ژنتیک نوین
دوره دوازدهم، شماره ۳، پاییز ۱۳۹۶
صفحه ۳۳۱ - ۳۲۳

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 قطب الدینی[۱]، محمدرضا محمدآبادی*[۱]، حسین نظام آبادی‌پور[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 HR[1], Mohammadabadi MR*[1], Nezamabadi Pour H[2]

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 گوسفندکرمانی 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 ٦ 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 چندلایه با ٦ متغییر ورودی و تعداد ۳ نرون در لایه با ضریب همبستگی ۰/۷٤ 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

[Downloaded from mail.mg.genetics.ir on 2026-11-20]

[DOR: 20.1001.1.20084439.1396.12.3.1.5]

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 عمدتا آب و هوای گرم و خشک غالب است و مراتع کم و کم کیفت 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 ـ 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 داوری 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 لیمینتیک 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[1] 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 شیرواری به‌خوبی جهت تست شیردهی روزانه در گوسفند چیوس[2] بررسی شده‌است (Kominakis 2002). همچنین در تحقیقی کاربرد شبکه عصبی مصنوعی در شناسائی 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 شناسائی ژنوتیپ‌های ژن DGATl 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 شیرواری 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

[Downloaded from mail.mg.genetics.ir on 2026-11-20]

[DOR: 20.1001.1.20084439.1396.12.3.1.5]

مدل رگرسیونی عمومی است، یعنی می‌تواند بین هر جفت مجموعه داده ارتباط را بررسی و در صورت وجود گزارش کند (Bahreini Behzadi and Aslaminejad 2010). در مقایسه با آنالیز رگرسیون، شبکه‌های عصبی مصنوعی ابزار مناسب‌تری برای برآورد هستند و دقیق‌تر از آنالیز رگرسیون خطی چندگانه هستند (Njubi et al. 2010). به‌علاوه، اگر مدل‌ها در یک سیستم ترکیب شوند، شبکه‌های عصبی مصنوعی شایسته‌تر از آنالیز رگرسیون خطی چندگانه هستند (Njubi et al. 2010). اگرچه شبکه‌های عصبی مصنوعی به‌طور گسترده‌ای برای پیش‌بینی و طبقه‌بندی در عرصه‌های گوناگون مانند امور مالی، پزشکی، زمین‌شناسی، مهندسی، فیزیک و زیست شناسی استفاده شده‌اند با این حال به‌کارگیری از این شبکه‌ها در اصلاح نژاد و به‌خصوص در پرورش نشخوارکنندگان کوچک خیلی کم مطالعه شده‌است (Grzesiak et al. 2003; Sharma et al. 2006 ; Sharma et al. 2007 ; Gandhi et al. 2009 ; Ruhil et al. 2011). از طرفی علی‌رغم این که در گوسفند کرمانی مطالعات ژنتیک کمی و ملکولی زیادی صورت گرفته است، ولی هیچ مطالعه‌ای در زمینه شبکه‌های عصبی مصنوعی روی این نژاد گزارش نشده‌است. از این رو، مطالعه حاضر به‌منظور توسعه شبکه عصبی مصنوعی برای پیش‌بینی ارزش اصلاحی صفات رشد برای اولین بار در گوسفند کرمانی انجام شد.

مواد و روش‌ها

داده‌ها و اطلاعات شجره‌نامه‌ای گوسفندان کرمانی که در این تحقیق مورد استفاده قرار گرفتند از پایگاه اصلاح نژادی گوسفند کرمانی و در طی سال‌های ۱۳۸۳-۱۳۷۳ جمع‌آوری شده‌است. داده‌های قابل دسترس برای آنالیز شامل رکوردهای ۸۶۷ بره‌ی متولد شده بود. صفات مورد مطالعه شامل جنس دام[1]، سن مادر، وزن تولد[2] و وزن سن ۳ ماهگی بود. برآورد ارزش اصلاحی وزن تولد و ارزش اصلاحی وزن سه ماهگی توسط نرم‌افزار ASReml صورت گرفت و به داده‌های مورد مطالعه اضافه شد. از کل داده‌ها، ۷۰ درصد از آن‌ها به‌عنوان داده‌های آموزش، ۱۵ درصد داده‌های تست و ۱۵ درصد هم به‌عنوان داده‌های اعتبارسنجی استفاده شدند.

مدل مورد استفاده در نرم‌افزار ASReml به‌صورت 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[3] (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[4] همانند معادله (۱) پیروی می‌کند (Haykin 1999; Moradi et al. 2015).

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

در رابطه (۱)، $\varepsilon(t)$ مقدار آنی خطا[5] در لحظه t و e بیانگر مقدار خطای مشاهده شده‌است.

هنگام طراحی یک شبکه باید پارامترهای ساختار شبکه، نوع الگوریتم آموزش، نرخ یادگیری، تعداد لایه‌های شبکه و تعداد نرون‌ها 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، ورودی‌ها و هدف مقیاس‌بندی شد تا آن‌ها در یک محدوده خاص قرار گیرند تا موجب بهبود عملکرد شبکه شود. روش‌های مختلفی برای نرمال‌سازی داده‌ها وجود دارد. اما، یکی از روش‌های معمول برای مقیاس‌بندی ورودی‌های شبکه، استفاده از ماکزیمم و مینیمم داده‌ها است. برای این منظور از معادله (۲) استفاده شد (Haykin 1999; Moradi et al. 2015).

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

که در آن xn، max و min به‌ترتیب داده نرمال شده، بزرگ‌ترین داده و کوچک‌ترین داده بوده و x داده‌ی قبل از نرمال شدن است.

[1] Sex
[2] Birth weight (BW)
[3] Multilayer perceptron
[4] Error function
[5] Instantaneous value of the error

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]

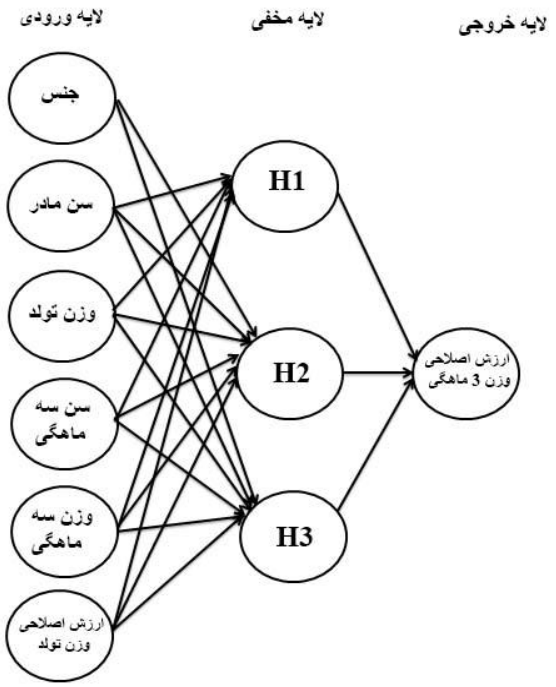
در این تحقیق پس از به کارگیری داده‌های معمولی و نرمال شده، مشاهده شد که داده‌های نرمال شده، عملکرد شبکه، به‌ویژه قابلیت تعمیم آن را افزایش می‌دهد. بنابراین، در این مطالعه از داده‌های نرمال شده استفاده شد.

شبکه عصبی می‌تواند ساختارهای مختلفی داشته باشد اما متداول‌ترین روش استفاده از ساختار لایه‌ای 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) به‌صورت ساده نشان داده شده‌است. پس از نرمال‌سازی داده‌های ورودی نسبت به انتخاب معماری مناسب شبکه اقدام شد. پس از ایجاد مدل‌ها، به‌منظور بررسی فرضیه‌های تحقیق دقت در پیش‌بینی به عنوان معیار عملکرد مدل‌ها مورد استفاده قرار گرفت. منظور از دقت پیش‌بینی میزان همبستگی میان مقدار پیش‌بینی شده و مقدار واقعی است که توسط خود نرم‌افزار MATLAB برآورد می‌شود که بیانگر این است که خروجی‌های برآورد شده تا چه اندازه به خروجی‌های واقعی نزدیک می‌باشند.

در این پژوهش، تعداد نرون‌های لایه ورودی در شبکه‌ی مربوط به وزن تولد ۳ نرون و در شبکه‌ی مربوط به وزن ۳ ماهگی ۵ و ٦ نرون بود. تعیین تعداد نرون‌های لایه‌ی میانی (پنهان) کار ساده‌ای نیست و بیش‌تر با استفاده از سعی و خطا صورت می‌گیرد، به نحوی که عملکرد کلی شبکه بهبود یابد. در واقع اگر تعداد نرون‌های لایه میانی بیش از اندازه باشد شبکه به جای یادگیری، حفظ می‌کند. بنابراین، باید بین این دو تعادل برقرار شود تا عملکرد کلی شبکه بهبود یابد. از کل داده‌های مورد استفاده ۷۰ درصد به‌عنوان آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد به‌عنوان تست در نظر گرفته شد. در طی فرآیند یادگیری، مرتباً میزان فراگیری شبکه توسط توابع هدف سنجیده شده و در نهایت شبکه‌ای مورد پذیرش قرار گرفت که دارای کمترین خطا بود. در سیستم عصبی مصنوعی مورد استفاده در این تحقیق داده‌ها با توابع آموزشی مختلفی از جمله traingd[1] و trainlm[2] مورد بررسی قرار گرفت (Beale et al. 2004) که روش trainlm بر 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 نرون‌های ورودی در لایه‌ی ورودی تعداد نرون‌ها 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 به‌عنوان 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 شده‌است تعداد ۸ نرون به‌عنوان نرون لایه مخفی انتخاب شدند. همانطورکه مشخص است ضریب همبستگی (R) براساس تعداد نرون‌ها در لایه‌ی مخفی تا ۱۵ نرون رسم شده که بالاترین ضریب همبستگی متعلق به نقطه‌ای است که شامل ۸ نرون در لایه مخفی است (جدول ۱).

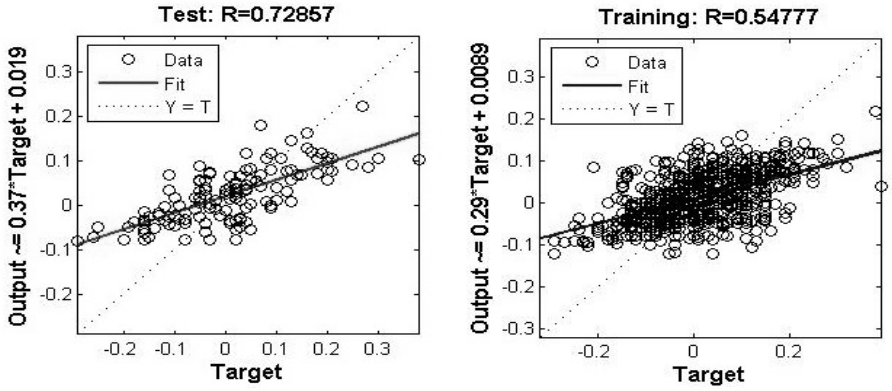


تعداد نرون لایه مخفی

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

[1] Gradient descent
[2] Levenberg-Marquardt back propagation

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]



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

جدول ۱- خلاصه نتایج شبکه‌های عصبی

شبکه عصبی	تعداد نرون‌های لایه ورودی	تعداد نرون‌های لایه میانی	ضریب همبستگی داده‌های آموزشی	ضریب همبستگی داده‌های تست
ارزش اصلاحی وزن تولد	۳	۸	۰/۵٤	۰/۷۳
ارزش اصلاحی وزن ۳ ماهگی	٦	۳	۰/۵۳	۰/۷٤

پس از مشخص شدن تعداد نرون‌های لایه مخفی، اقدام به اجـرای مجدد شبکه توسط نرم‌افزار با تعداد ۸ نرون شد که بهترین شـبکه برای پیش‌بینی ارزش اصلاحی وزن تولد شـامل ۳ نـرون در لایـه 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 داده‌هـای تسـت و ٥٤ درصد برای داده‌های آموزش بـود کـه در شـکل ۳ نشـان داده شده‌است.

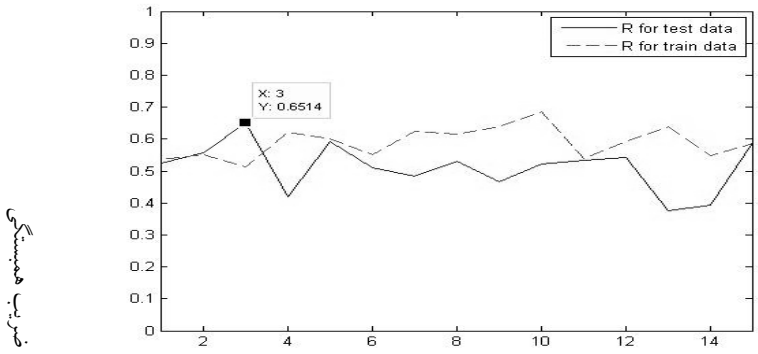
در هنگام آموزش شبکه خطای مربوط به داده‌های آموزش، تست و اعتبارسنجی مرتب اندازه‌گیری می‌شود و زمانی‌که به مدت ۱۰ تکرار دیگر هیچ کاهشی در میانگین مربعات خطای داده‌های اعتبار سنجی دیده نشد، آموزش متوقف می‌شود. اگر این فرایند طی نشود شبکه به جای یادگیری به حفظ داده‌ها می‌پردازد و پیش‌بینی با دقت پایینی انجام می‌گیرد. میانگین مربعات خطای داده‌های 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 داده‌های اعتبار سنجی در تکرار ۱۷ برابر ۰/۹٤ درصد (۰/۰۰۹٤) بود.

برای پیش‌بینی ارزش اصلاحی وزن سه ماهگی از شبکه‌ای 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 به‌دست آوردن تعداد نرون‌های بهینه در لایه مخفی شبکه‌ای با تابع آموزش trainlm و ٦ نرون در لایه ورودی با ۲۷ تکرار اجرا شد. تعداد ۳ نرون برای لایه مخفی با توجه به شکل ٤ به‌دست آمد (جدول ۱). پس از مشخص شدن تعداد نرون لایه مخفی اقدام به اجرای شبکه‌ای با مشخصات ٦ 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 داده‌های آموزش ۰/۵۳ و ضریب همبستگی داده‌های تست ۰/۷٤ به‌دست آمد که حد قابل قبولی برای پیش‌بینی ارزش اصلاحی است که در شکل ٥ نشان داده شده‌است.

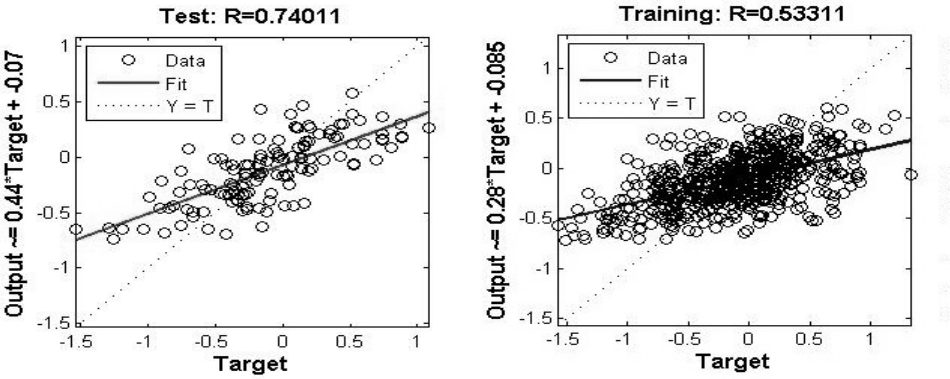
همانطورکه در شکل (٦) مشخص است، MSE داده‌های تست تا تکرار ۱۷ رو به کاهش بوده، ولی پس از این تکرار دیگر رو به کاهش نرفته است. لذا، در اینجا فرایند آموزش متوقف و وزن‌ها ثابت می‌شوند. خطای گرادیان برای این شبکه در بازه‌ی ۰/۰۰۰۱

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]

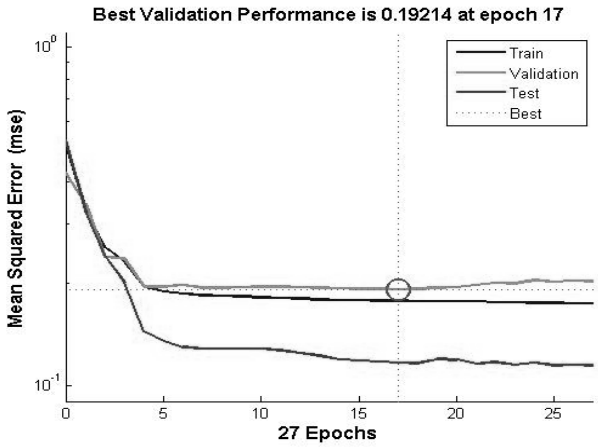
تا یک بود و همانطورکه در شکل ۷ نشان داده شده، خطای آموزش در داده‌های اعتبار سنجی تا تکرار ۱۷ دو بار بالا رفته ولی با فرصت ۱۰ تکراری که داده شده بود مجددا آموزش ادامه یافت تا در تکرار ۱۷ به‌دلیل افزایش بیش از حد تکرارهای خطا برای ۱۰ بار متوالی، متوقف شد.



شکل ٤- نمودار ضرایب همبستگی داده‌های آموزش و تست برای شبکه دوم وزن سه ماهگی

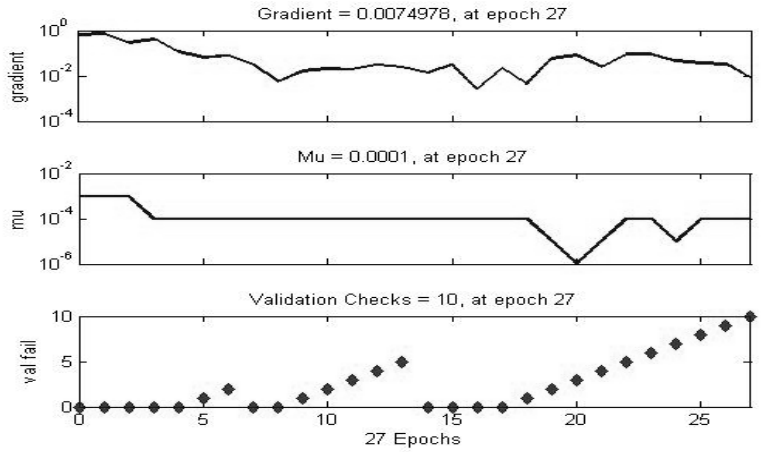


شکل ٥- ضرایب همبستگی برای داده‌های آموزش و تست در شبکه دوم وزن ۳ ماهگی



شکل ٦- نمودار عملکرد داده‌های اعتبار سنجی برای شبکه دوم وزن ۳ ماهگی

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]



شکل ۷- منحنی خطای گرادیان 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 چندلایه 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 ٦ متغییر ورودی و تعداد ۳ نرون در لایه با ضریب همبستگی ۰/۷٤ توانایی پیش‌بینی ارزش اصلاحی وزن ۳ ماهگی گوسفند نژاد کرمانی را دارا است.

با توجه به روش‌های ژنتیک آماری برای انتخاب، بعضی از دسته‌بندی‌های روش‌شناسی قابل توجه بوده و به‌طور گسترده‌ای، استفاده شده‌است که عبارتند از: شاخص‌های انتخاب (Verardi et al. 2014)، روش انتخاب ترکیبی (Ribeiro et al. 2013; Verardi et al. 2014)، و روش REML BLUP[1] (Ferreira et al. 2012). با این وجود نمونه جدیدی می‌تواند در ژنتیک و اصلاح نژاد برای اهداف انتخابی به کار گرفته شود که شامل روش‌های تصادفی نباشد. در پژوهشی Gorgulu (2012) از شبکه عصبی مصنوعی برای پیش‌بینی تولید شیر در ۳۰۵ روز گاو براون سویس استفاده کرد و مشاهده نمود که میانگین تولید پیش‌بینی شده با شبکه عصبی مصنوعی خیلی نزدیک به مقدار واقعی است. او ضریب همبستگی ۰/۸۲-۰/۷٤ را برای شبکه عصبی گزارش نمود. از مقایسه ٦ فرم رگرسیون غیرخطی با شبکه عصبی مصنوعی برای پیش‌بینی صفات رشد گوسفند بلوچی Bahreini Behzadi (2010) and Aslaminejad نتیجه گرفتند که شبکه عصبی مصنوعی نمودار رشد توصیفی بهتری نسبت به مدل‌های غیرخطی ایجاد می‌کند و پیش بینی دقیق‌تری می‌دهد. این محققان (Bahreini Behzadi and Aslaminejad, 2010) MSE برابر ۰/۰٦ 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 شده‌است. آن‌ها ضریب همبستگی و MSE به‌ترتیب برابر ۰/۸۸ و ۰/۰۸ را برای شبکه عصبی مصنوعی گزارش کردند که تأیید کننده نتایج این پژوهش است. در پژوهشی Ehret et al. (2015) معماری‌های غیرخطی مختلف را به‌عنوان ورودی‌های شبکه آزمون کردند تا توانایی آن‌ها را برای پیش‌بینی صفات شیرواری در گاو شیری با استفاده از داده‌های SNP مقیاس بزرگ ارزیابی کنند. برای آموزش آن‌ها از الگوریتم پس انتشار تنظیم شده استفاده کردند و از متوسط همبستگی بین فنوتیپ‌های مشاهده شده و پیش‌بینی شده برای ارزیابی توانایی پیش‌بینی استفاده کردند. این محققان نتیجه گرفتند که شبکه‌های عصبی مصنوعی ماشین‌هایی قدرتمند برای پیش‌بینی‌های ژنومی غیرخطی در اصلاح نژاد دام هستند. نتایج حاصل از تحقیقات مختلف نشان می‌دهد که شبکه عصبی MLP برای محاسبه ارزش اصلاحی

[1] Restricted maximum likelihood/best linear unbiased prediction

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]

گاوهای شیری نژاد هلشتاین ایران با همبستگی ۰/۹۲ (Shahinfar et al. 2012)، در پیش‌بینی تولید شیر، چربی و پروتئین (Ruhi et al. 2011)، در پیش‌بینی و مشخص کردن ارزش لاشه در گاو گوشتی با استفاده از اطلاعات پیش از کشتار (Salehi et al. 1998; Brethour 1994)، برای تخمین شیرواری بر پایه رکوردهای ۵ ماه ابتدایی با ضریب اطمینان ۸۰ درصد (Runil et al. 2011)، پیش‌بینی میزان تولید شیر و مقدار پروتئین و چربی شیر با همبستگی ٤٥ درصد (Khazaei et al. 2008) و در تخمین تولید شیر نژاد کاران فریز هندی با دقت ۹۲ 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. 2012; Khazaei et al. 2008; Kominakis 2002) در زمینه شبکه عصبی مصنوعی در علوم دامی هم‌سو است.

نتیجه‌گیری کلی

شبکه عصبی مصنوعی MLP با ۳ متغیر ورودی، یک لایه مخفی و تعداد ۸ نرون در لایه مخفی و تابع آموزش lm یا trainlm با ضریب همبستگی ۰/۷۲، توانایی پیش‌بینی قابل قبولی از ارزش اصلاحی وزن تولد گوسفند نژاد کرمانی را دارا است. همچنین شبکه عصبی مصنوعی MLP با ٦ متغییر ورودی، یک لایه مخفی، تابع محرک تانژانت سیگموئید و تعداد ۳ نورون در لایه مخفی و تابع آموزش lm یا trainlm با ضریب همبستگی ۰/۷٤، توانایی پیش‌بینی قابل قبولی از ارزش اصلاحی وزن ۳ ماهگی گوسفند نژاد کرمانی را دارا است. افزودن ارزش اصلاحی وزن تولد به‌عنوان متغیر ورودی به شبکه عصبی برای پیش‌بینی ارزش اصلاحی وزن ۳ ماهگی باعث افزایش دقت در تخمین ارزش اصلاحی وزن ۳ ماهگی می‌شود. به‌طور 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 به‌توان 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.

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 Matwork 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, AmaralJúnior 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.

[Downloaded from mail.mg.genetics.ir on 2026-11-20]

[DOR: 20.1001.1.20084439.1396.12.3.1.5]

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 Jersy.

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, Moradishahrbabak 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, Esmailizadeh Koshkoieh A, Moradi-Shahrebabak 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, Rogdakis 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 KermaniSheep.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.

Saatic 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, Esmailizadeh 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.

WilkinsonRF, 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.

[Downloaded from mail.mg.genetics.ir on 2026-11-20]
[DOR: 20.1001.1.20084439.1396.12.3.1.5]

[DOR: 20.1001.1.20084439.1396.12.3.1.5] [Downloaded from mail.mg.genetics.ir on 2026-11-20]