



Performance of Artificial Neural Networks (ANNs) and linear mixed models for prediction of breeding values

Samira Gavili¹, Mohammad Razmkabir^{2✉}, Amir Rashidi³, Rezgar Arabzadeh⁴

1. Department of Animal Science, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran. E-mail: samiragavili74@gmail.com
2. Corresponding Author, Department of Animal Science, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran. E-mail: m.razmkabir@uok.ac.ir
3. Department of Animal Science, Faculty of Agriculture, University of Kurdistan, Sanandaj, Iran. E-mail: arashidi@uok.ac.ir
4. Department of Civil and Environmental Engineering, University of Waterloo, Waterloo, Ontario, Canada. E-mail: rezgar.arabzadeh@uwaterloo.ca

Article Info	ABSTRACT
Article type: Research Article	Artificial neural networks (ANN) have been widely used for both prediction and classification tasks in many fields of knowledge; however, few studies are available on animal science. The objective of this study was to prediction of breeding values of weaning weight in Markhoz goats based on the Mixed Model Equation (MME) and Artificial Neural Networks (ANNs). Quality control and calculation of descriptive statistics was performed using the GLM procedure of the SAS statistical package. The pedigree file included 5541 kids produced by 261 bucks and 1616 does. In the first step, genetic evaluations and Best Linear Unbiased Prediction (BLUP) of breeding values for weaning weight was computed with the mixed model equations, animal model by DMU program. Later, unique dataset was introduced to the ANN models by the R statistical program. A variety of models including, multilayer perceptron (MLP), radial basis function (RBF) and Support Vector Regression (SVR) were used to build the neural models. The artificial neural networks were trained and several networks (different hidden layers and nodes/ neurons) were evaluated. In artificial neural networks, the data were randomly divided to two parts (75% training and 25% for test/validation). Best architecture was selected according to the mean square of error and correlation. Correlation between true breeding value (BVs predicted by MME) and estimated breeding value (BVs predicted by ANNs) for MLP, RBF and SVR models were 0.72, 0.49 and 0.73, respectively. Analysis of farm data showed that the MLP and SVR models have higher performance than RBF for prediction of breeding values or ranking of individuals.
Article history: Received: 17 February 2023 Received in revised form: 21 October 2023 Accepted: 30 October 2023 Published online: 21 June 2024	
Keywords: <i>Artificial Neural Network,</i> <i>Breeding Value,</i> <i>Genetic Evaluation,</i> <i>Markhoz Goat,</i> <i>Weaning Weight.</i>	

Cite this article: Gavili, S., Razmkabir, M., Rashidi, A. & Arabzadeh, R. (2024). Performance of Artificial Neural Networks (ANNs) and linear mixed models for prediction of breeding values. *Iranian Journal of Animal Science*, 55 (2), 401-418. DOI: <https://doi.org/10.22059/ijas.2023.353747.653928>



© The Author(s).

DOI: <https://doi.org/10.22059/ijas.2023.353747.653928>

Publisher: The University of Tehran Press.

Extended Abstract

Background and Objectives

Machine learning techniques, such as artificial neural networks (ANN) have been widely used for both prediction and classification tasks in many fields of knowledge; because they are quick, powerful, and flexible. ANNs are inspired by the human brain structure and function as if they are based on interconnected nodes in which simple processing operations take place. The spectrum of neural networks application is very wide, and it also includes agriculture. However, few studies are available on animal science (e.g., efficient farm management, classification of the quality of milk and meat products, discovery of mastitis, detection of pregnancy, animal diet formulation, verification of diseases, intelligent estrus control and prediction of 305

milk yields). The objective of this study was to prediction of breeding values of weaning weight in Markhoz goats based on the Mixed Model Equation (MME) and Artificial Neural Networks (ANNs).

Materials and Methods

Quality control and calculation of descriptive statistics was performed using the GLM procedure of the SAS statistical package. The pedigree file included 5541 kids produced by 261 bucks and 1616 does. CFC program was applied for pedigree monitoring and computation of inbreeding coefficients. In the first step, genetic evaluations and Best Linear Unbiased Prediction (BLUP) of breeding values for weaning weight was computed with the animal model by DMU program based on Mixed Model Equation (MME). Mixed model equations were derived by maximum likelihood from the joint normal probability distribution of the data and breeding values. Later, unique dataset was introduced to the ANN models by the R statistical program.

Results

A variety of models including, multilayer perceptron (MLP), radial basis function (RBF) and Support Vector Regression (SVR) were used to build the neural models. The artificial neural networks were trained and several networks (different hidden layers and nodes/ neurons) were evaluated. In artificial neural networks, the data were randomly divided to two parts (75% training and 25% for test/validation). Best architecture was selected according to the mean square of error and correlation. The final architecture was based on the two hidden layers for all models and the fitted numbers of neurons for MLP were 9 and 10, for RBF were 10 and 6, and for SVR were 7 and 10, respectively. The error and correlation factor are the two important performance metrics that helps to evaluate the performance of the ANN models.

Correlation between true breeding value (BVs predicted by MME) and estimated breeding value (BVs predicted by ANNs) for MLP, RBF and SVR models were 0.72, 0.49 and 0.73, respectively.

Conclusion

Analysis of farm data showed that the MLP and SVR models have higher performance than RBF for prediction of breeding values or ranking of individuals according to their genetic merit predictions. There is not sufficient evidence to support the application of ANNs for computation of EBV in animal breeding. More optimization of this novel methods, especially pedigree inclusion in analysis is recommended for future studies.

کارائی شبکه‌های عصبی مصنوعی و مدل‌های خطی مختلط در پیش‌بینی ارزش اصلاحی

سمیرا گویلی^۱ | محمد رزم کبیر^۲ | امیر رشیدی^۳ | رزگار عرب‌زاده^۴۱. گروه علوم دامی، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران. رایانامه: samiragavili74@gmail.com۲. نویسنده مسئول، گروه علوم دامی، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران. رایانامه: m.razmkabir@uok.ac.ir۳. گروه علوم دامی، دانشکده کشاورزی، دانشگاه کردستان، سنندج، ایران. رایانامه: arashidi@uok.ac.ir۴. گروه مهندسی عمران و محیط زیست، دانشگاه واترلو، واترلو، اونتاریو، کانادا. رایانامه: rezgar.arabzadeh@uwaterloo.ca

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	شبکه‌های عصبی مصنوعی در دهه‌ی اخیر رشد چشمگیری در زمینه‌های مختلف علوم و از جمله علوم دامی داشته است. پژوهش کنونی برای بررسی قابلیت کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی ارزش‌های اصلاحی صفت وزن از شیرگیری در بز مرخز انجام شد. در بخش نخست ارزش‌های اصلاحی صفت مذکور با کمک معادلات مختلط، بر اساس مدل حیوانی و توسط نرم‌افزار DMU پیش‌بینی شد. در بخش دوم، همان داده‌های مزرعه‌ای به‌عنوان پارامترهای ورودی برای اجرای شبکه‌های عصبی مصنوعی استفاده شدند. برای اجرای شبکه‌های عصبی مصنوعی توسط نرم‌افزار R، ابتدا داده‌ها طی چند مرحله کنترل و پردازش شدند که شامل جایگذاری داده‌های گمشده و نامتعارف با روش PPCA، انتخاب متغیرها بر اساس تجزیه و تحلیل همبستگی، تبدیل مقیاس و نهایتاً بخش‌بندی داده‌ها به دو دسته آموزش (۷۵٪) و آزمون (۲۵٪) بود. در پژوهش کنونی سه مدل از شبکه‌های عصبی مصنوعی اجرا شدند که شامل مدل‌های پرسپترون چند لایه (MLP)، تابع پایه شعاعی (RBF) و رگرسیون بردار پشتیبان (SVR) بودند. در مرحله بعد برای هر کدام از این مدل‌ها بهترین معماری جستجو شده شامل تعداد لایه پنهان و تعداد نورون‌ها در هر لایه بود. هر سه مدل با تعداد دو لایه پنهان، بهترین معماری و کارائی را داشتند. مقادیر عددی همبستگی ارزش اصلاحی حقیقی (ارزش اصلاحی حاصل از معادلات مختلط) و ارزش اصلاحی پیش‌بینی شده (ارزش اصلاحی حاصل از شبکه‌های عصبی مصنوعی) برای مدل‌های MLP، RBF و SVR در داده‌های مزرعه‌ای به ترتیب ۰/۷۲، ۰/۴۹ و ۰/۷۳ برآورد شد. نتایج پژوهش براساس داده‌های مزرعه‌ای نشان داد که مدل‌های MLP و SVR با ضریب همبستگی بالاتر و مقدار خطای پایین‌تری، قابلیت پیش‌بینی صفت ارزش اصلاحی وزن شیرگیری را دارند.
تاریخ دریافت: ۱۴۰۱/۱۱/۲۸ تاریخ بازنگری: ۱۴۰۲/۰۷/۲۹ تاریخ پذیرش: ۱۴۰۲/۰۸/۰۸ تاریخ انتشار: ۱۴۰۳/۰۴/۰۱	
کلیدواژه‌ها: ارزیابی ژنتیکی، ارزش اصلاحی، شبکه‌های عصبی مصنوعی، بز مرخز، وزن شیرگیری.	

استناد: گویلی، سمیرا؛ رزم کبیر، محمد؛ رشیدی، امیر و عرب‌زاده، رزگار (۱۴۰۳). کارائی شبکه‌های عصبی مصنوعی و مدل‌های خطی مختلط در پیش‌بینی ارزش اصلاحی.

نشریه علوم دامی ایران، ۵۵ (۲)، ۴۱۸-۴۰۱. DOI: <https://doi.org/10.22059/ijas.2023.353747.653928>

ناشر: مؤسسه انتشارات دانشگاه تهران.



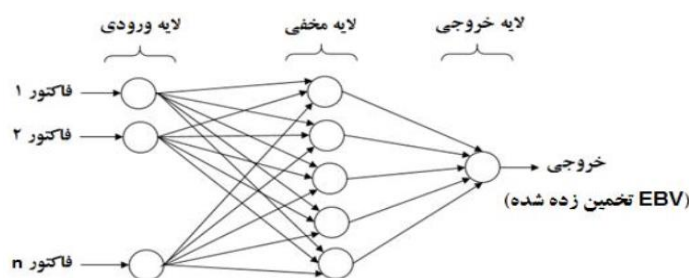
© نویسندگان.

DOI: <https://doi.org/10.22059/ijas.2023.353747.653928>

مقدمه

انتخاب بهترین حیوان مشروط به صحت بالای ارزش اصلاحی پیش‌بینی شده، جزو مراحل بنیادین اصلاح نژاد دام و طیور است. در واقع دستیابی به پیشرفت ژنتیکی و تغییر مطلوب میانگین ارزش اصلاحی افراد در طی نسل‌های متوالی، در گرو انتخاب والدینی است که شایستگی ژنتیکی بالاتری دارند. ارزش اصلاحی صحیح‌ترین مبنای تعیین والدین برتر و رتبه‌بندی حیوانات است (Razmkabir, 2011). پیش‌بینی ارزش اصلاحی حیوانات محصول ارزیابی ژنتیکی با بهره‌گیری از مدل آماری مناسب و استفاده از رکوردهای فنوتیپی و اطلاعات شجره‌ای است (Henderson, 1975). به‌طور کلی، امروزه رایج‌ترین روش برای پیش‌بینی ارزش اصلاحی حیوانات استفاده از بهترین پیش‌بینی ناآریب خطی می‌باشد. به کمک این روش می‌توان پارامترهای ژنتیکی روابط خویشاوندی میان حیوانات را با بالاترین صحت به دست آورد و در نهایت ارزش اصلاحی را پیش‌بینی کرد. این روش توسط هندرسون در سال ۱۹۵۴ ارائه و از سال ۱۹۸۴ به دلیل پیشرفت در کامپیوترها در زمینه ارزیابی ژنتیکی حیوانات استفاده شد (Bourdon, 1999; Henderson, 1985).

هر چند استفاده از معادلات مختلط در پیش‌بینی ارزش‌های اصلاحی و انتخاب ژنتیکی، کارآمد و مؤثر بوده است، اما این روش غالباً از نظر محاسباتی زمان‌بر و چالش‌برانگیز است. یکی از جایگزین‌های احتمالی برای ارزیابی ژنتیکی استفاده از روش‌های یادگیری ماشین است که برای مدل‌سازی در زمینه‌های مختلف علوم، توسعه پیدا کرده است (Shahinfar et al., 2012; McQueen et al., 1995). منعطف‌ترین روش در بین روش‌های یادگیری ماشین، شبکه‌های عصبی مصنوعی^۱ می‌باشد که در حال حاضر به دلیل اینکه پیش‌بینی‌کننده مناسبی بوده مورد توجه قرار گرفته است (Beale & Jackson, 2017). شبکه‌های عصبی مصنوعی زیر مجموعه‌ای از یادگیری ماشین و هوش مصنوعی^۲ می‌باشند که با پردازش اطلاعات، همانند مغز انسان قادر به حل مسائل پیچیده می‌باشند (Abdollahi-Arpanahi et al., 2020). اصطلاحاً در طراحی این شبکه از سیستم عصبی انسان که بر پایه نورون است، الهام گرفته شده است. به بیان ساده‌تر نورون‌های مصنوعی نیز همانند نورون‌های بیولوژیکی دارای دندریت و آکسون می‌باشند (Sharma et al., 2007; Khan, 2022).



شکل ۱. ساختار شماتیک یک شبکه عصبی مصنوعی

همانگونه که در شکل ۱ مشاهده می‌شود، یک شبکه عصبی مصنوعی از سه لایه اصلی شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است. تعداد لایه پنهان در مدل‌ها و شبکه‌های مختلف دارای تنوع است اما همواره یک خروجی بیشتر ندارد (Krenker et al., 2011). وظیفه دریافت اطلاعات بر عهده لایه‌ی ورودی است و هیچگونه محاسباتی در این لایه انجام نمی‌شود. معمولاً تعداد نورون‌ها در لایه ورودی با تعداد متغیرهای موجود در مدل برابر است. لایه میانی که به نام لایه

1Machine Learning (ML)
2Artificial Neural Network (ANN)
3Artificial Intelligence
4Neurons

پنهان معروف است تابع پیچیدگی مدل و ساختار داده‌ها می‌باشد و لازم است تعدا بهینه نورون در این لایه را تعیین نمود. پس از بهینه‌سازی معماری شبکه و تعیین تعداد نورون‌ها و لایه‌ها، شبکه در دو مرحله آموزش و آزمون اجرا می‌شود. در مرحله آموزش نورون و شبکه آموزش می‌بیند؛ یاد می‌گیرد و در برابر الگوهای ورودی برانگیخته می‌شود. در مرحله آزمون خروجی براساس مرحله آموزش و الگوی ورودی شناسایی شده، ارائه می‌شود (Adil *et al.*, 2022; Kujawa & Niedbala, 2021). در بین تمام مدل‌های آماری، شبکه‌های عصبی مصنوعی نیاز به فرض اولیه نداشته و به دلیل توانایی بالای آنها در پردازش غیرخطی و همچنین قدرت زیاد در مدل کردن سیستم‌های پیچیده، باعث شده در بسیاری از شاخه‌های علوم از شبکه‌های عصبی مصنوعی استفاده شده است (Bishop, 2006). به بیان دیگر شبکه‌های عصبی مصنوعی قابلیت یادگیری بالایی دارند و می‌توانند هر تابع محاسباتی را به کمک شبکه‌ای از داده‌های ورودی، مدل‌سازی توابع و روابط به سرانجام برسانند. این مسئله موجب شده است که در طول سه دهه گذشته در زمینه‌های مختلف علمی، موفقیت چشمگیری داشته باشند (Russell & Norvig, 2009).

اگرچه شبکه‌های عصبی مصنوعی در پیش‌بینی ارزش اصلاحی در گیاهان و حیوانات (Shahinfar *et al.* 2012; Rosado *et al.* 2016; Ghasemirad *et al.*, 2020; *et al.* 2017)، پیش‌بینی وزن بدن در بز (Akkol *et al.*, 2017)، پیش‌بینی میزان شیر، چربی و پروتئین در انتخاب نرهای برتر از لحاظ ژنتیکی (Lacroix *et al.*, 1995; Gandhi *et al.*, 2010)، منحنی رشد جوجه گوستی (Roush *et al.*, 2006)، پیش‌بینی امتیاز حرکتی در گاو (Norouzian *et al.*, 2021) به کار رفته است، با این حال تعداد پژوهش‌ها در به کارگیری این شبکه‌ها در اصلاح نژاد دام و به ویژه در پرورش نشخوارکنندگان کوچک محدود است (Magotra *et al.*, 2019; Pour Hamidi *et al.* 2017; Ghotbaldini *et al.*, 2022; *et al.* 2022). هدف از پژوهش کنونی، مطالعه قابلیت پیش‌بینی ارزش اصلاحی با استفاده از شبکه‌های عصبی مصنوعی به کمک داده‌های مزرعایی صفت وزن شیرگیری در بز مرخز بود.

مواد و روش‌ها

پژوهش کنونی در سه بخش شامل الف. تجزیه داده‌های مزرعایی، ب. کنترل کیفیت و پردازش داده‌ها و ج. اجرای شبکه‌های عصبی مصنوعی انجام گرفت که در ادامه، جزئیات و نحوه انجام هر کدام از بخش‌ها، توضیح داده می‌شود.

تجزیه ژنتیکی داده‌های مزرعایی

داده و اطلاعات

در این پژوهش برای برآورد ارزش اصلاحی صفت وزن شیرگیری در بز مرخز از اطلاعات ثبت شده طی سال‌های ۱۳۷۱ تا ۱۳۹۸ در ایستگاه پرورش و اصلاح نژاد بز مرخز شهرستان سنندج استفاده شد. فایل شجره شامل شماره بزغاله، شماره پدر و شماره مادر و تعداد رکوردهای شجره بود. اطلاعات شجره در ابتدا با استفاده از نرم‌افزار Excel آماده شد. تجزیه و تحلیل آماری داده‌ها و بررسی عوامل ثابت موجود در مدل توسط نرم‌افزار SAS 8.2 انجام گرفت.

مدل آماری

تجزیه آماری صفت وزن شیرگیری با استفاده از ۱۲ مدل حیوانی زیر و روش حداکثر درست‌نمایی محدود شده (REML) در نرم‌افزار DMU انجام گرفت. مدل‌های مورد استفاده به شرح زیر بودند (Rashidi *et al.*, 2011):

رابطه (۱)

جزئیات مدل	معادله مدل	شماره مدل
---	$y = Xb + Z_a a + e$	۱
---	$y = Xb + Z_a a + Z_{pe} pe + e$	۲
$Cov(a,m)=0$	$y = Xb + Z_a a + Z_m m + e$	۳
$Cov(a,m)=A\sigma_{am}$	$y = Xb + Z_a a + Z_m m + e$	۴
$Cov(a,m)=0$	$y = Xb + Z_a a + Z_m m + Z_{pe} pe + e$	۵
$Cov(a,m)=A\sigma_{am}$	$y = Xb + Z_a a + Z_m m + Z_{pe} pe + e$	۶
---	$y = Xb + Z_a a + Z_c c + e$	۷
---	$y = Xb + Z_a a + Z_{pe} pe + Z_c c + e$	۸
$Cov(a,m)=0$	$y = Xb + Z_a a + Z_m m + Z_c c + e$	۹
$Cov(a,m)=A\sigma_{am}$	$y = Xb + Z_a a + Z_m m + Z_c c + e$	۱۰
$Cov(a,m)=0$	$y = Xb + Z_a a + Z_m m + Z_{pe} pe + Z_c c + e$	۱۱
$Cov(a,m)=A\sigma_{am}$	$y = Xb + Z_a a + Z_m m + Z_{pe} pe + Z_c c + e$	۱۲

که در این مدل‌ها y : بردار مشاهدات، b : بردار اثرات ثابت، a : بردار اثرات ژنتیکی افزایشی مستقیم، m : بردار اثرات ژنتیکی افزایشی مادری، pe : بردار اثرات محیطی دائمی مادری، c : بردار اثرات محیطی مشترک و e : بردار اثرات باقیمانده است و A : ماتریس روابط خویشاوندی می‌باشد. همچنین X, Z_a, Z_c, Z_m و Z_{pe} ماتریس‌های طرح هستند که مشاهدات را به ترتیب به اثرات ثابت، اثرات ژنتیکی افزایشی مستقیم، اثرات محیطی دائمی مادری، اثرات ژنتیکی افزایشی مادری و اثرات محیطی مشترک را با بردار مشاهدات برقرار می‌کنند. همچنین σ_{am} کوواریانس بین اثرات ژنتیکی افزایشی مستقیم و اثرات ژنتیکی افزایشی مادری را نشان می‌دهد.

برای تعیین مناسب‌ترین مدل از معیار اطلاع آکایک استفاده شد (Akaike, 1974):

رابطه (۲)

$$AIC_i = -2 \log L_i + 2P_i$$

که در این فرمول AIC_i معیار اطلاع آکایک، $\log L_i$ نسبت لگاریتم درست‌نمایی مدل دام و P_i تعداد پارامترهای موجود در مدل می‌باشد. هر چقدر این معیار کمتر باشد، نشان‌دهنده این است که مدل به کار رفته برای برآورد اجزاء واریانس و کوواریانس صفت مورد نظر مدل مناسب‌تری است.

پردازش داده برای شبکه‌های عصبی مصنوعی

استخراج و معرفی داده‌ها از نرم افزار DMU

بعد از تجزیه و تحلیل صفت و محاسبه ارزش اصلاحی توسط نرم‌افزار DMU، ستون مربوط به ارزش اصلاحی به‌عنوان متغیر پنهان و غیرفعال به داده‌هایی اضافه شد که برای شبکه‌های عصبی لازم است به نرم افزار R معرفی شود. داده‌های مربوطه برای اجرای شبکه‌های عصبی مصنوعی، شامل ستون شماره حیوان، سال، جنس، نوع زایش، سن مادر، وزن از شیرگیری و سن از شیرگیری بود. فایل داده‌ها در Excel با فرمت csv ذخیره شد.

کنترل کیفیت و پردازش داده‌ها

پردازش داده‌ها و آماده سازی داده ها برای شبکه‌های عصبی مصنوعی طی چندین مرحله انجام شد. ابتدا برای جایگذاری داده‌های گمشده از پکیج `pcaMethodes` در محیط نرم افزار R استفاده شد (R Core Team, 2021). مبنای انجام جایگذاری بر اساس تحلیل مؤلفه‌های اصلی و تابع PCA^2 بود. نحوه عملکرد این تابع به این صورت است که اگر ستونی شامل داده‌های گمشده می‌باشد، به کمک این تابع می‌توان اعدادی را که منطقی با همان ستون است را با اعداد گمشده جایگزین کند. یکی دیگر از فرآیندهای پردازش و کنترل کیفیت، آنالیز همبستگی داده‌ها^۱ به منظور آزمون استقلال آماری متغیرهای موجود در مدل بود. آزمون همبستگی چندگانه با نرم افزار R و پکیج `corrplot` صورت گرفت.

انتخاب متغیرها و تبدیل مقیاس^۲

برای مدلسازی با روش‌های یادگیری ماشین، بایستی بُعدهای داده‌ها در یک دامنه بوده و نباید با هم تفاوت زیادی داشته باشد. زیرا باعث ایجاد خطا خواهد شد. برای مثال ستون مربوط به سن از شیرگیری اعداد بزرگتری نسبت به ستون‌های دیگر در داده‌ها دارد. بنابراین میانگین این ستون نقش بیشتری در واریانس ایفا می‌کند. هدف از استاندارد سازی این است که نقش تمام متغیرها به یک اندازه باشد. به عبارتی، تمامی ستون‌ها باید بی‌بعد گردد. از فرمول زیر برای استانداردسازی متغیرها استفاده می‌شود (García *et al.*, 2015)

رابطه^۳

$$z_i = \frac{x - \min}{\max - \min}$$

تقسیم داده‌ها به بخش‌های آموزش و آزمون^۴

گروه‌بندی و تعیین سهم داده‌ها در گروه‌های آموزش و آزمون در منابع مختلف، متفاوت است. در پژوهش کنونی، ۷۵ درصد از کل داده‌ها به داده‌های آموزش و ۲۵ درصد یا مابقی داده‌ها، به داده‌های تست اختصاص داده شد.

اجرای شبکه‌های عصبی مصنوعی

در پژوهش کنونی از سه مدل استفاده شد که هر کدام زیر مجموعه‌ای از شبکه‌های عصبی مصنوعی می‌باشند. از پکیج `RNNs` برای مدل شبکه پرسپترون چندلایه و هسته تابع پایه شعاعی و از پکیج `Kernlab` برای رگرسیون بردار پشتیبان استفاده گردید (R Core Team, 2021).

شبکه پرسپترون چند لایه^۵

این نوع مدل از شبکه‌های عصبی مصنوعی از سه لایه شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده است. نورون‌های لایه‌ی پنهان توسط اطلاعات ورودی که در یک سری از وزن‌ها ضرب شده، برانگیخته می‌شود و سیگنال‌هایی به سمت جلو یعنی به نورون‌های لایه خروجی می‌فرستند. نورون‌های لایه خروجی پس از دریافت سیگنال از نورون‌های لایه

1 Missing Values Imputation

2 Principal Component Analysis

3 Data Correlation Analysis

4 Features Extraction by PCA

5 Rescaling

6 Data Partitioning

7 Multiple Layer Perceptron (MLP)

پنهان، آن را تفسیر کرده و نهایتاً این سیگنال‌ها را از خود خارج می‌کند. وزن‌های لایه ورودی بصورت تصادفی ایجاد می‌شود و تا رسیدن به خروجی مورد نظر، این وزن‌ها تغییر می‌یابد.

تابع پایه شعاعی^۱

شبکه RBF به عنوان یک شبکه عصبی، همانند سایر مدل‌ها دارای سه لایه ورودی، میانی و خروجی است. تعداد لایه پنهان به صورت پیش‌فرض، برای شبکه RBF فقط یک لایه می‌باشد. از آنجا که در مدل‌های پیچیده به‌ویژه زمانیکه حجم داده‌ها بالا است، کارایی این مدل کاهش پیدا می‌کند لذا برای حل این مسئله راه‌های زیادی پیشنهاد شده است که یکی از این روش‌ها استفاده از چند لایه پنهان است (Zhao et al., 2019; Craddock and Warwick, 1996). در پژوهش حاضر نیز از مدل RBF به صورت چندلایه و با کمک پکیج RSNNs استفاده شد.

رگرسیون بردار پشتیبان^۲

از این روش برای طبقه‌بندی و رگرسیون استفاده می‌شود. روش‌های مختلفی برای دسته‌بندی و جداسازی داده‌ها وجود دارد. یکی از این روش‌ها شناسایی الگوی^۳ مابین داده‌ها است. در واقع با تشخیص الگوی موجود در داده‌ها، می‌توان اقدام به دسته‌بندی و جداسازی داده‌ها کرد. تابع کرنلی^۴ در رگرسیون بردار پشتیبان یکی از توابع فعالسازی است که در پژوهش کنونی از آن برای تشخیص الگوی موجود بین متغیر مستقل و متغیر وابسته استفاده شد.

اعتبارسنجی^۵

در مرحله اعتبارسنجی، برای آنکه هر داده شانس حضور در دسته داده‌های آموزش یا آزمون را داشته باشد، اعتبارسنجی انجام می‌شود. معمولاً اعتبارسنجی در طول فرآیند آموزش شبکه‌های عصبی مصنوعی شامل ۹ مرتبه (Fold) است و در این تحقیق نیز از ۹ مرتبه استفاده شد.

جستجو برای معماری بهینه شبکه‌ی عصبی

برای هر مدل از مدل‌های سه‌گانه (SVR, MLP, RBF)، ترکیبی متنوع از لایه‌های اول و دوم آنالیز شدند. برای تعیین تعداد لایه مناسب (تعیین معماری بهینه) و ارزیابی شبکه در طول فرآیند یادگیری، از روش‌های میانگین مربعات خطا^۶ (MSE) و همبستگی استفاده شد. بدیهی است هر کدام از مدل‌ها که بالاترین همبستگی (r_{max}) میان ارزش اصلاحی پیش‌بینی شده (ارزش اصلاحی پیش‌بینی شده با شبکه‌های عصبی مصنوعی) با ارزش اصلاحی حقیقی (ارزش اصلاحی پیش‌بینی شده با معادلات مختلط) را داشته باشد و از کمترین مقدار خطا (MSE) برخوردار باشد به عنوان بهترین مدل انتخاب خواهد شد. در پژوهش کنونی از فرمول زیر برای محاسبه شاخص بهترین مدل استفاده شد:

رابطه^۴

$$index = \frac{r_{model} / r_{max}}{MSE_{model} / MSE_{max}}$$

1 Radial Basis Function (RBF)

2 Support Vector Regression (SVR)

3 Pattern Recognition

4 Kernel Function

5 Cross Validation

6 Mean Square Error

مصورسازی نتایج

پس از آنالیز سه مدل از شبکه‌های عصبی مصنوعی توسط نرم‌افزار R نتایج آنالیز بصورت تصاویری از نقشه‌های حرارتی^۱ با فرمت jpeg تولید شدند. برای انجام این کار و برای نشان دادن بهترین معماری از هر مدل، نتایج تمام آنالیزها (۵۵ آنالیز به ازای هر مدل) ذخیره و توسط دستور filled.contour به تصویر کشیده شد. همچنین نمودار یا هیستوگرام مربوط به فراوانی داده‌های آموزش و تست و مقدار همبستگی و خطای آنها بصورت تصویر با فرمت jpeg ذخیره شد.

نتایج و بحث

تجزیه ژنتیکی داده‌های مزرعه‌ای

توصیف آماری داده‌ها و شجره

داده‌های توصیفی صفت وزن از شیرگیری در جدول زیر ارائه شده است. در طی تحقیق و در مرحله کنترل کیفیت چند مورد داده نامتعارف و خارج از دامنه وجود داشت که از آنالیز خارج گردید.

جدول ۱. توصیف آماری صفت وزن شیرگیری در بز مرخز

ضریب پراکنش %	حداکثر	حداقل	اشتباه معیار	انحراف معیار	میانگین	تعداد	صفت
۲۷/۵۹۵	۲۸/۵۰۰	۶/۵۰۰	۰/۰۶۷	۴/۲۵۶	۱۵/۴۲۲	۴۰۴۴	وزن شیرگیری

برای ارزیابی ژنتیکی، علاوه بر فایل داده‌ها به فایل شجره نیز نیاز است. شجره مورد استفاده مربوط به سالهای ۱۳۷۱ تا ۱۳۹۸ بود که شامل ۵۵۴۱ تعداد حیوان است (جدول ۲).

جدول ۲. اطلاعات مربوط به آنالیز شجره بز مرخز

۵۵۴۱	تعداد کل افراد جمعیت
۳۱۶۴	تعداد افراد همخون
۲۶۱	تعداد کل پدران
۱۶۱۶	تعداد کل مادران
۱۸۷۷	تعداد افراد دارای فرزند
۳۶۶۴	تعداد افراد بدون فرزند
۲,۱۱	متوسط اندازه خانواده


ارزیابی ژنتیکی بر اساس مدل مناسب

برای صفت وزن شیرگیری تعداد ۱۲ مدل مورد مقایسه قرار گرفت (Bahrami, 2019). در میان مدل‌های موجود بر اساس معیار اطلاع آکایک بهترین مدل، مدلی است که کمترین مقدار را دارد. در پژوهش کنونی، مدل ۵ نسبت به سایر مدل‌ها مقدار اطلاع آکایک کمتری داشت و به‌عنوان مناسب‌ترین مدل برای تجزیه و تحلیل ژنتیکی صفت وزن شیرگیری استفاده شد. پارامترهای ژنتیکی داده‌های مزرعه‌ای با استفاده از نرم‌افزار DMU برآورد شدند. وراثت پذیری برآورد شده برای صفت وزن از شیرگیری توسط مدل ۵، 0.11 ± 0.01 برآورد شد. در مرحله بعدی ارزش‌های اصلاحی پیش‌بینی شده با نرم افزار DMU استخراج و با برچسب و عنوان ارزش اصلاحی حقیقی همراه ستون‌های شماره حیوان، سال، جنس، نوع تولد، وزن از شیرگیری، سن شیرگیری و سن مادر به صورت یک فایل واحد تولید شد. این فایل به‌عنوان ورودی برای بخش دوم پژوهش استفاده شد که شبکه‌های عصبی مصنوعی هستند.

پردازش داده برای شبکه‌های عصبی مصنوعی

تجزیه و تحلیل همبستگی داده‌ها و انتخاب متغیرها

در شکل شماره ۲ میزان همبستگی پیرسون، میان متغیرها را نشان می‌دهد. اندازه‌گیری همبستگی با این هدف انجام شد که اگر دو متغیر مستقل هم‌پوشانی و همبستگی بالایی داشته باشند، فقط یکی از آنها در مدل نهایی باقی می‌ماند.




شکل ۲. همبستگی پیرسون میان متغیرهای مستقل موجود در مدل

نتایج نشان داد که متغیرهای موثر بر وزن شیرگیری دارای استقلال کافی هستند و تمام موارد در مدل نهایی به صورت خطی اعمال شدند.

تعیین معماری بهینه شبکه‌های عصبی مصنوعی

برای یافتن تعداد نورون هر لایه مخفی و ارزیابی شبکه‌های عصبی مصنوعی در طول فرآیند یادگیری، از روش‌های میانگین مربعات خطا (MSE) و همبستگی استفاده شد و در نهایت شبکه‌ای که دارای کمترین خطا و بالاترین همبستگی بود، مورد پذیرش قرار گرفته شد. برای تعیین معماری نهایی از نمودار حرارتی کمک گرفته شد که در شکل ۳ نشان داده شده است. در نمودار حرارتی دو محور مختصات بر اساس تعداد لایه مخفی اول و لایه مخفی دوم ترسیم شده است. نقاطی از نمودار که رنگ تیره‌تر دارد، بیانگر عملکرد بهتر مدل در آن نقطه می‌باشد. در این تحقیق شبکه پرسپترون چند لایه (MLP) در لایه مخفی اول، تعداد ۹ نورون و برای لایه مخفی دوم، تعداد ۱۰ نورون بهترین عملکرد را دارد. همچنین در شبکه تابع پایه شعاعی (RBF)، لایه مخفی اول با تعداد ۶ نورون و لایه مخفی دوم با تعداد ۱۰ نورون بهترین عملکرد را داشت. نهایتاً برای شبکه رگرسیون بردار پشتیبان (SVR) شبکه بهینه در لایه مخفی اول تعداد ۷ نورون و در لایه مخفی دوم تعداد ۱۰ نورون داشت.



شکل ۳. نمودار حرارتی مربوط به معماری مدل‌های SVR (تصویر راست)، RBF (تصویر میانی) و MLP (تصویر چپ) با لایه‌های متفاوت

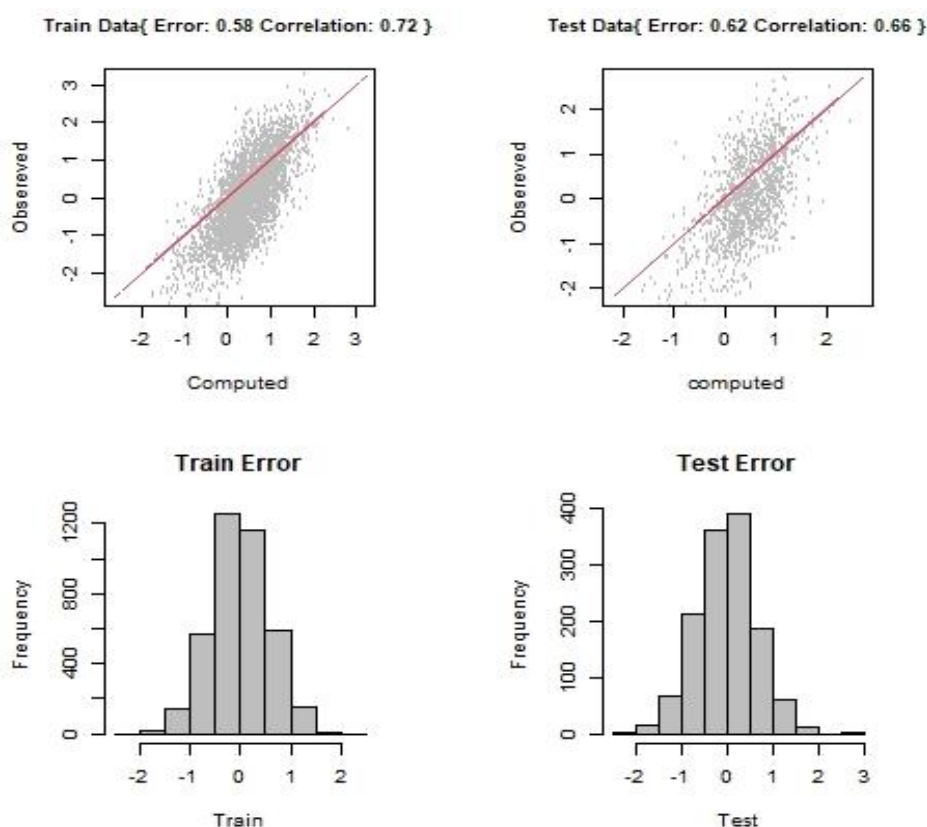
در مورد تعداد نورون انتخاب شده برای هر لایه لازم است با احتیاط برخورد شود. اگر تعداد نورون کمتر از تعداد بهینه باشد منجر به عدم برازش و پدیده *underfitting* خواهد شد. در این حالت، شبکه قادر نیست روابط میان متغیرهای ورودی و خروجی را کشف و آشکار کند. از طرفی دیگر اگر تعداد نورون بیش از تعداد بهینه باشد، منجر به پدیده *overfitting* خواهد شد. در این شرایط نیز به دلیل پیچیدگی مدل، کارایی و توانایی پیش‌بینی شبکه افت خواهد کرد (Adil *et al.*, 2022). مطالعه‌ی Grzesiak *et al.* (2003) نشان دادند که استفاده از شبکه‌های عصبی به فرضیه‌های مدل‌های رگرسیون احتیاج ندارد و استفاده از شبکه‌های عصبی آسان‌تر از مدل‌های رگرسیون است و قدرت پیش‌بینی کننده بالاتری دارد. همچنین در مقایسه با مدل‌های تخمینی وود و سیسملیک، شبکه‌های عصبی در برآورد پارامترها دارای قابلیت بهتری بودند. میزان خطای کمتر و دقت بالاتر در زمینه پیش‌بینی و برآورد تولید شیر از ویژگی‌های شبکه‌های عصبی بودند. در پژوهش Gorgulu (2012) از شبکه‌های عصبی مصنوعی برای پیش‌بینی تولید شیر ۳۰۵ روز استفاده گردید. در این پژوهش، شبکه با سه لایه، شامل لایه ورودی با ۴ نورون، لایه میانی با ۸ نورون و لایه خروجی با ۱ نورون طراحی شد. نتایج نشان داد که شبکه‌های عصبی عملکرد بهتری نسبت به رگرسیون خطی چندگانه دارد.

عملکرد شبکه‌های عصبی مصنوعی

برای ارزیابی عملکرد هر کدام از مدل‌های عصبی مصنوعی در طول فرآیند یادگیری، از معیارهای میانگین مربعات خطا (MSE) و همبستگی استفاده شد. در واقع با استفاده از MSE، میزان خطا با محاسبه اختلاف بین مقادیر حقیقی با مقادیر تخمین زده شده، بدست خواهد آمد. مقدار ضریب همبستگی عددی بین مقدار $+1$ و -1 می‌باشد که هرچه این عدد به $+1$ نزدیکتر باشد به این معنی است که مقدار خروجی با هدف مورد نظر نزدیکتر است یا به عبارت دیگر ارزش اصلاحی پیش‌بینی شده (ارزش اصلاحی پیش‌بینی شده با شبکه‌های عصبی مصنوعی) با ارزش اصلاحی حقیقی (ارزش اصلاحی پیش‌بینی شده با معادلات مختلط) نزدیکی بیشتری دارد.

شبکه پرسپترون چند لایه

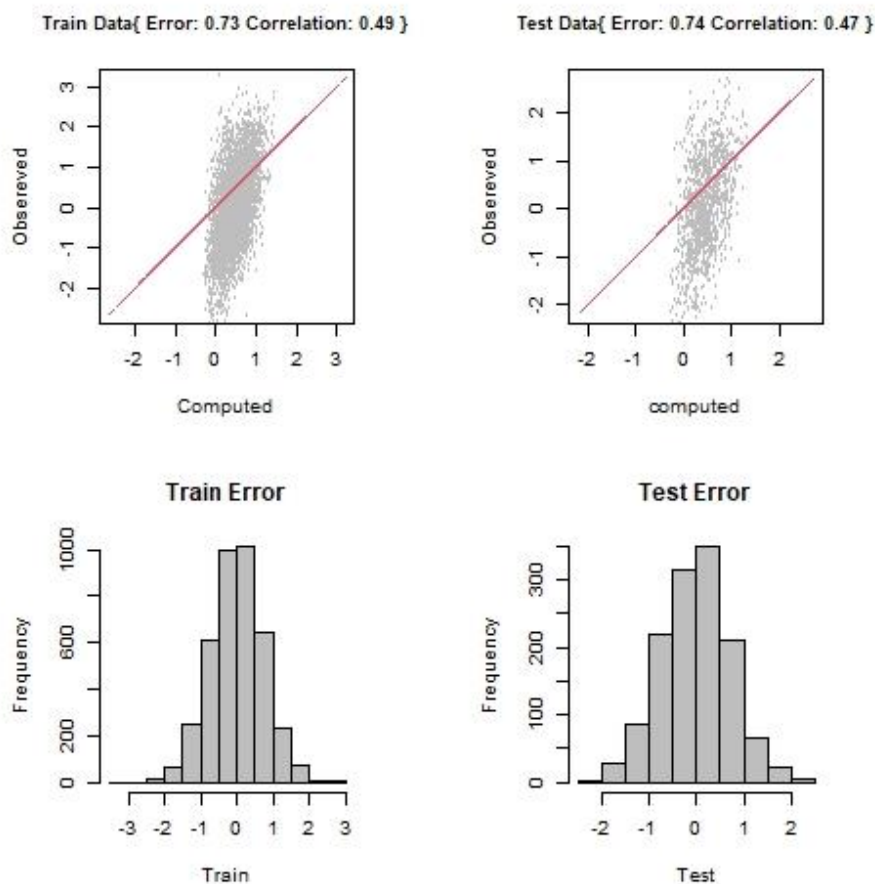
عملکرد مدل MLP بصورت گرافیکی در شکل ۴ نمایش داده شده است. میزان خطا و مقدار همبستگی در این مدل به ترتیب برای داده‌های آموزش $0/58$ و $0/72$ و برای داده‌های آزمون به ترتیب $0/62$ و $0/66$ بدست آمد.



شکل ۴. عملکرد مدل پرسپترون چندلایه MLP در گروه‌های آموزش و آزمون بر حسب همبستگی و میزان خطا

تابع پایه شعاعی

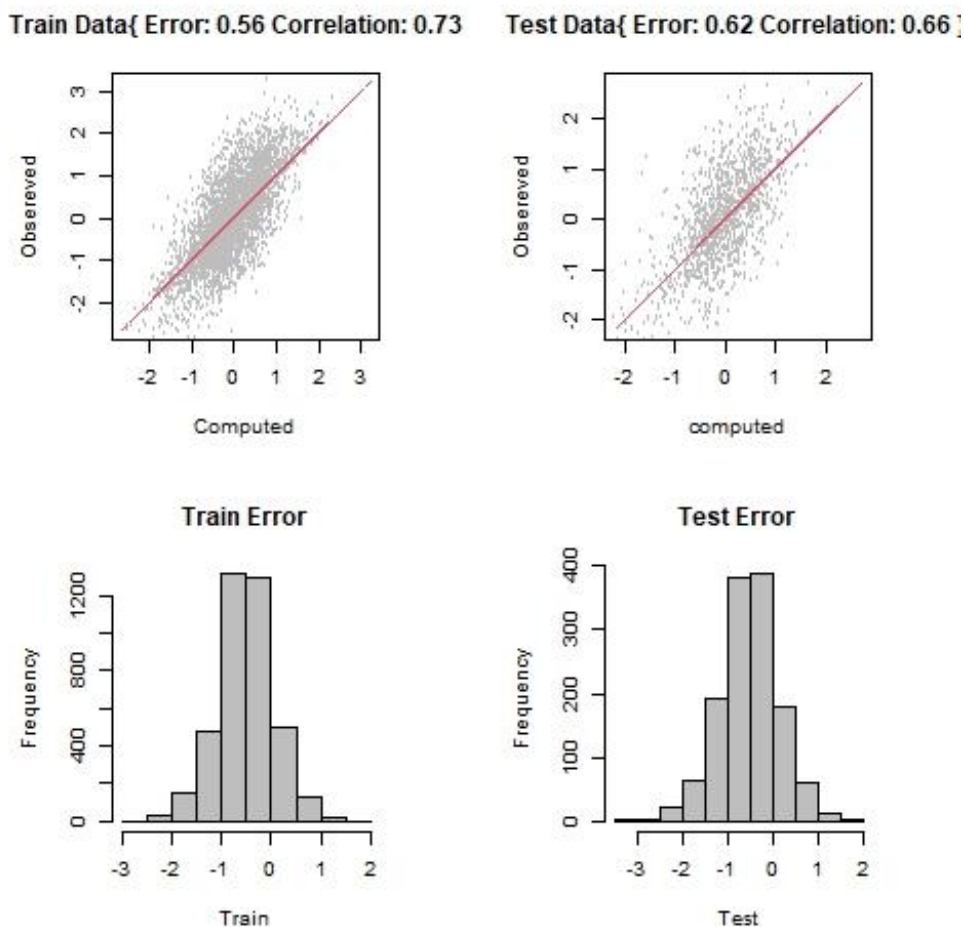
عملکرد مدل RBF بصورت گرافیکی در شکل ۵ نمایش داده شده است. میزان خطا و مقدار همبستگی در این مدل به ترتیب برای داده‌های آموزش $0/73$ و $0/49$ و برای داده‌های آزمون به ترتیب $0/74$ و $0/47$ بدست آمد.



شکل ۵. عملکرد مدل پرسپترون چندلایه RBF در گروه‌های آموزش و آزمون بر حسب همبستگی و میزان خطا

رگرسیون بردار پشتیبان

عملکرد مدل SVR بصورت گرافیکی در شکل ۶ نمایش داده شده است. میزان خطا و مقدار همبستگی در این مدل به ترتیب برای داده‌های آموزش ۰/۵۶ و ۰/۷۳ و برای داده‌های آزمون به ترتیب ۰/۶۲ و ۰/۶۶ بدست آمد.



شکل ۶. عملکرد مدل پرسپترون چندلایه SVR در گروه‌های آموزش و آزمون بر حسب همبستگی و میزان خطا

همانطور که نتایج نشان داد، میزان خطا در مدل پرسپترون چند لایه و همچنین رگرسیون بردار پشتیبان از دو مدل یگر کمتر و مقدار همبستگی داده‌های آموزش و آزمون در این دو مدل نسبت به مدل تابع پایه شعاعی بالاتر بوده است. بنابراین در پژوهش حاضر و بر اساس تجزیه و تحلیل داده‌های مزرعه‌ای بهترین مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی ارزش اصلاحی، مدل پرسپترون چندلایه و رگرسیون بردار پشتیبان می‌باشند.

جدول ۳. میانگین خطا و همبستگی مدل‌ها در گروه‌های آموزش و آزمون

مدل	میانگین مربع خطا		همبستگی	
	آموزش	آزمون	آموزش	آزمون
پرسپترون چندلایه	۰/۵۸	۰/۶۲	۰/۷۲	۰/۶۶
تابع پایه شعاعی	۰/۷۳	۰/۷۴	۰/۴۹	۰/۴۷
رگرسیون بردار پشتیبان	۰/۵۶	۰/۶۲	۰/۷۳	۰/۶۶

Hernández-Ramos *et al.* (2018) مطالعه‌ای برای ارزیابی شمارش سلول‌های سوماتیک از شبکه‌های عصبی مصنوعی استفاده کردند. نتایج این مطالعه نشان داد که استفاده از ANN می‌تواند شمار سلول‌های سوماتیک (SCC) را با صحت بالایی تخمین بزند. در مطالعه دیگری Khorshidi-Jalali *et al.* (2019) مدل‌های رگرسیونی و شبکه‌های عصبی مصنوعی را برای پیش‌بینی وزن بدن در بزهای کرکی رایینی مقایسه کردند. نتیجه این مطالعه نشان داد، اگرچه هر دو مدل رگرسیونی و شبکه‌های عصبی مصنوعی وزن بدن را نزدیک به مقدار واقعی پیش‌بینی می‌کنند اما استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی دقت بالاتری دارد. در تحقیق Roush *et al.* (2006)، استفاده از شبکه‌ی عصبی مصنوعی و مدل‌های رشد گومپرتز را در بررسی میزان رشد در طیور مورد مقایسه قرار دادند و نتایج نشان داد که شبکه عصبی مصنوعی به خوبی می‌تواند در برازش رشد مورد استفاده قرار گیرد.

در تحقیق Fernandez *et al.* (2006) از شبکه‌های عصبی مصنوعی جهت تخمین تولید شیر هفتگی بز استفاده شد. در تحقیق مذکور از تعداد ۳۶ راس دام تحت آزمایش، تعداد ۲۶ راس به عنوان گروه آموزش و ۱۰ راس به عنوان آزمون شبکه عصبی معرفی شدند. شبکه‌ی بهینه طراحی شده شامل لایه‌ی ورودی با ۶ نورون، ۲ لایه پنهان با ۳ نورون و لایه خروجی با ۱ نورون بود. نتایج نشان داد استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی تولید شیر مفید می‌باشد و مدل MLP بهترین مدل برای پیش‌بینی بوده است.

در پژوهش Nosrati *et al.* (2020) از مدل رگرسیونی MLR و شبکه‌های ANN برای پیش‌بینی تولید شیر ۳۰۵ روز در شیردهی اول و دوم استفاده شد. نتایج این تحقیق نشان داد هر چند صحت پیش‌بینی در مدل ANN با الگوریتم پس انتشار نسبت به مدل MLR بالاتر است اما هر دو مدل کارائی لازم را دارند. ضریب همبستگی بین رکورد واقعی و رکورد پیش‌بینی شده در شیردهی اول و دوم برای ANN به ترتیب ۰/۸۸ و ۰/۹۶ و برای MLR ۰/۶۶ و ۰/۸۹ بود.

نتیجه‌گیری کلی

نتایج پژوهش کنونی نشان داد در میان شبکه‌های عصبی مصنوعی، مدل پرسپترون چندلایه و مدل رگرسیون بردار پشتیبان نسبت به مدل تابع پایه شعاعی با مقدار خطای پایین‌تر و مقدار همبستگی بالاتر برای پیش‌بینی ارزش اصلاحی عملکرد بهتری داشتند. از آنجا که در تحقیق حاضر با وجود تلاش فراوان، قابلیت افزودن و معرفی شجره حیوانات و ماتریس روابط خویشاوندی به ANN مهیا نشد، ارزش‌های اصلاحی پیش‌بینی شده توسط شبکه‌های عصبی مصنوعی خاصیت BLUP ندارند.

منابع

بهرامی، بلال؛ رزم‌کبیر، محمد؛ محمودی، پیمان (۱۳۹۹). ارزیابی افت همخونی برای صفات رشد در نشخوارکنندگان کوچک: یک مطالعه فراتحلیلی. نشریه علوم دامی ایران. ۵۱ (۳). ۲۳۱-۲۴۱.

قاسمی‌راد، محمد رضا. (۱۳۹۴). مقایسه مدل‌های مختلط دامی و شبکه‌های عصبی مصنوعی برای پیش‌بینی ارزش‌های اصلاحی در داده‌های واقعی و شبیه‌سازی شده. پایان‌نامه کارشناسی ارشد ژنتیک و اصلاح نژاد دام، دانشکده کشاورزی، دانشگاه بوعلی سینا.

REFERENCES

- Abdollahi-Arpanahi, R., Gianola, D. & Peñagaricano, F. (2020). Deep learning versus parametric and ensemble methods for genomic prediction of complex phenotypes. *Genetics Selection Evolution*. 52 (1), 1-15.
- Adil, M., Ullah, R., Noor, S. & Gohar, N. (2022). Effect of number of neurons and layers in an artificial neural network for generalized concrete mix design. *Neural Computing and Applications*. 34, pages 8355-8363.
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on*

- Automatic Control*. 19 (6): 716–723.
- Akkol, S., Akilli, A. & Cemal, I. (2017). Comparison of artificial neural network and multiple linear regression for prediction of live weight in hair goats. *Journal of Agricultural Sciences*, 27(1): 21-29.
- Bahrami, B., Razmkabir, M. & Mahmoudi, M, P (2020). Inbreeding depression for growth traits in small ruminants: A meta-analysis. *Iranian Journal of Animal Science*. 51(3), 231-241. (in Persian).
- Beale, R. & Jackson, T. (2017). *Neural Computing - An Introduction*. 1st Edition. CRC Press. ISBN: 978-1138413092.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer New York, NY. 738 pages. ISBN: 978-0-387-31073-2.
- Bourdon, R. (1999). *Understanding Animal Breeding*. 2nd edition. Pearson, 538 pages.
- Craddock, R. J. and Warwick, K. (1996). Multi-layer radial basis function networks: an extension to the radial basis function. In: *Proceedings of International Conference on Neural Networks*, 3-6 Jun 1996, Washington DC, USA, pp. 700-705.
- Fernandez, C., Soria, E., Martin, J.D. & Serrano, A.J. (2006). Neural networks for animal science applications: Two case studies. *Expert Systems with Applications*. 31(2): 444-450.
- Gandhi, R.S., Raja, T. V., Ruhil, A. P. & Kumar, A. (2010). Artificial neural network versus multiple regression analysis for prediction of lifetime milk production in Sahiwal cattle. *Journal of Applied Animal Research*. 38 (2), 233-237.
- García, S., Luengo, J. & Herrera, F. (2015). *Data Preprocessing in Data Mining*. Springer. 336 pages. ISBN: 978-3-319-10246-7.
- Ghasemirad, M.R. (2016). Comparison of animal mixed models and artificial neural networks for prediction of breeding values in simulated data. *MSc Thesis*. Bu-Ali Sina University. Hamadan. Iran (in Persian).
- Ghotbaldini, H., Mohammadabadi, M., Nezamabadi-pour, H., Babenko, O. I., Bushtruk, M. V. & Tkachenko, S. V. (2019). Predicting breeding value of body weight at 6-month age using Artificial Neural Networks in Kermani sheep breed. *Acta Scientiarum Animal Sciences*, 41(1):45282
- Gorgulu, O. (2012). Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science*. 42(3):280-287.
- Grzesiak, W., Lacroix, R.R., Wojcik, J. & Blaszczyk, P. (2003). A comparison of neural network and multiple regression predictions for 305-day lactation yield using partial lactation records. *Canadian Journal of Animal Science*, 83(2): 307-310.
- Hernandez-Ramos, P.A., Vivar-Quintana, A.M. & Revilla, I. (2019). Estimation of somatic cell count levels of hard cheeses using physicochemical composition and artificial neural networks. *Journal of Animal Science*, 102: 1-11.
- Henderson, C.R. (1975). Best linear unbiased estimation & prediction under a selection model. *Biometrics*, 31(2): 423-447.
- Henderson, C. R. (1984). *Application of Linear models in animal breeding*. University of Guelph, Guelph, Ontario, Canada.
- Khan, M. A., Khan, R. & Ansari, M. A. (2022). *Application of Machine Learning in Agriculture*. Academic Press; 1st edition. 270 pages. ISBN: 0323905501.
- Khorshidi-Jalali, M., Mohammadabadi, M.R., Esmailizadeh, A., Barazandeh, A. & Babenko, O.I. (2019). Comparison of artificial neural network and regression models for prediction of body weight in Raini Cashmere Goat. *Iranian Journal of Applied Animal Science*, 9(3), 453-461.
- Krenker, A., Bester, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks. *Computer Science*. DOI:10.5772/15751.
- Kujawa, S. & Niedbala, G. (2021). *Artificial Neural Networks in Agriculture*. Multidisciplinary Digital Publishing Institute. 283 pages. ISSN 2077-0472.
- Lacroix, R., Wade, K.M., Kok, R. & Hayes, J.F. (1995). Prediction of cow performance with a

- connectionist model. *Transactions of the American Society of Agricultural Engineer*, 38: 1573–1579.
- McQueen, R.J., Garner, S.R., Nevill-Manning, C.G. & Witten, I.H. (1995). Applying machine learning to agricultural data. *Computers and Electronics in Agriculture*, 12(4), 275–293.
- Magotra, A., Bangar, Y.C. & Yadav, A.S. (2022). Neural network and Bayesian-based prediction of breeding values in Beetal goat. *Tropical Animal Health and Production*. 54, 282.
- Norouzian, M. A., Bayatani, H. & VakiliAlavijeh, M. (2021). Comparison of artificial neural networks and multiple linear regression for prediction of dairy cow locomotion score. *Veterinary Research Forum*. 12(1): 33–37.
- Nosrati, M., Hafezian, S.H. & Gholizadeh, M. (2020). Estimating Heritabilities and Breeding Values for real and Predicted Milk Production in Holstein Dairy Cows with Artificial Neural Network and Multiple Linear Regression Models. *Journal of Applied Animal Science*. 11: 67-78.
- Pour Hamidi, S., Mohammadabadi, M.R., AsadiFoozi, M. & Nezamabadi-pour, H. (2017). Prediction of breeding values for the milk production trait in Iranian Holstein cows applying artificial neural networks. *Journal of Livestock Science and Technologies*, 5 (2): 53-61.
- R Core Team. (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Rashidi, A., Bishop, S. C. & Matika, O. (2011). Genetic parameter estimates for pre-weaning performance and reproduction traits in Markhoz goats. *Small Ruminant Research*. 100: 100-106.
- Razmkabir, M. (2011). Genetic Evaluation of Production Traits with Random Regression Models in Holstein Dairy Cattle. *PhD Dissertation*. University of Tehran, Karaj, Iran.
- Rosado RDS, Cruz CD, Barili LD, de Souza Carneiro JE, Carneiro PCS, Carneiro VQ, da Silva JT, & Nascimento M. (2020). Artificial Neural Networks in the Prediction of Genetic Merit to Flowering Traits in Bean Cultivars. *Agriculture*. 10(12):638.
- Roush, W.B., Dozier, W.A. & Branton, S.L. (2006). Comparison of Gompertz and neural network model of broiler chicken growth. *Journal of Poultry Science*, 85: 794-797.
- Shahinfar, S., Mehrabani-Yeganeh, H., Lucas, C., Kahlor, A., Kazemian, M. & Weigel, K. (2012). Prediction of Breeding Values for dairy cattle using artificial neural networks and neuro-fuzzy systems. *Computational and Mathematical Methods in Medicine*, Article ID 127130, 9 pages.
- Sharma, A.K., Sharma, R.K. & Kasana, H.S. (2007). Prediction of first lactation 305-day milk yield in Karan Fries dairy cattle using ANN modeling. *Applied Soft Computing*, 7(3): 1112-1120.
- Russell, S. & Norvig, P. (2009). Artificial Intelligence: A Modern Approach. 3rd edition. Pearson Education, Inc. 1152 pages. ISBN 978-0136042594.
- Zhao, Y., Pei, J., & Chen, H. (2019). Multi-layer radial basis function neural network based on multi-scale kernel learning. *Applied Soft Computing*. 82: 105541.