

جنگل و فرآورده‌های چوب، مجله منابع طبیعی ایران
دوره ۶۸، شماره ۴، زمستان ۱۳۹۴

تاریخ دریافت: ۱۳۹۳/۰۶/۲۳

تاریخ پذیرش: ۱۳۹۴/۰۴/۱۱

ص ۷۶۹-۷۵۷

ارزیابی کارایی شبکه‌های عصبی مصنوعی در مدل‌سازی

زمان وینچینگ Timber Jack 450 C

- ❖ هادی بیاتی؛ دانشجوی دکتری مهندسی جنگل دانشکده منابع طبیعی دانشگاه تربیت مدرس، نور، ایران
- ❖ اکبر نجفی*؛ دانشیار گروه جنگلداری دانشکده منابع طبیعی دانشگاه تربیت مدرس، نور، ایران
- ❖ پرویز عبدالملکی؛ دانشیار گروه بیوفیزیک دانشکده علوم زیستی دانشگاه تربیت مدرس، تهران، ایران

چکیده

برآورد تولید تجهیزات جنگلی بخش مهمی از مدیریت هزینه‌ها در یک واحد جنگلداری است که با کاهش هزینه‌های عملیات همراه است. به عبارت دیگر، هزینه‌های بالای سرمایه‌گذاری در بهره‌برداری از جنگل دلیل خوبی برای تحقیقات مهندسی جنگل و همچنین مدل‌سازی زمان است. در این مطالعه از یکی از زیرمجموعه‌های هوش مصنوعی، که شبکه‌های عصبی مصنوعی نامیده می‌شود، به منظور مدل‌سازی زمان وینچینگ Timber Jack 450C، در جنگل‌های نکاچوب استفاده شد. برای جمع‌آوری داده‌های زمان وینچینگ روش مطالعه زمانی پیوسته به کار رفت. هم‌زمان با اندازه‌گیری زمان وینچینگ، عوامل مؤثر بر زمان وینچینگ - مانند شیب وینچینگ، فاصله وینچینگ، تعداد بینه در هر نوبت وینچینگ، و حجم بار در هر نوبت وینچینگ - نیز بررسی شد. برای مدل‌سازی زمان وینچینگ، به کمک شبکه‌های عصبی مصنوعی، از دو شبکه عصبی پرسپترون چندلایه و تابع شعاع مدار استفاده شد. همچنین، به منظور مقایسه دقت شبکه عصبی مصنوعی با روش رایج رگرسیون، به کمک تحلیل رگرسیون، مدل ریاضی پیش‌بینی زمان وینچینگ تهیه شد. نتایج نشان داد شبکه عصبی RBF در مقایسه با شبکه MLP در پیش‌بینی زمان وینچینگ دقت بیشتری دارد. در هر دو شبکه متغیر فاصله بینه تا مرکز مسیر چوب کشی بیشترین اهمیت را داشت. همچنین، مقایسه نتایج روش رگرسیون و شبکه عصبی نشان داد شبکه‌های عصبی مصنوعی دقت بیشتر و خطای کمتری در برآورد زمان وینچینگ دارند.

واژگان کلیدی: بهره‌برداری جنگل، پرسپترون چندلایه، تابع شعاع مدار، زمان‌سنجی، وینچینگ، هوش مصنوعی.

مقدمه

متغیرهایی که بیشترین تأثیر را در کاهش باقی مانده تغییرات داشته باشند وارد مدل می‌شوند. برآورد زمان چوب‌کشی با استفاده از مدل‌های پیش‌بینی زمان چوب‌کشی و به تبع آن برآورد هزینه چوب‌کشی برای مسئولان واحد جنگلداری امکان تصمیم‌گیری در زمینه تعداد نیروی کار، تعداد ماشین‌های مورد نیاز، و میزان بودجه لازم را با توجه به خروج حجم مشخص در مدت زمان مقرر فراهم می‌سازد. مطالعات بسیاری درباره مدل‌سازی زمان چوب‌کشی، ارزیابی تولید، و هزینه‌های ماشین در سیستم‌های مختلف بهره‌برداری انجام گرفته [۳] که در همه آن‌ها، روش‌های عددی مانند رگرسیون برای مدل‌سازی به کار رفته است.

در مطالعه‌ای [۴] این نتیجه حاصل شد که از بین عامل‌های تأثیرگذار فاصله چوب‌کشی و حجم بار بر زمان یک نوبت چوب‌کشی تأثیر می‌گذارد. محققان دیگر [۵] با بررسی زمان‌سنجی ماشین HSM 904، در جنگل‌های چوب و کاغذ مازندران، متغیرهای فاصله چوب‌کشی و تعداد بینه را در هر نوبت چوب‌کشی مهم‌ترین متغیرهای تأثیرگذار معرفی کردند. یکی از پژوهشگران [۶] با ارزیابی نرخ تولید چوب در حمل و نقل اولیه و ثانویه در جنگل حوزه نکاچوب به این نتیجه دست یافت که مدل ریاضی پیش‌بینی زمان چوب‌کشی اسکیدر تاف تابعی از متغیرهای فاصله چوب‌کشی، شیب طولی مسیر چوب‌کشی، و تعداد و حجم گرده‌بینه است. مطالعه در جنگل‌های پهن‌برگ ویرجینیا در آمریکا [۷] نشان داد فاصله چوب‌کشی، تعداد بینه، و حجم بار در هر نوبت چوب‌کشی از عوامل تأثیرگذار در یک نوبت چوب‌کشی است. بررسی جنگل‌های آپالچین در

در جنگل‌های کوهستانی شمال ایران، به دلیل وجود شیب‌های نسبتاً زیاد و درختان قطور پهن‌برگ و استفاده از روش‌های برداشت گزینشی، مکانیزاسیون پیشرفته و استفاده از ماشین‌های چندکاره قطع و تبدیل کاربرد چندانی ندارد [۱]. تقریباً همه گرده‌بینه‌های بهره‌برداری شده از جنگل در ایران با چوب‌کش‌های زمینی از عرصه جنگل خارج می‌شوند. در واقع، می‌توان گفت چوب‌کشی زمینی معمول‌ترین روش برای خروج چوب و محصولات جنگلی است. امروزه، با وجود مکانیزاسیون بهره‌برداری، تعیین کارایی ماشین‌ها، به دلیل کاهش هزینه‌های بهره‌برداری، برای همه متخصصان شناخته شده است. داشتن اطلاعات دقیق در زمینه کارایی ماشین‌آلات جنگلی، به منظور بهبود وضعیت اقتصادی پروژه، برای مدیران و پیمانکاران جنگل ضروری است. برآورد تولید تجهیزات جنگلی بخش مهمی از مدیریت هزینه‌ها در یک واحد جنگلداری است که با کاهش هزینه‌های عملیات همراه است [۲]. به عبارت دیگر، هزینه‌های بالای سرمایه‌گذاری در بهره‌برداری از جنگل دلیل خوبی برای تحقیقات مهندسی جنگل و همچنین مدل‌سازی زمان است. موضوع بسیار مهم در مدل‌سازی زمان در مهندسی جنگل در نظر گرفتن همه عوامل مؤثر در چارچوب تحقیق است؛ به نحوی که بتواند روابط خطی و غیر خطی بین متغیر وابسته (زمان) و متغیرهای مستقل را در بر گیرد. متداول‌ترین مدل‌ها در مطالعات کار مدل‌های رگرسیونی چندمتغیره‌اند که نتیجه آن‌ها یک مدل ریاضی پیش‌بینی زمان‌های چرخه کاری است.

عصبی تابع پایه شعاعی نسبت به شبکه عصبی پرسپترون چندلایه در برآورد زمان قطع درخت دقت بیشتری دارد. همچنین، مقایسه معیارهای ارزیابی شبکه عصبی مصنوعی با رگرسیون گام‌به‌گام نشان داد شبکه عصبی MLP و RBF به ترتیب RMSE ۰/۹۴ و ۰/۸۱ دارد؛ در حالی که مقدار RMSE مدل رگرسیون ۱/۱۵ بود. برآورد حجم تنه درختان با دو مدل شبکه عصبی MLP و RBF و مقایسه آن‌ها با تحلیل رگرسیون نشان داد شبکه عصبی مصنوعی در مقایسه با تحلیل رگرسیون دقت بیشتری دارد؛ نیز دقت شبکه عصبی RBF نسبت به MLP بیشتر است [۱۳].

با توجه به قابلیت‌های یادشده شبکه‌های عصبی مصنوعی در مدل‌سازی سعی شد در این مطالعه از دو مدل شبکه عصبی مصنوعی MLP و RBF به منزله ابزاری توانمند در مدل‌سازی زمان وینچینگ اسکیدر Timber Jack 450C استفاده شود؛ به گونه‌ای که ضریب آن با روش رگرسیون قابل مقایسه باشد.

مواد و روش‌ها

منطقه مطالعه

این مطالعه در قطعه ۳۲۹ بخش ۲ جنگل‌های حوزه نکاچوب، با مختصات جغرافیایی "۳۶° ۳۰' ۵۰" تا "۳۶° ۳۱' ۱۵" عرض شمالی و "۴۵° ۳۱' ۵۳" تا "۳۰° ۳۲' ۵۳" طول شرقی، با مساحت ۳۹ هکتار و ارتفاع از سطح دریا از ۷۳۰ تا ۷۸۰ متر، انجام گرفت. تیپ جنگلی راش-ممرز و شیب عمومی منطقه ۰ تا ۳۰ درصد است. تعداد و حجم درختان در هکتار به ترتیب ۱۹۲/۵ و ۳۷۲/۹ متر مکعب، درصد تاج‌پوشش و میزان پوشش کف جنگل به ترتیب ۸۰ تا ۸۵ و ۲۰ درصد است. همچنین این مجموعه به روش دانه‌زاد نهم‌سال و به شیوه تک‌گزینی مدیریت می‌شود [۱۴].

آمریکا [۳] حاکی از آن بود که حجم بار و فاصله چوب‌کشی عوامل مؤثر در یک نوبت چوب‌کشی‌اند. پژوهشگری [۸] در زمینه چوب‌کشی از پای‌کننده تا دیوی کنار جاده عواملی مانند اندازه گرده‌بینه، شیب، فاصله متوسط چوب‌کشی، و حجم در هکتار را عوامل مؤثر معرفی کرد.

امروزه، به موازات روش‌های رایج آماری روش‌های جدیدتری به منظور پیش‌بینی به کار می‌رود که یکی از آن‌ها شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی به دلیل برخورداری از دو ویژگی اساسی یادگیری یا نگاشت‌پذیری بر اساس داده‌های تجربی (قدرت و توانایی تعمیم‌پذیری) و ساختارپذیری موازی، برای کنترل بسیار مناسب‌اند؛ به‌ویژه در سیستم‌های پیچیده که مدل‌سازی آن‌ها ممکن نیست یا به‌سختی انجام می‌پذیرد [۹].

مطالعات متعددی نیز در زمینه استفاده از ANN در پیش‌بینی متغیرهای مختلف جنگل صورت گرفته است. برآورد حجم تنه چهار گونه از جنگل‌های ترکیه (کاج بروسیا، کاج جنگلی، نوئل، سدر لبنان) با استفاده از شبکه عصبی مصنوعی، در مقایسه با سه روش رایج دیگر که برای برآورد حجم استفاده می‌شود، نشان داد شبکه عصبی مصنوعی خطای کمتری دارد [۱۰]. مطالعه عوامل مؤثر بر زمان قطع درخت حاکی از آن بود که مدل‌های شبکه عصبی مصنوعی برای شرایط مختلف کاری و زمینی در مقایسه با رگرسیون توانی به واقعیت نزدیک‌تر و قابل اعتمادترند [۱۱]. محققان [۱۲] زمان خالص قطع درخت را با استفاده از شبکه پرسپترون چندلایه و تابع شعاع مدار و همچنین روش رایج تحلیل رگرسیون پیش‌بینی کردند. نتایج نشان داد شبکه

روش تحقیق

فاصله تک تک بینه‌ها از مسیر چوب‌کشی با متر لیزری و شیب مسیر وینچینگ با سونتو اندازه‌گیری شد. به منظور جمع‌آوری داده‌های زمان وینچینگ از روش مطالعه زمانی پیوسته [۱۵] استفاده شد و به کمک کرومومتر، با دقت یک‌صدم دقیقه، زمان‌های یک سیکل وینچینگ با تیمبر جک $450C$ ، شامل باز کردن و کشیدن کابل وینچ^۱ و بستن چوکر یا قلاب کردن کابل دور گردبینه‌ها^۲ و جمع کردن کابل وینچ توسط ماشین^۳، ثبت شد. عملیات وینچینگ را یک اکیپ دونفره (یک راننده اسکیدر و یک چوکر بند) مجهز به اسکیدر Timber Jack 450C انجام دادند. همچنین، هنگام زمان‌سنجی، ضمن اندازه‌گیری قسمت‌های مختلف کار، زمان‌های توقف در مراحل مختلف کاری، شامل زمان تأخیر اجرایی و تأخیر فنی و تأخیر شخصی، اندازه‌گیری و ثبت شد. در این مطالعه هشتاد و چهار سیکل وینچینگ ثبت و اندازه‌گیری شد. هم‌زمان با اندازه‌گیری زمان وینچینگ، عوامل مؤثر بر زمان وینچینگ - مانند شیب وینچینگ SW ، فاصله وینچینگ D ، تعداد بینه در هر نوبت وینچینگ N ، و حجم بار در هر نوبت وینچینگ V - بررسی شد.

روش شبکه عصبی مصنوعی

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی کنار هم عمل می‌کنند. ساختار و عملکرد ANN از مغز انسان تقلید می‌کند و از تعدادی اجزای ساختاری ساده تشکیل شده‌اند، با ارتباطی پیچیده؛ که به مثابه نرون یا نود شناخته می‌شوند [۱۶].

پرسپترون چندلایه^۴ (MLP)

یکی از شبکه‌های پرکاربرد در منابع طبیعی شبکه‌های پس‌انتشار است [۱۷]. شبکه پس‌انتشار، با داشتن بایاس و یک لایه ورودی و یک لایه خروجی خطی، توانایی تخمین زدن هر تابعی را با تعداد نقاط ناپیوستگی محدود دارد [۱۸].

شبکه عصبی تابع شعاع مدار^۵ (RBF)

این نوع شبکه به نرون‌های بیشتر نیاز دارد. اما حسن آن‌ها در زمان طراحی کوتاه‌تر نسبت به شبکه‌های استاندارد پس‌انتشار است. این شبکه‌ها هنگامی که بردارهای آموزشی بسیار زیادند بهترین کارایی را دارند [۱۸]. RBF، مانند MLP، از سه لایه ورودی و پنهان و خروجی تشکیل می‌شود؛ با این تفاوت که در این نوع شبکه فقط یک لایه پنهان وجود دارد. این لایه پنهان انطباقی غیرخطی بین فضای ورودی و فضای (معمولاً) با بعد بزرگ‌تر برقرار می‌کند که در آن الگوها به صورت تفکیک‌پذیر خطی درمی‌آیند. سرانجام، لایه خروجی جمع وزنی را همراه یک خروجی خطی تولید می‌کند.

در طراحی شبکه عصبی مصنوعی داده‌ها به صورت تصادفی به دو دسته آموزش (۸۰٪ داده‌ها) و آزمون (۲۰٪ داده‌ها) به شکلی تقسیم شدند که بیشترین و کمترین داده در دسته آموزش قرار گیرد. در طراحی و اجرای شبکه عصبی این مطالعه از جعبه ابزار شبکه عصبی مصنوعی نرم‌افزار SPSS 17 استفاده شد. متغیرهای شیب وینچینگ SW ، فاصله وینچینگ D ، تعداد بینه در هر نوبت وینچینگ N ، و

1. Release and pulling Winch
2. Hook
3. Winching

4. Multi Layer Perceptron
5. Radial Basis Function

وینچینگ تهیه شد. البته، پیش از تهیه مدل، ۲۰ درصد داده‌ها (۱۷ داده) به منظور مقایسه نزدیک‌تر با تکنیک شبکه عصبی برای ارزیابی نتایج رگرسیون کنار گذاشته شده و در تهیه مدل شرکت داده نشد.

در ارزیابی دقت شبکه عصبی مصنوعی و رگرسیون از معیارهای ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE)، %Bias، و درصد مجذور میانگین مربعات خطا (%RMSE) استفاده شد (جدول ۱).


y_t ، \hat{y}_t ، \bar{y}_t ، و \bar{y}_t به ترتیب برابر با مقدار زمان وینچینگ مشاهداتی، زمان وینچینگ پیش‌بینی شده، میانگین کل زمان‌های وینچینگ مشاهداتی، میانگین کل زمان‌های وینچینگ پیش‌بینی شده، و تعداد مشاهدات است.

حجم بار در هر نوبت وینچینگ V ورودی‌های شبکه و متغیر زمان وینچینگ خروجی شبکه در نظر گرفته شد (شکل‌های ۱ و ۲). همچنین، با استفاده از جعبه ابزار این نرم‌افزار میزان حساسیت داده خروجی (زمان وینچینگ) نسبت به هر یک از متغیرهای ورودی بررسی شد. از آنجا که در تعیین تعداد لایه‌های پنهان انواع الگوریتم‌های آموزش و تعداد نرون‌ها در هر لایه قاعده مشخصی وجود ندارد، الگوریتم‌های آموزش، تعداد لایه‌های لایه پنهان، و تعداد نرون‌های هر لایه با آزمون و خطا تعیین شد. این روند تا زمانی ادامه یافت که خطای بین داده برآوردی و داده واقعی به کمترین حد خود رسید.


به منظور مقایسه دقت شبکه عصبی مصنوعی با روش رایج رگرسیون، پس از جمع‌آوری و وارد کردن داده‌ها در نرم‌افزار آماری SPSS و با استفاده از تحلیل رگرسیون، مدل ریاضی پیش‌بینی زمان

جدول ۱. روابط معیارهای ارزیابی کارایی مدل

رابطه ریاضی	معیار	ردیف
$RMSE = \sqrt{\frac{\sum (\hat{y}_t - y_t)^2}{n}}$	RMSE	۱
$R^2 = \left[\frac{\sum_{i=1}^n (y_t - \bar{y}_t)(\hat{y}_t - \bar{y}_t)}{\sqrt{\sum_{i=1}^n (y_t - \bar{y}_t)^2} \sqrt{\sum_{i=1}^n (\hat{y}_t - \bar{y}_t)^2}} \right]^2$	R^2	۲
$\%RMSE = \frac{RMSE}{\bar{y}_t} \times 100$	%RMSE	۳
$\%Bias = \left[\frac{1}{n} \sum_{i=1}^n \left(\frac{y_t - \hat{y}_t}{y_t} \right) \right] \times 100$	%Bias	۴



شکل ۱. ساختار شبکه عصبی مصنوعی MLP طراحی شده



شکل ۲. ساختار شبکه عصبی مصنوعی RBF طراحی شد

یافته‌ها و بحث

وجود شیب‌های مثبت و منفی در داده‌ها باشد یا اینکه شیب کمتر از حدی بوده که بر قدرت ماشین تأثیر بگذارد (جدول ۲). این وضعیت با نتایج سایر مطالعات [۴ و ۶] هم‌سوست.

نتیجه آزمون همبستگی نشان داد زمان خالص وینچینگ بیشترین همبستگی را با فاصله بینه تا مرکز مسیر وینچینگ (۰٫۸۰) و کمترین همبستگی (۰٫۰۴) را با شیب مسیر وینچینگ دارد. علت آن می‌تواند

جدول ۲. ضریب همبستگی بین زمان خالص وینچینگ و سایر متغیرها

فاصله	تعداد بینه	حجم بینه	شیب وینچینگ
زمان خالص وینچینگ	۰٫۸۰	۰٫۴۲	۰٫۰۴

جدول ۳ تجزیه واریانس مدل زمان‌سنجی وینچینگ را نشان می‌دهد. با توجه به Sig، که کمتر از ۰/۰۱ است، رابطه رگرسیونی به دست آمده با اطمینان ۹۹ درصد تأیید می‌شود. جدول ۴ نتایج معیارهای ارزیابی روش رگرسیون و شبکه‌های عصبی مصنوعی را در برآورد زمان وینچینگ نشان می‌دهد.

به کمک تحلیل رگرسیون و روش گام‌به‌گام، مدل زمان‌سنجی مرحله وینچ کردن بینه‌ها تعیین شد. مدل حاصله تابعی از متغیرهای مستقل فاصله بینه تا مرکز مسیر چوب‌کشی و حجم بینه است که با برخی مطالعات [۳، ۴، ۷] مطابقت دارد (رابطه ۱):

$$T = 0.265 + 0.32D + 0.74V \quad (1)$$

T زمان یک نوبت وینچینگ به دقیقه، D فاصله بینه تا مرکز مسیر چوب‌کشی به متر، و V حجم بار به متر مکعب در هر نوبت است.

جدول ۳. تجزیه واریانس مدل زمان‌سنجی مرحله وینچینگ

منبع	مجموع مربعات	درجه آزادی	میانگین مربعات	F	Sig
رگرسیون	۱۷/۳۱۶	۲	۸/۶۵۸	۸۰/۰۹۳	۰/۰۰۰
باقی مانده	۶/۹۱۸	۶۴	۰/۱۰۸		
مجموع	۲۴/۲۳۵	۶۶			

جدول ۴. نتایج معیارهای ارزیابی کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون در مرحله واسنجی


روش	ترکیب	تابع فعال‌سازی				% Bias	% RMSE	RMSE	R ²
		لایه ورودی	لایه خروجی	Identity	TanHyp				
رگرسیون	$T = 0.265 + 0.32D + 0.74V$	-	-	-	-	۳۰/۰۸	۰/۳۳	۰/۷۲	-۹/۳۸
MLP	۴-۳-۲-۱	TanHyp	Identity	Identity	Identity	۲۶/۸۳	۰/۲۹	۰/۹۳	-۷/۵۵
RBF	۴-۱۷-۱	Softmax	Identity	Identity	Identity	۲۱/۴۹	۰/۲۳	۰/۹۴	-۶/۶۳

به منظور اعتبارسنجی مدل، از کل نمونه‌ها هفده نمونه (۲۰٪ داده‌ها) به طور تصادفی انتخاب و در تعیین مدل وارد نشد. جدول ۵ نتایج معیارهای ارزیابی روش رگرسیون و شبکه‌های عصبی مصنوعی


شکل‌های ۳ تا ۵ نتیجه اختلاف خطا بین زمان پیش‌بینی شده و زمان واقعی را در مرحله مدل‌سازی برای روش رگرسیون و همچنین شبکه‌های عصبی مصنوعی نشان می‌دهد.

می‌توانند برتری مدل‌ها را نشان دهند که بین مقادیر مشاهده شده و مقادیر پیش‌بینی شده محاسبه شوند.


را در مرحله اعتبارسنجی نشان می‌دهد. ارزیابی مدل‌های مختلف به کمک معیارهای R^2 و RMSE و %RMSE امکان‌پذیر است. این معیارها زمانی



شکل ۳. مقایسه اختلاف خطا بین زمان پیش‌بینی شده و زمان واقعی در روش رگرسیون



شکل ۴. مقایسه اختلاف خطا بین زمان پیش‌بینی شده و زمان واقعی در شبکه عصبی MLP



شکل ۵. مقایسه اختلاف خطا بین زمان پیش‌بینی شده و زمان واقعی در شبکه عصبی RBF

جدول ۵. نتایج معیارهای ارزیابی کارایی مدل‌های شبکه عصبی مصنوعی و رگرسیون در مرحله اعتبارسنجی

روش	R^2	RMSE	%RMSE	%Bias
رگرسیون	۰٫۸۳	۰٫۴۳	۴۲٫۳۲	-۹٫۸۳
MLP	۰٫۹۱	۰٫۳۶	۳۵٫۴۴	-۸٫۳۹
RBF	۰٫۹۳	۰٫۲۸	۲۷٫۸۴	-۲٫۷۷


می‌دهد مقدار مورد انتظار کمتر از مقدار واقعی پیش‌بینی شده است. البته در این زمینه نیز شبکه RBF نسبت به MLP و همچنین رگرسیون مقدار %Bias کمتری دارد. این وضعیت به علت تشابه بیشتر مقدار پیش‌بینی شده با مقدار واقعی در شبکه RBF است. شکل‌های ۶ تا ۸ نتیجه اختلاف خطا بین زمان وینچینگ پیش‌بینی شده و زمان وینچینگ واقعی را در مرحله اعتبارسنجی برای روش رگرسیون و همچنین شبکه‌های عصبی مصنوعی نشان می‌دهد. این شکل‌ها تشخیص چشمی عملکرد روش‌های مختلف برآورد زمان وینچینگ را آشکار می‌سازد.

توجه به مقادیر R^2 و RMSE و %RMSE مزیت نسبی مدل‌ها را نشان می‌دهد. بیشترین ضریب تبیین معنادار و کمترین میزان خطا بهترین روش را معرفی می‌کند. بنابراین، برتری روش‌ها به ترتیب RBF و MLP و رگرسیون چندمتغیره با میزان ضرایب تبیین ۰٫۹۳ و ۰٫۹۱ و ۰٫۸۳، مقادیر RMSE ۰٫۲۸ و ۰٫۳۶ و ۰٫۴۳ و مقادیر %RMSE ۲۷٫۸۴ و ۳۵٫۴۴ و ۴۲٫۳۲ تعیین می‌شود. مقایسه معیار %Bias برای هر سه روش نشان می‌دهد در همه مدل‌های به‌دست آمده مقدار %Bias منفی است^۱ که نشان


1. Under Estimate

RBF نسبت به دو مدل دیگر در پیش‌بینی زمان وینچینگ خطای کمتری دارد که با نتایج برخی تحقیقات [۱۲ و ۱۳] هم‌سوست.


خطوط پیوسته داده‌های مشاهداتی (واقعی) و خطوط منقطع داده‌های پیش‌بینی شده توسط روش‌ها را نشان می‌دهد. همان‌طور که مشاهده می‌شود، شبکه عصبی



شکل ۶. مقایسه اختلاف خطای زمان پیش‌بینی شده و زمان واقعی در روش رگرسیون چندمتغیره



شکل ۷. مقایسه اختلاف خطای زمان پیش‌بینی شده و زمان واقعی در شبکه عصبی MLP



شکل ۸. مقایسه اختلاف خطای زمان پیش‌بینی‌شده و زمان واقعی در شبکه عصبی RBF

عصبی RBF فاصله بینه تا مرکز مسیر چوب‌کشی (۱۰۰٪) و متغیر تعداد بینه در هر نوبت وینچینگ (۴۲٫۷٪)، به ترتیب، بیشترین و کمترین اهمیت را دارند. این وضعیت نتیجه آزمون همبستگی را نیز تأیید می‌کند (جدول ۶).

تحلیل حساسیت مدل‌های شبکه‌های عصبی مصنوعی

تحلیل حساسیت نشان داد در شبکه عصبی MLP متغیر فاصله بینه تا مرکز مسیر چوب‌کشی (۱۰۰٪) و تعداد بینه در هر نوبت وینچینگ (۲۸٪) و در شبکه

جدول ۶. اهمیت متغیرهای مستقل در دو شبکه عصبی در پیش‌بینی زمان وینچینگ

شبهه	متغیر	اهمیت	اهمیت نرمال‌شده به درصد
MLP	D	۰٫۴۱۹	۱۰۰
	V	۰٫۳۳۶	۸۰٫۱
	S.W	۰٫۱۲۸	۳۰٫۵
	N.B	۰٫۱۱۷	۲۸
RBF	D	۰٫۴۰۶	۱۰۰
	V	۰٫۲۰۱	۴۹٫۵
	S.W	۰٫۲۱۹	۵۳٫۹
	N.B	۰٫۱۷۴	۴۲٫۷

تفاوت عملکرد بهتر شبکه‌های عصبی مصنوعی را در مقایسه با روش‌های آماری می‌توان در قابلیت تخمین و پیش‌بینی شبکه‌های عصبی مصنوعی با حجم کم داده‌ها جست‌وجو کرد. این در حالی است عملکرد و دقت روش‌های رگرسیونی به شدت از حجم نمونه تبعیت می‌کند و حجم کم نمونه‌ها می‌تواند عامل محدودیت مدل‌های آماری شود. بنابراین، در مدل‌های طراحی‌شده شبکه عصبی مصنوعی کم بودن تعداد نمونه‌ها محدودیت چشمگیری ایجاد نکرده است.

اهمیت یک متغیر مستقل، با اندازه‌گیری میزان تغییر داده برآورد شده توسط شبکه به نسبت مقادیر مختلف متغیر مستقل، تعیین می‌شود. متغیری که بیشترین وزن و تأثیر را داشته باشد اهمیت ۱۰۰ درصد دارد. برای محاسبه اهمیت نرمال‌شده سایر متغیرها میزان اهمیت آن را بر میزان اهمیت مهم‌ترین متغیر تقسیم می‌کنند، که به صورت درصد بیان می‌شود.

نتیجه‌گیری

از آنجا که ماشین‌آلات و تجهیزات خروج چوب‌آلات در جنگل استفاده می‌شوند و هزینه‌های ساعتی بسیار بالایی دارند، مطالعات زمان‌سنجی برای مسئولان واحد جنگلداری به منظور سازماندهی کار، شناسایی بخش‌های تأثیرگذار در زمان، کاهش تأخیر، برآورد هزینه‌های چوب‌کشی، و تصمیم‌گیری در زمینه تعداد

نیروی کار و تعداد ماشین‌ها و میزان بودجه، با توجه به خروج حجم مشخص در مدت زمان معین و در نتیجه کاهش هزینه‌ها، ضروری به نظر می‌رسد. استفاده از روشی مانند شبکه‌های عصبی مصنوعی، که بتواند زمان را با دقت بیشتر و خطای کمتر برآورد کند، در مطالعات مهندسی جنگل ارزش بسیار دارد. در طراحی ساختار شبکه‌های عصبی مصنوعی انتخاب تعداد ورودی‌های شبکه، تعداد لایه‌های پنهان، تعداد نرون در هر لایه، توابع فعال‌سازی، و سایر مشخصات یک شبکه عصبی به پیچیدگی مسئله مورد نظر بستگی دارد و به کمک آزمون و خطا به دست می‌آید؛ طوری که در مسائل پیچیده تا زمانی که خطای شبکه افزایش پیدا نکرده باشد باید بر تعداد لایه‌های پنهان و نرون‌ها افزود. به طور کلی، در مدل‌سازی اهداف فیزیکی، مانند زمان‌سنجی وینچینگ، به این علت که عواملی ناشناخته ممکن است بر زمان تأثیر بگذارد و در بیشتر مواقع این اثرگذاری باعث ایجاد فضایی غیر خطی می‌شود، مدل‌سازی بسیار حساس است و با خطا روبه‌رو می‌شود. در نهایت، اگرچه در این تحقیق نتایج خوبی از شبکه عصبی حاصل شد، استفاده از سایر مدل‌های شبکه عصبی در بخش‌های مختلف علوم جنگل و در مقیاس‌های بزرگ‌تر ضروری به نظر می‌رسد تا بتوان نتایج قابل مقایسه به دست آورد.

References

- [1]. Sarikhani, N. (2008). *Forest Utilization*. 3ed, University of Tehran Press, Tehran, Iran.
- [2]. Davis, C. T. and Kellogg, L. D. (2005) Measuring machine productivity with the multiDat datalogger: a demonstration on three forest machines. Council on Forest Engineering Conference Proceedings.
- [3]. Wang, J., McNeel, J., and Baumgras, J. (2003). A computer-based time study system for timber harvesting operations. *Forest Products Journal*, 53(3): 47-53.
- [4]. Naghdi, R., Nikooy, M., Mohammadi Limaiei, S., and Shormage, Y. (2010). Evaluation of felling productivity in Shafarood forest (Guilan Province). *Iranian Journal of Forest And Poplar Research*, 18(3): 417-425.
- [5]. Pir Ba Vaghar , M., Sobhani, H., Fegghi, J., Darvishsefat, A. A., and Marvi Mohajer, M. R. (2008). Investigation on production rate and cost of Timberjack-450C in two skidding direction in combined harvesting system. *Iranian Journal of Forest and Poplar Research*, 15(4): 374-385.
- [6]. Eghtesadi, A. (2008). Evaluation of Wood Productivity Rate in Primary and Secondary Transportation in Nekachub Region. *Iranian Journal of Forest and Poplar Research*, 16(2): 274-291.
- [7]. Egan, A. F. and Baumgras, J. E. (2003). Ground skidding and harvested stand attributes in Appalachian hardwood stands in West Virginia. *Forest Products Journal*, 53(9): 59-63.
- [8]. Adams, T. C. (1965). High-lead logging costs as related to log size and other variables. *USFS Res. Pap. Pacific. Northwest. For. Range Exp. Sta. No. PNW-23*.
- [9]. Menhaj, M. B. (2002). *Neural Network Basis*, Amir Kabir Industrial University Publication, Tehran, Iran.
- [10]. Özçelik, R., Diamantopoulou, M. J., Brooks, J. R., and Wiant, H. V. (2010). Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of environmental management*, 91(3): 742-753.
- [11]. Karaman, A. and Çalışkan, E. (2009). Affective factors weight estimation in tree felling time by artificial neural networks. *Expert Systems with Applications*, 36(3): 4491-4496.
- [12]. Bayati, H., Najafi, A., and Abdolmaleki, P. (2013). Comparison between Artificial Neural Network (ANN) and Regression Analysis in Tree Felling Time Estimation). *Iranian Journal of Forest and Poplar Research*, 20(4): 595-607.
- [13]. Bayati, H. and Najafi, A. (2013). Performance comparison Artificial Neural Networks with regression analysis in trees trunk volume estimation. *Journal of Forest and Wood Products*, 66(2): 177-191.
- [14]. FRO. (2008). *Forestry Plan Notebook*, District 2, watershed 75, Neka-Zalem rood, Neka Choob Forest Co, Forests and Ranges Organization, Sari, Iran.
- [15]. Gardner, R. W. (1963). New tools to hone harvesting. *Pulp and Paper*. April, 29 73-75.
- [16]. Strobl, R. O. and Forte, F. (2007). Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological processes*, 21(22): 2965-2978.
- [17]. Rumelhart, D. E., McClelland, J. L., and Group, U. o. C. S. D. P. R. (1986). *Parallel distributed processing : explorations in the microstructure of cognition*, MIT Press, Cambridge, Mass.
- [18]. Kia, M. (2010). *Neural network in MATLAB*. Kian Rayaneh Sabz, Tehran.