

استفاده از هوش مصنوعی جهت برآورد ارزش‌های اصلاحی اوزان تولد و سه ماهگی گوسفند نژاد کرمانی

Application of artificial intelligence for estimating breeding value of body weight in birth and 3 months age in Kermani sheep breed

حمیدرضا قطب‌الدینی^۱، محمدرضا محمدآبادی^{۱*}، حسین نظام‌آبادی‌پور^۲

۱- به‌ترتیب دانش‌آموخته کارشناسی ارشد، استاد، بخش علوم دامی، دانشکده کشاورزی، دانشگاه شهید باهنر
کرمان، کرمان، ایران

۲- استاد، بخش برق، دانشکده فنی و مهندسی، دانشگاه شهید باهنر کرمان، کرمان، ایران

Ghotbaldini HR¹, Mohammadabadi MR^{*1}, Nezamabadi Pour H²

1- MSc Graduate Student, Professor, Department of Animal Science, Faculty of
Agriculture, Shahid Bahonar University of Kerman, Kerman, Iran

2- Professor, Department of Electrical Engineering, Shahid Bahonar University of
Kerman, Kerman, Iran

* نویسنده مسئول مکاتبات، پست الکترونیکی: mmohammadabadi@yahoo.ca

(تاریخ دریافت: ۹۵/۹/۲۸ - تاریخ پذیرش: ۹۶/۵/۱۷)

چکیده

هدف از این تحقیق کاربرد هوش مصنوعی برای برآورد ارزش اصلاحی مربوط به صفات رشد گوسفند کرمانی بود. برای این منظور از رکوردهای مربوط به ۸۶۷ بره که شامل جنس دام، سن مادر، وزن تولد و وزن از شیرگیری (در سن ۳ ماهگی) بود، استفاده شد. ابتدا این داده‌ها توسط نرم‌افزار ASReml بررسی شد و سپس برای استفاده در نرم‌افزار MATLAB مورد پیش پردازش قرار گرفت. پس از آزمایش‌های اولیه روی معماری مناسب برای شبکه‌های عصبی، مشخص شد که برای وزن تولد تعداد نرون‌های لایه ورودی ۳ نرون و برای وزن ۳ ماهگی ۶ نرون بود. مدل به کار رفته در این تحقیق پرسپترون چند لایه (MLP) و الگوریتم مورد استفاده پس انتشار خطا بود که به دنبال حداقل‌سازی مربعات خطا است. از کل داده‌های مورد استفاده ۷۰ درصد به‌عنوان آموزش، ۱۵ درصد به عنوان اعتبارسنجی و ۱۵ درصد برای تست در نظر گرفته شد تا آموزش به نحو مطلوب انجام شود. در طی فرآیند آموزش مرتباً میزان فراگیری شبکه توسط توابع هدف سنجیده و در نهایت شبکه‌ای مورد استفاده قرار گرفت که دارای کم‌ترین خطا و بیش‌ترین همبستگی بود. شبکه عصبی مصنوعی پرسپترون چند لایه با ۳ متغیر ورودی و تعداد ۸ نرون در لایه مخفی با ضریب همبستگی ۰/۷۳ توانایی پیش‌بینی ارزش اصلاحی وزن تولد و هم‌چنین شبکه عصبی مصنوعی پرسپترون چند لایه با ۶ متغیر ورودی و تعداد ۳ نرون در لایه با ضریب همبستگی ۰/۷۴ توانایی پیش‌بینی ارزش اصلاحی وزن ۳ ماهگی گوسفند نژاد کرمانی را دارا است. بنابراین می‌توان نتیجه گرفت که شبکه عصبی مصنوعی توانایی خوبی برای پیش‌بینی صفات رشد در گوسفند کرمانی با سرعت و دقت قابل قبول دارد و می‌تواند برای برآورد ارزش‌های اصلاحی تمام صفات در حیوانات اهلی استفاده شود.

واژه‌های کلیدی

پیش‌بینی
شبکه عصبی مصنوعی
صفات رشد
گوسفند کرمانی

مقدمه

بالغ بر ۲۶ نژاد گوسفند در ایران وجود دارد که با مناطق مختلف سازگار شده‌اند (Zamani et al. 2015; Khodabakhshzadeh et al. 2016). گوسفند کرمانی یکی از مهم‌ترین نژادهای گوسفند بومی ایران است و به‌خوبی با شرایط محیطی خشن و نامطلوب قسمت جنوب شرقی کشور که عمدتاً آب و هوای گرم و خشک غالب است و مراتع کم و کم کیفیت هستند سازگار شده‌است. این گوسفند دنبه دار دو منظوره (گوشت و پشم) با اندازه متوسط و پشم سفید است (Mohammadabadi and Sattayi mokhtari 2013) و در استان کرمان بسیاری از نیازهای مردم عشایر و دامپروران این استان را تأمین می‌کند. از این رو توجه به بحث اصلاح نژاد این دام و بهبود شرایط محیطی و ژنتیکی گوسفند کرمانی کمک به‌سزایی در تأمین بخشی از نیازهای دامی مردم کرده است. با کاهش تقاضای داخلی و خارجی برای پشم گوسفند کرمانی که به‌عنوان گوسفند پشمی - گوشتی شناسایی می‌شود، نقش اقتصادی این محصول در مقابل سایر محصولات و به‌ویژه گوشت کم رنگ‌تر شده و تولید گوشت هم‌اکنون عمده درآمد دامداران پرورش دهنده این نژاد را به خود اختصاص داده است (Kargar et al. 2006). از صفات اقتصادی مهمی که می‌توان در جهت انجام اصلاح نژاد گوسفند به‌منظور افزایش تولید گوشت اندازه‌گیری کرد صفات مرتبط با رشد است که عبارتند از: اوزان تولد، سه، شش، نه و دوازده ماهگی. وزن ۳ ماهگی که اغلب در این سن از شیرگیری انجام می‌شود از جمله صفات تولیدی مهم در گوسفند به شمار می‌رود. در این سن اثرات مادری بر روی بره رو به کاهش است و می‌توان این صفت را به‌عنوان یکی از معیارهای انتخاب به حساب آورد (Saatic 1999). اندازه‌گیری ساختارهای مختلف بدن، معیارهای خوبی برای دآوری خصوصیات گوشت هستند و همچنین در توسعه معیارهای مناسب انتخاب مفید می‌باشند (Bose and Basu 1984; Sharaby and Sulleiman 1987). دانستن وزن بدن گوسفند به‌دلایل اصلاح نژادی (انتخاب)، تغذیه‌ای، مراقبت‌های بهداشتی (تجویز آنتی بیوتیک و لیمیتیک و غیره) و نظارت بر الگوی رشد بسیار حائز اهمیت است. از طرفی وزن زنده بدن را می‌توان به‌وسیله سنجش بدن پیش‌بینی نمود و در مزرعه‌ای با امکانات کم

برای وزن‌کشی حیوانات، معادله پیش‌بینی بر اساس اندازه گیری‌های بدن بسیار مفید خواهد بود (Bhattacharya et al. 1984).

برنامه‌های کاربردی مدل‌های شبکه عصبی مصنوعی در تحقیقات علوم دامی به‌وسیله مؤلفان اندکی برای پیش‌بینی تولید شیر، چربی و پروتئین (Salehi et al. 1998)، پیش‌بینی مقدار سلول‌های بدنی و محتوای چربی و پروتئین در شیر (Whyte 2000) و پیش‌بینی میزان تولید شیر و مقدار پروتئین و چربی شیر (Khazaei et al. 2008)، محاسبه ارزش اصلاحی گاوهای شیری نژاد هلشتاین^۱ ایران (Shahinfar et al. 2012)، ارزیابی وضعیت فیزیولوژیکی گاوها نظیر فحلی، گوساله زایی و سلامت (Vassileva and Radev. 2001) و آنالیز آزمایشگاهی توسعه جنینی (Wilkinson et al. 1996) گزارش شده‌است. فواید شبکه عصبی مصنوعی برای پیش‌بینی شیرداری به‌خوبی جهت تست شیردهی روزانه در گوسفند چیوس^۲ بررسی شده‌است (Kominakis 2002). همچنین در تحقیقی کاربرد شبکه عصبی مصنوعی در شناسایی و طبقه‌بندی سه نژاد گوسفند ایرانی شال، زندی و زل بررسی شد (Mousavizade et al. 2009). در تحقیقی دیگر کاربرد شبکه عصبی مصنوعی در پیش‌بینی و شناسایی ژنوتیپ‌های ژن DGAT1 در گاو هلشتاین بررسی شد (Hosseinpour et al. 2009) که از مدل پس انتشار برای طراحی و آموزش شبکه عصبی استفاده شد. در پژوهشی (Ehret et al. 2015) معماری‌های غیرخطی مختلف را به‌عنوان ورودی‌های شبکه آزمون کردند تا توانایی آن‌ها را برای پیش‌بینی صفات شیرداری در گاو شیری با استفاده از داده‌های SNP مقیاس بزرگ ارزیابی کنند. در شبکه‌های عصبی مصنوعی به دانش قبلی از مسئله نیاز نیست و تنظیم و تطابق بین متغیرهای ورودی و خروجی بدون هیچ فرضی انجام می‌شود، بدون این‌که با فرض نادرست، خطایی ایجاد شود. از آنجاکه خروجی نرون غیر خطی است، شبکه‌های عصبی مصنوعی مانند مدل‌های غیرخطی عمل می‌کنند. بنابراین، همبستگی‌های غیرخطی بین ورودی‌ها و خروجی‌ها را می‌توانند پیدا کنند. در حقیقت با روش‌های ریاضی می‌توان نشان داد که پرسپترون چند لایه یک

¹ Holstein

² Chios

داده های تست و ۱۵ درصد هم به عنوان داده های اعتبارسنجی استفاده شدند.

مدل مورد استفاده در نرم افزار ASReml به صورت زیر بود:

$$y = Xb + Zu + e$$

که در آن، y بردار مشاهدات، X ماتریس طرح برای اثرات ثابت، b بردار اثرات ثابت، Z ماتریس طرح برای اثرات ژنتیکی، u بردار اثرات ژنتیکی و e بردار خطا.

مدل شبکه عصبی به کار رفته در این تحقیق پرسپترون چند لایه^۳ (MLP) و الگوریتم مورد استفاده در آن الگوریتم پس انتشار خطا بود (Reed and Marks 1998). این الگوریتم همواره به دنبال حداقل سازی مربعات خطا است. بنابراین، هر شبکه عصبی از یک تابع خطایی^۴ همانند معادله (۱) پیروی می کند (Haykin 1999; Moradi et al. 2015).

$$\varepsilon(t) = \frac{1}{2} e^2 \quad \text{معادله (۱)}$$

در رابطه (۱)، $\varepsilon(t)$ مقدار آنی خطا^۵ در لحظه t و e بیانگر مقدار خطای مشاهده شده است.

هنگام طراحی یک شبکه باید پارامترهای ساختار شبکه، نوع الگوریتم آموزش، نرخ یادگیری، تعداد لایه های شبکه و تعداد نرون ها در هر لایه و تعداد تکرارها برای هر الگو در خلال آموزش مد نظر قرار گیرد. نوع آموزش در شبکه MLP آموزش با نظارت است و قانون یادگیری در آن، یادگیری پس از انتشار یا دلتای تعمیم یافته است.

قبل از آموزش شبکه، ورودی ها و هدف مقیاس بندی شد تا آن ها در یک محدوده خاص قرار گیرند تا موجب بهبود عملکرد شبکه شود. روش های مختلفی برای نرمال سازی داده ها وجود دارد. اما، یکی از روش های معمول برای مقیاس بندی ورودی های شبکه، استفاده از ماکزیمم و مینیمم داده ها است. برای این منظور از معادله (۲) استفاده شد (Haykin 1999; Moradi et al. 2015).

$$xn = \frac{(x - \min)}{(\max - \min)} \quad \text{معادله (۲)}$$

که در آن xn ، $\max$ و $\min$ به ترتیب داده نرمال شده، بزرگ ترین داده و کوچک ترین داده بوده و x داده ی قبل از نرمال شدن است.

مدل رگرسیونی عمومی است، یعنی می تواند بین هر جفت مجموعه داده ارتباط را بررسی و در صورت وجود گزارش کند (Bahreini Behzadi and Aslaminejad 2010). در مقایسه با آنالیز رگرسیون، شبکه های عصبی مصنوعی ابزار مناسب تری برای برآورد هستند و دقیق تر از آنالیز رگرسیون خطی چندگانه هستند (Njubi et al. 2010). به علاوه، اگر مدل ها در یک سیستم ترکیب شوند، شبکه های عصبی مصنوعی شایسته تر از آنالیز رگرسیون خطی چندگانه هستند (Njubi et al. 2010). اگرچه شبکه های عصبی مصنوعی به طور گسترده ای برای پیش بینی و طبقه بندی در عرصه های گوناگون مانند امور مالی، پزشکی، زمین شناسی، مهندسی، فیزیک و زیست شناسی استفاده شده اند با این حال به کارگیری از این شبکه ها در اصلاح نژاد و به خصوص در پرورش نشخوارکنندگان کوچک خیلی کم مطالعه شده است (Grzesiak et al. 2003; Sharma et al. 2006; Sharma et al. 2007; Gandhi et al. 2009; Ruhil et al. 2011). از طرفی علی رغم این که در گوسفند کرمانی مطالعات ژنتیک کمی و ملکولی زیادی صورت گرفته است، ولی هیچ مطالعه ای در زمینه شبکه های عصبی مصنوعی روی این نژاد گزارش نشده است. از این رو، مطالعه حاضر به منظور توسعه شبکه عصبی مصنوعی برای پیش بینی ارزش اصلاحی صفات رشد برای اولین بار در گوسفند کرمانی انجام شد.

مواد و روش ها

داده ها و اطلاعات شجره نامه ای گوسفندان کرمانی که در این تحقیق مورد استفاده قرار گرفتند از پایگاه اصلاح نژادی گوسفند کرمانی و در طی سال های ۱۳۸۳-۱۳۷۳ جمع آوری شده است. داده های قابل دسترس برای آنالیز شامل رکودهای ۸۶۷ بره ی متولد شده بود. صفات مورد مطالعه شامل جنس دام^۱، سن مادر، وزن تولد^۲ و وزن سن ۳ ماهگی بود. برآورد ارزش اصلاحی وزن تولد و ارزش اصلاحی وزن سه ماهگی توسط نرم افزار ASReml صورت گرفت و به داده های مورد مطالعه اضافه شد. از کل داده ها، ۷۰ درصد از آن ها به عنوان داده های آموزش، ۱۵ درصد

^۳ Multilayer perceptron

^۴ Error function

^۵ Instantaneous value of the error


^۱ Sex

^۲ Birth weight (BW)

اساس ضریب همبستگی و میانگین مربعات خطا (MSE) نتیجه بهتری نسبت به سایر توابع آموزشی داشت چون بیشترین ضریب همبستگی و کمترین MSE را دارا بود.

نتایج

بعد از مشخص شدن تعداد نرون های ورودی در لایه ورودی و تعداد نرون ها در لایه مخفی بررسی شد و شبکه عصبی با تابع آموزش trainlm با سه متغیر ورودی جنس، سن مادر و وزن تولد و یک خروجی به عنوان ارزش اصلاحی وزن تولد با ۱ تا ۱۵ نرون در لایه مخفی با ۲۷ تکرار اجرا شد و بر اساس نتایج حاصل شده که در شکل ۲ هم نشان داده شده است تعداد ۸ نرون به عنوان نرون لایه مخفی انتخاب شدند. همانطور که مشخص است ضریب همبستگی (R) براساس تعداد نرون ها در لایه مخفی تا ۱۵ نرون رسم شده که بالاترین ضریب همبستگی متعلق به نقطه ای است که شامل ۸ نرون در لایه مخفی است (جدول ۱).



تعداد نرون لایه مخفی

شکل ۱- شبکه عصبی مصنوعی چند لایه با شش متغیر ورودی و سه نرون در لایه مخفی برای ارزش اصلاحی وزن سه ماهگی.


در این تحقیق پس از به کارگیری داده های معمولی و نرمال شده، مشاهده شد که داده های نرمال شده، عملکرد شبکه، به ویژه قابلیت تعمیم آن را افزایش می دهد. بنابراین، در این مطالعه از داده های نرمال شده استفاده شد.

شبکه عصبی می تواند ساختارهای مختلفی داشته باشد اما متداول ترین روش استفاده از ساختار لایه ای است که در این پژوهش استفاده شد و شامل یک لایه ورودی، یک تا چند لایه میانی یا پنهان و یک لایه خروجی است. در هر لایه تعدادی گره یا به اصطلاح زیستی نرون وجود دارد که در شکل (۱) به صورت ساده نشان داده شده است. پس از نرمال سازی داده های ورودی نسبت به انتخاب معماری مناسب شبکه اقدام شد. پس از ایجاد مدل ها، به منظور بررسی فرضیه های تحقیق دقت در پیش بینی به عنوان معیار عملکرد مدل ها مورد استفاده قرار گرفت. منظور از دقت پیش بینی میزان همبستگی میان مقدار پیش بینی شده و مقدار واقعی است که توسط خود نرم افزار MATLAB برآورد می شود که بیانگر این است که خروجی های برآورد شده تا چه اندازه به خروجی های واقعی نزدیک می باشند.

در این پژوهش، تعداد نرون های لایه ورودی در شبکه ی مربوط به وزن تولد ۳ نرون و در شبکه ی مربوط به وزن ۳ ماهگی ۵ و ۶ نرون بود. تعیین تعداد نرون های لایه ی میانی (پنهان) کار ساده ای نیست و بیش تر با استفاده از سعی و خطا صورت می گیرد، به نحوی که عملکرد کلی شبکه بهبود یابد. در واقع اگر تعداد نرون های لایه میانی بیش از اندازه باشد شبکه به جای یادگیری، حفظ می کند. بنابراین، باید بین این دو تعادل برقرار شود تا عملکرد کلی شبکه بهبود یابد. از کل داده های مورد استفاده ۷۰ درصد به عنوان آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد به عنوان تست در نظر گرفته شد. در طی فرآیند یادگیری، مرتباً میزان فراگیری شبکه توسط توابع هدف سنجیده شده و در نهایت شبکه ای مورد پذیرش قرار گرفت که دارای کمترین خطا بود. در سیستم عصبی مصنوعی مورد استفاده در این تحقیق داده ها با توابع آموزشی مختلفی از جمله ¹trainlm و ²traind مورد بررسی قرار گرفت (Beale et al. 2004) که روش trainlm بر

¹ Gradient descent

² Levenberg-Marquardt back propagation



شکل ۲- خطوط رگرسیون و ضرایب همبستگی برای شبکه عصبی وزن تولد.

جدول ۱- خلاصه نتایج شبکه های عصبی

شبکه عصبی	تعداد نرون های لایه ورودی	تعداد نرون های لایه میانی	ضریب همبستگی داده های آموزشی	ضریب همبستگی داده های تست
ارزش اصلاحی وزن تولد	۳	۸	۰/۵۴	۰/۷۳
ارزش اصلاحی وزن ۳ ماهگی	۶	۳	۰/۵۳	۰/۷۴

پس از مشخص شدن تعداد نرون های لایه مخفی، اقدام به اجرای مجدد شبکه توسط نرم افزار با تعداد ۸ نرون شد که بهترین شبکه برای پیش بینی ارزش اصلاحی وزن تولد شامل ۳ نرون در لایه ورودی یعنی جنس، سن مادر و وزن تولد، ۸ نرون در لایه مخفی با تابع آموزش trainlm در تکرار ۱۷ از مجموع ۲۷ تکرار بود. این شبکه دارای ضریب همبستگی ۷۳ درصد برای داده های تست و ۵۴ درصد برای داده های آموزش بود که در شکل ۳ نشان داده شده است.


در هنگام آموزش شبکه خطای مربوط به داده های آموزش، تست و اعتبار سنجی مرتب اندازه گیری می شود و زمانی که به مدت ۱۰ تکرار دیگر هیچ کاهش در میانگین مربعات خطای داده های اعتبار سنجی دیده نشد، آموزش متوقف می شود. اگر این فرایند طی نشود شبکه به جای یادگیری به حفظ داده ها می پردازد و پیش بینی با دقت پایینی انجام می گیرد. میانگین مربعات خطای داده های اعتبار سنجی تا تکرار ۱۷ رو به کاهش بود، ولی از تکرار ۱۷ به بعد اندکی ثابت و سپس روند صعودی به خود گرفته است و میانگین مربعات خطای داده های اعتبار سنجی در تکرار ۱۷ برابر ۰/۹۴ درصد (۰/۰۰۹۴) بود.

برای پیش بینی ارزش اصلاحی وزن سه ماهگی از شبکه ای شامل شش ورودی جنس، سن مادر، وزن تولد، ارزش اصلاحی وزن تولد، سن در وزن سه ماهگی و وزن سه ماهگی استفاده شد. سپس برای به دست آوردن تعداد نرون های بهینه در لایه مخفی شبکه ای با تابع آموزش trainlm و ۶ نرون در لایه ورودی با ۲۷ تکرار اجرا شد. تعداد ۳ نرون برای لایه مخفی با توجه به شکل ۴ به دست آمد (جدول ۱). پس از مشخص شدن تعداد نرون لایه مخفی اقدام به اجرای شبکه ای با مشخصات ۶ نرون در لایه ورودی، ۳ نرون در لایه پنهان و یک نرون در لایه خروجی، دارای تابع آموزش trainlm با ۲۷ تکرار شد. شبکه در تکرار ۱۷ متوقف شد و ضرایب همبستگی داده های آموزش ۵۳/۰ و ضریب همبستگی داده های تست ۷۴/۰ به دست آمد که حد قابل قبولی برای پیش بینی ارزش اصلاحی است که در شکل ۵ نشان داده شده است.


همانطور که در شکل (۶) مشخص است، MSE داده های تست تا تکرار ۱۷ رو به کاهش بوده، ولی پس از این تکرار دیگر رو به کاهش نرفته است. لذا، در اینجا فرایند آموزش متوقف و وزن ها ثابت می شوند. خطای گرادینان برای این شبکه در بازه ۰/۰۰۰۱

تا در تکرار ۱۷ به دلیل افزایش بیش از حد تکرارهای خطا برای ۱۰ بار متوالی، متوقف شد.


تا یک بود و همانطور که در شکل ۷ نشان داده شده، خطای آموزش در داده های اعتبار سنجی تا تکرار ۱۷ دو بار بالا رفته ولی با فرصت ۱۰ تکراری که داده شده بود مجددا آموزش ادامه یافت




شکل ۴- نمودار ضرایب همبستگی داده های آموزش و تست برای شبکه دوم وزن سه ماهگی



شکل ۵- ضرایب همبستگی برای داده های آموزش و تست در شبکه دوم وزن ۳ ماهگی



شکل ۶- نمودار عملکرد داده های اعتبار سنجی برای شبکه دوم وزن ۳ ماهگی



شکل ۷- منحنی خطای گرادین و ارزیابی اعتبارسنجی شبکه دوم وزن ۳ ماهگی

بحث

در این پژوهش از شبکه عصبی پرسپترون چند لایه (MLP) برای برآورد ارزش اصلاحی صفات وزن تولد و سه ماهگی گوسفند کرمانی استفاده شد. نتایج نشان داد که شبکه عصبی مصنوعی پرسپترون چند لایه با ۳ متغیر ورودی و تعداد ۸ نرون در لایه مخفی با ضریب همبستگی 0.73 توانایی پیش بینی ارزش اصلاحی وزن تولد و همچنین شبکه عصبی مصنوعی پرسپترون چند لایه با ۶ متغیر ورودی و تعداد ۳ نرون در لایه با ضریب همبستگی 0.74 توانایی پیش بینی ارزش اصلاحی وزن ۳ ماهگی گوسفند نژاد کرمانی را دارا است.

با توجه به روش های ژنتیک آماری برای انتخاب، بعضی از دسته بندی های روش شناسی قابل توجه بوده و به طور گسترده ای، استفاده شده است که عبارتند از: شاخص های انتخاب (Verardi et al, 2014)، روش انتخاب ترکیبی (Ribeiro et al. 2013; Verardi et al, 2014)، و روش REML BLUP¹ (Ferreira et al. 2012). با این وجود نمونه جدیدی می تواند در ژنتیک و اصلاح نژاد برای اهداف انتخابی به کار گرفته شود که شامل روش های تصادفی نباشد. در پژوهشی (Gorgulu 2012) از شبکه عصبی مصنوعی برای پیش بینی تولید شیر در ۳۰۵ روز گاو براون سویس استفاده کرد و مشاهده نمود که میانگین تولید پیش بینی شده با شبکه عصبی مصنوعی خیلی نزدیک به مقدار واقعی است. او ضریب

¹ Restricted maximum likelihood/best linear unbiased prediction

همبستگی $0.74-0.76$ را برای شبکه عصبی گزارش نمود. از مقایسه ۶ فرم رگرسیون غیرخطی با شبکه عصبی مصنوعی برای پیش بینی صفات رشد گوسفند بلوچی (Bahreini Behzadi 2010) and Aslaminejad نتیجه گرفتند که شبکه عصبی مصنوعی نمودار رشد توصیفی بهتری نسبت به مدل های غیرخطی ایجاد می کند و پیش بینی دقیق تری می دهد. این محققان (Bahreini Behzadi 2010) MSE برابر 0.06 را برای شبکه عصبی مصنوعی گزارش کردند که مشابه نتایج پژوهش حاضر است. مقایسه رگرسیون چندگانه و شبکه عصبی مصنوعی برای برآورد تولید شیر در ۳۰۵ روز توسط (Grzesiak et al. 2003) انجام شده است. آن ها ضریب همبستگی و MSE به ترتیب برابر 0.88 و 0.08 را برای شبکه عصبی مصنوعی گزارش کردند که تأیید کننده نتایج این پژوهش است. در پژوهشی (Ehret et al. 2015) معماری های غیرخطی مختلف را به عنوان ورودی های شبکه آزمون کردند تا توانایی آن ها را برای پیش بینی صفات شیرواری در گاو شیری با استفاده از داده های SNP مقیاس بزرگ ارزیابی کنند. برای آموزش آن ها از الگوریتم پس انتشار تنظیم شده استفاده کردند و از متوسط همبستگی بین فنوتیپ های مشاهده شده و پیش بینی شده برای ارزیابی توانایی پیش بینی استفاده کردند. این محققان نتیجه گرفتند که شبکه های عصبی مصنوعی ماشین هایی قدرتمند برای پیش بینی های ژنومی غیرخطی در اصلاح نژاد دام هستند. نتایج حاصل از تحقیقات مختلف نشان می دهد که شبکه عصبی MLP برای محاسبه ارزش اصلاحی

ضریب همبستگی 0.72 ، توانایی پیش‌بینی قابل قبولی از ارزش اصلاحی وزن تولد گوسفند نژاد کرمانی را دارا است. همچنین شبکه عصبی مصنوعی MLP با 6 متغیر ورودی، یک لایه مخفی، تابع محرک تانژانت سیگموئید و تعداد 3 نورون در لایه مخفی و تابع آموزش lm یا trainlm با ضریب همبستگی 0.74 ، توانایی پیش‌بینی قابل قبولی از ارزش اصلاحی وزن 3 ماهگی گوسفند نژاد کرمانی را دارا است. افزودن ارزش اصلاحی وزن تولد به عنوان متغیر ورودی به شبکه عصبی برای پیش‌بینی ارزش اصلاحی وزن 3 ماهگی باعث افزایش دقت در تخمین ارزش اصلاحی وزن 3 ماهگی می‌شود. به طور کلی می‌توان نتیجه گرفت که شبکه‌های عصبی مصنوعی پتانسیل برآورد ارزش اصلاحی وزن تولد و وزن سه ماهگی گوسفند و دیگر دام‌ها را دارند و باید با روش‌های معمول و مرسوم مقایسه شوند و از جنبه‌های مختلف مورد آزمون قرار گیرند تا مزیت‌ها و یا معایب احتمالی آن‌ها مشخص شود و به توان تصمیم گرفت که می‌توانند به موازات یا به جای دیگر نرم‌افزارهای معمول برای برآورد ارزش‌های مورد نظر جهت مقاصد اصلاح نژادی مورد استفاده قرار گیرند.

گاوهای شیری نژاد هلشتاین ایران با همبستگی 0.42 (Shahinfar et al. 2012)، در پیش‌بینی تولید شیر، چربی و پروتئین (Rui et al. 2011)، در پیش‌بینی و مشخص کردن ارزش لاشه در گاو گوشتی با استفاده از اطلاعات پیش از کشتار (Salehi et al. 1994; Brethour 1994)، برای تخمین شیرواری بر پایه رکوردهای 5 ماه ابتدایی با ضریب اطمینان 80 درصد (Runil et al. 2011)، پیش‌بینی میزان تولید شیر و مقدار پروتئین و چربی شیر با همبستگی 45 درصد (Khazaei et al. 2008) و در تخمین تولید شیر نژاد کاران فریز هندی با دقت 92 درصد (Kominakis 2002) کاربرد دارد. در این پژوهش نیز نشان داده شد که شبکه عصبی (MLP) پتانسیل برآورد ارزش اصلاحی صفات رشد گوسفند کرمانی را دارد. پس، می‌توان گفت نتایج به دست آمده با نتایج تحقیقات انجام شده (Benavides et al. 2003; Ruhil et al. 2011; Craninx et al. 2008; Salehi et al. 1998; Hosseinpour et al. 2009; Whyte 2000; Brethour 1994; Shahinfar et al. 2002; Khazaei et al. 2008; Kominakis 2002) در زمینه شبکه عصبی مصنوعی در علوم دامی هم‌سو است.

نتیجه‌گیری کلی

شبکه عصبی مصنوعی MLP با 3 متغیر ورودی، یک لایه مخفی و تعداد 8 نورون در لایه مخفی و تابع آموزش lm یا trainlm با

منابع

- Bahreini Behzadi MR, Aslaminejad AA (2010) A comparison of neural network and nonlinear regression prediction of sheep growth. *Journal of Animal and Veterinary advances* 9: 2128-2131.
- Beale MH, Hagan MT, Demuth HB (2004). *Neural Network Toolbox User's Guide* (Release 14). The Mathworks Inc., Natick MA.
- Benavides MG, Samarasinghe S, Hikford JGH (2003). The use of artificial neural network to diagnose mastitis in dairy cattle. *Proceedings of the International IEEE conference, Portland, OR, USA.*
- Bhattacharya B, Ghosh TK, Duttagupta R, Maitra DN (1984) Estimation of body weight in Black Bengal goats from body measurements [India]. *Indian Veterinary Journal* 61: 406-408.
- Bose S, Basu SB (1984) Relationship between body weight measurement and meat production in Beetal goats. *Indian Veterinary Journal* 61:670-673.
- Brethour JR (1994) Estimating marbling score in live cattle from ultrasound images using pattern recognition

- and neural network procedures. *Journal of animal science* 72:1425-1432.
- Craninx M, Fievez V, Vlaeminck B, De Baets B (2008) Artificial neural network models of the rumen fermentation pattern in dairy cattle. *Computers and Electronics in Agriculture* 60: 226-238.
- Ehret A, Hochstuhl D, Gianola D, Thaller G (2015) Application of neural networks with back-propagation to genome-enabled prediction of complex traits in Holstein-Friesian and German Fleckvieh cattle. *Genetics Selection Evolution* (2015) 47:22.
- Ferreira RT, Viana AP, Barroso DG, Resende MDV, Amaral Júnior AT (2012) Toonaciliata genotype selection with the use of individual BLUP with repeated measures. *Scientia Agricola* 69: 210-216.
- Gandhi RS, Raja TV, Ruhil AP, Kumar A (2009) Evolving prediction equations for lifetime milk production using artificial neural network methodology in Sahiwal cattle. In *Proceedings of 37th dairy industry conference Goa* (7-9).
- Gorgulu O (2012) Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science* 42: 280-287.

- Grzesiak W, Lacroix RR, 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: 307-310.
- Gorgulu O (2012) Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *South African Journal of Animal Science* 42: 280-287.
- Haykin S (1999) *Neural Network*, second Edition, Simon and Schuster company, new Jersey.
- Hosseinpour MA, Mousavizadeh H, Aminafshar M (2009) Prediction of DGAT1 genotypes using artificial neural network. The 18th Annual Growth Factor and Signal Transduction Conference Scheman Building. June 11-14. Iowa State Center at Iowa State University, Ames, Iowa, U.S.A.
- Kargar N, Moradishahrababak M, Moravej H, Rokuei M, (2006) Genetic estimate of growth and wool traits in kermani sheep. *Animal science Journal (Pajouhesh and sazandegi)* 73: 88-95. (In Farsi).
- Khazaei J, Nikosiar M, Nagatsuka T, Ninomiya S (2008) Approximating milk yield and milk fat and protein concentration of cows through the use of mathematical and artificial neural networks models. In *World conference on agricultural information and IT, IAALD AFITA WCCA* 91-105.
- Khodabakhshzadeh R, Mohammadabadi MR, Esmailzadeh Koshkoieh A, Moradi-Shahrehababak H, Bordbar F, Ansari Namin S (2016) Identification of point mutations in exon 2 of GDF9 gene in Kermani sheep. *Polish Journal of Veterinary Sciences* 19: 281-289.
- Kominakis AP, Abas Z, Maltaris I, Rogdakakis E (2002) A preliminary study of the application of artificial neural networks to prediction of milk yield in dairy sheep. *Journal of Computers and electronics in agriculture* 35: 35-48.
- Mohammadabadi MR, Sattayi mokhtari, R (2013) Estimation of (Co) Variance Components of Ewe Productivity Traits in Kermani Sheep. *Slovak Journal of Animal Science* 46: 45-51.
- Moradi H, Jokar I, Forouzantabar A (2015) Modelling and forecasting gold price using GMDH neural network. *Indian Journal of Fundamental and Applied Life Sciences* 5: 30-41
- Mousavizadeh A, Salehi A, Barzekar A, Mahmoodi M (1999) Application of artificial neural network in classification and forecast livestock production. *Theird animal science congress. Mashhad University (In farsi)*.
- Njubi DM, Wakhungu JW, Badamana MS (2010) Use of test-day records to predict first lactation 305-day milk yield using artificial neural network in Kenyan Holstein-Friesian dairy cows. *Tropical Animal Health and Production* 42: 639-644.
- Raman KS, Sundararaman MN, Haribhaskar S, Ganesakale D (2003) Biometrics and breed characteristics of Madras Red sheep. *Indian Journal of Small Rumimants* 9: 6-9.
- Reed RD, Marks RJ (1998) *Neural smithing: Supervised learning in feed forward artificial neural networks*. Cambridge: MIT Press.
- Ribeiro ND, Mambrin RB, Storck L, Prigol M, Nogueira CW (2013) Combined selection for grain yield, cooking quality and minerals in the common bean. *Revista Ciência Agronômica* 44: 869-877.
- Ruhil AP, Gandhi RS, Monalisa D, Behra K, Raja TV (2011) Prediction of lactation yield based on partial lactation records using artificial neural networks. In *Proc. 5th National Conference on Computing for Nation Development, INDIACOM-2011*.
- Saatci M, Ultas Z (1999) Variance component due to direct and maternal effect and estimates of breeding value for 12-week weight welsh mountain lamb. *Animal science* 69: 345-352.
- Salehi F, Lacroix R, Wade KM (1998) Improving dairy yield predictions through combined record classifiers and specialized artificial neural networks. *Computers and Electronics in Agriculture* 20: 199-213.
- Shahinfar S, Mehrabani-Yeganeh H, Lucas C, Kalhor A, Kazemian M, Weigel KA (2012) Prediction of breeding values for dairy cattle using artificial neural networks and neuro-fuzzy systems. *Computational and mathematical methods in medicine*.
- Sharaby MA, Sulleiman I (1987) Factors influencing meat production traits and their association with body weight dimensions. *Word Review of Animal Production* 23: 86-88.
- Sharma AK, Sharma RK, Kasana HS (2006) Empirical comparisons of feed-forward connectionist and conventional regression models for prediction of first lactation 305-day milk yield in Karan Fries dairy cows. *Neural Computing & Applications* 15: 359-365.
- Sharma AK, Sharma RK, Kasana HS (2007) Prediction of first lactation 305-day milk yield in Karan Fries dairy cattle using ANN modeling. *Applied Soft Computing* 7: 1112-1120.
- Vajed Ebrahimi, MT, Mohammad Abadi MR, Esmailzadeh AK (2016) Analysis of genetic diversity in five Iranian sheep population using microsatellites markers. *Journal of Agricultural Biotechnology* 7: 143-158 (In Farsi).
- Vassileva ST, Radev D (2001) Application of neural networks in dairy husbandry. *Biotechnology in Animal Husbandry* 17: 287-294.
- Verardi CK; Oliveira ALB; Silva GAP; Gouvêa LRL; Gonçalves PS (2014) Comparison between different selection methods of rubber trees. *Industrial Crops and Products* 52: 255-263.
- Whyte D, Claycomb RK, Unnemeyer R (2000) Measurement of somatic cell count, fat and protein in milk using visible to near infrared spectroscopy, *ASAE Annual International Meeting, Milwaukee, Wisconsin, USA* 1-11.
- Wilkinson RF, Ming R, Anderson B, Bunch TD, White KL (1996) The use of neural networks in developing novel embryoculture media-formulations. *Theriogenology* 45: 41-49.
- Zamani P, Akhondi M, Mohammadabadi MR (2015) Associations of Inter-Simple Sequence Repeat loci with predicted breeding values of body weight in sheep. *Small Ruminant Research* 132: 123-127.

