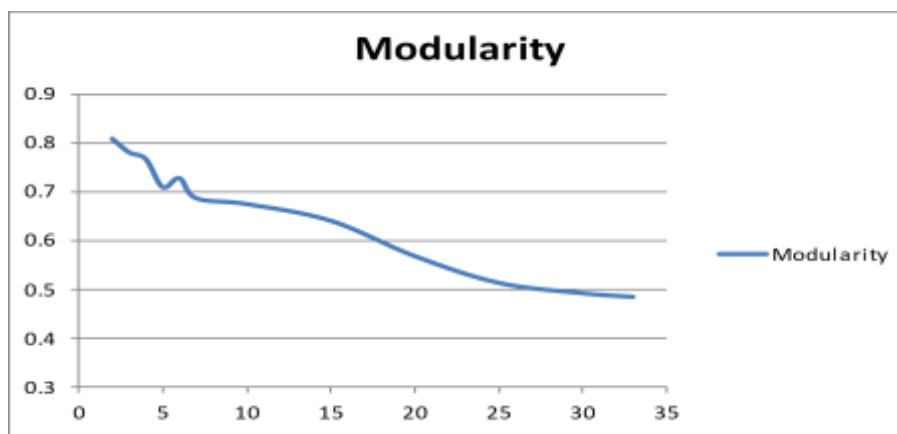
Figure 6. DAPC result. The Turkmen breed is shown in red and the Darehshori breed is shown in blue. The upper right histogram shows the amount of variance explained by the remaining principal components ($\text{PCs} = 40$)

نتایج این پژوهش نشان داد هر سه روش مورد استفاده (DAPC، PCA و SPC) نمونه‌های دو نژاد را کاملاً از هم تفکیک کردند و هیچگونه همپوشانی بین نمونه‌های دو نژاد وجود نداشت؛ در مطالعه Abdoli et al. (2021) نیز نژادهای ترکمن و دره‌شوری در گروههای مجزای ژنتیکی قرار گرفتند (Abdoli et al. 2021). نتایج این مطالعات نشان‌دهنده مطابقت خوشبندی ژنتیکی جمعیت‌ها با فاصله جغرافیایی محل پرورش آن‌هاست. ویژگی مشتبی که بین هر سه روش، مشترک بود، این است که همه آن‌ها بسیار سریع و کارآمد هستند. همچنین به فرض‌های پیشین وابسته نیستند و تجزیه و تحلیل مجموعه داده‌های ژنوم بسیار حجمی را بدون دانش قبلی درباره شجره امکان‌پذیر می‌کنند. در این پژوهش، روش DAPC هیچ اطلاعاتی راجع به زیرجمعیت‌ها ارائه نداد و صرفاً دو جمعیت اصلی را از هم تفکیک کرد، اما روش‌های PCA و SPC اطلاعات مفیدی را درباره تعداد زیرجمعیت‌ها و نحوه اختصاص افراد به هر زیرجمعیت فراهم کردند. در مطالعه Zargar et al. (2018) روش DAPC در تعیین تعداد بهینه خوشبهاها بهتر از روش PCA عمل کرد و در انتساب افراد به خوشبها موفق‌تر بود (Zargar et al. 2018). در مطالعه Jemaa et al. (2015) روش DAPC نتایجی مشابه با نتایج PCA نشان داد؛ اما تفکیک بهتری بین نژادهای با منشا یکسان ارائه داد (Jemaa et al. 2015).



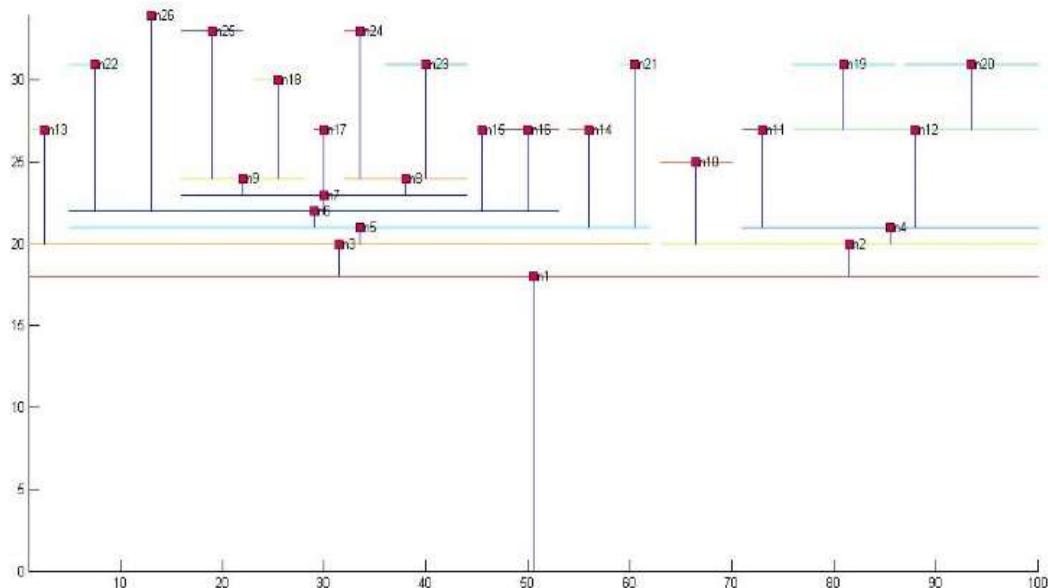
شکل ۷. پاسخ های خوشبندی SPC به ازای تعداد متفاوت $k\text{-NN}$. محور y نشانگر دما و محور x نشانگر افراد است. فاصله افقی خوشبندیها از یکدیگر نشانگر میزان همچواری آنهاست و فاصله عمودی خوشبندیها نشانگر میزان پایداری خوشبندیهاست

Figure 7. SPC clustering responses for different $k\text{-NN}$ values. The y-axis represents the temperature and the x-axis represents the samples. The horizontal distance of the clusters from each other indicates the degree of their neighborhood and the vertical distance of the clusters indicates the degree of stability of the clusters



شکل ۸. برای هر پیمایش SPC میزان مدولاریته را نشان می‌دهد. محور x نشانگر مقدار k-NN و محور y نشانگر میزان مدولاریته است

Figure 8. Indicates the degree of modularity for each SPC run. The x-axis represents the value of k-NN and the y-axis represents the degree of modularity



شکل ۹. دندروگرام خوش بندی با k-NN بهینه. محور y نشانگر دما و محور x نشانگر افراد است

Figure 9. Clustering dendrogram with optimal k-NN. The y-axis represents the temperature and the x-axis represents the samples

در مطالعه DAPC (Azizi et al. 2017) روش احتمال عضویت افراد جمعیت‌ها را با صحت ۱۰۰٪ پیش‌بینی کرد؛ همچنین این روش برای به دست آوردن تصویری روشن از واریانس بین جمیعت‌ها بهتر از PCA بود (Azizi et al. 2017). نتایج پژوهش حاضر نیز نشان می‌دهد با توجه به توانایی روش DAPC در حداکثر کردن واریانس بین خوش‌ای و نادیده گرفتن

واریانس درون خوشه ای، این روش در به تصویر کشیدن واریانس بین خوشه ها بهتر از PCA عمل می کند. از نقاط ضعف روش PCA می توان به این نکته اشاره کرد که این روش برای خوشه بندی نمونه ها به یک الگوریتم خوشه بندی (مانند الگوریتم K-means) نیاز دارد و این الگوریتم نمی تواند تعداد بھینه خوشه ها را به طور عینی ارائه دهد (Gao & Starmer 2007). اما روش SPC با این محدودیت مواجه نیست و تعیین تعداد خوشه ها در SPC، "خود سازماندهی شده" است. یکی دیگر از نقاط ضعف روش PCA این است که تجسم تعداد زیادی PC به طور همزمان امکان پذیر نیست و تفسیر روابط به مجموعه ای از حالات بصری دو بعدی محدود می شود (Neuditschko 2011). همچنین الگوریتم K-means در روش PCA ممکن است گرفتار بھینه های محلی شود و بسته به نقطه شروع، نتایج متفاوتی تولید کند (Pham et al. 2005) اما SPC دارای یک بھینه سراسری واحد است و بنابراین چندین بار اجرای SPC، نتایج یکسانی ارائه می دهد. در مطالعه Rahmaninia et al. (2015) روش SPC در شناسایی ساختار جمعیت بدون پیش آگاهی از انساب افراد، موفقیت آمیز عمل کرد (Rahmaninia et al. 2015). روش های DAPC و PCA می توانند حیوانات را بر اساس نژاد تفکیک کنند، اما این روش ها نمی توانند روابط فیلوجنتیک بین نژادها را نشان دهند. در مقابل، روش SPC، ساختار سلسله مراتبی بین نژادها را نشان می دهد (شکل ۹) که کاملاً با روابط فیلوجنتیک بین نژادها مطابقت دارد و بدین ترتیب، زیر جمعیت های درون نژادها را نشان می دهد و تاریخچه نژادها را منعکس می کند (Neuditschko 2011). نتایج ما نشان می دهد روش SPC می تواند برای مطالعه ساختار جمعیت نژادها بومی با اطلاعات ناشناخته، بسیار مفید باشد. بنابراین، با کمک این روش می توان برنامه مناسبی برای حفظ منابع ژنتیکی و استفاده پایدار از آن ها طراحی کرد. سیاست های حفاظت از نژادهای بومی تا حد زیادی به دانش ما از روابط ژنتیکی بین نژادها بستگی دارد (Marwal et al. 2014). بنابراین، می توان از نتایج این پژوهش و پژوهش های مشابه، در تدوین برنامه های اصلاحی و تولید مثالی استفاده کرد (Hedayat-Evriugh et al. 2018). این پژوهش ها اطلاعات مفیدی در مورد سطح فعلی تنوع ژنتیکی فراهم می کنند. این اطلاعات می توانند برای پیش بینی چگونگی تأثیر برنامه های مدیریتی خاص بر تنوع ژنتیکی گله، مورد استفاده قرار گیرند (Rahimi-Mianji et al. 2015). به طور کلی، برای چشم اندازهای طولانی مدت، استفاده از این اطلاعات، راه مناسبی برای رسیدن به تعادل تنوع ژنتیکی است (Eusebi et al. 2020).

نتیجه گیری: نتایج این پژوهش نشان داد که روش های PCA و DAPC توانستند بدون هیچ گونه داشتن قبلی از انساب افراد، ساختار ژنتیکی نژادهای ترکمن و دره شوری را با موفقیت شناسایی کنند. این روش ها به دلیل توانایی در کاهش پیچیدگی مجموعه داده های حجمی، می توانند در تدوین برنامه های حفاظت از منابع ژنتیکی نقش قابل توجهی داشته باشند. این روش ها می توانند یک مکمل یا جایگزین برای الگوریتم های خوشه بندی وقت گیر باشند، زیرا در عرض چند ثانیه می توانند ساختارهای جمعیتی را تشخیص دهنند. همچنین می توان گفت اطلاعات بدست آمده از نشانگرهای متراکم SNP می تواند برای شناسایی ساختار جمعیتی نژادهای بومی بسیار کاربردی باشد.

سپاسگزاری: از معاونت محترم پژوهشی پردیس کشاورزی و منابع طبیعی دانشگاه تهران و شرکت دانشبنیان ساینا گستر البرز بخاطر حمایت و همکاری در اجرای پژوهش حاضر سپاسگزاری می‌شود.

اختصارات: PCA: principal component analysis, PC: principal component, DAPC: discriminant analysis of principal components, DA: discriminant analysis, SPC: superparamagnetic clustering, SNP: single nucleotide polymorphism, WSS: within sum of squares, k-NN: k-nearest neighbor, RMSE: root mean squared error

منابع

- رحمانی نیا جواد، میرائی آشتیانی سیدرضا، مرادی شهربابک حسین (۱۳۹۴) بررسی ساختارهای جوامع و خرد جوامع دامی به روش خوشه‌بندی شبکه‌ای بدون نظارت با استفاده از نشانگرهای ژنتیکی متراکم. علوم دامی ایران ۴۶، ۲۷۷-۲۸۷.
- زرگ محمدرضا، فیاضی جمال، بیگی نصیری محمدتقی، مرادی شهربابک حسین (۱۳۹۷) بررسی ژنومی ساختار جمعیتی و ارتباط فیلوجنتیکی گاموییش نژاد خوزستانی. پژوهش‌های علوم دامی ۲۸، ۱۸۱-۱۹۴.
- سیدشریفی رضا، بادرین سجاد، خمیس آبادی حسن، هدایت ایوریق نعمت، سیف دواتی جمال (۱۳۹۸) بررسی ساختار ژنتیکی و دقت انتساب افراد به پنج جمعیت اسب با استفاده از نشانگرهای ریزماهواره. پژوهش‌های تولیدات دامی ۱۰، ۱۲۰-۱۲۶.
- سیدشریفی رضا، بادرین سجاد، هدایت ایوریق نعمت، ساورسفی سیما، سیف دواتی جمال، خمیس آبادی حسن (۱۳۹۸) بررسی ساختار ژنتیکی و روابط فیلوجنی اسب‌های کاسپین، عرب و تالشی. پژوهش‌های علوم دامی ایران ۱۱، ۲۲۳-۲۳۲.
- عبدی محمد، زندی محمدباقر، هرکی نژاد طاهر، خلیلی مسعود (۱۴۰۰) بررسی ساختار ژنتیکی اسب‌های بومی ایران با استفاده از نشانگرهای ریزماهواره. تولیدات دامی ۲۳، ۱۶۳-۱۵۵.
- عزیزی زهراء، مرادی شهربابک حسین، مرادی شهربابک محمد (۱۳۹۶) مقایسه روش‌های DAPC و PCA در تجزیه و تحلیل ساختار جمعیتی گاموییش‌های ایران با تراشه‌های اسنیپ. علوم دامی ایران ۴۸، ۱۶۱-۱۵۳.
- عسکری ناهید، باقی زاده امین، محمدآبادی محمدرضا (۱۳۸۹) مطالعه تنوع ژنتیکی در چهار جمعیت بزرگ‌کرکی راینی با استفاده از نشانگرهای ISSR. ژنتیک نوین ۵، ۵۶-۴۹.
- محمدی فر آمنه، فقیه ایمانی سید علی، محمدآبادی محمدرضا، سفلایی محمد (۱۳۹۲) تأثیر ژن $TGF\beta_3$ بر ارزش‌های فنوتیپی و ارثی صفات وزن بدن در مرغ بومی استان فارس. بیوتکنولوژی کشاورزی ۴۵(۴)، ۱۳۶-۱۲۵.
- مریدی میثاق، مسعودی علی‌اکبر، واعظ ترشیزی رسول (۱۳۹۱) مطالعه ساختار ژنتیکی اسب‌های بومی ایران با استفاده از توالی D-loop ژنوم میتوکندری. علوم دامی ایران ۴۳، ۱۸۲-۱۷۲.
- مقصودی صابرمحمد، مهربانی یگانه حسن، نجاتی جوارمی اردشیر، یوسفی مشعوف نوید (۱۳۹۶) بررسی ساختار جمعیت و شناسایی نواحی تحت انتخاب در ژنگان اسب‌های کرد و عرب ایرانی. علوم دامی ایران ۴۸، ۴۳۸-۴۲۹.

مولادوست کیومرث، حسینی سیدصفدر، مقدسی رضا (۱۳۹۸) مدیریت تقاضای واردات اسب در ایران. پژوهش در حسابداری و علوم اقتصادی (۳)، ۱۷، ۲۶-۱۳.

هدایت ایوریق نعمت، آزادمرد الهام، سیدشیری رضا، نیک بین سعید، شکوری میرداریوش، خلخالی ایوریق رضا (۱۳۹۸) بررسی تنوع ژنتیکی جمعیت اسب های شمالغرب ایران با استفاده از نشانگرهای ریزماهواره ای. بیوتکنولوژی کشاورزی ۱۱، ۵۰-۳۵.

References

- Abdoli M, Zandi MB, Harkinezhad T et al. (2021) Genetic structure survey of Iranian native horse breeds by microsatellite markers. *J Anim Pro* 23, 155-163. (In Persian).
- Askari N, Baghizadeh A, Mohammadabadi MR (2010) Study of genetic diversity in four populations of Raeini cashmere goat using ISSR markers. *Modern Genet J* 5 (2), 49-56 (In Persian).
- Askari N, Baghizadeh A, Mohammadabadi MR (2008) Analysis of the genetic structure of Iranian indigenous Raeni cashmere goat populations using microsatellite markers. *Biotechnol* 2 (3), 1-4.
- Azizi Z, Moradi Shahrabak H, Moradi Shahrabak M (2017) Comparison of PCA and DAPC methods for analysis of Iranian buffalo population structure using SNPchip90k data. *Iran J animal Sci* 48, 153-161. (In Persian).
- Blatt M, Wiseman S, Domany E (1996) Superparamagnetic clustering of data. *Physical review letters* 76, 3251.
- Campoy JA, Lerigoleur-Balsemin E, Christmann H et al. (2016) Genetic diversity, linkage disequilibrium, population structure and construction of a core collection of *Prunus avium* L. landraces and bred cultivars. *BMC Plant Biol* 16, 1-15.
- Colli L, Milanesi M, Talenti A et al. (2018) Genome-wide SNP profiling of worldwide goat populations reveals strong partitioning of diversity and highlights post-domestication migration routes. *Genet Sel* 50, 1-20.
- Ding C, He X (2004) K-means clustering via principal component analysis. In: Proceedings of the twenty-first international conference on Machine learning. pp. 29.
- Dinno A, Dinno MA (2018) Package ‘paran’. CRAN.
- Eusebi PG, Martinez A, Cortes O (2020) Genomic tools for effective conservation of livestock breed diversity. *Diversity* 12(1), 8.
- Gao X, Starmer J (2007) Human population structure detection via multilocus genotype clustering. *BMC Genet* 8, 1-11.
- García-Girón J, García P, Fernández-Aláez M et al. (2019) Bridging population genetics and the metacommunity perspective to unravel the biogeographic processes shaping genetic differentiation of *Myriophyllum alterniflorum* DC. *Sci Rep* 9, 1-10.
- Ghasemi M, Baghizadeh A, Abadi MRM (2010) Determination of genetic polymorphism in Kerman Holstein and Jersey cattle population using ISSR markers. *Aust J Basic Appl Sci* 4 (12), 5758-5760.
- Greenbaum G, Templeton AR, Bar-David S (2016) Inference and analysis of population structure using genetic data and network theory. *Genetics* 202, 1299-1312.
- Hassan F-u, Khan MS, Saif-ur-Rehman M et al. (2019) Genetic diversity among some horse breeds in Pakistan. *Pak J Zool* 51, 1203-1209.
- Hedayat-Evrligh N, Azadmard E, Seyed Sharifi R et al. (2020) Investigation of genetic diversity of Iran northwest horses using microsatellite markers. *Agric Biotechnol J* 11, 35-50. (In Persian).
- Holland SM (2008) Principal components analysis (PCA). Department of Geology, University of Georgia, Athens, GA, 1-12.

- Jemaa SB, Boussaha M, Mehdi MB et al. (2015) Genome-wide insights into population structure and genetic history of tunisian local cattle using the illumina bovinesnp50 beadchip. *BMC Genom* 1, 1-12.
- Jeon J-Y, Choi J-S, Byun H-G (2016) Implementation of Elbow method to improve the gases classification performance based on the RBFN-NSG algorithm. *J Sens Sci Technol* 25, 431-434.
- Jolliffe I (2003) Principal component analysis. *Technometrics* 45, 276.
- Jombart T, Collins C (2015) A tutorial for discriminant analysis of principal components (DAPC) using adegenet 2.0. 0. London: Imperial College London, MRC Centre for Outbreak Analysis and Modelling.
- Jombart T, Devillard S, Balloux F (2010) Discriminant analysis of principal components: a new method for the analysis of genetically structured populations. *BMC Genet* 11, 1-15.
- Jombart T, Kamvar ZN, Collins C et al. (2018) Package ‘adegenet’. CRAN.
- Karimi K, Strucken EM, Moghaddar N et al. (2016) Local and global patterns of admixture and population structure in Iranian native cattle. *BMC Genet* 17, 1-14.
- Kassambara A (2017) Practical guide to cluster analysis in R: Unsupervised machine learning. Sthda.
- Kassambara A, Mundt F (2017) Package ‘factoextra’. Extract and visualize the results of multivariate data analyses 76.
- Kaufman L, Rousseeuw PJ (2009) Finding groups in data: an introduction to cluster analysis. John Wiley & Sons.
- Khadka R (2010) Global horse population with respect to breeds and risk status. In: Department of Animal Breeding and Genetics. Swedish University of Agricultural Sciences.
- Khamisabad H, Badbarin S, Seyedsharifi R (2020) Genetic structure and assignment tests of Kurdish horse based on microsatellite markers. *Mod Genet* 14, 337-344.
- Kijas JW, Lenstra JA, Hayes B et al. (2012) Genome-wide analysis of the world's sheep breeds reveals high levels of historic mixture and strong recent selection. *PLoS Biol* 10(2)
- Laliotis GP, Avdi M (2017) Genetic diversity assessment of an indigenous horse population of Greece. *Biotechnol Anim Husb* 33, 81-90.
- Lavine BK, Mirjankar N (2006) Clustering and classification of analytical data. Encyclopedia of Analytical Chemistry: Applications ,Theory and Instrumentation.
- Liu N, Zhao H (2006) A non-parametric approach to population structure inference using multilocus genotypes. *Hum Genomics* 2, 1-12.
- Maghsoodi SM, Mehrabani Yeganeh H, Nejati Javaremi A et al. (2017) Investigating population structure and identifying signatures of selection in Iranian Kurdish and Arabian horses. *Iran J animal Sci* 48, 429-438. (In Persian).
- Marwal A, Sahu AK, Gaur R (2014) Molecular markers: Tool for genetic analysis, in animal biotechnology. Elsevier 289-305.
- Mohammadabadi M, Bordbar F, Jensen J et al. (2021) Key genes regulating skeletal muscle development and growth in farm animals. *Animals* 11 (3), e835.
- Mohammadabadi MR (2017) Inter-simple sequence repeat loci associations with predicted breeding values of body weight in Kermani sheep. *Genet millenn* 14 (4), 4383-4390.
- Mohammadabadi MR, Esfandyarpoor E, Mousapour A (2017) Using inter simple sequence repeat multi-loci markers for studying genetic diversity in Kermani sheep. *J Res Develop* 5 (2), e154.
- Mohammadifar A, Mohammadabadi MR (2011) Application of microsatellite markers for a study of Kermani sheep genome. *Iran J animal Sci* 42 (4), 337-344.
- Mohammadifar A, Faghih Imani SA, Mohammadabadi MR, Soflaei M (2014) The effect of TGFb3 gene on phenotypic and breeding values of body weight traits in Fars native fowls. *Agric Biotechnol J* 5 (4), 125-136.
- Mohammadifar A, Mohammadabadi M (2018) Melanocortin-3 receptor (MC3R) gene association with growth and egg production traits in fars indigenous chicken. *Malays Appl Biol* 47 (3), 85-90.

- Moladoust K, Hosseini SS, Moghadasi R (2020) Horse import demand management in Iran. Research in Accounting and Economic Sciences 17(3), 13-24. (In Persian).
- Moridi M, Masoudi Aa, Vaez torshizi R (2012) A study of the genetic structure of Iranian native horses using mitochondrial DNA sequence. Iran J Animal Sci 43, 172-182. (In Persian).
- Neuditschko M (2011) A whole-genome population structure analysis within cattle breeds. Department of Veterinary Sciences. Ludwig-Maximilians-University München.
- Neuditschko M, Maxa J, Russ I et al. (2010) Spinnet: a new tool to study the population structure with a genome-wide SNP survey. In: Proceedings of the 9 th World Congress on Genetics Applied to Livestock production Leipzig, Germany.
- Newman ME (2006) Modularity and community structure in networks. Proc Natl Acad Sci U.S.A. 103, 8577-8582.
- Petersen JL, Mickelson JR, Cleary KD et al. (2014) The American Quarter Horse: population structure and relationship to the Thoroughbred. J Hered 105, 148-162.
- Petersen JL, Mickelson JR, Cothran EG et al. (2013) Genetic diversity in the modern horse illustrated from genome-wide SNP data. PLoS One 8, e54997.
- Pham DT, Dimov SS, Nguyen CD (2005) Selection of K in K-means clustering. Proceedings of the Institution of Mechanical Engineers, Part C: J Mech Eng Sci 219, 103-119.
- Purcell S, Neale B, Todd-Brown K et al. (2007) PLINK: a tool set for whole-genome association and population-based linkage analyses. Am J Hum Genet 81, 559-575.
- Rahimi-Mianji G, Nejati-Javaremi A, Farhadi A (2015) Genetic diversity, parentage verification, and genetic bottlenecks evaluation in Iranian Turkmen horse. Russ J Genet 51(9), 916-924.
- Rahmaninia J, Miraei-Ashtiani SR, Moradi Shahrabak H (2015) Unsupervised clustering analysis of population and subpopulation structure using dense SNP markers. Iran J Animal Sci 46, 277-287. (In Persian).
- Reddy CK (2018) Data clustering: Algorithms and applications. Chapman and Hall/CRC.
- Reich D, Price AL, Patterson N (2008) Principal component analysis of genetic data. Nat Genet 40, 491-492.
- Sadeghi R, Moradi Shahrabak M, Miraei Ashtiani SR et al. (2019) Genetic diversity of Persian Arabian horses and their relationship to other native Iranian horse breeds. J Hered 110, 173-182.
- Seyedsharifi R, Badbarin S, Hedayat N et al. (2019a) Investigation of the genetic structure and phylogenetic relationships of Caspian, Arabic and Taleshi horses. Iranian Journal of Animal Science Research 11, 223-232. (In Persian).
- Seyedsharifi R, Badbarin S, Khamisabadi H et al. (2019b) Study of genetic structure and accuracy of assignment of individuals to five horse populations using microsatellite markers. Research on Animal Production 10, 120-126. (In Persian).
- Tsafrir D, Tsafrir I, Ein-Dor L et al. (2005) Sorting points into neighborhoods (SPIN): data analysis and visualization by ordering distance matrices. Bioinformatics 21, 2301-2308.
- Tsiafouli MA, Drakou EG, Orgiazzi A et al. (2017) Optimizing the delivery of multiple ecosystem goods and services in agricultural systems. Frontiers Media.
- Visser C, Lashmar SF, Van Marle-Köster E et al. (2016) Genetic diversity and population structure in South African, French and Argentinian Angora goats from genome-wide SNP data. PLoS One 11, e0154353.
- Zargar M, Fayazi J, Beigi M et al. (2018) Genomic study of population structure and phylogenetic relationship of Khuzestani buffaloes. Journal of Animal Science Research 28, 181-194. (In Persian).