

مقایسه عملکرد شبکه‌های عصبی مصنوعی و شبکه‌های عصبی موجکی در پیش‌بینی درصد شکستگی جو در کمباین برداشت

سید میثم مظلوم‌زاده*، سید ناصر علوی** و مجتبی نوری***

تاریخ وصول مقاله: ۸۶/۵/۲۷، تاریخ پذیرش مقاله: ۸۷/۷/۲۴

چکیده

در این تحقیق، نحوه عملکرد شبکه‌های عصبی موجکی با شبکه‌های عصبی مصنوعی در پیش‌بینی درصد شکستگی دانه‌های جو در کمباین مقایسه شد. شبکه‌های مزبور به صورت تابعی از درجه حرارت هوا، سرعت کوبنده، سرعت پیشروی کمباین، فاصله کوبنده و ضدکوبنده در جلو و عقب واحد کوبنده و درصد رطوبت جو آموزش داده شد. شبکه عصبی موجکی (RASP1) با دقت ۹۰/۲ درصد در پیش‌بینی شکستگی دانه جو به‌عنوان یک جایگزین مناسب برای شبکه‌های عصبی با دقت ۸۸ درصد تعیین شد. نتایج آنالیز حساسیت نشان داد که تأثیر کلیه ورودی‌های شبکه بر شکستگی دانه‌های جو معنی‌دار بوده و بیشترین تأثیر مربوط به سرعت کوبنده و کمترین تأثیر مربوط به درجه حرارت هوا بود. کلمات کلیدی: جو، درصد شکستگی، شبکه‌های عصبی مصنوعی، شبکه‌های عصبی مصنوعی موجکی، کمباین برداشت

* - مربی، دانشکده کشاورزی سراوان، دانشگاه سیستان و بلوچستان، سیستان و بلوچستان - ایران (E-mail: mazlounzadeh@gmail.com)

** - استادیار، گروه مکانیک ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه شهید باهنر کرمان، کرمان - ایران

*** - دانشجوی دکترای مهندسی منابع آب، دانشگاه آزاد اسلامی واحد علوم و تحقیقات، تهران - ایران

مقدمه

استفاده شده است (۵). ساختار شبکه مزبور یک شبکه پرسپترون با ساختار ۱-۴-۶-۱۵ و تابع فعال‌سازی Hyperbolic Tangent بود. برای این منظور، ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد آنها برای ارزیابی شبکه استفاده شد. میانگین مربعات خطای آموزش در مرحله آزمون بین ۰/۲-۰/۱ بود. یک مدل شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد محصولات کشاورزی بررسی و پس از آزمایش مدل‌های گوناگون مشخص شد که تابع فعال‌سازی Sigmoid و ساختار شبکه ۱-۱۰-۶ بهترین عملکرد را دارند (۴). در یک تحقیق، یک مدل شبکه‌های عصبی مصنوعی برای شناسایی گیاهان از علف‌های هرز، برای استفاده در سم‌پاش‌ها بررسی شد (۱۷). سنسورها علف‌های هرز را توسط پردازش تصویر شناسایی می‌کردند. تابع فعال‌سازی Hyperbolic Tangent و ساختار شبکه ۲-۳-۳-۳ دارای بهترین کارایی بودند. از شبکه‌های عصبی مصنوعی برای تشخیص موقعیت گیاهان توسط پردازش سیگنال نیز استفاده شده است (۱۸). از دیگر کاربردهای شبکه عصبی مصنوعی در کشاورزی در سال‌های اخیر، پیش‌بینی مقدار و کیفیت آب سطحی آبریزگاه‌ها، مطالعه توابع کویدن در کمباین برداشت، مقایسه روش‌های آموزشی مختلف برای آموزش شبکه عصبی پرسپترون چند لایه در جهت پیش‌بینی مسیر جریان آب حاصل از بارندگی در حوزه آبریز و پیش‌بینی رطوبت نسبی هوا می‌باشد (۳، ۷، ۱۴ و ۱۶).

شبکه عصبی مصنوعی^۱ که یکی از مباحث هوش مصنوعی می‌باشد، نوعی پردازشگر اطلاعات است که آن را با معرفی درصدی از داده‌های ورودی و خروجی آموزش داده و سپس نحوه عملکرد سیستم در حافظه آن ذخیره می‌شود. سپس از مابقی داده‌ها برای سنجش قدرت یادگیری شبکه و یا به عبارت دیگر سنجش صحت کار شبکه استفاده می‌شود. پس از آموزش شبکه و اطمینان از صحت کار آن، می‌توان از آن برای پیش‌بینی فرآیند موردنظر استفاده نمود. این شبکه‌ها قادر هستند روابط بین ورودی‌ها و خروجی‌ها را به خوبی مشخص نمایند (۱۱).

شبکه‌های عصبی مصنوعی براساس محاسبات روی داده‌های عددی یا مثال‌ها، آموزش داده می‌شوند (۲ و ۱۳). یک ویژگی جالب شبکه‌های عصبی، توانایی آنها در استخراج روابط بین ورودی‌ها و خروجی‌های یک فرآیند، بدون نیاز به شرایط پیچیده فیزیکی است. آنها قادر هستند یک فضای چند بعدی را با فضای دیگری مرتبط کنند، حتی اگر اطلاعات ناقص و دارای خطا باشند. این خصوصیات سبب شده که برای مسایل مربوط به برآورد و پیش‌بینی در کشاورزی و صنعت مناسب باشند. همچنین در مواردی که روابط بین پارامترها غیرخطی است، شبکه‌های عصبی مصنوعی کارایی خوبی دارند (۱۳). نوعی از شبکه‌های عصبی مصنوعی برای پیش‌گویی تلفات و کاهش کیفیت گندم در کمباین برداشت

1 - Artificial Neural Network (ANN)

$$F(nn) = \frac{1}{1 + \exp(-nn)} \quad (۲)$$

در این رابطه، nn پارامتری است که نرون می‌گیرد.

در هر الگوریتم آموزشی، هدف حداقل کردن خطای شبکه است که به صورت رابطه زیر تعریف می‌شود (۳):

$$E = \frac{1}{PN_{outout}} \sum_p^b \sum_{i=1}^{output} (t_i - o_i)^2 \quad (۳)$$

در این فرمول، P تعداد الگوی آموزشی، N تعداد نرون‌های خروجی، o_i مقدار مورد انتظار و t_i مقدار محاسباتی توسط شبکه است. برای این که طی فرآیند آموزش شبکه، خطا کمترین مقدار باشد، ضرایب و مقادیر ثابتی که با آنها جمع می‌شوند و در اصطلاح اریبی نامیده می‌شوند باید به طور متوالی اصلاح شوند. روشی که برای بهینه نمودن ضرایب و اریب‌ها اتخاذ می‌گردد، فرآیند یادگیری نام دارد. فرآیند یادگیری در واقع یک الگوریتم ریاضی پیچیده می‌باشد. هر شبکه برای به وجود آمدن به دو سری داده (شامل سری آموزش و سری آزمون) نیاز دارد. معمولاً در حدود ۷۵-۷۰ درصد داده‌ها برای آموزش و مابقی برای آزمون شبکه به کار می‌روند (۱۵). در طی فرآیند آموزش، میزان یادگیری شبکه توسط توابع هدف مرتباً سنجیده می‌شود و در نهایت شبکه‌ای با کمترین میزان خطا پذیرش می‌شود. توابع هدف مورد استفاده در این مقاله عبارت از

شبکه عصبی مصنوعی

ساختار کلی شبکه‌های عصبی مصنوعی براساس شبکه عصبی انسان طراحی شده و تقریباً قادر به انجام عملیاتی نظیر سیستم‌های عصبی زیستی ولی در اندازه و ابعاد بسیار ابتدایی می‌باشند. یک شبکه عصبی مصنوعی (به اختصار شبکه عصبی) یک سیستم پردازش اطلاعات است که دارای کارایی و خواص شبکه مغز انسان می‌باشد (۱۲). ساختار یک شبکه عصبی مصنوعی چند لایه پرسپترون^۱ دارای چند لایه بوده و هر لایه از تعدادی نرون تشکیل شده است (شکل ۱).

در این شکل، x_i ، w_{ij} ، $f(\cdot)$ ، v_i و $y_{1...M}$ به ترتیب عبارت از ورودی شبکه، ضریب i ام لایه j ام، تابع تحریک، خروجی مشاهداتی و خروجی محاسباتی اول تا m ام می‌باشد.

ارتباط درون ساختمان شبکه توسط ماتریس ضرایب (w_i) برقرار می‌شود. ورودی خالص هر نرون تابعی از ماتریس ضرایب و اطلاعات دریافتی آن نرون (x_i) می‌باشد و از رابطه ۱ محاسبه می‌شود (۴).

$$nn = \sum_{i=1}^n w_i x_i + \theta \quad (۱)$$

در این فرمول، θ ضریب اریبی^۲ و خروجی هر نرون $F(nn)$ با استفاده از تابع Sigmoid توسط رابطه (۲) محاسبه می‌شود.

1 - Multi Layer Perceptron (MLP)

2 - Bias

جذر میانگین مربعات خطا^۱ و ضریب همبستگی^۲ می‌باشد که به صورت ذیل تعریف می‌شوند:

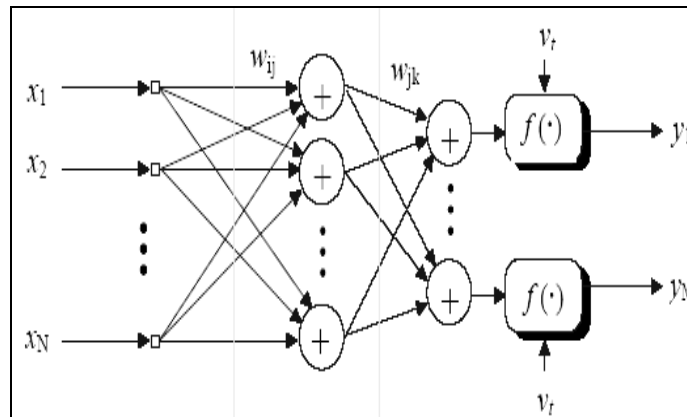
$$RMSE = \sqrt{\frac{1}{n} \sum (A_i - \tilde{A}_i)^2} \quad (۴)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (A_i - \tilde{A}_i)^2}{\sum_{i=1}^n (A_i - \bar{A}_i)^2} \quad (۵)$$

در فرمول‌های ۴ و ۵، متغیر A_i عبارت از iامین داده واقعی، \bar{A}_i میانگین داده‌های واقعی و \tilde{A}_i نیز iامین داده برآورد شده است.

3 - Root of Mean Square Error (RMSE)

4 - Root Square (R^2)



لایه خروجی (Output layer) لایه میانی (Middle layer) لایه ورودی (Input layer)

شکل ۱ - ساختار شبکه عصبی مصنوعی

Fig. 1 . Structure of artificial neural network (ANN)

الگوریتم‌های موجود در ساختار شبکه عصبی کاهش می‌دهد. هر واحد لایه مخفی با وجود یک موجک در ساختار خود به عنوان تابع تحریک که یک پنجره مربعی زمان در ساختار خود دارد با تغییر در مقادیر پنجره نسبت به استفاده از قانون بهینه‌سازی اقدام می‌نماید و با تغییر در موقعیت مکانی و زمانی به فشرده و یا باز شدن موجک اقدام می‌نماید. بنابراین شبکه از توابع با موقعیت-های مکانی و زمانی مختلف روبرو بوده و احتمال رسیدن به جواب مطلوب افزایش می‌یابد (۶) و (۱۵).

در شبکه عصبی - موجکی هر سیگنال مطلوب $\hat{y}(t)$ با ترکیب موجک‌های دختر^۲ مختلف $h_{a,b}(t)$ از موجک‌های مادر^۳ حاصل

شبکه عصبی مصنوعی موجکی^۱

ترکیب موجک و شبکه عصبی مصنوعی، الگوی جدیدی از هوش مصنوعی با نام شبکه عصبی - موجکی را تشکیل می‌دهد که می‌تواند جایگزین مناسبی برای شبکه‌های عصبی انتشار برگشتی باشد که تقریباً می‌تواند از هر تابع غیرخطی موردنظر استفاده نماید (۸ و ۱۹). الگوریتم این شبکه از دو فرآیند اساسی شامل خود ساماندهی شبکه و کاهش خطا تشکیل شده است. در فرآیند اول ساختار شبکه با استفاده از موجک به عنوان تابع تحریک تعیین می‌شود. شبکه به تدریج با تعیین مقدار مناسب واحدهای مخفی خود با در نظر گرفتن ورودی و خروجی (هدف) به طور هم‌زمان، پارامترهای شبکه را تجدید کرده و ساختار شبکه را حفظ نموده و فرآیند بعدی را طی می‌نماید. در فرآیند دوم برآوردکننده شبکه، خطای شبیه سازی را بر مبنای

1 - Daughter Wavelets

2 - Mother Wavelets

1. Wavelet Neural Network (WNN)

در نتیجه ضرایب و پارامترهای شبکه تجدید می‌شوند.

$$\frac{\partial E}{\partial w_k} = -\sum_{t=1}^T e(t)h(\tau)u(t) \quad (10)$$

$$\frac{\partial E}{\partial b_k} = -\sum_{t=1}^T e(t)u(t)w_k \frac{\partial h(\tau)}{\partial b_k} \quad (11)$$

$$\frac{\partial E}{\partial a_k} = -\sum_{t=1}^T e(t)u(t)w_k \tau \frac{\partial h(\tau)}{\partial b_k} = \tau \frac{\partial E}{\partial b_k} \quad (12)$$

در این فرمول‌ها $\tau = \frac{t-b_k}{a_k}$ می‌باشد. تغییرات افزاینده ضرایب از رابطه ۱۳ محاسبه می‌شود:

$$\Delta w = -\frac{\partial E}{\partial w} \Delta a = -\frac{\partial E}{\partial a} \Delta b = -\frac{\partial E}{\partial b} \Delta b \quad (13)$$

در نهایت ضرایب شبکه براساس روابط ۱۴-۱۵ تجدید می‌شوند.

$$\underline{w}(n+1) = \underline{w}(n) + \mu_w \Delta w \quad (14)$$

$$\underline{b}(n+1) = \underline{b}(n) + \mu_b \Delta b \quad (15)$$

$$\underline{a}(n+1) = \underline{a}(n) + \mu_a \Delta a \quad (16)$$

از موجک‌های $h(\tau)$ و مشتق‌های آن‌ها می‌توان استفاده نمود (جدول ۱).

می‌شود که $h_{a,b}(t)$ با عوامل تأخیر (a) و انتقال (b) حاصل می‌شود (شکل ۲).

$$h\left(\frac{t-b}{a}\right) = h_{a,b}(t) \quad (6)$$

در شکل ۲، متغیرهای $u(t)$ ، $\hat{y}(t)$ ، ورودی مدل، خروجی محاسباتی، تابع موجک، ورودی، پارامتر تأخیر و پارامتر انتقال می‌باشد.

مقدار عددی عامل تأخیر همواره مثبت است ($a > 0$) و رابطه برآوردکننده به صورت رابطه (۷) است:


$$\hat{y}(t) = u(t) \sum_{k=1}^k w_k h_{ax,bx}(t) \quad (7)$$

در رابطه ۷، متغیر k شماره پنجره موجک و w_k نیز ضرایب می‌باشند. سپس در فرآیند حداقل کردن خطا، پارامترهای شبکه یعنی w_k, a_x, b_x طبق فرآیند الگوریتم‌هایی مانند LMS^۱ در تمام مراحل حساب شده و با توجه به رابطه ۸ مقدار خطا محاسبه شده و بهینه می‌شود. در نهایت تابع خطا با استفاده از آن رابطه به صورت پلکانی کاهش می‌یابد.

$$e(t) = y(t) - \hat{y}(t) \quad (8)$$

$$E = \frac{1}{2} \sum_{t=1}^T e^2(t) \quad (9)$$

در این فرمول، E و گرادینان‌های ۱۰-۱۲ در هر مرحله تجدید می‌شوند و



شکل ۲ - ساختار شبکه عصبی موجکی

Fig. 2 . Structure of wavelet neural network (WNN)

جدول ۱ - موجک‌های پیشنهادی برای کاربرد در شبکه عصبی موجکی

Table 1 - Proposed wavelets for the application in WNN

Name	$h(\tau)$	$\frac{\partial h(\tau)}{\partial b}$
Morlet	$\cos(\omega_0 \tau) \exp(-0.5\tau^2)$	$\frac{1}{a} [\omega_0 \sin(\omega_0 \tau) \exp(-0.5\tau^2) + \tau h(\tau)]$
RASP1	$\frac{\tau}{(\tau^2 + 1)^2}$	$\frac{1}{a} \frac{(3\tau^2 - 1)}{(\tau^2 + 1)^3}$
RASP2	$\frac{\tau \cos(\tau)}{\tau^2 + 1}$	$\frac{\tau \left(\frac{\tau^2 + 1}{a} \sin(\tau) + \left(\frac{\tau^2 - 1}{a} \right) \cos(\tau) \right)}{(\tau^2 + 1)^2}$
RASP3	$\frac{\sin(\pi\tau)}{\tau^2 - 1}$	$\frac{\left(\frac{2\tau}{a} \right) \sin(\pi\tau) - \pi \left(\frac{\tau^2 - 1}{a} \right) \cos(\pi\tau)}{(\tau^2 - 1)^2}$
SLOG1	$\frac{1}{1 + e^{-\tau+1}} - \frac{1}{1 + e^{-\tau+3}}$ $-\frac{1}{1 + e^{-\tau-3}} + \frac{1}{1 + e^{-\tau-1}}$	$\frac{1}{a} \left[-\frac{e^{-\tau+1}}{(1 + e^{-\tau+1})^2} + \frac{e^{-\tau+3}}{(1 + e^{-\tau+3})^2} \right.$ $\left. + \frac{e^{-\tau-3}}{(1 + e^{-\tau-3})^2} - \frac{e^{-\tau-1}}{(1 + e^{-\tau-1})^2} \right]$
SLOG2	$\frac{3}{1 + e^{-\tau-1}} - \frac{3}{1 + e^{-\tau+1}}$ $-\frac{1}{1 + e^{-\tau-3}} + \frac{1}{1 + e^{-\tau+3}}$	$\frac{1}{a} \left[-\frac{3e^{-\tau-1}}{(1 + e^{-\tau-1})^2} + \frac{3e^{-\tau+1}}{(1 + e^{-\tau+1})^2} \right.$ $\left. + \frac{e^{-\tau-3}}{(1 + e^{-\tau-3})^2} - \frac{e^{-\tau+3}}{(1 + e^{-\tau+3})^2} \right]$
POLYWOG1	$\tau \exp\left(-\frac{\tau^2}{2}\right)$	$\frac{1}{a} (\tau^2 - 1) \exp\left(-\frac{\tau^2}{2}\right)$
POLYWOG2	$(\tau^3 - 3\tau) \exp\left(-\frac{\tau^2}{2}\right)$	$\frac{1}{a} (\tau^4 - 6\tau^2 + 3) \exp\left(-\frac{\tau^2}{2}\right)$
POLYWOG3	$(\tau^4 - 6\tau^2 + 3) \exp\left(-\frac{\tau^2}{2}\right)$	$\frac{1}{a} (\tau^5 - 10\tau^3 + 15\tau) \exp\left(-\frac{\tau^2}{2}\right)$
POLYWOG4	$(1 - \tau^2) \exp\left(-\frac{\tau^2}{2}\right)$	$\frac{1}{a} (3\tau - \tau^3) \exp\left(-\frac{\tau^2}{2}\right)$
POLYWOG5	$(3\tau^2 - \tau^4) \exp\left(-\frac{\tau^2}{2}\right)$	$\frac{1}{a} (-\tau^5 + 7\tau^3 - 6\tau) \exp\left(-\frac{\tau^2}{2}\right)$
Shannon	$\frac{\sin 2\pi\tau - \sin \pi\tau}{\pi\tau}$	$\frac{\pi}{a} \frac{(-\pi\tau \cos \pi\tau - 2\pi \cos 2\pi\tau + \sin \pi\tau + \sin 2\pi\tau)}{(\pi\tau)^2}$

مواد و روشها

شکستگی از تقسیم وزن دانه‌های خرد شده در هر نمونه به وزن کل نمونه محاسبه شد. متغیرهای مستقل شامل فاصله کوبنده و ضدکوبنده در جلوی واحد کوبنده، فاصله کوبنده و ضدکوبنده در عقب واحد کوبنده و سرعت پیشروی باتوجه به دفترچه راهنمای تنظیمات کمباین جان‌دیر ۳۹۹ در محدوده‌های مجاز برای جو در طی زمان برداشت تغییر داده شد (جدول ۲). به‌عنوان مثال، فاصله کوبنده و ضدکوبنده در جلوی واحد کوبنده در مدت زمان برداشت در بازه ۱۲ تا ۱۶ میلی‌متر تغییر داده شد. ایجاد تغییرات مختلف با یکدیگر کاملاً انتخابی و تصادفی بود تا شبکه تحت شرایطی که ممکن است برای هر کمباین پیش آید آموزش داده شود. برای تعیین درصد رطوبت جو، نمونه‌های برداشت شده از مخزن کمباین توزین و در آون الکتریکی با 130°C به مدت ۲۰ ساعت (ASAE S352.1) نگهداری و سپس توزین شد. با استفاده از فرمول ۱۷ درصد رطوبت براساس وزن تر تعیین گردید (۵). نتایج در جدول ۲ ارایه شده است.

$$M_w = \frac{W_w}{W_t} \times 100 \quad (17)$$

در معادله ۱۷ متغیرهای W_t ، W_w و M_w به ترتیب عبارت از وزن تر محصول (گرم)، مقدار رطوبت (گرم) و درصد رطوبت براساس وزن تر است.

آزمایش‌های این تحقیق، در مزارع جو دانشگاه شهید باهنر کرمان انجام شد. از تاریخ ۱۷ تیر تا چهار مرداد، برداشت جو مزارع توسط یک عدد کمباین جان‌دیر ۳۹۹ انجام شد. به سبب بارندگی شدید در اواخر تیر و کار نامرتب کمباین، مدت زمان برداشت افزایش یافت. پارامترهای مورد اندازه‌گیری در مدت برداشت جو شامل میانگین درجه حرارت هوا، سرعت کوبنده، فاصله کوبنده و ضدکوبنده در جلوی واحد کوبنده، فاصله کوبنده و ضدکوبنده در عقب واحد کوبنده، درصد رطوبت جو براساس وزن تر، سرعت پیشروی کمباین و درصد شکستگی جو بود. تغییرات در فاصله کوبنده و ضدکوبنده، همچنین سرعت کوبنده و سرعت حرکت کمباین در طول یک روز در سه آزمایش مستقل انجام و داده‌های حاصل ثبت شد. امکان انجام آزمایش بیش از سه نوبت در روز برای افزایش تعداد داده نیز میسر بود، اما به دلیل تأثیر پارامترهای درجه حرارت هوا و رطوبت جو در شکستگی و عدم تغییر محسوس این دو در یک روز، اندازه‌گیری‌ها در طی ۱۵ روز برداشت و به طور کاملاً تصادفی انجام شد. بعد از انجام تنظیمات و شروع کار کمباین، برای هر نمونه در پنج تکرار ۳۰ گرم جو با استفاده از استاندارد ASAE S352.1 (۳۰ گرم جو تقریباً برابر با ۱۰۰۰ دانه) با تفاوت زمانی یک دقیقه از مخزن برداشت شده و در کیسه پلاستیکی قرار داده شد تا میانگین درصد شکستگی تعیین شود (۱). درصد

جدول ۲ - عوامل مؤثر در شکستگی جو در آزمایش اول

Table 2 - Effective factors on barely breakage in first experiment

متغیر وابسته Dependent variable	سرعت پیشروی (km/h) Combine movement speed	رطوبت جو (درصد) Barely moisture (%)	فاصله کوبنده و ضد کوبنده در عقب (میلی متر) Distance between thresher cylinder and concave in back (mm)	فاصله کوبنده و ضد کوبنده در جلو (میلی متر) Distance between thresher cylinder and concave in front (mm)	سرعت کوبنده (rpm) Thresher cylinder speed	میانگین درجه حرارت هوا Average of air temperature (°C)	تاریخ Date
محدوده قابل قبول Acceptable range	5-10	13-20	10-14	12-16	700-1200	برحسب شرایط جوی Based on atmosphere conditions	
7	7.0	21	8	14	820	29	84.3.17
6	7.5	22	7	13	780	30	84.3.18
5	8.0	20	9	15	850	31	84.3.19
9	8.5	19	6	12	890	33	84.3.20
4	9.0	19	10	16	910	31	84.3.21
4	8.5	18	8	14	930	34	84.3.22
6	8.0	19	7	13	920	31	84.3.23
5	7.5	17	9	15	940	32	84.3.24
12	7.0	15	6	12	980	34	84.3.25
6	6.5	16	10	16	1020	35	84.3.26
5	6.0	16	8	14	1060	32	84.3.27
13	7.0	18	7	13	960	34	84.4.1
6	7.5	17	9	15	950	32	84.4.2
17	8.0	15	6	12	930	34	84.4.3
9	9.0	15	10	16	880	34	84.4.4

تغییر در الگوهای آموزش می تواند سبب بهبود نتایج شبکه عصبی مصنوعی شود (۹).

$$X_N = \frac{X_{MAX} - X_i}{X_{MAX} - X_{MIN}} \quad (18)$$

در فرمول ۱۸، متغیر X_N عبارت از داده نرمال شده، X_{MAX} داده حداکثر، X_i داده مورد نظر و X_{MIN} حداقل داده ها می باشد.

آماده کردن داده ها

به منظور افزایش دقت شبکه و برآورد دقیق و افزایش سرعت همگرایی در شبکه ها، برای آموزش و آزمون شبکه از رابطه ۱۸ با نرمال سازی داده ها و تقسیم کردن آن ها به دو سری ۸۰ و ۲۰ درصد (به ترتیب برای آموزش و آزمون شبکه پیشخور انتشار برگشتی^۱) استفاده شد (۱۵). به طور کلی روش هایی نظیر نرمال کردن داده ها و

1 - Feed-Forward Backpropagation Network

آموزش شبکه عصبی

هدف از آموزش شبکه، دستیابی به شبکه‌ای است که بتواند روابط بین ورودی‌ها و خروجی‌های شبکه را فراگیری نماید. چون قوانین خاصی برای طراحی شبکه‌های عصبی موجود نیست، چندین ساختار بررسی شد. الگوهای موجود به دو گروه تقسیم شده و از ۸۰ درصد داده‌ها برای آموزش شبکه و ۲۰ درصد داده‌ها برای صحت آزمون شبکه استفاده شد. آنالیز حساسیت برای بررسی تأثیر ورودی‌ها بر خروجی‌ها انجام شد. تعداد چرخه‌های آموزش^۱ با ۱۵۰۰ واحد بهترین نتایج را داشت و ترکیبات مختلفی از ورودی‌ها ارزیابی گردید (آنالیز حساسیت) (جدول ۳). همچنین تعداد واحدهای پردازشگر، تعداد لایه‌های مخفی و نوع تابع تحریک نیز بررسی شد. از موجک‌های گوناگون برای جایگزینی کردن با توابع تحریک استفاده شد. برای آموزش از الگوریتم‌های LM^۲ و SCG^۳ استفاده شد. در الگوریتم LM، در صورت یکسان بودن طول ماتریس‌ها پارامتر mem_reduc قادر به محاسبه ماتریس‌های ورودی می‌باشد. از سوی دیگر هم‌گرایی الگوریتم LM زیاد است و باعث افزایش دقت الگوریتم می‌گردد. الگوریتم SCG بر مبنای قاعده شیب کاهنده عمل می‌نماید و شامل پارامترهای خاصی می‌شود که از آن جمله می‌توان ضریب مومنتوم^۴ و میزان یادگیری^۵ را نام برد. علی‌رغم این‌که سرعت آموزش این الگوریتم

کمتر از سایر الگوریتم‌هاست در بسیاری از شبکه‌ها یک گزینه مناسب می‌باشد. در این تحقیق، چون الگوریتم LM نتایج بهتری ارائه می‌کرد به‌عنوان الگوریتم آموزشی انتخاب شد. طی فرآیند آموزش شبکه، ضرایب و مقادیر ثابتی که با آنها جمع می‌شود و در اصطلاح اریب^۶ نامیده می‌شوند، به طور متوالی تغییر کرد تا این‌که خطا به کمترین مقدار خود برسد.

طراحی شبکه‌های عصبی مصنوعی و موجکی این مطالعه در محیط نرم‌افزار Matlab انجام شد. وجود جعبه ابزارهای ANN و Wavelet در این نرم‌افزار استفاده از آن را در سطح دنیا رونق داده است (۱۰ و ۱۱).

آنالیز حساسیت

به‌منظور بررسی تأثیر هر یک از پارامترها آنالیز حساسیت انجام گرفت. لذا داده‌ها بر روی بهترین شبکه عصبی یک به یک حذف و تأثیر هر کدام از آنها بر نتایج بررسی شد (۱۵).

نتایج

نتایج آنالیز حساسیت نشان داد که تأثیر کلیه ورودی‌های شبکه (شامل، میانگین درجه حرارت هوا در مدت زمان برداشت، سرعت کوبنده، فاصله کوبنده و ضدکوبنده در جلوی واحد کوبنده، فاصله کوبنده و ضدکوبنده در عقب واحد کوبنده، سرعت پیشروی کمباین و درصد رطوبت جو براساس وزن تر) بر درصد شکستگی دانه‌های جو معنی‌دار است. بیشترین تأثیر مربوط به سرعت کوبنده و کمترین تأثیر مربوط به درجه حرارت هوا بود. با افزایش نرون‌ها در لایه‌های

- 1 - Epochs
- 2 - Levenberg Marquardt
- 3 - Scaled Conjugate Gradient
- 4 - Momentum Coefficient
- 5 - Learning Rate

6 - Bias

لایه مخفی اول، شش نرون در لایه مخفی دوم و هفت نرون در لایه مخفی سوم) به عنوان لایه‌های پنهان شبکه و با ساختار نرونی ۱-۶-۶-۶، مناسب‌ترین حالت بود.

میانی، دقت آموزش شبکه به دلیل افزایش زمان ضعیف می‌شد. تعداد لایه‌های پنهان از یک تا هفت در ساختار آموزشی شبکه ارزیابی شد. با افزایش لایه‌ها میزان خطا به دلیل پیچیدگی ساختار شبکه افزایش یافت. تعداد سه لایه (شش نرون در

جدول ۳ - نتایج آنالیز حساسیت

Table 3 - Results of Sensitivity Analysis

RMSE	پارامتر حذف شده Omitted parameter	
0.005	میانگین درجه حرارت هوا (°C) Average of air temperature (°C)	1
0.090	سرعت کوبنده (rpm) Thresher cylinder speed (rpm)	2
0.0810	فاصله کوبنده و ضدکوبنده در جلو (mm) Distance between thresher cylinder and concave in front (mm)	3
0.078	فاصله کوبنده و ضدکوبنده در عقب (mm) Distance between thresher cylinder and concave in back (mm)	4
0.062	رطوبت جو براساس وزن تر (%) Barely moisture (%)	5
0.073	سرعت پیشروی (km/h) Combine movement speed (km/h)	6

تکرار به جز در بخشی از تکرارهای اولیه که دارای نوسان بود، میزان RMSE کاهش یافت. در این مرحله با توجه به بهترین ضرایب حاصل از مرحله آموزش شبکه، داده‌های آموزش و داده‌های آزمون ارزیابی شد. در جداول ۴ و ۵ تغییرات مشاهده‌ای برآورد حاصل از شبکه ایجاد شده در دو مرحله آموزش و آزمون ارائه شده است.

در ساختار شبکه عصبی برای آموزش شبکه میزان گشتاور از ۰/۱ تا ۰/۹ تغییر داده شد. مناسب‌ترین آموزش با الگوریتم آموزش LM و تابع تحریک Logsig^۱ در میزان گشتاور ۰/۸ حاصل شد و در نهایت مناسب‌ترین شبکه با ساختار ۱-۶-۶-۶ انتخاب شد. با افزایش میزان

1 - Log sigmoid transfer function (Logsig)

جدول ۴ - نتایج مشاهداتی و محاسباتی حاصل از شبکه‌های عصبی مصنوعی و شبکه‌های عصبی موجکی

Table 4 - Results of observed and predicted data obtained from the ANN model and WNN model

نتایج محاسباتی: شبکه عصبی موجکی (SHANNON)	نتایج محاسباتی: شبکه عصبی موجکی (RASP 1)	نتایج محاسباتی: شبکه عصبی موجکی (POLYWOG 2)	نتایج محاسباتی: شبکه عصبی مصنوعی Predicted results (ANN)	داده‌های مشاهداتی (درصد شکستگی) Observed data (Breakage percentage)
Predicted results (WNN)	Predicted results (WNN)	Predicted results (WNN)		
16.236	22.241	19.653	22.853	21
10.361	11.483	11.412	11.249	13
7.985	12.755	9.526	9.678	11
9.562	17.128	26.912	16.181	18
70.680	90.180	79.610	88	پیش‌بینی درصد شکستگی Prediction of breakage percentage

جدول ۵ - نتایج حاصل از شبکه عصبی موجکی

Table 5 - Results obtained from the WNN

RMSE		R ²		ضریب انتقال b	ضریب تأخیر a	ساختار نرونی	نوع موجک wavelet type
آزمون	آموزش	آزمون	آموزش	Transmission	Dilation	Neural	
Test	Train	Test	Train	b	a	structure	
0.052	0.0004	0.943	0.9984	0.20	1		
0.072	0.0004	0.941	0.9985	2.50	1	5-6-7-1	POLYWOG2
0.078	0.0004	0.945	0.9983	10	1		
0.053	0.0004	0.957	0.9700	0.20	1		
0.046	0.0004	0.955	0.9700	2.50	1	5-6-7-1	RASP1
0.068	0.0004	0.945	0.9600	10	1		
1.550	0.0014	0.910	0.9740	0.20	1		SHANNON
1.860	0.0019	0.930	0.9830	2.50	1	5-6-7-1	
2.560	0.0019	0.910	0.9830	10	1		

لایه چهارم) حاصل شد. از موجک‌های مختلف با ضرایب متنوع تأخیر و انتقال استفاده شد (جدول ۵). موجک SHANON نتایج قابل قبول نداشت و برای جایگزینی مناسب نبود. موجک RASPI بهترین نتایج را داشت که ضریب انتقال ۲/۵ و ضریب تأخیر یک، نسبت به سایر انتخاب‌ها موفق‌تر بود. البته در هنگام تعویض توابع محرک با موجک‌ها مشتق‌های آنها نیز باید تعویض شود. استفاده از موجک به‌عنوان تابع تحریک در ساختار شبکه عصبی موجکی موجب بهبود نسبی نتایج گردید.

در این تحقیق، کارایی مدلی از شبکه‌های عصبی با نام پیش‌خور انتشار برگشتی و شبکه عصبی موجکی برای برآورد درصد شکستگی جو بررسی شد. اطلاعات میانگین درجه حرارت هوا در زمان برداشت، سرعت کوبنده، فاصله کوبنده و ضدکوبنده در جلو و عقب واحد کوبنده، سرعت پیشروی کمباین و درصد رطوبت جو به‌عنوان ورودی و درصد شکستگی جو به‌عنوان خروجی شبکه در نظر گرفته شد. بهترین شبکه در ساختار ۱-۶-۷-۶ (شش نرون در لایه اول، شش نرون در لایه دوم، هفت نرون در لایه سوم و یک نرون در

جدول ۶ - مقایسه نتایج شبکه‌های ANN و WNN

Table 6 - Comparison of the results between the ANN and the WNN

RMSE		R ²		ضریب انتقال b	ضریب تأخیر a	ساختار نرونی	نوع شبکه
آزمون	آموزش	آزمون	آموزش	Transmission	Dilation	Neural	Network type
Test	Train	Test	Train	b	a	structure	
0.0004	0.046	0.955	0.970	2.5	1	6-6-7-1	(RASPI) WNN
0.0009	0.160	0.923	0.970	-	-	6-6-7-1	ANN

همبستگی و کاهش میزان خطای داده‌های محاسباتی به مشاهداتی، موفقیت آمیز بود. بعد از استفاده از الگوریتم‌های آموزشی مختلف در فاز آموزش، مشخص گردید که نتایج الگوریتم SCG و LM نسبت به سایر روشها بهتر است.

درضمن، به مقداری که ضریب مربوط به انتقال کوچکتر بود، نتایج حاصل بهتر بود. البته این امر یک قانون کلی نبوده و موارد متفاوت نیز (در بهینه‌سازی سازه‌های فضاکار) مشاهده گردیده است (۱۵). استفاده هم‌زمان شبکه‌های عصبی مصنوعی و تبدیل موجک در افزایش ضریب

بحث

نتایج نشان داد که ضریب همبستگی در مرحله آزمون مدل‌ها از ۰/۹۲ به ۰/۹۵ افزایش پیدا کرده و RMSE از ۰/۱۶ به ۰/۰۶۶ کاهش پیدا کرده است. این نکته افزایش دقت شبکه عصبی - موجکی نسبت به شبکه عصبی مصنوعی را نشان می‌دهد. شبکه‌های عصبی مصنوعی و موجکی قادر هستند که یک فضای چندگانه را حتی در صورت ناقص بودن اطلاعات تطبیق دهند (۷). لذا با تعداد ورودی‌های کمتر ولی داده‌های بیشتر نیز می‌توان شبکه را به خوبی برای پیش‌بینی تربیت نمود و در مورد پیش‌بینی شکستگی جو که شش ورودی در نظر گرفته شد نیز این امر صادق است.

باتوجه به عملکرد شبکه و نیز مقایسه نتایج حاصل با نتایج مشاهداتی شبکه عصبی موجکی می‌تواند یک جایگزین خوب برای شبکه عصبی مصنوعی در پیش‌بینی درصد شکستگی غلات باشد (جدول ۶). البته برای پیش‌بینی درصد شکستگی گندم از ۱۶ ورودی در یک کمباین پیشرفته نیز استفاده شده است (۵). استفاده از ۱۶ ورودی نتایج دقیق‌تری در پیش‌بینی شکستگی جو و یا گندم دارد. ولی برای بیشتر کمباین‌های موجود در داخل کشور تعیین کلیه پارامترها ممکن نبوده و به سنسورهای مخصوص نیاز است که کلیه این موارد در کمباین‌های پیشرفته تعیین می‌گردند.

References

- 1 . ASAE (2002) ASAE Standard S352.1: Moisture Measurement-Grain and Seeds. American Society of Agricultural Engineers, St. Joseph, MI.
- 2 . Beal R and Jackson T (1998) Neural Computing: an Introduction, Institute of Physics Publishing.
- 3 . Białobrzewski (2008) Neural modeling of relative air humidity. Computers and Electronics in Agriculture 60: 1-7.
- 4 . Drummond ST, Suddeth KA and Birrell SJ (1995) Analysis and Correlation Methods for Spatial Data. ASAE Paper 95-1335. ASAE, 2950 Niles Rd., St. Joseph, MI 49085-9659.
- 5 . Hall JW (1992) Emulating Human Process Control Functions with Neural Networks. Unpublished Ph.D. Dissertation. Department of Mechanical Engineering. University of Illinois, Urbana Illinois.
- 6 . Iyama J and Kuwamura H (1999) Application of wavelet to analysis and simulations of earthquake motions," Earth Eng. Struct Dyn 28: 255-272.
- 7 . Kim M, Chung J and Kim C (2005) Artificial neural network approach for predicting surface water quality and quantity. Proceedings of the third Conference, 5-9 March. Atlanta.

- 8 . Lekutai G (1997) Adaptive self-tuning neuro wavelet network controllers. Ph.D. thesis, Virginia.
- 9 . Malik N (2005) Artificial Neural Networks and Their Applications. National Conference on 'Unearthing Technological Developments and their Transfer for Serving Masses'. GLA ITM, Mathura, India 17-18 April.
- 10 . Mathworks (1999) MATLAB manual network toolbox user's guide.
- 11 . Matlab Software, Wavelet Toolbox, Help
- 12 . Menhaj MB (1998) Application of Intelligence Computation in Control. Amir Kabir Industrial University Center of Publication. Number 2.
- 13 . Menhaj MB (2000) Foundation of Artificial Neural Networks. Amir Kabir Industrial University Press, Tehran.
- 14 . Miyamoto M and Murase H (2003) Study of threshing function of combine harvester with artificial neural network. ASAE Annual Meeting St. Joseph, Michigan, www.asae.org .
- 15 . Nouri M (2006) Rainfall runoff modeling with neural wavelet network, case study: Halil River and Ghazan river basin. M.Sc. Project, Shahid Bahonar University of Kerman, Kerman, Iran.
- 16 . Sanaga SA and Jain A (2006) A comparative analysis of training methods for artificial neural network rainfall-runoff models. Applied Soft Computing 6: 295-306.
- 17 . Stone ML (1994) High Speed Networking in Construction and Agricultural Equipment. Symposium on Future Transportation Electronics: Multiplexing and In-Vehicle Networking. SAE, Warrendale PA.
- 18 . Zheng D and Rohrbach RP (1994) Neural Networks for Ultrasonic Position Control During Blueberry Pruning. ASAE Paper No. 94-1058. ASAE, 2950 Niles Rd., St. Joseph, MI 49085-9659.
- 19 . Zhou B, Shi A, Cai F and Zhang Y (2004) Wavelet neural networks for nonlinear time series analysis. Lecture Notes in Computer Science 3174: 430-435.

Comparison of Artificial Neural and Wavelet Neural Networks for Prediction of Barley Breakage in Combine Harvester

S. M. Mazlounzadeh*, S. N. Alavi** and M. Nouri***

Abstract

In this study the wavelet neural network (WNN) and artificial neural network (ANN) were used to simulate barley breakage percentage in combine harvester. The models have been trained using the same data conditions. Air temperature, thresher cylinder speed, distance between thresher cylinder and concave (back and forth) and the percentage of barely moisture were as the input variables. The results showed that the wavelet network (WNN, RASP 1) with 90.2% correlation coefficient for barely breakage would be an appropriate substitute for artificial neural network with 88% correlation coefficient. The result of sensitivity analysis showed that all input variables had a significant effect on barely breakage. Speed of thresher cylinder had the most effect and the degree of air temperature had the least effect on barely breakage.

Keywords: Artificial neural network, Barley, Breakage percentage, Combine harvester, Wavelet neural network

* - Instructor, Agriculture Faculty of Saravan, University of Sistan and Balouchestan, Sistan and Balouchestan - Iran
(E_mail: mymy_5226370@yahoo.com)

** - Assistant Professor, Department of agricultural machinery, Shahid Bahonar Uni. of Kerman, Kerman - Iran

*** - Ph.D. Student, Department of Water resource, Faculty of Agriculture, Science and Research Branch, Islamic Azad University, Tehran - Iran