

مقایسه توان پیش بینی شبکه عصبی مصنوعی و رگرسیون خطی چندگانه جهت پیش بینی وزن یک سالگی بزهای نژاد رائینی

سمیه رحیم نهال^۱، جمال فیاضی^۲، بیژن خلیلی مقدم^۳ و عباس مسعودی^۴

۱، ۲ و ۳ - به ترتیب دانش آموخته دکترای ژنتیک و اصلاح دام، دانشیار اصلاح نژاد دام و دانشیار گروه علوم خاک دانشگاه علوم کشاورزی و منابع طبیعی خوزستان ۴ - دانش آموخته دکترا، گروه علوم دامی، دانشگاه لرستان

تاریخ دریافت: ۹۴/۱۱/۱۵

تاریخ پذیرش: ۹۵/۲/۱۶

چکیده

به منظور مقایسه دو روش شبکه‌های عصبی مصنوعی و رگرسیون خطی چندگانه جهت پیش‌بینی وزن یک‌سالگی بزهای نژاد رائینی از رکورد ۷۳۶ راس بز نژاد رائینی استفاده شد. اثرات و متغیرهای مورد بررسی موثر بر صفت افزایش وزن این دام شامل؛ جنس دام، تیپ تولد، گله، فصل تولد، سال تولد و صفات مربوط به وزن تولد، سه ماهگی، شش ماهگی و نه ماهگی بودند. به منظور پردازش داده‌ها با استفاده از شبکه‌های عصبی مصنوعی، ۳ مدل شبکه‌ی پرسپترون چند لایه هر کدام با تعداد و نوع ورودی متفاوت ایجاد و استفاده شد. مدل‌سازی داده‌ها با استفاده از نرم‌افزار شبکه‌های عصبی STATISTICA 10 انجام شد. داده‌ها در مدل رگرسیونی چندگانه با استفاده از نرم‌افزار SAS 9.1.3 با روش رگرسیون گام به گام (stepwise) آنالیز شدند و مدل مناسب با توجه به ضریب تبیین، حداقل میانگین مربعات خطا و بایاس انتخاب شد. نتایج این پژوهش نشان داد که شبکه‌های عصبی مصنوعی دارای دقت و صحت بالاتری نسبت به روش‌های رگرسیونی برای پیش‌بینی وزن یک‌سالگی این دام‌ها می‌باشند. بطوریکه میزان R^2 در شبکه‌های ساخته شده ۱ تا ۳ به ترتیب برابر با ۰,۹۹۸، ۰,۹۹۷ و ۰,۹۹۶، ۰,۹۷ و ۱,۲۲ می‌باشد.

کلمات کلیدی: بز رائینی - مدل‌های رگرسیونی - شبکه عصبی مصنوعی.

مقدمه

بز کرکی رائینی یکی از مهمترین نژادهای بز در ایران است که به واسطه تولید کرک مرغوب و کیفیت بالا از ارزش اقتصادی بالایی در بازارهای جهانی برخوردار است. زیستگاه اصلی این حیوان حاشیه کویر و اطراف یزد تا حدود رائین کرمان و قسمت شرقی استان فارس است. در ایستگاه اصلاح نژاد بز کرکی رائینی، پرورش و توزیع بزهای نر انتخابی در بین دامداران مهمترین هدف است و انتخاب دامها بر اساس رنگ کرک بدن و فنوتیپ ظاهری انجام و بزهای رنگی از گله حذف می‌شوند (عسکری، ۲۰۰۷). پیش بینی وزن یک سالگی بزها در مدیریت دامداری نقش بسزایی ایفا می نماید، لذا می توان از روشهای مختلف مانند رگرسیون چندمتغیره خطی، رگرسیون غیرخطی، رگرسیون درختی، شبکه عصبی مصنوعی، الگوریتم ژنتیک و شبکه عصبی-فازی برای برآورد این پارامتر استفاده کرد. که از بین روشهای مذکور دو روش رگرسیون چندمتغیره خطی و شبکه عصبی مصنوعی بیشتر مورد توجه قرار گرفته است (احمدی و همکاران، ۲۰۰۸).

تجزیه رگرسیون روشی آماری برای بررسی و مدل سازی رابطه بین متغیرها می باشد. یکی از اهداف مهم در تجزیه رگرسیون، برآورد پارامترهای ناشناخته مدل می باشد. مدل رگرسیونی نشان دهنده وجود رابطه علت و معلولی بین متغیرها نیست. حتی اگر یک رابطه تجربی قوی بین دو یا چند متغیر برقرار باشد، نمی تواند دلیل وجود رابطه علت و معلولی بین متغیرهای وابسته و مستقل باشد. تجزیه رگرسیون ممکن است در تأیید رابطه

علت و معلولی مفید باشد، اما به تنهایی نمی تواند مبنای چنین ادعایی قرار بگیرد (یزدچی، ۱۹۹۴). شبکه های عصبی سیستم های یادگیرنده ای هستند که با دارا بودن پیچیدگی لازم و زمان کافی برای آموزش، می توانند هر تابع غیرتصادفی از هر درجه ای را مدل کنند. اجزای سازنده شبکه های عصبی مصنوعی به عنوان یک مدل از سیستم عصبی جانداران، نرون ها هستند. وظیفه هر یک از این نرون ها انجام نوعی پردازش بر روی سیگنال های ورودی و تولید یک خروجی واحد است. پیش از ورود هر سیگنال به نرون، سیگنال از فضایی موسوم به فضای سیناپسی عبور می کند که در آن عملیات تقویت و یا تضعیف سیگنال انجام می پذیرد. این فضا در واقع مکان ارتباط یک نرون با نرون دیگر است. وظیفه شبکه عصبی این است که در طی یک دوره آموزشی، بیاموزد که به ازای هر ورودی، خروجی مطلوب را تولید نماید. این کار با تغییر وزن سیناپس ها، در یک فرآیند تدریجی انجام می پذیرد. وزن هر سیناپس همان توانایی سیناپس در تضعیف یا تقویت سیگنال ورودی است (هایکین، ۱۹۹۴). نرون های مصنوعی چهار قسمت اصلی نرون بیولوژیکی را شبیه سازی می کنند به عبارت دیگر می توانند دانسته ها را دریافت، جمع آوری، پردازش و به دیگر نرون ها انتقال دهند. توانایی پردازش دانسته های نرون های مصنوعی شبیه نرون های بیولوژیکی در شبکه ای از نرون ها بهتر نمایان می گردد. با این تفاوت که شبکه های عصبی بیولوژیکی دارای پیوستگی نرونی پیچیده ای می باشند. شبکه های عصبی مصنوعی دارای ساختار لایه ای می باشند که در هر لایه پردازش دانسته ها

به صورت موازی انجام شده و انتقال آن به لایه‌های دیگر سریع انجام می‌شود (هایکین، ۱۹۹۴).

با توجه به اهداف تحقیق، انواع مختلفی از شبکه‌های عصبی می‌توانند مورد استفاده قرار گیرند. پرسپترون چند لایه در بین شبکه‌های عصبی بیشترین کاربرد را دارد. این شبکه دارای لایه ورودی، خروجی و لایه یا لایه‌های پنهان می‌باشد که خروجی لایه اول، بردار ورودی لایه دوم به حساب می‌آید (چلانی و همکاران، ۲۰۰۲). این روند ادامه می‌یابد تا اینکه یک پاسخ در لایه خروجی ایجاد شود. نحوه عمل پرسپترون چند لایه بدین صورت است که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد. مقایسه خروجی واقعی و خروجی مطلوب، باعث می‌شود که ضریب وزنی شبکه تغییر یابد به طوری که در دفعات بعد خروجی درست تری حاصل می‌شود (چلانی و همکاران، ۲۰۰۲).

اخیراً شبکه‌های عصبی مصنوعی بطور کم و بیش در مطالعات مربوط به علوم دامی در جهت پیش‌بینی و انجام کارهای اصلاح نژادی بکار گرفته می‌شوند، چرا که این مدل‌ها دارای یکسری مزایا می‌باشند، اول اینکه؛ در کار با شبکه عصبی هیچ اطلاع قبلی از مسئله مورد نیاز نمی‌باشد. در واقع بدون نیاز به هر گونه فرض قبلی، تعادل بین مقادیر ورودی و خروجی بدست می‌آید و نیز اینکه از بوجود آمدن خطاهای احتمالی جلوگیری می‌کند. و دوم اینکه؛ از آنجایی که خروجی نرون‌ها بصورت غیر-خطی می‌باشد، در نتیجه شبکه عصبی مانند یک مدل غیر-خطی عمل می‌کند. بنابراین می‌توان روابط غیر-خطی بین داده‌های ورودی و خروجی را

پیدا کرد. در حقیقت، می‌توان بیان کرد که از لحاظ ریاضی، یک مدل پرسپترون چند لایه، یک مدل رگرسیون یونیورسال می‌باشد که با استفاده از آن می‌توان رابطه بین هر جفت داده را بدست آورد (بحرینی‌بهزادی و اسلمی‌نژاد، ۲۰۱۰). از جمله کاربردهای شبکه عصبی در پژوهش‌های علوم کشاورزی و دامی می‌توان به موارد زیر اشاره نمود؛ سلیمانی رودی و همکاران (۲۰۱۲)، برای پیش‌بینی اسیدهای آمینه ارزش مروریدی از مدل‌های رگرسیون خطی چندگانه و شبکه عصبی مصنوعی استفاده نمودند. این محققین گزارش کردند که بین اسیدهای آمینه دانه‌ی ارزش مروریدی و ترکیبات شیمیایی آن ارتباط قابل توجهی وجود دارد. همچنین ارزیابی آماری این تحقیق نشان داد که مدل ANN در مقایسه با MLR دارای قدرت تخمین بیشتری برای برآورد میزان هر یک از اسیدهای آمینه ارزش مروریدی می‌باشد (سلیمانی‌رودی و همکاران، ۲۰۱۲). احمدی و همکاران (۲۰۰۸) در مطالعه‌ای که به بررسی مدل‌های پیش‌بینی برای سوخت و ساز انرژی واقعی (TMEn) پودر پر پرداختند، بیان کردند که شبکه‌های عصبی مصنوعی نسبت به مدل‌های رگرسیون خطی چندگانه با دقت بیشتری TMEn را پیش‌بینی می‌کند (احمدی و همکاران، ۲۰۰۸). بعلاوه ANN برای پیش‌بینی کل تولید شیر در مزرعه، پیش‌بینی تولید شیر ۳۰۵ روز و تشخیص ورم پستان مورد استفاده قرار می‌گیرد (سانزوگنی و کر، ۲۰۰۱). کیم و هیلد (۱۹۹۹) همچنین بیان کردند که این تکنیک برای تشخیص فحلی و کشف دلایل حذف دام مورد استفاده قرار می‌گیرد (کیم و

از آنها استفاده شد. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود از این رو داده‌های ورودی به شبکه بایستی نرمال شوند. پس از استخراج رکوردهای مورد نظر، آماده سازی داده‌ها با نرم افزار Excel انجام گرفت، اثر معنی‌داری هر یک از عوامل فوق بر صفت مورد مطالعه با استفاده از آنالیز واریانس بررسی و در مدل مربوطه بکار گرفته شد و ضرایب هر یک از اثرات فوق بر صفت وزن بدن با استفاده از نرم افزار SAS 9.1 به روش رگرسیون خطی چندگانه تعیین و بررسی گردید.

شبکه‌های عصبی جهت طراحی و آموزش، نیازمند یک سری داده‌های ورودی و خروجی می‌باشند تا با تجزیه و تحلیل منطقی این داده‌ها به عنوان نمونه، بتوانند روابط غیر خطی یا نامشخص بین آنها را استخراج کرده و کار شبیه‌سازی را برای موارد احتمالی مشابه انجام دهند. به منظور پردازش داده‌ها، ۳ مدل شبکه‌ی پرسپترون چند لایه هر کدام با تعداد و نوع ورودی متفاوت ساخته و استفاده شد (جدول ۱).

هیلد، ۱۹۹۹). لاکرویکس و همکاران در سال ۱۹۹۵ گزارش نمودند که ANN برای پیش بینی اولیه و دقیق تولید شیر در هلشتاین‌های کانادایی می‌باشد. شبکه عصبی مصنوعی به عنوان یک مدل در سازمان ثبت شیر کانادا بخصوص در ثلث اول دوره شیردهی مورد استفاده قرار گرفته است (لاکرویکس و همکاران، ۱۹۹۵). در واقع هدف از این مطالعه مقایسه دو روش شبکه عصبی مصنوعی و مدل رگرسیون چندگانه در پیش‌بینی وزن یک‌سالگی بزهای راینی و معرفی روش موثرتر در این زمینه و جهت کارهای اصلاح نژادی می‌باشد.

مواد و روش‌ها

برای انجام این پژوهش، از اطلاعات مربوط به رکوردهای بز نژاد راینی که توسط ایستگاه پرورش و اصلاح نژاد این دام و سایر گله‌های مردمی تحت پوشش این ایستگاه که از سال ۶۲ تا سال ۸۹ جمع‌آوری شده بود، استفاده شد. داده‌های استفاده شده شامل جنس تولد، تیپ تولد، سال تولد، فصل تولد، گله، فصل زایش، وزن تولد، وزن سه، شش و نه ماهگی بود که جهت پیش‌بینی وزن یک سالگی

جدول ۱- پارامترهای بردار ورودی و خروجی شبکه‌های موجود
Table 1. Input and output vector parameters of available networks

شماره شبکه	مدل ۱	مدل ۲	مدل ۳
ورودی‌ها			
جنس	•		•
تیپ تولد	•		•
سال تولد	•	•	•
فصل تولد	•	•	•
گله	•	•	•
وزن تولد	•		
وزن سه ماهگی	•	•	•
وزن شش ماهگی	•	•	
وزن نه ماهگی	•		
خروجی			
وزن دوازده ماهگی	•	•	•

کدام از سطوح صفات قابل دسته بندی (متغیرهای گسسته) به عنوان یک ورودی توسط شبکه شناسایی شد (مثلا اثر جنسیت با توجه به دو سطح نر و ماده بودن به صورت دو ورودی شناخته شد) اما هر کدام از اثرات پیوسته تنها به عنوان یک ورودی شناسایی شدند.

داده‌های مورد استفاده به طور تصادفی به سه دسته آموزش، تست و صحت سنجی به ترتیب ۷۵، ۱۵ و ۱۰ درصد اختصاص داده شدند. برای ساخت شبکه‌های عصبی مصنوعی از الگوریتم پرسپترون چند لایه و توابع شعاعی با ۲۲، ۱۴ و ۱۹ ورودی و یک خروجی استفاده شد. مدل‌سازی داده‌ها با استفاده از نرم افزار STATISTICA 10 انجام گردید، و ۲۰۰ ترکیب متفاوت (مدل) با لایه میانی و تعداد نرون مختلف توسط نرم‌افزار ساخته شد. سپس بهترین مدل به لحاظ شاخص‌های ضریب تبیین (R^2) و ریشه‌ی میانگین حداقل مربعات خطا (RMSE) انتخاب گردید (جدول ۲).

انتخاب شبکه‌ها با ورودی‌های مختلف بر اساس درجه اهمیت و حساسیت هر کدام از این فاکتورها صورت گرفت و از آنجایی که همه این عوامل بصورت یکجا ممکن است وجود نداشته باشند در نتیجه، پیش‌بینی با این شبکه‌ها بر اساس فاکتورهای ورودی آنها حائز اهمیت خواهد بود. هر

جدول ۲- خصوصیات مدل‌های شبکه عصبی مصنوعی ساخته شده

Table 2: Characteristics of artificial neural network models

مدل Model	ساختار Structure	ورودی Input	لایه مخفی Hidden layer	خروجی Output	تابع خطا Error function	تابع لایه مخفی Hidden layer function	تابع لایه خروجی Outer layer function	R ²	RMSE
مدل 1 Model 1	MLP	22	7	1	SOS	نمایی Exponential	نمایی Exponential	0.96	0.002
مدل 2 Model 2	MLP	14	15	1	SOS	لجستیک Logistic	Identity	0.95	0.002
مدل 3 Model 3	MLP	19	5	1	SOS	نمایی Exponential	تانژانت هایپربولیک Hyperbolic tangent	0.92	0.002

خطا (MSE) و اریبی (Bias) استفاده گردید. بهترین مقدار برای R² برابر ۱ و برای سایر معیارها صفر می‌باشد. میانگین حداقل مربعات خطا (RMSE) نیز از فرمول زیر محاسبه گردید.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n |y_t - \hat{y}_t|^2}{n}}$$

اریبی (Bias) از فرمول زیر تعیین شد.

$$Bias = \frac{\sum_{t=1}^n y_t - \hat{y}_t}{n}$$

ضریب تعیین (R²) از فرمول زیر تعیین شد.

$$R^2 = 1 - \frac{\sum (y_t - \hat{y}_t)^2}{\sum \hat{y}_t^2}$$

در این فرمول‌ها، y_t مساوی است با میزان وزن زنده مشاهده شده در زمان t، \hat{y}_t مساوی است با میزان وزن زنده تخمین زده شده در زمان t، و n مساوی با تعداد مشاهدات است.

بهترین مدل برای شبکه اول دارای ساختار MLP 22-7-1، شبکه دوم دارای ساختار MLP 14-15-1 و ساختار شبکه سوم بصورت MLP 19-5-1 می‌باشد که به ترتیب از چپ به راست: نوع شبکه، تعداد ورودی‌ها، تعداد نرون در لایه پنهان و تعداد خروجی را نشان می‌دهند.

به منظور انجام آنالیز رگرسیون خطی چندگانه از نرم افزار SAS 9.1 و با استفاده از رگرسیون گام به گام (stepwise) استفاده شد. سه مدل رگرسیونی بر اساس نوع ورودی بکار رفته‌ی مشابه در شبکه عصبی مصنوعی ایجاد شدند. جهت پیش‌بینی وزن یک‌سالگی با استفاده از رگرسیون خطی، از داده‌های استفاده شده در آموزش شبکه‌های عصبی مصنوعی استفاده شد.

در مرحله ارزیابی و مقایسه مدل‌های شبکه‌های عصبی مصنوعی و مدل رگرسیون خطی چندگانه از شاخص‌های ضریب تعیین R²، میانگین مربعات

نتایج و بحث

مشابه ایجاد شده توسط MLR (۰/۸۸)، بیشتر می‌باشد. این تفاوت، برتری نسبی شبکه‌های عصبی مصنوعی را نسبت به مدل‌های رگرسیون چندگانه نشان می‌دهد.

ارزیابی آماری مدل MLR نشان داد که بین متغیرهای مستقل و متغیر وابسته در هر دو گروه آموزش و ارزیابی ارتباط خطی وجود دارد. در جدول ۳ مدل‌های رگرسیونی بدست آمده در ارتباط با داده‌های آموزش برای پیش‌بینی وزن یک‌سالگی بزهای نژاد رائینی نشان داده شده است. بررسی این مدل‌ها نشان داد که بین وزن یک‌سالگی و فاکتورهای مورد استفاده در این پژوهش، یک رابطه خطی وجود دارد. مقایسه دقت تخمین بین مدل‌های رگرسیون خطی چندگانه و شبکه‌های عصبی مصنوعی نشان می‌دهد که شبکه‌های عصبی مصنوعی می‌توانند وزن یک‌سالگی در بزهای نژاد رائینی را با دقت و صحت بیشتری پیش‌بینی نمایند (جدول ۴ و ۵). میزان دقت شبکه‌های مختلف نیز با توجه به نوع داده‌های در دسترس (به عنوان ورودی شبکه) جهت آنالیز متفاوت می‌باشد. کومیناکیس و همکاران در سال ۲۰۰۲، با استفاده از شبکه عصبی مصنوعی به پیش‌بینی تولید شیر گوسفندان شیری پرداختند، این محققین بیان کردند که شبکه عصبی مصنوعی یک پیش‌بینی کننده موثر برای پیش‌بینی کل تولید شیر بر اساس شیر روز آزمون می‌باشد و همچنین این تکنیک (ANN) در آینده‌ای نزدیک در اکثر کارهای تحقیقی جایگزین دیگر تکنیک‌های موجود خواهد شد (کومیناکیس و همکاران، ۲۰۰۲). عبادی و همکاران (۲۰۱۱) با

در مقایسه عملکرد بین مدل‌های رگرسیونی و شبکه‌های عصبی، بررسی R^2 و ریشه میانگین مربع خطا بین داده‌های ارزیابی نسبت به داده‌های آموزش حاصل از دو مدل از اهمیت بیشتری برخوردار است. چرا که مقایسه این داده‌ها در مدل‌های استفاده شده نشان می‌دهد که کدام یک از این مدل‌ها نسبت به معرفی داده‌های جدید انعطاف‌پذیری بیشتری نشان می‌دهند.

صالحی و همکاران (۱۹۹۸)، مدل‌های شبکه‌ای که شامل هر دو قسمت داده‌های قابل دسته‌بندی و پیوسته هستند را برای پیش‌بینی تولید شیر مناسب گزارش کردند. این محققین در نتایج خود گزارش کردند که وقتی یک شبکه‌ی آموزش دیده با رکوردهای ثابت مقایسه می‌شود، مجموعه سیستم طبقه‌بندی کننده - پیش‌بینی کننده نتایج بهتری را ارائه خواهد داد، هر چند در اینصورت نیاز به زمان محاسباتی بیشتری خواهد بود (صالحی و همکاران، ۱۹۹۸). تابع فعال‌سازی خروجی که برای پیش‌بینی در شبکه اول بکار گرفته شد تابع نمایی می‌باشد. در واقع این ساختار نشان می‌دهد که، نرم‌افزار پس از ایجاد شبکه‌های مختلف، خروجی حاصل از این مدل را به عنوان بهترین مدل می‌شناسد. در نمودار (۱) رابطه رگرسیونی بین مقدار واقعی و مقدار پیش‌بینی شده وزن یک‌سالگی توسط شبکه آورده شده است. نتایج این نمودار نشان می‌دهد که مدل در اوزان بالاتر به خوبی جوابگو نمی‌باشد. ضریب تبیین حاصل از این مدل برابر با ۰,۹۹۸ بود که در مقایسه با مقدار

استفاده از مدل‌های ANN و MLR میزان TMEn دانه سورگوم را با استفاده از ترکیبات شیمیایی تخمین زدند. این محققین بیان کردند که صحت و دقت تخمین شبکه‌های عصبی بیشتر از مدل‌های رگرسیونی می‌باشد (عبادی و همکاران، ۲۰۱۱). شاهین‌فر و همکاران (۲۰۱۲) با استفاده از شبکه‌های عصبی مصنوعی و سیستم نوروفازی

بحرینی‌بهرزادی و اسلمی‌نژاد (۲۰۱۰)، در مطالعه‌ای به مقایسه پیش‌بینی رشد گوسفندان بلوچی با استفاده از مدل‌های شبکه عصبی و رگرسیون غیر-خطی پرداختند. این محققین بیان کردند که؛ نتایج حاصل از شبکه عصبی مصنوعی در مقایسه با سایر مدل‌های غیر-خطی در پیش‌بینی رشد گوسفند بلوچی دارای دقت بیشتری بوده و کاربرد آن در

جدول ۳- مدل‌های رگرسیونی بدست آمده با داده‌های آموزش برای پیش‌بینی وزن یک‌سالگی بزهای راینی

Table 3. Regression models obtained with Training data to predict Yearling weight of Rheini Goats

نه) $+0.34$ (شش ماهگی) -0.103 (وزن سه ماهگی) $+ 0.07$ (گلّه) $+ 2.04$ (فصل) $- 0.21$ (سال) $+ 0.1$ (تیپ تولد) $+ 0.14$ (جنس) $+ 0.16$ (وزن یک‌سالگی ماهگی)

Yearling weight = $7.97 + 0.16(\text{sex}) + 0.14(\text{, type of birth}) + (\text{year}) - 0.21(\text{season}) + 2.04(\text{herd}) + 0.07(3 \text{ month weight}) - 0.103(6 \text{ month weight}) + 0.34 (9 \text{ month weight})$

(وزن نه ماهگی) $+ 0.35$ (گلّه) $+ 0.93$ (فصل) $- 0.21$ (سال) $- 8.21 + 0.13$ (وزن یک‌سالگی)

Yearling weight = $-8.21 + 0.13(\text{year}) - 0.21(\text{season}) + 0.93(\text{herd}) + 0.35(9 \text{ months weight})$

(وزن سه ماهگی) $+ 0.19$ (گلّه) $+ 1.15$ (جنس) $+ 0.34$ (وزن یک‌سالگی)

Yearling weight = $2.66 + 0.34(\text{sex}) + 1.15(\text{herd}) + 0.19 (3 \text{ months weight})$

ارزش اصلاحی گاوهای هلشتاین ایران را بررسی و این دو سیستم را با هم مقایسه کردند. آنها ابتدا با استفاده از یک مدل دام ارزش اصلاحی گاوهای هلشتاین را برای تولید چربی شیر محاسبه کردند سپس با استفاده از شبکه‌های عصبی مصنوعی و سیستم عصبی-فازی آن را پیش‌بینی کردند. برای تولید شیر همبستگی بین ارزش اصلاحی واقعی و پیش‌بینی شده با استفاده از شبکه‌های عصبی مصنوعی و عصبی-فازی به ترتیب 0.92 و 0.93 و همبستگی بین ارزش اصلاحی واقعی و پیش‌بینی چربی شیر با استفاده از هر دو سیستم 0.93 گزارش کردند (شاهین‌فر و همکاران، ۲۰۱۲).

پیش‌بینی با استفاده از اطلاعات موجود مناسب‌تر می‌باشد (بحرینی‌بهرزادی و اسلمی‌نژاد، ۲۰۱۰). با توجه به نتایج حاصل از این مطالعه، می‌توان اینگونه نتیجه‌گیری کرد که وزن یک‌سالگی بزغاله‌های نژاد راینی را می‌توان با استفاده از فاکتورهای ثابت از جمله اثرات مربوط به جنس تولد، تیپ تولد، گلّه، سال و فصل تولد و رکوردهای مربوط به افزایش وزن، پیش‌بینی نمود. در واقع هدف از انجام این مطالعه مقایسه توان پیش‌بینی مدل‌های شبکه عصبی مصنوعی و رگرسیونی خطی چندگانه در جهت پیش‌بینی یکی از صفات اقتصادی مهم (وزن بدن) در دام بود که همانطور که

انتظار می‌رفت مدل‌های شبکه عصبی مصنوعی دارای قدرت تخمین بالاتری بوده و این مدل‌ها می‌توانند به عنوان یک تکنیک جایگزین نسبت به مدل‌های رگرسیونی جهت پژوهش‌های تحقیقاتی استفاده شوند.

جدول ۵- نتایج حاصل از رگرسیون برای پیش‌بینی وزن یک‌سالگی

Table 5. Regression results to predict Yearling weight


	R ²	R ²	RMSE	RMSE
مدل	مجموعه آموزش	مجموعه ارزیابی	مجموعه آموزش	مجموعه ارزیابی
Model	Training set	Evaluation set	Training set	Evaluation set
1	0.85	0.88	1.50	1.31
2	0.85	0.88	1.50	1.31
3	0.84	0.87	1.53	1.35

جدول ۴- حاصل از مدل‌های شبکه‌های عصبی مصنوعی برای پیش‌بینی وزن یک‌سالگی براساس ضریب تعیین، میانگین حداقل مربعات خطا و اریبی

Table 4. Artificial neural network models for predicting Yearling weight based on coefficient of determination, Average least squared error and Bias

		R ²		RMSE		BIAS	
شبکه	تعداد نرون	مجموعه آموزش	مجموعه ارزیابی	مجموعه آموزش	مجموعه ارزیابی	مجموعه آموزش	مجموعه ارزیابی
Network	Neuron number	Training set	Evaluation set	Training set	Evaluation set	Training set	Evaluation set
۱ANN	7	0.998	0.998	0.96	1.16	0.01	-0.02
۲ANN	15	0.9985	0.9982	0.97	1.18	0.01	-0.1
۳ANN	5	0.997	0.9997	1.22	1.21	0.01	0.02

R²: ضریب تعیین، RMSE: میانگین حداقل مربعات خطا، BIAS: اریبی



نمودار ۱- رابطه رگرسیونی بین مقدار واقعی (Target) و پیش‌بینی شده (Output) وزن یک‌سالگی در مدل کامل

**Chart 1. Regression relationship between Target and Output of
Yearling weight in full model**

منابع

1. Ahmadi, H, Golian, A., Mottaghtalab, M. and Nariman-Zadeh, N., 2008. Prediction model for true metabolizable energy of feather meal and poultry offal meal using group method of data handling-type neural network. *Poultry Science*. 87:1909–1912.
2. Askari, N., 2007. Study on genetic diversity in Raeini Cashmere goat based on microsatellite analysis. Thesis for Master of Science in Domestic of Animal. University of Khuzestan Ramin Agriculture and Natural Resources.
3. Bahreini Behzadi, M.R. and Aslaminejad, A.A., 2010. A Comparison of Neural Network and Nonlinear Regression Prediction of sheep Growth. *Journal of Animal and Veterinary Advances* 9(16): 2128-2131, 2010.
4. Chelani, A.B., Chalapati, R.C.V., Phadke, K.M. and Hasan, M.Z., 2002. Prediction of sulphur dioxide concentration using artificial neural networks. *Environ. Modell. Softw.* 17:161–168.
5. Demuth, H. and Beale, M., 2003. *Neural Network Toolbox for Matlab- Users Guide Version 4.1*. The Mathworks Inc. Natick. USA.
6. Ebadi, M. R. sedghi, M. Golian, A. and Ahmadi, H., 2011. Prediction of the true digestible amino acid contents from the chemical composition of sorghum grain for poultry. *Poultry Science*. 90: 2397-2401.
7. Haykin, S., 1994. *Neural Networks: A comprehensive foundation*.
8. Kim, T. and Heald, W.C., 1999. Inducing inference rules for the classification of bovine mastitis. *Puttersers and Electronics in Agriculture*. Vol. 23, no. 1, pp. 27-42.
9. Kominakis, A.P. Abas, Z. Maltaris, I. and Rogdakakis, E., 2002. A preliminary study of the application of artificial neural networks to prediction of milk yield in dairy sheep. *ELSEVIER*. 35(2002) 35-48.

-
10. Lacroix, R., Wade, K.M. Kok, R. and Hayes, J.F., 1995. Prediction of cow performance with a connectionist model. *Trans. ASAE* 38(5), 1573-1579.
 11. Salehi, F. Lacroix, R. and Wade, K.M., 1998. Improving dairy yield predictions through combined records classifiers and specialized artificial neural networks. *Comput. Electron. Agric.* 20, 199–213.
 12. Sanzogny, L. and Kerr, D., 2001. Milk production estimates using feed forward artificial neural network. *Computers and Electronics in Agriculture*. Vol. 32, no. 1, pp. 21-30.
 13. Shahinfar, S. Mehrabani-Yeganeh, H. Lucas, C. Kalhor, A. Kazemian, M. and Weigel, K.A., 2012. Prediction of Breeding Values for Dairy Cattle Using Artificial Neural Networks and Neuro-Fuzzy Systems. Hindawi Publishing Corporation. 127130: 9 pages.
 14. Soleimani Roodi, P., Golian, A. and Sedghi, M., 2012. Multiple linear regression and artificial neural network models for prediction of amino acids in pearl millet using an approximate analysis. *Iranian Journal of Animal Science Research*. Vol. 3, No. 4, winter 2012, p. 363-368.
 15. Yazdchi, M., 1994. Advanced soil mechanics. Sahand University of technology publications. (In Persian).

Compare the predictive power of artificial neural network and multiple linear regression to forecast the yearling weight Raeini goats breed

S. Rahimnahal¹, J. Fayazi², B. Khalilimoghadam³ and A. Masoudi⁴

1-PhD Graduated of Animal Sciences, Agricultural and Natural Resources University of Khuzestan, 2- Associate Prof., Dept. of Animal Sciences Agricultural and Natural Resource University of Khuzestan, 3- Assistant Prof., Dep. Of Soil Sciences, Ramin Agricultural and Natural Resource University, 4- PhD Graduated of Animal Sciences, Lorestan University.

Received: 02/04/2016

Accepted: 05/05/2016

Abstract

In order to compare the two methods of artificial neural networks (ANN) and multiple linear regression to predict yearling weight used records of 736 Raeini goat. Effects and variables influencing on yearling weight were; animal sex, type of birth, birth year, birth season, herd and characters related to birth weight, three months weight, six months weight and nine months weight. In order to process of data using a neural network model, applied the 3 MLP with a different number of input type. Data modeling were created by neural network software STATISTICA 10. In multiple regression data analyzed using software SAS 9.1.3 Protable with stepwise regression method and suitable model were selected according to R^2 , RMSE and bias. The results in this research showed a better accuracy of the ANN systems than regression methods (R-square value made by neural networks MLP1 to MLP3 equal to 0.998, 0.998 and 0.997 and RMSE value were estimated 0.96, 0.97 and 1.22, respectively) for predicting yearling weight of these animals.

Key words: Raeini goat - Artificial Neural Network - Regression models.