

مقایسه عملکرد شبکه‌های عصبی پرسپترون چندلایه و توابع با پایه شعاعی در برآورد ستانده انرژی مرغ

گوشتی

سما عمید^{۱*}، ترحم مصری گندشمین^۲، غلامحسین شاهقلی^۳

۱. دانش آموخته کارشناسی ارشد، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

۲. دانشیار، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

۳. دانشیار، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی

(تاریخ دریافت: ۱۳۹۴/۶/۱۷ - تاریخ تصویب: ۱۳۹۴/۱۰/۲۸)

چکیده

مدیریت انرژی یکی از اصلی‌ترین راه‌های بهینه‌سازی مصرف منابع انرژی است. پیش‌بینی عملکرد محصولات بر اساس ورودی‌های انرژی می‌تواند به کشاورزان و سیاست‌گذاران به منظور برآورد سطح تولید کمک کند. داده‌های مورد نیاز برای مطالعه به طور تصادفی از ۷۰ مزرعه مرغ‌گوشتی در شمال غرب ایران جمع‌آوری گردید. انرژی‌های ورودی شامل نیروی انسانی، ماشین‌آلات، سوخت، خوراک و الکتریسیته و انرژی‌های خروجی تولید شده به عنوان متغیرهای خروجی در نظر گرفته شد. شبکه‌های عصبی پرسپترون چندلایه (MLP) و تابع با پایه شعاعی (RBF) به منظور پیش‌بینی انرژی‌های خروجی تولید مرغ‌گوشتی مورد استفاده قرار گرفت. با توجه به نتایج مقایسه به‌دست آمده از شاخص‌های ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و میانگین قدرمطلق خطا (MAE) عملکرد مدل شبکه عصبی RBF بهتر از شبکه عصبی MLP برآورد گردید. در ارزیابی تأثیرپذیری خروجی از نهاده‌های ورودی، در هر دو مدل سوخت فسیلی بالاترین حساسیت را در بین نهاده‌های تولیدی از خود نشان داد.

واژه‌های کلیدی: پیش‌بینی، حساسیت، مدیریت انرژی، منابع انرژی.

مقدمه

انرژی به دلیل نقش برجسته آن در زندگی انسان به عنوان یک مسئله اساسی در قرن حاضر محسوب می‌شود. افزایش چشم‌گیر جمعیت و تقاضا برای استانداردهای بالای زندگی باعث افزایش شدید مصرف انرژی شده است (Shamshirband et al., 2015). کشاورزی مصرف‌کننده اصلی منابع انرژی است. با توسعه سیستم‌های تولید محصولات کشاورزی و حرکت به سوی نوسازی، وابستگی به منابع انرژی در این بخش افزایش یافته است (Yousefi et al., 2014). صنایع کشاورزی نقشی دوگانه و به عنوان مصرف‌کننده انرژی و تأمین‌کننده انرژی در قالب انرژی زیستی عمل می‌کند. عملکرد محصول و تأمین مواد غذایی به‌طور مستقیم به انرژی مرتبط است به‌طوری که کفایت و کارایی استفاده از انرژی نیز پیش‌نیاز بهبود تولیدات کشاورزی است (Mohammadi et al., 2008; Mohammadshirazi et al., 2015). اهمیت مدیریت انرژی و در نتیجه کاهش اثرات منفی زیست‌محیطی از مصرف بالای انرژی در تولید محصولات

کشاورزی از یک سو و نقش کلیدی تولیدات کشاورزی در تأمین امنیت غذایی از سوی دیگر موجب شده است که مطالعات بسیاری در زمینه تجزیه و تحلیل جریان انرژی ورودی و خروجی در بخش کشاورزی انجام گیرد (Khoshnevisan et al., 2014).

مدل‌های کلاسیک آماری به منظور یافتن روابط بین ورودی و خروجی‌های فرآیند تولید هنوز هم یکی از روش‌های مناسب در تحلیل سیستم است، با این پیش‌فرض که روش کلاسیک نیازمند تعریف دقیق پارامترهای معادلات ریاضی برای توصیف پدیده‌هاست. شبکه‌های عصبی مصنوعی (ANN)^۱، یکی از کارآمدترین روش‌های محاسباتی نسبت به سایر تکنیک‌های تحلیلی و آماری است (Naderloo et al., 2012). مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد پیش‌فرض‌های آماری آن‌هاست. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به مدل‌سازی رابطه بین مجموعه ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه

عصبی، این مطالعه به دنبال بررسی و مقایسه کارایی دو روش شبکه عصبی در برآورد پارامترهای این مطالعه نیز است. در این مطالعه برای نخستین بار شبکه عصبی با RBF برای برآورد انرژی خروجی در تولید محصولات کشاورزی به کار گرفته شد و نتایج آن با مدل شبکه عصبی MLP مقایسه شد. همچنین در هر دو روش مورد مطالعه، سهم تأثیر هر یک از متغیرهای ورودی در تخمین انرژی خروجی محاسبه گردید.

مواد و روش‌ها

جمع‌آوری و پردازش داده‌ها

استان اردبیل در موقعیت جغرافیایی بین مختصات ۴۵ درجه و ۱۵ دقیقه و ۴۸ درجه و ۵۶ دقیقه طول شرقی و ۳۷ دقیقه و ۹ درجه و ۳۹ دقیقه و ۴۲ درجه عرض شمالی واقع شده است. استان اردبیل دارای ۳۴۷ واحد مرغداری در سال ۱۳۹۲ بوده است که از این تعداد ۳۳۸ واحد فعال گزارش شده‌اند. ظرفیت کل مرغداری‌های استان برابر ۵/۵۰۲ میلیون قطعه مرغ می‌باشد. تولید استان در سال ۱۳۹۲ حدود ۹/۵۴۰ میلیون تن گزارش شده است (Anonymous, 2013). اطلاعات مورد نیاز در این تحقیق از مرغداری‌های پرورش مرغ گوشتی در استان اردبیل جمع‌آوری شد. در مطالعه حاضر، محاسبات برای یک دوره جوجه‌ریزی صورت گرفته است و زمان جمع‌آوری داده‌ها برای این مطالعه از اوایل مهر ماه سال ۱۳۹۲ شروع و تا اواخر آذرماه همان سال ادامه یافت. برای نمونه‌گیری از روش نمونه‌گیری تصادفی استفاده شد زیرا آسان‌ترین و اصولی‌ترین روش برای نمونه‌گیری بوده و قابل تعمیم به کل جامعه است. برای تعیین حجم نمونه از رابطه تعیین حجم نمونه کوکران به شرح زیر استفاده شد (Cochran, 1977):

$$n = \frac{N(s \times t)^2}{Nd^2 + (s \times t)^2} \quad (\text{رابطه ۱})$$

که در آن N، اندازه جامعه آماری یا تعداد مرغداران، t ضریب اطمینان قابل قبول که با فرض نرمال بودن توزیع صفت مورد نظر از جدول t استیودنت به دست می‌آید S₂، برآورد واریانس صفت مورد مطالعه در جامعه که در اینجا واریانس شاخص‌های انرژی در منطقه مورد مطالعه است، d دقت احتمالی مطلوب و n حجم نمونه می‌باشد. با این روش حجم نمونه ۶۴ عدد برآورد گردید و برای افزایش دقت کار به ۷۰ عدد افزایش یافت. بدین جهت اطلاعات لازم از ۷۰ مرغدار استان اردبیل در قالب پرسشنامه و مصاحبه حضوری جمع‌آوری گردید. در این مطالعه پنج نهاد شامل نیروی انسانی،

می‌باشد (Pahlavan et al., 2012). شبکه عصبی مصنوعی به طور گسترده به منظور شبیه‌سازی عملکرد سیستم به خصوص هنگامی که نیاز به شبیه‌سازی سیستم‌های پیچیده بوده و تعداد محدودی از داده‌های تجربی در دسترس است، مورد استفاده قرار می‌گیرند. شبکه پرسپترون چندلایه (MLP) و شبکه تابع پایه شعاعی (RBF) از جمله مهم‌ترین شبکه‌های پیشروی عصبی محسوب می‌شوند. تفاوت بین MLP و RBF نشان می‌دهد که RBF یک نوع رایج از یادگیری شبکه عصبی بوده که تنها به بخش محدودی از فضای ورودی پاسخ می‌دهد و روش آموزشی سریع‌تر، دقیق‌تر با ساختار شبکه‌ای ساده‌تر در مقایسه با دیگر شبکه‌های عصبی دارد. از سوی دیگر، MLP رویکرد تعمیم‌پذیرتری دارد. هرکدام از این شبکه‌ها به‌طور جداگانه در این مطالعه مورد بررسی قرار گرفته است.

در زمینه استفاده از شبکه‌های عصبی، در مطالعات کشاورزی تاکنون پژوهش‌های مختلفی صورت پذیرفته که از جمله آن‌ها می‌توان به مطالعه‌ای که بر روی مزارع گندم و آبی در نیوزلند انجام شده است، اشاره کرد. در این مطالعه چندین عامل مستقیم و غیرمستقیم به‌منظور ایجاد مدل شبکه عصبی مصنوعی شناسایی و انرژی مصرفی در تولید گندم پیش‌بینی شده است. همچنین مقایسه بین مدل شبکه عصبی و رگرسیون خطی چندگانه (MLR) نشان داده که مدل ANN می‌تواند مدل نسبتاً بهتری از مصرف انرژی نسبت به رگرسیون چندگانه را ارائه نماید (Safa & Samarasinghe, 2011). در مطالعه Pahlavan et al. (2012) شبکه عصبی عملکرد تولید ریحان گلخانه‌ای در ایران را نسبت به روش‌های آماری با دقت بالاتری پیش‌بینی نموده است. کارایی شبکه عصبی در مدل‌سازی نسبت هزینه به سود در واحدهای مرغداری گوشتی در مناطق گرمسیری ایران نیز نتایج مشابهی داشته است (Heidari et al., 2011b). Sefeedpari et al. (2012) الگوی مصرف انرژی در مزارع مرغ‌های تخم‌گذار را به روش ANN در استان تهران مدل‌سازی نمودند. نتایج حاصل از مدل نشان می‌دهد که عملکرد شبکه دارای ضریب تبیین بالا و برابر ۰/۹۹۲ می‌باشد و می‌توان نتیجه گرفت که ANN یک روش بسیار مناسب برای مدل‌سازی الگوی مصرف انرژی در صنایع کشاورزی باشد.

هدف اصلی از این مطالعه تخمین انرژی خروجی در تولید جوجه‌های گوشتی می‌باشد که با توجه به کارایی مناسب شبکه

1. Multilayer Perceptron Network
2. Radial Basis Function Network
3. Multi Linear Regression

بین لایه‌های پنهان و لایه خروجی، ماتریس وزن خروجی را تشکیل می‌دهد (Zhao et al., 2009). هر نرون، پس از محاسبه مجموع وزن n سیگنال ورودی خود ($x_j, j=1, \dots, n$) یک تابع غیرخطی فعال از سیگنال خروجی (Y) را تولید می‌کند (Deh Kiani et al., 2010):

$$y = \varphi \left(\sum_{j=1}^n w_j x_j \right) \quad (\text{رابطه ۳})$$

تابع سیگموئید این معیار را برآورده و همچنین این تابع به‌طور کلی در بسیاری از شبکه‌های عصبی پیش‌خور مورد استفاده قرار می‌گیرد. این تابع توسط رابطه (۴) ارائه شده است (Dawson & Wilby, 1998):

$$y = \frac{1}{1 + \exp \left(- \sum_{j=1}^n w_j x_j \right)} \quad (\text{رابطه ۴})$$

عملکرد شبکه را می‌توان با مقایسه خطای به‌دست آمده از شبکه عصبی همگرا و داده‌های اندازه‌گیری شده ارزیابی نمود. خطا در پایان فرایندهای آموزش و آزمون براساس تفاوت مقادیر هدف و خروجی پیش‌بینی شده، محاسبه می‌گردد. تابع الگوریتم پس‌انتشار خطا، تابع خطا را که توسط متوسط مقدار مجموع مربعات خطا بین مقدار پیش‌بینی شده توسط هر نرون در لایه خروجی و خروجی هدف تعریف می‌شود را به حداقل می‌رساند. تابع خطا می‌تواند به صورت زیر بیان شود (Deh Kiani et al., 2010):

$$E = \frac{1}{p} \sum_p \sum_k (z_{pk} - z'_{pk})^2 \quad (\text{رابطه ۵})$$

که در آن P شاخص جفت آموزش بردارها، K شاخص مؤلفه‌ها در بردار خروجی، Z_{pk} مؤلفه k ام از بردار الگوی هدف p ام و Z'_{pk} مؤلفه k ام بردار پیش‌بینی است که الگوی P به عنوان ورودی شبکه ارائه شده است.

در این تحقیق از الگوریتم‌های آموزش لوبنبرگ-مارکواریت (LM^1) برای بهنگام‌سازی وزن‌های شبکه عصبی مصنوعی استفاده شد که از الگوریتم‌های پرکاربرد می‌باشند. چون آموزش شبکه را بسیار سریع انجام داده و سطح خطای موجود را حداقل می‌سازند.

مدل تابع پایه شعاعی

این شبکه در مقایسه با شبکه عصبی MLP، نیاز به نرون بیشتری دارد؛ اما طراحی آن سریع‌تر از شبکه MLP بوده و سریع‌تر آموزش می‌بیند. این شبکه‌ها زمانی که بردارهای ورودی فراوانی

ماشین‌آلات، سوخت فسیلی، خوراک دام و الکتریسیته به عنوان ورودی‌های سامانه تولید و عملکرد مرغ تولیدی و کود بستر به ازای ۱۰۰۰ قطعه مرغ نیز به عنوان ستانده سامانه در نظر گرفته شد. محاسبه انرژی مصرفی با استفاده از معادل انرژی مربوط به هر واحد نهاده یا ستانده و ضرب آن در مقدار نهاده مصرف‌شده یا ستانده تولیدشده به ازای هر ۱۰۰۰ قطعه مرغ انجام گرفت. معادل‌های انرژی مورد استفاده در جدول ۱ ارائه شده‌اند.

شبکه‌های عصبی مصنوعی

به منظور تعمیم و افزایش دقت مدل، با استفاده از رابطه ۲، عملیات نرمال‌سازی روی داده‌های اولیه انجام شد و داده‌ها به دامنه صفر تا یک نگاشت شدند: (Sajikumar & Thandaveswara, 1999).

$$X_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (\text{رابطه ۲})$$

که در آن X_n داده نرمال شده، x داده اولیه، x_{\min} و x_{\max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه می‌باشد. برای پیش‌بینی جریان مصرف انرژی تولید مرغ گوشتی تعداد ۷۰ واحد مرغداری در منطقه مورد مطالعه وارد مدل گردید. نهاده‌های نیروی کارگری، ماشین‌آلات، سوخت، خوراک، الکتریسیته به عنوان ورودی‌ها و انرژی گوشت مرغ و کود بستر به عنوان مقدار مورد انتظار استفاده شد. در طراحی مدل شبکه عصبی مصنوعی، پیش از شروع شبیه‌سازی داده‌ها به دو دسته‌ی داده‌های آموزشی و داده‌های آزمون مدل تقسیم شدند. ۷۰ درصد از داده‌های تحقیق به عنوان داده‌های آموزشی انتخاب و ۳۰ درصد از داده‌ها نیز جهت آزمون مدل مشخص شدند که این داده‌ها در آموزش نقشی نداشتند. برای دستیابی به بهترین پیش‌بینی توسط شبکه، چندین ساختار با استفاده از داده‌های تجربی مورد ارزیابی و آموزش قرار گرفتند.

مدل پرسپترون چندلایه

شبکه‌های پرسپترون چند لایه، قادر به مدل‌سازی مسائل مختلف می‌باشند. در شبکه MLP، مجموع وزنی ورودی‌ها و بایاس‌ها از طریق یک تابع انتقال به سطح فعال منتقل می‌شوند تا خروجی مربوطه را تولید کنند و واحدها در توپولوژی لایه پیش‌خور، قرار می‌گیرند (Venkatesan & Anitha, 2006). یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی مؤلفه‌های شبکه MLP هستند. هر لایه شامل تعدادی از مؤلفه‌ها به نام نرون یا گره است. تمام اتصال‌های بین لایه ورودی و لایه‌های پنهان، ماتریس وزن ورودی و تمام اتصال‌های

$$R^2 = 1 - \left(\frac{\sum_{i=1}^N (z - z')^2}{\sum_{i=1}^N z_i^2} \right) \quad (\text{رابطه ۸})$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (z - z')^2} \quad (\text{رابطه ۹})$$

$$MAE = \frac{1}{N} \sum_{i=1}^N (|z - z'|) \quad (\text{رابطه ۱۰})$$

که در آن z مقدار اندازه‌گیری شده و z' مقدار پیش‌بینی شده و N تعداد کل مشاهدات می‌باشد (Khoshnevisan et al., 2014; Rahman & Bala, 2010).

آنالیز حساسیت

آنالیز حساسیت می‌تواند از طریق شبکه عصبی مصنوعی (SAANN) عمده متغیرهای ورودی را طی تجزیه و تحلیل، رتبه‌بندی کرده و انتخاب کند. آنالیز حساسیت (SA) با مشتق جزئی بر اساس محاسبه‌ای از متغیرهای ورودی، وزن‌ها و متغیرهای خروجی با شبیه‌سازی ANN است. محاسبه حساسیت، S به شرح زیر می‌باشد (Sung, 1998):

$$S = \frac{\partial O}{\partial I} = O' \left(\sum_{j=1}^J w_{ij}^1 H' w_{ij}^2 \right) \quad (\text{رابطه ۱۱})$$

$$S = \frac{\partial f(O)}{\partial X} \sum_{j=1}^J \left(w_{ij}^1 \frac{\partial f(H)}{\partial X} w_{ij}^2 \right) \quad (\text{رابطه ۱۲})$$

که در آن O لایه خروجی و H یک گره پنهان بوده که متمایز شده است، w_{ij}^1 و w_{ij}^2 وزن‌های مربوط به اتصال قبل و بعد از لایه پنهان در شبکه عصبی هستند. اتصال اول برای ورودی و لایه مخفی و اتصال دوم برای گره پنهان و لایه خروجی است (Sung, 1998).

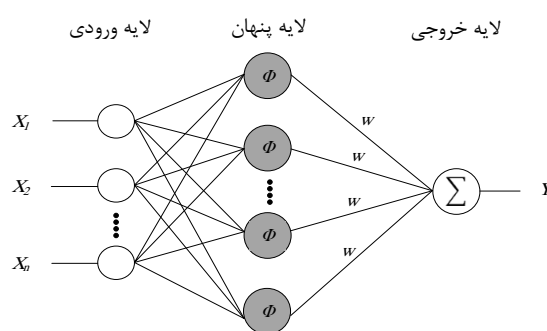
در این مطالعه به منظور پیش‌بینی جریان مصرف انرژی و تعیین درصد تأثیر هر یک از متغیرها در پیش‌بینی انرژی خروجی از نرم‌افزار MATLAB R2013a استفاده شد.

نتایج و بحث

تجزیه و تحلیل انرژی

در تحقیق حاضر، هم‌ارز انرژی نهاده‌ها، ستانده‌ها و انرژی مصرفی معادل در جدول ۱ نمایش داده شده است. نتایج مطالعه نشان می‌دهد که به طور متوسط برای پرورش ۱۰۰۰ قطعه مرغ گوشتی ۱۵۳،۷۹۳ مگاژول انرژی از منابع مختلف مصرف می‌شود. در مقابل متوسط انرژی ستانده برای تولید مرغ گوشتی

در دسترس باشد از عملکرد مطلوب‌تری برخوردار است و با تعداد نرون کافی می‌تواند هر تابع منطقی را تقریب زند. شبکه از سه لایه که شامل لایه ورودی، لایه پنهان با تابع فعال شعاعی غیرخطی و یک لایه خروجی خطی تشکیل شده است (شکل ۱). مهم‌ترین ماهیت شبکه‌های RBF این است که نرون‌های لایه پنهان در میانه تابع پایه فقط دارای واکنش محلی از تابع ورودی بوده و به این دلیل است زمانی که فضای ورودی تنها در یک ناحیه می‌افتد، تابع اولیه می‌تواند پاسخ معنی‌دار غیرصفری را تولید کند، در غیر این صورت، خروجی از توابع پایه کوچک‌تر است (Xianhai, 2011).



شکل ۱- ساختار شبکه عصبی RBF

خروجی شبکه توسط معادله زیر به دست می‌آید:

$$y_k = \sum_{j=1}^M w_{kj} \phi_j(x) + w_{k0} \quad (\text{رابطه ۶})$$

که در آن M تعداد توابع پایه، x بردار داده ورودی، w_{kj} نشان‌دهنده وزن متصل بین تابع پایه و لایه خروجی و w_{k0} تابع غیرخطی واحد am که به طور معمول یک تابع گوسی به صورت زیر می‌باشد:

$$\phi_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (\text{رابطه ۷})$$

که در آن X و μ به ترتیب ورودی و مرکز واحد RBF هستند. σ دامنه تابع پایه گوسی (پارامتر مقیاس) است (Foody, 2004).

برای ارزیابی قابلیت شبکه عصبی پرسپترون چندلایه و تابع پایه شعاعی در پیش‌بینی انرژی‌های خروجی گوشت مرغ و کود بستر از معیارهای ضریب تبیین (R^2) ، جذر میانگین مربعات خطا $(RMSE)$ و میانگین قدرمطلق خطا (MAE) بین مقادیر پیش‌بینی شده و مقادیر واقعی شبکه استفاده شد:

4. Sensitivity Analysis via ANN
5. Sensitivity Analysis

1. Coefficient of determination
2. Root mean square error
3. Mean absolute error


عمید و همکاران: مقایسه عملکرد شبکه‌های عصبی پرسپترون چندلایه ... ۲۲۳

را به خود اختصاص داده است. نتایج حاصل نشان داد که مدیریت مصرف سوخت دیزل و خوراک دام، نهاده‌های مهمی برای بهبود بهره‌وری انرژی در مزارع پرورش مرغ گوشتی به نظر می‌رسد.

برابر ۲۷،۴۴۷ مگاژول برآورد گردیده است. همان‌طور که در شکل ۲ نشان داده شده است سوخت دیزل (۶۱/۴۸ درصد) و خوراک (۳۴/۹۸ درصد) مهم‌ترین عوامل در مصرف انرژی بودند و به دنبال آن برق با ۳/۰۵ درصد بیشترین میزان مصرف انرژی

جدول ۱- ضرایب انرژی و معادل انرژی نهاده‌های مصرف شده و ستانده‌های تولید شده در پرورش مرغ گوشتی

مرجع	کل انرژی معادل (مگاژول بر ۱۰۰۰ قطعه مرغ)	معادل انرژی (مگاژول)	واحد	عنوان
الف) نهاده‌ها:				
(Salehi <i>et al.</i> , 2014)	۱۵۰/۱۲	۱/۹۶	h	نیروی انسانی
	۳۰۴/۲۲			تجهیزات
(Heidari <i>et al.</i> , 2013)		۴۶/۳	kg	پلی اتیلن
(Amid <i>et al.</i> , 2015)		۳۸	kg	گالوانیزه
(Chauhan <i>et al.</i> , 2006)		۶۲/۷	kg	فولاد
(Chauhan <i>et al.</i> , 2006)		۶۴/۸	kg	موتور الکتریکی
(Kitani, 1999)	۹۴۸۵۱/۶۹	۴۷/۸	l	سوخت
	۵۳۷۹۳/۹۸			دان مصرفی
(Atilgan & Hayati, 2006)		۷/۹	kg	ذرت
(Atilgan & Hayati, 2006)		۱۲/۰۶	kg	سویا
(Amid, 2014)		۱۳/۷	kg	گندم
(Alrwis & Francis, 2003)		۱۰	kg	دی کلسیم فسفات
(Berg <i>et al.</i> , 2002)		۹	kg	اسید چرب
(Khoshnevisan <i>et al.</i> , 2014)	۴۶۹۳/۱۷	۱۲	kWh	الکتریسیته
	۱۵۳۷۹/۱۸		MJ	کل انرژی نهاده
ب) ستانده‌ها:				
(Celik & Ozturkcan, 2003)	۲۶۷۶۰/۲۳	۱۰/۳۳	kg	گوشت مرغ
(Heidari <i>et al.</i> , 2011a)	۶۸۷/۰۳	۰/۳	kg	کود بستر
	۲۷۴۴۷/۲۶		MJ	کل انرژی ستانده



شکل ۲- سهم ورودی‌های انرژی در تولید مرغ گوشتی

۲۲۴/۱۱ گیگاژول بر ۱۰،۰۰۰ قطعه مرغ و کل انرژی خروجی ۲۷/۴۶ گیگاژول بر ۱۰،۰۰۰ قطعه مرغ محاسبه شد. نتایج بدست آمده نشان می‌دهد که گازوئیل با ۴۹ درصد بیشترین میزان


در مطالعه مشابه، Heidari *et al.* (2013)، مقدار انرژی مصرفی در مراحل تولید واحدهای مرغ گوشتی در استان یزد را بررسی کردند. کل انرژی مصرف شده در یک دوره پرورش

بررسی مدل شبکه عصبی مصنوعی


به منظور پیش‌بینی میزان عملکرد تولید مرغ گوشتی با توجه به انرژی مصرفی نهاده‌های مختلف برای مرغداران از مدل‌های شبکه عصبی مصنوعی استفاده شد و نتایج به‌دست آمده ارائه شده است. در این مطالعه، یک الگوریتم یادگیری پس‌انتشار به منظور ایجاد مدل‌های پیش‌بینی انتخاب شد. جهت دستیابی به بهترین ساختار شبکه، تعداد مختلفی از ساختارها با یک و دو لایه و با تعداد یک تا ۲۰ نرون در لایه مخفی مورد آموزش و آزمون قرار گرفتند. انرژی‌های ورودی و خروجی‌های مدل انتخاب شدند. نتایج نشان داد که بهترین مدل شامل یک لایه ورودی با پنج پارامتر ورودی، یک لایه پنهان با ۱۴ نرون و یک لایه خروجی با دو پارامتر خروجی (ساختار ۲-۱۴-۵) بدست آمد. شماتیک بهترین ساختار شبکه در شکل ۳ نشان داده شده است.

نمودارهای پراکندگی بین مقادیر پیش‌بینی شده و مقادیر واقعی انرژی‌های خروجی گوشت مرغ و کود بستر مبتنی بر شبکه عصبی MLP به ترتیب در شکل ۴ و ۵ برای داده‌های آموزش و آزمون رسم شده است.

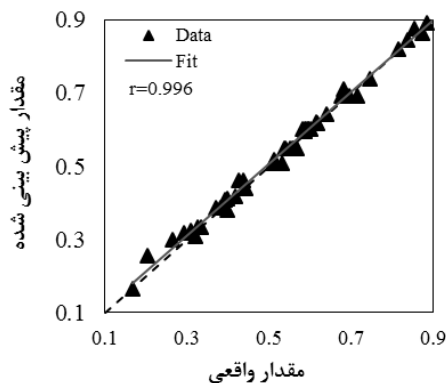
مصرف انرژی را دارد. همچنین، نتایج تحلیل مصرف انرژی برای تولید مرغ گوشتی در استان گیلان نشان داد که سوخت دیزل با ۵۴ درصد و دان مصرفی با ۲۳ درصد از جمله پرمصرف‌ترین نهاده‌ها برای تولید مرغ گوشتی در این منطقه بودند (Nabavi-Pelesaraei et al., 2013). با توجه به مقایسه مطالعات پیشین و مطالعه انجام شده تفاوتی در پرمصرف‌ترین نهاده مصرفی وجود ندارد و تنها تفاوت آن در مقدار عددی و نسبت توزیع انرژی در مناطق مختلف می‌باشد که حاکی از متفاوت بودن شرایط محیطی است. از سوخت برای گرمایش سالن‌ها استفاده می‌شود و با توجه به اینکه جوجه‌ها در یک دوره کوتاه پرورش از وزن تقریبی ۴۷/۵ گرم به وزن تقریبی ۳-۲/۵ کیلوگرم می‌رسند و نیاز به اکسیژن برای رشد لزوم تهویه سالن‌های مرغداری بایستی منجر به ورود هوای سرد خارج از سالن در حین تهویه به داخل سالن می‌گردد. بنابراین تأسیسات حرارتی دائماً در حال گرم کردن سالن بوده و میزان زیادی از انرژی از آن‌ها به خارج از سالن انتقال پیدا می‌کند. بدین جهت مصرف انرژی سوخت دیزل بالاست. با دقت در انتخاب سیستم عایق‌بندی برای جلوگیری از اتلاف گرما می‌توان از مصرف سوخت بیشتر جلوگیری نمود.



شکل ۳- ساختار شبکه MLP در تولید مرغ گوشتی




ب) آزمون




الف) آموزش

شکل ۴- همبستگی بین مقادیر واقعی و مقادیر پیش‌بینی شده انرژی خروجی گوشت مرغ برای داده‌های آموزش (الف) و داده‌های آزمون (ب) مدل MLP



(ب) آزمون




(الف) آموزش


شکل ۵- همبستگی بین مقادیر واقعی و مقایر پیش‌بینی شده انرژی خروجی کود بستر برای داده‌های آموزش (الف) و داده‌های آزمون (ب) مدل MLP

جمع‌کننده می‌شود که خروجی شبکه عصبی می‌باشد. مقدار خطای هدف صفر بوده و شبکه با تعداد ۹ نرون در لایه مخفی به این خطا دست یافته است. نمودارهای پراکندگی انرژی‌های گوشت مرغ و کود بستر پیش‌بینی شده بر اساس مقادیر واقعی مبتنی بر شبکه عصبی RBF به ترتیب در شکل ۶ و ۷ برای داده‌های آموزش و آزمون رسم شده است.

پس از شبکه عصبی از نوع MLP، عملکرد شبکه RBF در پیش‌بینی انرژی‌های خروجی تولید مرغ گوشتی مدل‌سازی شده است. داده‌های ورودی و خروجی برای آموزش شبکه همان اطلاعاتی هستند که در تعمیم شبکه MLP استفاده شد. RBF یک شبکه عصبی تک‌لایه است. به عبارت دیگر، ورودی‌ها به طور مستقیم به نرون‌های لایه پنهان وارد شده و خروجی نرون‌های لایه پنهان پس از ضرب در وزن‌های مربوطه وارد یک

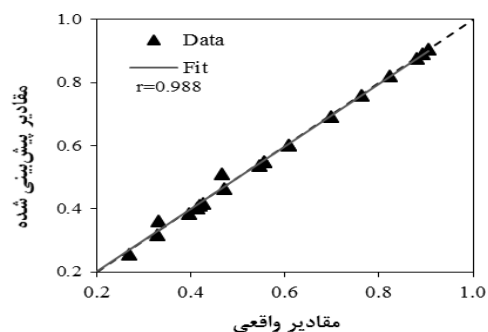


(ب) آزمون




(الف) آموزش

شکل ۶- همبستگی بین مقادیر واقعی و مقایر پیش‌بینی شده انرژی خروجی گوشت مرغ برای داده‌های آموزش (الف) و داده‌های آزمون (ب) مدل RBF



(ب) آزمون



(الف) آموزش

شکل ۷- همبستگی بین مقادیر واقعی و مقایر پیش‌بینی شده انرژی خروجی کود بستر برای داده‌های آموزش (الف) و داده‌های آزمون (ب) مدل RBF

MLP می‌باشد. مقادیر RMSE هر دو شبکه از دقت نسبتاً مناسبی در برآورد انرژی‌های خروجی گوشت مرغ و کود بستر برخوردار بوده و تفاوت چندانی با هم ندارند ولی خطای شبکه RBF کمتر از خطای شبکه MLP می‌باشد. این نتایج نشان می‌دهد که شبکه عصبی RBF قابلیت بالایی برای پیش‌بینی انرژی‌های خروجی تولید مرغ گوشتی دارد.

عملکرد شبکه‌های MLP و RBF برحسب معیارهای R^2 ، RMSE و MAE برای پیش‌بینی انرژی‌های خروجی تولید مرغ گوشتی در دو فاز آموزش و آزمون در جدول ۲ ارائه شده است. همان‌طور که در جدول مشخص است مقادیر R^2 برای داده‌های آموزش و آزمون شبکه عصبی RBF اندکی بیشتر از مقادیر R^2 برای داده‌های استفاده شده در آموزش و آزمون شبکه عصبی

جدول ۲- عملکرد شاخص‌ها برای مدل‌های شبکه عصبی MLP و RBF


نوع شبکه	خروجی	آموزش		آزمون	
		MAE	R^2	MAE	R^2
MLP	گوشت مرغ	۰/۰۱۶	۰/۹۹۴	۰/۵۳۷	۰/۹۲۹
	کود بستر	۰/۰۶۶	۰/۸۷۶	۰/۵۵۶	۰/۹۰۸
RBF	گوشت مرغ	۰/۰۲۴	۰/۹۹۵	۰/۰۱۸	۰/۹۸۲
	کود بستر	۰/۰۲۷	۰/۹۷۸	۰/۰۱۹	۰/۹۷۸

خروج تک به تک هر کدام از پارامترهای ورودی درحالی‌که تغییری در پارامترهای مربوط به الگوهای دیگر وجود ندارد، باعث آموزش مدل‌های MLP و RBF می‌شود. با توجه به نتایج به‌دست آمده در شکل ۸، سهم هر یک از پارامترهای ورودی از مدل‌های MLP و RBF برآزش شده در خروجی‌های مورد نظر (گوشت مرغ و کود بستر) به وضوح دیده می‌شود. با این نوع تحلیل، امکان قضاوت این‌که طی تولید شبکه MLP و RBF مطلوب، کدام پارامتر دارای بیشترین معنی‌داری (با حساسیت نزدیک به یک) و کمترین معنی‌داری (با حساسیت نزدیک به صفر) است، وجود دارد. بر اساس نتایج، سوخت دیزل بالاترین حساسیت را در میان ورودی‌ها برای گوشت مرغ با ۰/۰۵۱ و ۰/۰۴۴ و کود بستر با ۰/۱۰۴ و ۰/۰۴۹ به ترتیب برای مدل‌های MLP و RBF داشتند. این نشان می‌دهد که با استفاده از یک مگاژول انرژی اضافی برای انرژی سوخت دیزل ۰/۰۵۱ و ۰/۰۴۴ مگاژول افزایش در انرژی خروجی گوشت مرغ و ۰/۱۰۴ و ۰/۰۴۹ مگاژول افزایش در انرژی خروجی کود بستر به ترتیب در مدل‌های MLP و RBF نتیجه می‌شود. به دنبال سوخت دیزل، تجهیزات و دان مصرفی بالاترین حساسیت را به خود اختصاص دادند. حساسیت الکتریسیته و نیروی انسانی نسبتاً کم بودند.

در مطالعه‌ای پیرامون مدل‌سازی نسبت هزینه به سود در واحدهای مرغدای گوشتی در استان یزد با استفاده از شبکه عصبی، ساختار بهینه ۱-۲۰-۵ را به عنوان بهترین مدل معرفی نمودند. همچنین در این پژوهش مقادیر ضریب تبیین (R^2)، MSE و MAPE به ترتیب ۰/۹۷۸، ۰/۰۰۲ و ۲/۵۶۹ گزارش شدند (Heidari et al., 2011b). در مطالعه دیگری، یک مدل بر اساس شبکه‌های عصبی مصنوعی به منظور پیش‌بینی انرژی خروجی در طیور برای تولید تخم‌مرغ توسعه داده شد. آن‌ها گزارش دادند که بهترین مدل از یک لایه ورودی با سه متغیر، یک لایه پنهان با سیزده نرون و یک لایه خروجی با یک متغیر خروجی تشکیل شده است. نتایج اعتبارسنجی عملکرد شبکه را با ضریب تبیین بالا برابر با ۰/۹۹۲، حداقل میانگین خطای نسبی برابر با ۰/۰۰۱۷ و متوسط درصد خطای مطلق برابر با ۱/۲۴ درصد نشان داد (Sefeedpari et al., 2012).

آنالیز حساسیت

تجزیه و تحلیل حساسیت با استفاده از بهترین شبکه انتخاب برآزش شده به منظور ارزیابی توانایی پیش‌بینی و اعتبارسنجی هر دو مدل انجام شد (شکل ۸). توان مدل‌ها با بررسی و مقایسه خروجی تولید شده با مقادیر محاسبه شده مشخص گردید.



شکل ۸- نتایج تجزیه و تحلیل حساسیت برای انرژی نهاده‌ها در پیش‌بینی خروجی گوشت مرغ (الف) و کود بستر (ب) برای دو مدل MLP و RBF

نتیجه‌گیری

گردید. در این تحقیق برای نخستین بار شبکه RBF به منظور پیش‌بینی انرژی خروجی تولید محصولات کشاورزی به‌کار گرفته شد. مدل‌های پیش‌بینی با استفاده از روش‌های ذکر شده با پنج ورودی و دو خروجی توسعه داده شدند. نتایج حاصل از مدل برای پیش‌بینی انرژی‌های گوشت مرغ و کود بستر نشان داد که معادلات به‌دست آمده از مدل شبکه عصبی مصنوعی RBF عملکرد پیش‌بینی نسبتاً بالایی دارد. با توجه به تجزیه و تحلیل حساسیت، انرژی‌های سوخت فسیلی و تجهیزات بالاترین حساسیت و الکتریسیته و نیروی انسانی کمترین حساسیت را در فرآیند انرژی تولید گوشت مرغ و کود بستر به خود اختصاص دادند. مقایسه بین دو شبکه نشان داد که مدل شبکه RBF تکنیکی است که می‌تواند به‌طور مؤثر برای مدل‌سازی و پیش‌بینی انرژی‌های ستانده بر اساس انرژی‌های نهاده مورد استفاده قرار گیرد.

سامانه‌های تولید در صنایع زیستی بر مدیریت منابع مختلف انرژی استوار است. استفاده بهینه از انرژی در بخش کشاورزی یکی از نیازهای اساسی برای پایداری محصولات کشاورزی می‌باشد. برآورد دقیق و پیش‌بینی مقدار کل محصول تولید شده در پایان فصل تولید به طرح‌ریزی مناسب برای آینده کمک می‌کند. در سیستم‌های تولیدی ارزیابی ورودی‌های انرژی مصرف شده در طول فصل تولید به دلیل ناسازگاری داده‌ها پیچیده هستند. از آنجایی که محاسبات نرم یک ابزار خوب برای به حداقل رساندن عدم قطعیت در پروژه‌های مدیریت انرژی می‌باشد به بررسی و مدل‌سازی غیرپارامتریک ضریب تبدیل انرژی تولید مرغ‌گوشتی در این مطالعه پرداخته شده است. بدین منظور از دو نوع شبکه عصبی مصنوعی تحت عنوان MLP و RBF برای برآورد انرژی‌های خروجی تولید مرغ‌گوشتی استفاده

REFERENCES

- Alrwis, K.N. & Francis, E. (2003). Technical efficiency of broiler farms in the central region of Saudi Arabia. *Research Bulletin*, 116, 5-34.
- Amid, A. (2014). Assessment of energy efficiency in poultry production units using fuzzy techniques, case study: Ardabil province. M.Sc. dissertation thesis, University of Mohaghegh Ardabili, Iran, (In Farsi).
- Amid, S., Mesri-Gundoshmian, T., Rafiee, S. & Shahgoli, G. (2015). Energy and economic analysis of broiler production under different farm sizes. *Elixir Agriculture*, 78, 29688-29693.
- Anonymous. (2013). Statistics and information of Agricultural Jihad of Ardebil province. Department of Animal Production.
- Atilgan, A. & Hayati, K. (2006). Cultural energy analysis on broilers reared in different capacity poultry houses. *Italian Journal of Animal Science*, 5, 393-400.
- Berg, M.J., Tymoczko, L.J. & Stryer, L. (2002). *Biochemistry* (5th ed). New York: W.H. Freeman.
- Celik, L.O. & Ozturkcan, O. (2003). Effects of dietary supplemental L-carnitine and ascorbic acid on performance, carcass composition and plasma L-carnitine concentration of broiler chicks reared under different temperature. *Archives of Animal Nutrition*, 57(1), 27-38.
- Chauhan, N.S., Mohapatra, P.K.J. & Pandey, K.P. (2006). Improving energy productivity in paddy production through benchmarking: an application of data envelopment analysis. *Energy Conversion and Management*, 47, 1063-1085.
- Cochran, W.G. (1977). *Sampling Techniques*. Third Edition.
- Dawson, C.W. & Wilby, R. (1998). An artificial neural network approach to rainfall-runoff modelling. *Mathematical and Computer Modelling*, 43(1), 47-66.
- Deh Kiani, M.K., Ghobadian, B., Tavakoli, T., Nikbakht, A.M. & Najafi, G. (2010). Application of artificial neural networks for the prediction of performance and exhaust emissions in SI engine using ethanol- gasoline blends. *Energy*, 35, 65-69.
- Foody, G.M. (2004). Supervised image classification by MLP and RBF neural networks with and without an exhaustively defined set of classes. *International Journal of Remote Sensing*, 25(15), 3091-3104.
- Heidari, M.D., Omid M. & Akram, A. (2011a). Energy efficiency and econometric analysis of broiler production farms. *Energy*, 36, 6536-6541.
- Heidari, M.D., Omid, M. & Akram, A. (2011b). Application of Artificial Neural Network for Modeling Benefit to Cost Ratio of Broiler Farms in Tropical Regions of Iran. *Research Journal of Applied Science, Engineering and Technology*, 3(6), 546-552.
- Heidari, M.D., Omid, M. & Akram, A. (2013). An investigation on energy consumption and the effects of number of chicks and ventilation system type on energy efficiency of broiler farms of Yazd province. *Journal of Researches in Mechanics of Agricultural Machinery*, 1(1), 33-39, (In Farsi).
- Khoshevisan, B., Rafiee, S., Omid, M., Mousazadeh, H. (2014). Application of multi-layer adaptive neuro-fuzzy inference system for estimation of greenhouse strawberry yield. *Measurement*, 47, 903-910.
- Khoshevisan, B., Bolandnazar, E., Barak, S., Shamshirband, S., Maghsoudlou, H., Altameem, T.A. & *et al.* (2014). A clustering model based on

- an evolutionary algorithm for better energy use in crop production. *Stochastic Environmental Research and Risk Assessment*.
- Kitani, O. (1999). *CIGR handbook of agricultural, volume 5: Energy and biomass engineering*. ASAE publications, St Joseph, MI.
- Mohammadi, A., Tabatabaefar, S., Shahin, S., Rafiee, S. & Keyhani, A. (2008). Energy use and economical analysis of potato production in Iran a case study: Ardabil province. *Energy Conversion and Management*, 49, 3566–3570.
- Mohammadshirazi, A., Akram, A., Rafiee, S. & Bagheri Kalhor, E. (2015). On the study of energy and cost analyses of orange production in Mazandaran province. *Sustainable Energy Technologies and Assessments*, 10, 22-28.
- Nabavi-Pelesaraei, A., Fallah, A. & Hematian, A. (2013). Relation between energy inputs and yield of broiler production in Guilan province of Iran. In: *The Second International Conference on Agriculture and Natural Resources*, 25-26 Dec, Razi University, Kermanshah, Iran, pp. 109-117.
- Naderloo, L., Alimardani, R., Omid, M., Sarmadian, F., Jvadikia, P., Torabi, M. Y & Alimardani, F. (2012). Application of ANFIS to predict crop yield based on different energy inputs. *Measurement*, 45, 1406–1413.
- Pahlavan, R., Omid, M. & Akram, A. (2012). Energy input-output analysis and application of artificial neural networks for predicting greenhouse basil production. *Energy*, 37, 171–176.
- Rahman, M.M. & Bala, B.K. (2010). Modeling of jute production using artificial neural networks. *Biosystems Engineering*, 105, 350-356.
- Safa, M. & Samarasinghe, S. (2011). Determination and modelling of energy consumption in wheat production using neural networks: A case study in canterbury province, Newzealand. *Energy*, 36, 5140–5147.
- Sajikumar, N. & Thandaveswara, B.S. (1999). A nonlinear rainfall-runoff model using artificial neural networks. *Journal of Hydrology*, 216, 32-55.
- Salehi, M., Ebrahimi, R., Maleki, A. & Ghasemi Mobtaker, H. (2014). An assessment of energy modeling and input costs for greenhouse button mushroom production in Iran. *Journal of Cleaner Production*, 64, 377-383.
- Sefeedpari, P., Rafiee, S. & Akram, A. (2012). Modeling of energy output in poultry for egg production farms using Artificial Neural networks. *Journal of Animal Production Advances*, 2(5), 247–253.
- Shamshirband, S., Khoshnevisan, B., Yousefi, M., Bolandnazar, E., Badrul Anuar, N., Abdul Wahab, A.W. & Rehman Khan, S.U. (2015). A multi-objective evolutionary algorithm for energy management of agricultural systems—A case study in Iran. *Renewable and Sustainable Energy Reviews*, 44, 457-465.
- Sung, A. H. (1998). Ranking importance of input parameters of neural networks. *Expert Systems with Applications*, 15, 405-411.
- Venkatesan, P. & Anitha, S. (2006). Application of a radial basis function neural network for diagnosis of diabetes mellitus. *Current Science*, 91(9), 1195–1199.
- Xianhai, G. (2011). Study of emotion recognition based on electrocardiogram and RBF neural network. *Procedia Engineering*, 15, 2408–2412.
- Yousefi, M., Khoramivafa, M. & Mondani, F. (2014). Integrated evaluation of energy use, greenhouse gas emissions and global warming potential for sugar beet (*Beta vulgaris*) agroecosystems in Iran. *Atmospheric Environment*, 92, 501-505.
- Zhao, Z., Chow, T.L., Rees, H.W., Yang, Q., Xing, Z. & Meng, F.R. (2009). Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*, 65(1), 36–48.