



بررسی ارتباط بین فاصله گواسله‌زایی با صفات اقتصادی گاوها در تلقیح‌های مختلف با استفاده از شبکه عصبی مصنوعی

*مصطفی قادری زفره‌ایی^۱، محمدرضا بحرینی بهزادی^۱، محمد فیاض^۲ و سمیه شریفی^۳

^۱استادیار ژنتیک و اصلاح دام، گروه علوم دامی، دانشکده کشاورزی، دانشگاه یاسوج، ^۲دانشجوی دکتری آمار زیستی، گروه زیست شناسی، دانشکده علوم پایه، دانشگاه شهید بهشتی و ^۳دانشجوی دکتری ژنتیک و اصلاح دام، گروه علوم دامی، دانشکده کشاورزی، دانشگاه صنعتی اصفهان

تاریخ دریافت: ۱۳۹۴/۹/۳۰؛ تاریخ پذیرش: ۱۳۹۴/۱۲/۲۷

چکیده

سابقه و هدف: فاصله گواسله‌زایی از جمله صفاتی است که به میزان قابل توجهی تحت تأثیر اثرات محیطی و مدیریتی قرار می‌گیرد. استفاده از الگوریتم‌های هوشمند روش‌های یادگیری ماشین در بررسی سامانه‌های پیچیده رو به افزایش است و این روش‌ها نیز می‌تواند رهیافت مناسبی برای تحلیل داده‌های صنعت گاو‌شیری به حساب آیند. شبکه‌های عصبی مصنوعی بخشی از هوش مصنوعی بوده و معمولاً از این الگوریتم‌ها بهره می‌جویند. هدف از انجام این مطالعه بررسی ارتباط بین صفات تولیدی و تولیدمثلی با فاصله گواسله‌زایی در تلقیح‌های متفاوت بود. چنین فرض گردید که استخراج این ارتباط می‌تواند در مدیریت بهتر این صفت نقش بهتری ایفا کند.

مواد و روش‌ها: در این مطالعه، از داده‌های تولیدی و تولیدمثلی شرکت کشت و دامداری فکا وابسته به شرکت تعاملی وحدت گاوداران اصفهان استفاده شد. داده‌های مربوط به فاصله گواسله‌زایی (روز)، طول دوره‌ی خشکی (روز)، تعداد تلقیح، کل شیر تولیدی (کیلوگرم)، کل چربی تولیدی (کیلوگرم)، کل پروتئین تولیدی (کیلوگرم)، روزهای شیردهی (روز)، شیر تصحیح شده (کیلوگرم)، چربی تصحیح شده (کیلوگرم)، پروتئین تصحیح شده (کیلوگرم) مورد بررسی قرار گرفت. داده‌ها مربوط به ۱۵۴۶۵ رأس گاو بود که تاریخ زایش آن‌ها در بازه بین

*مسئول مکاتبه: mosmos741@yahoo.com

مصطفی قادری زفراوی و همکاران

سال‌های ۱۳۶۸ تا ۱۳۹۳ قرار داشت. جهت کاهش ابعاد داده‌های مورد استفاده در آموزش شبکه عصبی مصنوعی از دو رویکرد حذف همبستگی بالا و تحلیل مؤلفه اصلی استفاده شد. سپس به ازای هر تلقیح، یک شبکه عصبی آموزش داده شد. برای بررسی کارایی شبکه عصبی از معیارهای ضریب تعیین و جذر میانگین مربعات خطأ استفاده شد. میزان رابطه خطی و غیرخطی بین متغیرهای ورودی با فاصله گوساله‌زایی نیز با معیار ضریب اطلاعات بیشین بررسی گردید.

یافته‌ها: مقادیر مشابه معیارهای ضریب تعیین و جذر میانگین مربعات خطأ حاصل از شبکه عصبی مصنوعی نشان داد که ارتباط بین متغیرهای ورودی و فاصله گوساله‌زایی در تلقیح‌های مختلف از روند تقریباً یکسانی پیروی می‌کند. مقادیر بزرگتر جذر میانگین مربعات خطأ حاصل از رویکرد تحلیل مؤلفه اصلی نسبت به رویکرد حذف همبستگی بالا نشان داد که استفاده از رویکرد حذف همبستگی بالا مناسبتر می‌باشد. معیار ضریب اطلاعات بیشین روند تقریباً یکسانی در میزان رابطه‌ی خطی و غیرخطی متغیرهای مختلف و فاصله گوساله‌زایی در تلقیح‌های مختلف نشان داد. در این راستا روزهای شیردهی و تولید شیر بیشترین ارتباط را با فاصله گوساله‌زایی داشتند.

نتیجه‌گیری کلی: نتایج نشان داد که معیارهای ضریب تعیین و جذر میانگین مربعات خطأ در تلقیح‌های مختلف تقریباً یکسان هستند. از این‌رو نباید انتظار داشت که رابطه بین متغیرهای ورودی به کار رفته در این پژوهش با فاصله گوساله‌زایی در تلقیح‌های مختلف متفاوت باشد. بر اساس نتایج این مطالعه مشخص گردید که متغیرهای به کار رفته در این مطالعه پیش‌بینی خوبی از فاصله گوساله‌زایی را نشان می‌دهند. همچنین می‌توان چنین استنباط کرد که شرایط محیطی- مدیریتی در تلقیح‌های مختلف اثر ناچیزی روی ارتباط بین فاصله گوساله‌زایی و سایر متغیرها داشته است.

واژه‌های کلیدی: تحلیل مؤلفه اصلی، شبکه عصبی مصنوعی، ضریب اطلاعات بیشین، فاصله گوساله‌زایی

 نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

مقدمه

با توجه به همبستگی ژنتیکی نامطلوب بین صفات تولید شیر و باروری، توجه به صفات باروری در برنامه‌های اصلاح نژادی توصیه شده است (۳۲). تولیدمثل از جمله سازه‌های کلیدی در تعیین بازده و سودآوری در صنعت پرورش گاوهاش شیرده محسوب می‌شود (۷). فاصله گوساله‌زایی یکی از صفات شاخص باروری در پرورش گاوهاش شیری است و از نظر اقتصادی، میزان باروری در گاوهاش شیری معمولاً با توجه به فاصله گوساله‌زایی ارزیابی می‌شود. گزارش شده است که افزایش فاصله گوساله‌زایی باعث کاهش سودآوری می‌گردد (۳۲). پهلوان افشار و همکاران (۲۰۱۲) بر اساس یک مدل زیستمحیطی گزارش کردند که گاوهاش با میانگین فاصله گوساله‌زایی $420/2$ روز، در طول عمر تولیدی خود تعداد $36/0$ رأس گوساله کمتری نسبت به گاوهاش دارای فاصله گوساله‌زایی $375/4$ روز تولید می‌کنند (۲۲). در گله‌هایی که با مشکلات تولیدمثلی مواجه هستند، حذف غیراختیاری افزایش می‌باید و موجب کاهش تعداد گوساله در گله می‌شود. همچنین کاهش تعداد گوساله نیز باعث کاهش تلیسه جایگزین می‌شود. از طرفی درآمد حاصل از فروش گوساله، به ازای هر روز افزایش در فاصله گوساله‌زایی کاهش می‌باید. در واقع تمرکز روی پیشرفت صفات تولیدی در صنعت پرورش گاو شیری باعث کاهش عملکرد صفات تولیدمثلی شده است. استفاده از شبکه عصبی در تحلیل داده‌های گاو شیری سابقه نسبتاً طولانی دارد (۳۳، ۸). در واکاوی و تحلیل بیماری ورم پستان از شبکه عصبی مصنوعی استفاده شده است (۳، ۶، ۱۲، ۱۳، ۲۰، ۳۱، ۳۴، ۳۵، ۳۶، ۳۷). گزارش‌هایی مربوط به استفاده از شبکه عصبی در تولید شیر و ارزیابی ژنتیکی آن نیز وجود دارد (۱۰، ۱۱، ۱۵، ۲۰، ۲۵، ۲۰، ۲۷، ۲۶، ۲۹). همچنین برای تشخیص فحلی، کنکاش بیماری لنگش و برای پژوهش‌های تغذیه‌ای نیز در گاو شیری مورد استفاده قرار گرفته است (۵، ۴، ۱۶، ۲۳). برای تحلیل داده‌های حس‌گرهای ریزجریان^۱ در برآورد دقیق زمان باروری گاو شیری نیز از شبکه عصبی استفاده شده است (۲). گزارش شده است که در بررسی سازه‌های موثر بر عملکرد تولیدمثلی گاوهاش شیری نیز می‌توان از شبکه عصبی استفاده کرد (۱، ۹). ولی استفاده از روش‌های هوش مصنوعی در بررسی عملکرد تولیدمثلی بسیار کم است. از این‌رو، گسترش و کاربرد روش‌های توسعه یافته در سایر علوم مانند شبکه‌های عصبی مصنوعی که به جهت ریاضی و عملی کارا هستند، در بخش پرورش گاو شیری منطقی به نظر می‌رسد. شبکه‌های

 1- Microfluidic

مصطفی قادری زفهایی و همکاران

عصبی مصنوعی از روش‌های محاسباتی یادگیری ماشین هستند که توانایی پیش‌بینی پاسخ‌های مناسب از سامانه‌های پیچیده را دارا می‌باشند. از شبکه‌های عصبی مصنوعی می‌توان برای پیش‌بینی استفاده نمود و برای این کار لازم است که ورودی شناخته شده، خروجی شناخته شده و داده‌های کافی وجود داشته باشد (۲۸). ساختار صفات تولیدی و تولیدمثلی اندازه‌گیری شده در گاوهاشییری پیچیده بوده و به علت وابستگی توزیع احتمالی آن‌ها به یکدیگر، استخراج بسیاری از فراسنجه‌های موردنظر با مشکل روی روی می‌شود (۶، ۱۸، ۲۱). نتایج حاصل از یادگیری شبکه‌ی عصبی مصنوعی در تلقیح‌های مختلف روی فاصله گوساله‌زایی تاکنون بررسی نشده است و انتظار می‌رود نتایج حاصله بتواند مدیریت این صفت را در واحدهای پرورش گاو شیری هموارتر سازد. پژوهش حاضر بر پایه آموزش شبکه عصبی مصنوعی بر روی متغیرهای مؤثر بر فاصله گوساله‌زایی صورت گرفت. هدف از پژوهش حاضر بررسی ارتباط بین فاصله گوساله‌زایی و صفات تولیدی و تولیدمثلی در تلقیح‌های مختلف بود.

مواد و روش‌ها

ویرایش داده‌ها: در این مطالعه، از داده‌های تولیدی و تولیدمثلی شرکت کشت و دامداری فکا وابسته به شرکت تعاقنی وحدت گاوداران اصفهان استفاده شد. داده‌های مربوط به فاصله گوساله‌زایی (روز)، طول دوره خشکی (روز)، تعداد تلقیح، شیر تولیدی کل (کیلوگرم)، چربی تولیدی کل (کیلوگرم)، پروتئین تولیدی کل (کیلوگرم)، روزهای شیردهی (روز)، شیر تصحیح شده ۳۰۵ روز دوبار دوشش معادل بلوغ^۱، چربی تصحیح شده ۳۰۵ روز دوبار دوشش معادل بلوغ مورد بررسی قرار گرفت. داده‌ها مربوط به ۱۵۴۶۵ رأس گاو بود که تاریخ زایش آن‌ها در بازه بین سال‌های ۱۳۶۸ تا ۱۳۹۳ قرار داشت. از آنجایی که داده‌های پرت تأثیری نامناسب روی برآوردها خواهند داشت، با استفاده از الگوریتم باکن^۲ نرم‌افزار استاتا^۳ مقادیر پرت برای هر صفت مشخص شدند. در این الگوریتم از معیار چندک تصحیح شده توزیع کای دو^۴ استفاده می‌شود. این الگوریتم تمام مشاهدات با فاصله بیشتر از حد آستانه‌ای را به عنوان مشاهدات پرت در نظر می‌گیرد. همچنین برای درک صحیح از ساختار داده‌های مورد مطالعه، توزیع صفات و نرمال بودن

1- ME-305-2x

2- Bacon

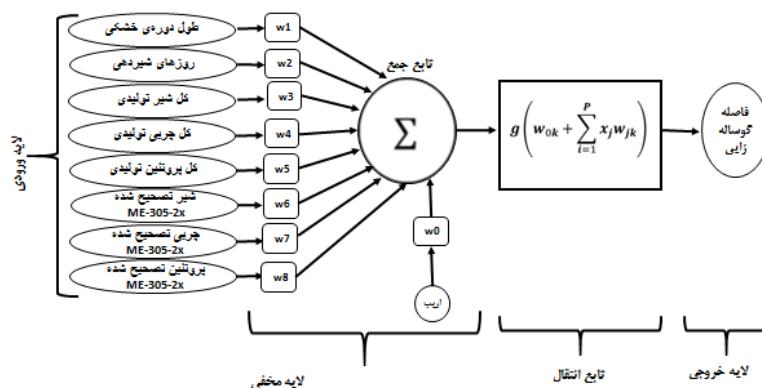
3- STATA

4- Adjusted quantile of chi-square distribution

نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

داده‌ها با بررسی نمودارهای هیستوگرام و همچنین آزمون شاپیرو-ولک^۱ مورد بررسی قرار گرفت. بعد از ویرایش داده‌ها و حذف اطلاعات ناقص، تعداد داده‌ها به ۱۴۳۷۱ کاهش پیدا کرد. سپس داده‌ها در بسته نرم‌افزاری کارت^۲ فرآخوانده شدند که متکی به محیط نرم‌افزار آماری آر^۳ است. خلاصه آماری صفات مورد بررسی در جدول ۱ نشان داده شده است. داده‌ها از لحاظ تعداد تلقیح، هفت گروه شدند. به طور کلی، از هفت شبکه عصبی که معادل با تعداد گروه تلقیح می‌باشد، استفاده شد.

یادگیری شبکه عصبی مصنوعی: برای مدل‌سازی شبکه عصبی از نرم‌افزار وکا^۴ استفاده شد. در مدل‌سازی با استفاده از شبکه عصبی و تعیین معماری آن باید مواردی شامل الگوریتم آموزش شبکه، تابع انتقال و تعداد چرخه‌های مورد استفاده برای آموزش شبکه یا تعداد دوره^۵ را در نظر گرفت. در این تحقیق، معماری سه لایه به کار برده شد که در آن تعداد نورون‌ها در لایه مخفی متفاوت بود. همچنین از تابع انتقال سیگموئیدی^۶ و ۱۰۰ چرخه آموزش شبکه استفاده گردید. تصویر تفهیمی و ساده شبکه عصبی مصنوعی مورد استفاده در شکل ۱ نشان داده شده است.



شکل ۱- تصویر شماتیک شبکه عصبی به کار برده شده در تحلیل داده‌ها.

Figure 1. Schematic representation of neural network used in data analysis.

- 1- Shapiro-Wilk Test
- 2- Caret
- 3- R
- 4- WEKA
- 5- Epoch
- 6- Sigmoid Transfer Function

مصفوفی قادری زفهایی و همکاران

جدول ۱- آمار توصیفی متغیرهای مورد استفاده در این مطالعه در هر تلقیح.

Table 1. Descriptive statistics of the variables used in this study in each insemination.

صفت Trait	تعداد تلقیح NO. of Insemination	تعداد مشاهدات NO. of Observations	میانگین Mean	انحراف معیار Standard Deviation	ضریب تغییرات Coefficient of Variation(CV)	حالات Maximum	حالات Minimum
فاصله‌ی گوساله‌زایی (روز) Calving Interval (day)	1	3783	356.8147	28.49815	0.079868	563	330
	2	4156	386.8354	44.85663	0.115958	717	330
	3	2690	425.6926	57.54205	0.135173	708	333
	4	1688	460.4828	59.5577	0.129338	708	351
	5	1018	493.3134	61.6029	0.124876	714	373
	6	645	522.5101	60.37786	0.115553	720	407
	7	391	550.2634	59.45983	0.108057	720	442
طول دوره‌ی خشکی (روز) Dry off Period (day)	1	3783	58.45229	10.30676	0.176328	100	35
	2	4156	57.58566	10.92176	0.189661	100	35
	3	2690	58.94387	11.39351	0.193294	100	35
	4	1688	60.28851	11.5654	0.191834	100	35
	5	1018	61.34283	11.6778	0.190369	100	35
	6	645	62.48992	12.882	0.206145	100	36
	7	391	64.02813	13.22553	0.206558	100	36
روزهای شیردهی (روز) Days in milk (day)	1	3783	298.3349	29.12839	0.097637	521	233
	2	4156	329.2351	43.84702	0.133178	656	237
	3	2690	366.713	56.12369	0.153045	655	264
	4	1688	400.1996	58.48765	0.146146	643	297
	5	1018	431.9774	60.35295	0.139713	652	313
	6	645	460.0279	60.13728	0.130725	671	350
	7	391	486.243	58.33528	0.119971	659	375
کل شیر تولیدی (کیلوگرم) Total Milk Production (kg)	1	3783	10034.32	2303.736	0.229586	18922.84	4028.79
	2	4156	11174.33	2521.87	0.225684	23331.8	4443.64
	3	2690	12122.51	2836.111	0.233954	25794.91	4856.15
	4	1688	13224.8	2896.393	0.219012	27771.73	4201.99
	5	1018	14001.22	3077.818	0.219825	27316.59	6787.67
	6	645	14743.83	3120.972	0.21168	25302.31	6435.04
	7	391	15370.98	3064.219	0.199351	24614.61	7479.47
کل چربی تولیدی (کیلوگرم) Total Fat Production (kg)	1	3783	284.3125	75.58757	0.265861	579.26	101.99
	2	4156	319.7135	85.02688	0.265947	708.35	103.08
	3	2690	350.3711	96.81964	0.276335	842.42	111.69
	4	1688	380.4234	102.1181	0.268433	861.88	131.53
	5	1018	403.5149	105.7196	0.261997	843.03	150.1
	6	645	429.9958	113.6399	0.264281	847.4	164.29
	7	391	447.3487	104.4772	0.233548	824.67	172.43
کل پروتئین تولیدی (کیلوگرم) Total Protein Production (kg)	1	3783	258.3467	78.91108	0.305446	538.77	90.17
	2	4156	286.8106	89.13846	0.310792	727.11	90.43
	3	2690	311.1614	99.79946	0.320732	699.29	90.63
	4	1688	338.7716	103.9294	0.306783	776.5	92.55
	5	1018	359.225	104.7391	0.29157	793.25	104.32
	6	645	374.2997	114.8682	0.306888	722.62	92.47
	7	391	394.8617	105.4927	0.267164	727.8	100.76
شیر تصویح شده (کیلوگرم) Adjusted Milk (kg)	1	3783	9364.823	2001.235	0.213697	16627.5	3616.25
	2	4156	9786.498	1898.501	0.193992	17240.85	4072.92
	3	2690	9836.11	1911.22	0.194306	16025.31	4353.05
	4	1688	10084.34	1790.004	0.177503	15608.61	3728.84
	5	1018	10087.86	1811.05	0.179528	15926.2	5352.89
	6	645	10175.24	1733.66	0.17038	15917.75	5017.74
	7	391	10285.57	1687.378	0.164053	15686.58	5722.64
چربی تصویح شده (کیلوگرم) Adjusted Fat (kg)	1	3783	264.8661	66.61082	0.251489	493.09	101.71
	2	4156	277.7617	67.21158	0.241976	507.53	101.3
	3	2690	280.2372	70.35158	0.251043	562.11	100.73
	4	1688	283.656	69.54588	0.245177	500.75	101.76
	5	1018	284.1192	69.67012	0.245214	491.88	101.41
	6	645	287.8417	71.96567	0.250018	506.36	112.43
	7	391	289.0307	68.16248	0.235831	464.38	100.75
پروتئین تصویح شده (کیلوگرم) Adjusted Protein (kg)	1	3783	235.869	69.35771	0.294052	484.81	80.94
	2	4156	248.2248	72.07396	0.290358	726.82	80.04
	3	2690	250.4399	74.30437	0.296695	488.22	80.71
	4	1688	253.9144	71.52309	0.281682	459.99	80.52
	5	1018	253.7561	68.09905	0.268364	459.78	80.94
	6	645	252.6501	71.36414	0.282462	422.89	82
	7	391	254.4802	64.07755	0.251798	411.2	81.27

نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

میزان اریب^۱ معمولاً در شبکه‌های عصبی اعمال می‌گردد که مهم‌ترین نقش آن این است که باعث تغییر تابع انتقال به چپ یا راست می‌شود. معمولاً در شبکه‌های عصبی ترکیب خطی از متغیرهای مستقل، به یک تابع غیرخطی مانند تابع سیگموئیدی (g)، تبدیل می‌شوند. تابع سیگموئیدی مورد استفاده در پژوهش حاضر به صورت زیر است.

$$h_k(x) = g\left(w_{0k} + \sum_{i=1}^P x_i w_{ik}\right)$$

در این رابطه، ضرایب وزن W همانند ضرایب رگرسیون هستند که در واقع W_{jk} انر زمین متغیر مستقل روی k امین واحد مخفی شبکه می‌باشد. در این مطالعه داده‌های هر تلقیح به دو قسمت آموزش (۸۰ درصد) و آزمون (۲۰ درصد) تقسیم‌بندی شدند. برای جلوگیری از اثر همبستگی خطی بین متغیرهای لایه ورودی شبکه عصبی از دو رویکرد حذف همبستگی^۲ بالا و تحلیل مؤلفه اصلی^۳ استفاده شد. در رویکرد اول در هر مجموعه از داده‌های متعلق به هر گروه تلقیح، ابتدا همبستگی خطی بین متغیرها محاسبه گردید. سپس متغیرهایی که همبستگی بین آن‌ها بیش از ۷۵ درصد بود، شناسایی شدند و تنها یکی از آن دو متغیر در مدل‌سازی شبکه‌های عصبی مورد استفاده قرار گرفت. در رویکرد دوم، ابتدا متغیرهای ورودی به روش تحلیل مؤلفه اصلی مورد بررسی و تحلیل قرار گرفتند و سپس برآشش شبکه‌های عصبی روی متغیرهای جدید انجام شد. انجام این روش باعث شد که تعداد متغیرهای ورودی مورد استفاده در تلقیح‌های مختلف، یکسان نباشند. برای این که بهترین نتایج حاصل گردد، شبکه‌های عصبی مختلف با تعداد لایه‌های مخفی و وزن‌های اختصاص داده شده مختلف مورد بررسی قرار گرفت. نتایج شبکه‌های عصبی مختلف بر اساس دو معیار ضریب تعیین و جذر میانگین مربعات خطأ مورد ارزیابی قرار گرفتند. شبکه‌ای که ضریب تعیین بیشتر و جذر میانگین مربعات خطأ کمتری داشت به عنوان بهترین شبکه عصبی انتخاب شد. این معیارها با استفاده از فرمول‌های زیر محاسبه شدند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_{id})^2}{n}} \quad \text{معادله (۱)}$$

 1- Bias

2- Pearson Correlation

3- Principle Component Analysis

مصطفی قادری زفراوی و همکاران

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_{id})^2}{\sum_{i=1}^n (y_{id} - y_m)^2} \quad \text{معادله (۲)}$$

که در آن y مقدار برآورده شده فاصله گوساله‌زایی با استفاده از شبکه عصبی است، y_{id} مقدار مشاهده شده فاصله گوساله‌زایی است و y_m میانگین مقدار مشاهده شده فاصله گوساله‌زایی است.

جلوگیری از بیش‌برازش شبکه‌های عصبی: شبکه‌های عصبی به دلیل تعداد زیاد ضرایب وزن (W_{jk})، تمایل به ایجاد بیش‌برازشی از ارتباط بین متغیرهای پیشگو و پاسخ دارند. در این پژوهش از روش وزن‌های جریمه‌ای^۱ برای از بین بردن این مشکل استفاده شد (۱۹). در این روش، جریمه‌ای برای ضرایب شبکه عصبی در نظر گرفته می‌شود. بنابراین مقدار وزن‌های جریمه‌ای باید اثر معنی‌داری روی خطاهای مدل جهت هموار کردن آن داشته باشد. فرایند بهینه‌سازی به دنبال کمینه کردن، نسخه دیگری از مجموع مربعات خطاهای برای مقدار مشخص λ به دست می‌آورد که به صورت زیر می‌باشد:

$$\sum_{i=1}^n (y_i - f_i(x))^2 + \lambda \sum_{k=1}^H \sum_{j=0}^P w_{jk}^2 + \lambda \sum_{k=0}^H \gamma_k^2.$$

در این حالت شبکه برآذش داده شده از نظر ریاضی هموارتر^۲ می‌شود و احتمال بیش‌برازش کاهش می‌باید. انتخاب وزن‌های جریمه‌ای و تعداد لایه‌های پنهان، نیازمند نمونه‌گیری‌های مجدد از داده‌هاست. بهمین منظور از مدل‌های شبکه عصبی میانگین شده استفاده شد (۲۴، ۲۳). سه مقدار $\lambda = 0.00$ ، $\lambda = 0.01$ و $\lambda = 0.10$ برای وزن‌های جریمه‌ای کاهنده به همراه یک لایه پنهان با اندازه بین ۱ تا ۱۳ واحد پنهان در نظر گرفته شد. همچنین میزان رابطه خطی و غیرخطی بین متغیرهای ورودی با فاصله گوساله‌زایی نیز با معیار ضریب اطلاعات بیشین^۳ بررسی گردید.

نتایج و بحث

مدل‌سازی به کار رفته در این پژوهش برای مدیریت بهتر فرایند تولیدمثل در گاو شیری انجام گرفت. فرض اساسی پژوهش حاضر این بود که به کارگیری مدل‌های مبتنی بر شبکه عصبی مصنوعی می‌تواند توانایی مدیریت‌های تولیدمثلی را در گاوداری‌ها افزایش دهد. گاوها به نحوی گروه‌بندی

1- Penalty weights

2- Smoothness

3- Maximal Information Coefficient

نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

شدن که امکان محاسبه فاصله گوساله‌زایی در آن‌ها وجود داشته باشد. با در نظر گرفتن کل داده‌ها (بدون گروه‌بندی آن در تلقیح‌های مختلف)، میانگین فاصله گوساله‌زایی $412/93$ روز بود. گزارش شده است که به ازای هر روز افزایش در فاصله گوساله‌زایی، نزدیک به 140 هزار ریال هزینه ایجاد می‌شود (۳۰). ضعف در تشخیص فحلی با افزایش فاصله زایش و متعاقب آن به علت کاهش تعداد تلیسه جایگزین و کاهش شدت انتخاب در تلیسه‌ها، سبب کاهش روند ژنتیکی تولید شیر در گله‌ها خواهد شد. فاصله بین گوساله‌زایی تا اولین تلقیح و دوره تلقیح و همچنین تعداد تلقیح به ازای آبستنی مهم‌ترین فاکتورهای مؤثر بر فاصله گوساله‌زایی می‌باشد (۳۰).

نتایج شبکه‌های عصبی در رویکرد حذف: نتایج بررسی نرمال بودن متغیرها با استفاده از آزمون شاپیرو-ولیک نشان داد که در تمام آن‌ها مقدار ارزش پی^۱ کمتر از $0/05$ به دست آمد. لذا می‌توان گفت که امکان استفاده از روش‌های رایج رگرسیونی برای مدل‌سازی این داده‌ها و با توجه به مفروضات این مدل‌ها به سختی وجود دارد. در بررسی اولیه صفات مختلف توسط ضربه همبستگی مشخص گردید که متغیرهای کل شیر تولیدی با شیر تصحیح شده، کل چربی تولیدی با چربی تصحیح شده و کل پروتئین تولیدی با پروتئین تصحیح شده دارای ضربه همبستگی پرسون بالای $0/75$ بودند. از این‌رو تنها یکی از آن‌ها (رکوردهای تصحیح شده) در شبکه عصبی نهایی مورد استفاده قرار گرفت. در جدول ۲ نتایج برآش هفت مدل شبکه عصبی مورد استفاده به تفکیک تعداد تلقیح نشان داده شده است.

جدول ۲- نتایج شبکه‌های عصبی با روش حذف در تلقیح‌های مختلف.

Table 2. Results of neural networks using elimination method in different inseminations.

آزمون ۲۰ درصد (20% testing)		آموزش ۸۰ درصد (80% training)				تعداد No.	تعداد وزن بنهان	تعداد واحد بنهان	تعداد تلقیح No. of insemination
RMSE	R ²	تعداد No.	RMSE	R ²	تعداد No.	No. of weights	No. of hidden units		
0.4294	0.9998	755	0.3814	0.9998	3028	3783	50	7	1
1.0544	0.9994	830	0.4708	0.9998	6332	6415	21	4	2
0.4851	0.9999	535	0.4753	0.9999	2155	2690	57	8	3
0.5463	0.9999	337	0.4714	0.9999	1135	8168	71	10	4
0.5282	0.9999	203	0.4783	0.9999	815	1018	71	10	5
0.7123	0.9998	128	0.4753	0.9999	517	654	71	10	6
0.6293	0.9999	77	0.5374	0.9999	314	391	50	10	7

1- P-value

مصطفی قادری زفراوی و همکاران

در گروه تعداد تلقیح یک، بهترین ساختار شبکه عصبی دارای ۷ نورون پنهان با اختصاص ۵۰ وزن بود. در مجموع ۳۷۸۳ مشاهده در این دسته قرار داشتند که با تعداد ۳۰۲۸ مشاهده شبکه عصبی آموزش داده شد و ضریب تعیین و جذر میانگین مربعات خطأ به ترتیب برابر 0.9998 و 0.3814 به دست آمد. سپس این شبکه با استفاده از ۷۵۵ مشاهده باقیمانده برآش داده شد که ضریب تعیین آن ثابت ماند ولی جذر میانگین مربعات خطأی آن اندکی افزایش پیدا کرد و به مقدار 0.4294 رسید. در سایر گروههای تلقیح نیز تفسیر جدول به همین صورت انجام می‌گیرد. تعداد وزن‌ها، در ستون سوم جدول ۲ نشان داده شده است. در شبکه‌های عصبی مورد استفاده، تنها یک لایه پنهان وجود دارد که خود شامل چندین واحد پنهان می‌باشد. تعداد وزن‌های این شبکه از فرمول $H(P + 1) + H + 1$ به دست می‌آید. در این فرمول H تعداد واحدهای پنهان و P تعداد متغیرهای ورودی شبکه است. در گروه تعداد تلقیح یک، ۷ واحد پنهان و ۵ متغیر ورودی وجود دارد که ایجاد ۵۰ وزن می‌کند. در گروه تعداد تلقیح دو، ۴ واحد پنهان و ۵ متغیر ورودی وجود دارد که ایجاد ۲۹ وزن می‌کند. این در حالی است که در جدول ۲، تعداد وزن‌ها برابر با ۲۱ می‌باشد که نشان‌دهنده این است که نیاز به برآورده ۸ وزن در مدل نبوده است و مدل مورد استفاده ساده‌تر است.

نتایج شبکه‌های عصبی در رویکرد تحلیل مؤلفه اصلی: تحلیل مؤلفه اصلی روی متغیرهای ورودی انجام شد. جدول ۳ نتایج برآش شبکه عصبی روی مؤلفه‌های اصلی استخراج شده از هر مجموعه داده را نشان می‌دهد. در هر مجموعه، تعداد مؤلفه‌های استخراجی برای به دست آوردن ۹۹ درصد از کل واریانس نشان داده شده است. در جدول ۳ مشاهده می‌شود که در گروه تلقیح یک، ۵ مؤلفه اصلی ۹۹ درصد واریانس موجود در داده‌ها را بیان می‌کردند. شبکه عصبی برآش یافته با ۴ نورون پنهان و بر روی این ۵ مؤلفه دارای ضریب تعیین 0.9941 و 0.9942 و جذر میانگین مربعات 2.2026 و 2.1395 به ترتیب در مجموعه آموزش و آزمون می‌باشد. در بقیه گروههای تلقیح نیز تفسیر نتایج جدول به همین صورت می‌باشد. همان‌طور که در جدول ۳ مشاهده می‌شود، تعداد مؤلفه‌های اصلی در تلقیح‌های مختلف متفاوت بوده که این شاید ساختار خاص داده‌ها را در ارتباط با فاصله گوساله‌زایی نشان دهد.

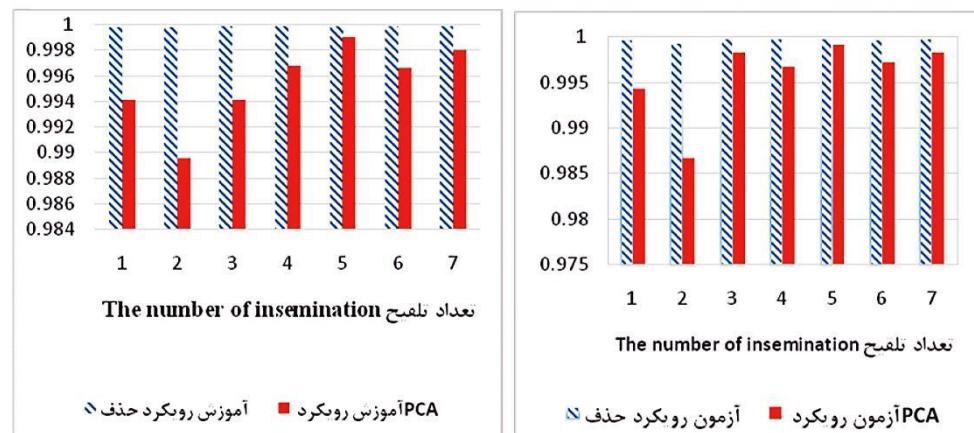
نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

جدول ۳- نتایج شبکه‌های عصبی با روش تحلیل مؤلفه‌های اصلی در تلقیح‌های مختلف.

Table 3. Results of neural networks using principle component analysis method in different inseminations.

آزمون ۲۰ درصد (20% testing)			آموزش ۸۰ درصد (80% training)			درصد واریانس تبیین شده	تعداد واحد پنهان	تعداد مؤلفه‌های اصلی	تعداد تلقیح
RMSE	R ²	تعداد NO	RMSE	R ²	تعداد NO	The percentage of explained variance	No. of hidden units	No. of principal components	No. of insemination
2.1395	0.9942	755	2.2026	0.9941	3028	99	4	5	1
5.2509	0.9866	830	4.5756	0.9895	6332	99	5	5	2
2.5366	0.9983	535	2.2026	0.9941	2155	99	7	6	3
3.4629	0.9966	337	3.3865	0.9968	1135	99	7	6	4
1.8594	0.9991	203	1.8831	0.9990	815	99	3	6	5
2.9540	0.9971	128	3.6337	0.9965	517	99	7	6	6
2.4775	0.9982	77	3.0711	0.9980	314	99	6	6	7

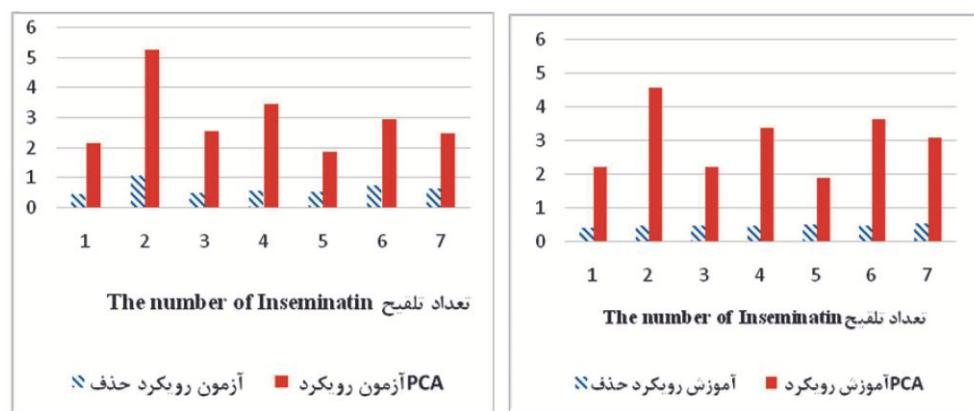
مقایسه ضریب تعیین دو رویکرد حذف و تحلیل مؤلفه اصلی در مجموعه آموزش (سمت راست) و مجموعه آزمون (سمت چپ) در شکل ۲ نشان داده شده است. مقادیر ضریب تعیین در مجموعه آموزش و آزمون در هر دو رویکرد بالای ۰/۹۸ است و رویکرد حذف در تمام تلقیح‌ها دارای ضریب تعیین بالاتری است. پس هر دو رویکرد از نظر ضریب تعیین مناسب هستند ولی مدل با رویکرد حذف از دقت بالاتری برخوردار است. در استخراج شبکه چه بر اساس رویکرد حذف و چه بر اساس تحلیل مؤلفه اصلی، با افزایش تعداد تلقیح، ضریب تعیین افزایش و دقت برآورد شبکه دقیق‌تر شده است. البته همان‌طور که مشخص است اختلاف دقت در حد کمتر از ۰/۰۱ است.



شکل ۲- مقایسه ضریب تعیین (R^2) دو رویکرد در مجموعه آموزش (سمت راست) و مجموعه آزمون (سمت چپ).
Figure 2. Comparison the coefficient of determination (R^2) of two approaches in the training set (left) and test set (right).

مصطفی قادری زفراوی و همکاران

مقایسه معيار جذر میانگین مربعات خطأ در دو رویکرد حذف و تحلیل مؤلفه اصلی در مجموعه آموزش (سمت چپ) و مجموعه آزمون (سمت راست) در شکل ۳ نشان داده شده است. مقادیر جذر میانگین مربعات خطأ مربوط به مجموعه آموزش و آزمون در رویکرد حذف کمتر از یک بوده ولی در رویکرد تحلیل مؤلفه اصلی همگی بالای $1/5$ هستند و در تلقیح دوم این معيار در هر دو رویکرد بیشینه می‌شود. این نتایج نشان می‌دهد که رویکرد حذف مناسب‌تر می‌باشد.



شکل ۳- مقایسه جذر میانگین مربعات خطای دو رویکرد در مجموعه آموزش (سمت چپ) و مجموعه آزمون (سمت راست).
Figure 3. Comparison between RMSE of the two approaches in the training set (left) and test set (right).

اندازه‌گیری رابطه خطی و غیر خطی متغیرهای ورودی با متغیر خروجی: در محاسبه معيار ضریب اطلاعات بیشین از اطلاعات متقابل^۱ بین دو متغیر استفاده می‌شود. در جدول ۴ میزان تأثیر متغیرهای ورودی بر متغیر فاصله گوساله‌زایی توسط معيار ضریب اطلاعات بیشین تعیین شده است. همان‌طور که در جدول ۴ نشان داده شده است، متغیرهای روزهای شیردهی و کل شیری تولیدی، کل چربی تولیدی و کل پروتئین تولیدی، بیشترین میزان ارتباط آماری را با فاصله گوساله‌زایی نشان می‌دهند. این روند ارتباطی تقریباً با افزایش تعداد تلقیح‌ها افزایش یافت. همان‌طور که ملاحظه می‌شود، ارتباط بین متغیرهای ورودی و خروجی با استفاده از شبکه عصبی و در تلقیح‌های مختلف تعیین گردید.

1- Mutual information

نشریه پژوهش در نشخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

جدول ۴- میزان رابطه خطی و غیرخطی با استفاده از معیار ضریب اطلاع بیشین.

Table 4. Measurement of linear and nonlinear relationship with maximal information coefficient.

طول دوری خشک Length of dry off period	متغیرها Variables									
	کل شیر تولیدی Total Milk Production	کل چربی تولیدی Total Fat Production	کل پrotein تولیدی Total Protein Production	کل چربی و پrotein تولیدی Total Milk	روزهای شیردهی Days in Milk	شیر تصحیح شده Adjusted Milk (ME-305-2x)	چربی تصحیح شده Adjusted Fat (ME-305-2x)	گروهی تصحیح شده Adjusted Protein (ME-305-2x)	تعداد تلقیح No. of Insemination	
0.0436	0.1179	0.1024	0.1012	0.5875	0.1041	0.0919	0.0972	1		
0.0761	0.1477	0.1318	0.1115	0.6987	0.0876	0.0860	0.0905	2		
0.0914	0.1904	0.1753	0.1490	0.7888	0.1034	0.1006	0.1049	3		
0.1028	0.1955	0.1927	0.1725	0.8017	0.1078	0.1130	0.1190	4		
0.1278	0.2403	0.2036	0.1739	0.8300	0.1367	0.1203	0.1432	5		
0.1584	0.2254	0.2716	0.1904	0.8809	0.1671	0.1720	0.1455	6		
0.1804	0.3109	0.2360	0.2555	0.8539	0.1783	0.1970	0.1530	7		

انجوبی و همکاران (۲۰۰۹) توانستند رکوردهای تولید شیر اولین دوره شیردهی گاوها را با استفاده از شبکه عصبی پیش‌بینی کنند (۲۱). بهترین توپولوژی شبکه عصبی مورد استفاده این محققین شامل یک لایه پنهان به همراه ۸ نورون و تابع انتقال از نوع تانژانت سیگموئیدی^۱ بود. آن‌ها نشان دادند که با وارد کردن اطلاعات والد نر به شبکه، معیار جذر میانگین مربعات خطأ کاهش یافته است. برای بهینه‌سازی شبکه عصبی باید تعداد لایه‌های پنهان و تعداد نورون‌های موجود در آن تعیین گردد. انتظار می‌رود که هرچه تعداد لایه‌های پنهان بالا رود، شبکه بهینه‌تر گردد. اما افزایش تعداد لایه‌های پنهان همراه با افزایش هزینه محاسباتی است (۱۴). در مطالعه کومار و شارما (۲۰۱۴) برای بررسی میزان تولید شیر و طول عمر، شبکه عصبی با لایه‌های مختلف آموزش داده شد. در این پژوهش از دو تابع انتقال متفاوت تانسیگ^۲ و کاملاً خطی^۳ به ترتیب در لایه‌های اول و دوم مخفی استفاده گردید (۱۸). از شبکه عصبی برای گروه‌بندی متغیرها نیز استفاده می‌شود. در مطالعه‌ای که روی میزان سخت‌زایی در گاو شیری صورت گرفت، تعداد ۱۵ متغیر با ماهیت‌های متفاوت هورمونی، مدیریتی و تولیدی به عنوان متغیرهای ورودی شبکه عصبی به کار برده شدند. هدف این بود که مشخص گردد چه تعداد از متغیرها باعث بروز سخت‌زایی می‌گردند. نشان داده شد که متغیرهای فصل گوساله‌زاوی، ژنوتیپ ژن

1- Tangent sigmoid

2- Tansig

3- Pure line

مصطفی قادری زفرهایی و همکاران

CYP19-PvuII و طول آبستنی بیشترین ارتباط را با بروز سخت‌زایی داشتند. در این مطالعه تابع شعاعی پایه^۱ در دو توپولوژی مختلف با یک و دو لایه مخفی به کار برده شد (۲۰). همچنین گزارش شده است که در گروه‌بندی متغیرهای مؤثر در عملکرد تلقیح مصنوعی، استفاده از رگرسیون سازش‌پذیر اسپلاین چند متغیره^۲ و شبکه عصبی بهتر از رگرسیون لجستیک و توابع گروه‌بندی^۳ عمل می‌کنند (۷). با توجه به نتایج حاصل، پیشنهاد می‌شود که این‌گونه آموزش‌های شبکه عصبی روی داده‌های حاصل از واحدهای پرورش گاو شیری اعمال گردد. همچنین نیاز به استفاده از متغیرهای ورودی که در این مطالعه به کار نرفتند نیز احساس می‌شود. مثلاً ثابت شده است که سن اولین زایش نیز یکی از عوامل مؤثر بر عملکرد تولیدمثلی می‌باشد که تأثیر آن بر عملکرد تولیدمثلی مشابه با دوره شیردهی می‌باشد (۱۷).

نتیجه‌گیری کلی

به‌طور کلی نتایج این پژوهش نشان داد که متغیرهای به‌کار رفته در این مطالعه توانسته است پیش‌بینی خوبی از فاصله گوساله‌زایی ارائه دهد. از طرفی مشخص شد که این معیارها در تلقیح‌های مختلف تقریباً یکسان است و از این‌رو نباید انتظار داشت که مدل‌سازی تلقیح‌های مختلف، جواب متفاوتی ارایه کند. در این مطالعه مشخص شد که با افزایش تعداد تلقیح‌ها، روند ارتباطی متغیرها با فاصله گوساله‌زایی تغییر نمی‌کند. بعضی از این متغیرها مثل روزهای باز ارتباط ساختاری زیادی با فاصله گوساله‌زایی دارند. لذا پیشنهاد می‌شود با استفاده از روش‌های بیزی^۴ و لاسو^۵ ابتدا انتخاب متغیر صورت گیرد و سپس آموزش شبکه عصبی انجام پذیرد. همچنین با توجه به این که شبکه‌های عصبی مصنوعی نیاز به فرضیه‌ها و مدل‌های از پیش تعیین شده ندارند، می‌توانند به عنوان جایگزینی برای مدل‌های رگرسیون مطرح شوند.

سپاسگزاری

نویسنده‌گان از مدیریت محترم مجتمع کشت و دامداری فکا، آقای مهندس جلیل نژاد که داده‌های این تحقیق را در اختیار ما گذاشتند، تشکر و قدردانی می‌نمایند.

1- Radius Base Function

2- Multivariate Adaptive Regression Spline

3- Classification Functions

4- Bayesian

5- Lasso

منابع

1. Ansari-Lari, M., Rezagholi, M., and Reiszadeh, M. 2009. Trends in calving age and calving intervals for Iranian Holstein in Fars province, Southern Iran. *Trop. Anim. Health Prod.* 41: 1283-1288.
2. Borecki, M., Korwin-Pawlowski, M.L., Beblowska, M., Szmidt, M., Urbańska, K., Kalenik, J., Chudzian, L., Szczepański, Z., Kopczyński, K., Jakubowski, A., and Szmidt, A.J. 2010. Capillary microfluidic sensor for determining the most fertile period in cows. *Acta Physica Polonica A.* 118(6): 1093-1099.
3. Cavero, D., Tölle, K.H., Henze, C., Buxadé, C., and Krieter, J. 2008. Mastitis detection in dairy cows by application of neural networks. *Livest. Sci.* 114: 280–286.
4. Chen, L.J., Cui, L.Y., Xing, L., and Han, L.J. 2008. Prediction of the nutrient content in dairy manure using artificial neural network modeling. *J. Dairy Sci.* 91: 4822-4829.
5. Chen, L.J., Xing, L., and Han, L.J. 2009. Quantitative determination of nutrient content in poultry manure by near infrared spectroscopy based on artificial neural networks. *Poult. Sci.* 88: 2496-2503.
6. Curtis, C.R., Erb, H.N., Sniffen, C.J., Smith, R.D., and Kronfeld, D.S. 1985. Path analysis of dry period nutrition, postpartum metabolic and reproductive disorders, and mastitis in Holstein cows. *J. Dairy Sci.* 68: 2347-2360.
7. De Vries, A. 2006. Economic value of pregnancy in dairy cattle. *J. Dairy Sci.* 89: 3876-3885.
8. Finn G.D., Lister, R., Szabo, R., Simonetta, D., Mulder, H., and Young, R. 1996. Neural Networks applied to a large biological database to analyse dairy industry pattern. *Neural Comput. Appl.* 4: 237-253.
9. Ghiasi, H., Pakdel, A., Nejati-Javaremi, A., Mehrabani-Yeganeh, H., Honarvar, M., Gonzalez-Recio, O., Jesus Carabano, M., and Alenda, R. 2011. Genetic variance components for female fertility in Iranian Holstein cows. *Livest. Sci.* 139(3): 277-280.
10. Gorgulu, O. 2012. Prediction of 305-day milk yield in Brown Swiss cattle using artificial neural networks. *S. Afr. J. Anim. Sci.* 42(3): 280-287.
11. Grzesiak, W., Lacroix, R., Wójcik, J., and Blaszczyk, P. 2003. A comparison of neural network and multiple regression predictions for 305-day lactation yield using partial lactation records. *Can. J. Anim. Sci.* 83: 307-310.
12. Grzesiak, W., Zaborski, D., Sablik, P., Žukiewicz, A., Dybus, A., and Szatkowska, I. 2010. Detection of cows with insemination problems using selected classification models. *Comput. Electron. Agr.* 74(2): 265–273.
13. Hassan, K.J., Samarasinghe, S., and Lopez-Benavides, M.G. 2009. Use of neural networks to detect minor and major pathogens that cause bovine mastitis. *J. Dairy Sci.* 92: 1493-1499.

14. Haykin, S. 1999. Neural Networks, A comprehensive Foundation. Prentice Hall, Upper saddle River, NJ. Pp: 156-158.
15. Hosseinnia, P., Edrisi, M., Edriss, M.A., and Nilforooshan, M.A. 2007. Prediction of second parity milk yield and fat percentage of dairy cows based on first parity information using neural networks system. *J. Appl. Sci.* 7: 3274-3279.
16. Krieter, J., Stamer, E., and Junge, W. 2006. Control charts and neural networks for oestrus detection in dairy cows. *Lecture Notes in Informatics.* 133-136.
17. Kuhn, M. 2008. Building predictive models in R using the caret package. *J Stat Softw.* 28(5): 1-26.
18. Kumar, S., and Sharma, S.K. 2014. Anticipating milk yield using artificial neural network. *Int. J. Appl. Sci. Engeer. Res.* 3(3): 690-695.
19. Krogh, A., and Hertz, J.A. 1992. A simple weight decay can improve generalization. In *Advances in neural information processing systems.* 4: 950-957.
20. Nielen, M., Spigt, M.H., Schukken, Y.H., Deluyker, H.A., Maatje, K., and Brand, A. 1995. Application of a neural network toanalyse on-line milking parlour data for the detection of clinical mastitis in dairy cows. *Prev. Vet. Med.* 22: 15-28.
21. Njubi, D.M., Wakhungu, J., and Badamana, M.S. 2009. Milk yield prediction in Kenyan Holstein-Friesian cattle using computer neural networks system. *Livest. Res. Rural Dev.* 21(4): 46-51.
22. Pahlavan Afshar, K., Honarvar, M., and Lavvaf, A. 2012. Estimated economic value of estrous detection using bio-economic model in Iranian Holestein herds. *J. Anim. Sci. Res.* 12: 37-50. (In Persian)
23. Pastell, M.E., and Kujala, M. 2007. A probabilistic neural network model for lameness detection. *J. Dairy Sci.* 90: 2283- 2292.
24. Ripley, B.D. 1995. Statistical ideas for selecting network architectures. In *Neural networks: Artificial intelligence and industrial applications.* Springer. Pp: 183-190.
25. Salehi, F., Lacroix, R., and Wade, K.M. 1998. Improving dairy yield predictions through combined record classifiers andspecialized artificial neural networks. *Comput. Electron. Agr.* 20: 199-213.
26. Salehi, F., Lacroix, R., Yang, X.Z., and Wade, K.M. 1997. Effects of data preprocessing on the performance of artificial neural networks for dairy yield prediction and cow culling classification. *Trans. ASAE,* 40(3): 839-846.
27. Sanzogni, L., and Kerr, D. 2001. Milk production estimates using feed forward artificial neural networks. *Comput. Electron. Agric.* 32: 21-30.
28. Shahabifar, M. 2005. The ore reserve estimate by artificial neural network technique. *Iran mining Engineering Conference, Tarbiat modares university, Tehran, Iran.* (In Persian)

نشریه پژوهش در نسخوارکنندگان (۳)، شماره (۴) ۱۳۹۴

29. 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. *Comput. Math. Methods Med.* 2012: 127130.
30. Slama, H., Wells, M.E., Adams, G.D., and Morrison, R.D. 1996. Factors affecting calving interval in dairy herds. *Anim. Sci.* 59: 1334-1339.
31. Sun, Z. 2008. Application of artificial neural networks in early detection of mastitis from improved data collected on-line by robotic milking stations. Ph.D. Dissertation, Lincoln University, New Zealand.
32. Toghiani Pozveh, S., Shadparvar, A.A., Moradi Shahrabak, M., and Dadpasand Taromsari, M. 2009. Genetic analysis of reproduction traits and their relationship with conformation traits in Holstein cows. *Livest. Prod. Sci.* 125: 84-87.
33. Tumer, K., and Ghosh, J. 1996. Analysis of decision boundaries in linearly combined neural classifiers. *Pattern Recog.* 29(2): 341-348.
34. Wang, E., and Samarasinghe, S. 2005. On-Line Detection of Mastitis in Dairy Herds Using Artificial Neural Networks. 273-278.
35. Yang, X.Z., Lacroix, R., and Wade, K.M. 1999. Neural detection of mastitis from dairy herd improvement records. *Trans. ASAE.* 42: 1063-1071.
36. Yang, X.Z., Lacroix, R., and Wade, K.M. 2000. Investigation into the production and conformation traits associated with clinical mastitis using artificial neural networks. *Can. J. Anim. Sci.* 80: 415-426.
37. Zaborski, D., and Grzesiak, W. 2011. Detection of difficult calving in dairy cows using neural classifier. *Archiv Tierzucht*, 54(5): 477-489.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Ruminant Research, Vol. 3(4), 2016
<http://ejrr.gau.ac.ir>

Association between calving interval and productive traits in dairy cattle over different inseminations using artificial neural network

***M. Ghaderi Zefrehei¹, M.R. Bahreini Behzadi¹, M. Fayaz² and S. Sharifi³**

¹Assistant Prof., Dept. of Animal Sciences, Faculty of Agriculture, Yasouj University,

²Ph.D. Student, Dept. of Biology, Faculty of Basic Sciences, Shahid Beheshti University,

³Ph.D. Student, Dept. of Animal Sciences, Faculty of Agriculture, Isfahan University of Technology

Received: 21/12/2015; Accepted: 17/03/2016

Abstract

Background and objectives: Calving interval is sought to be substantially affected by management and environmental effects. Using intellectual algorithms of machine learning methods to investigate complex systems are growing and these algorithms could be assumed as right approach to analysis dairy cattle industry data. Artificial neural networks which are part of artificial intelligence, gain from these algorithms. The objective of this study was to find the association between productive and reproductive traits with calving interval over different course of inseminations. It was assumed that extracting this association may improve the management of this trait.

Materials and methods: In this research, the productive and reproductive traits from FOKA, an agriculture and animal husbandry, associated to Isfahan Vahdat Cooperative was used. The records were calving interval (day), the length of dry off period (day), number of insemination, total milk production (kg), total fat production (kg), total protein production (kg), adjusted milk production (kg), adjusted fat production (kg) and adjusted protein production (kg). The data were due to 15465 cows in which their parturition date spanned between 1368 and 1393. The data dimensions were reduced using elimination of high level of correlation among variables and principal component analysis before undertaking artificial neural network modeling. For each insemination, we learned a neural network. We used coefficient of determination and root mean square error to investigate the

*Corresponding author: mosmos741@yahoo.com

efficiency of neural network. The linear and nonlinear relationship among input variables with calving interval was measured using maximal information criterion.

Results: The similar values of coefficient of determination and root mean square error due to neural network in different insemination obtained which would indicated that there is almost identical associations between calving interval input variables. Higher values of root mean square error obtained in neural network which learned based upon principal component analysis of independent data than elimination one. Therefore, it was concluded that elimination approach is suitable choice in this context. The maximal information criterion showed almost an identical association between calving interval and input variables over different inseminations. In this way, days in milk and milk production showed high amount of correlation with calving interval.

Conclusion: The results indicated that coefficient of determination and root mean square error of different inseminations was similar. Therefore, it is hardly expected that the association between calving interval and independent variables to be different over different inseminations. Based upon these results, it was elucidated that independent variables used in this study could fairly adequately predict the calving interval. Also, we could say that management – environmental conditions over different inseminations had minuscule effect on the associations of calving interval with independent variables.

Keywords: Principal component analysis, artificial neural network, Maximal information coefficient, Calving interval

