

مدل عصبی - فازی خطای افت در عملیات قطع هدایت شده با استفاده از روش خوشه‌بندی کاهنده

اسماعیل فجر^{۱*}، رامین نقدی^۲ و مهرداد نیکوی^۳

* نویسنده مسئول، استادیار، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران. پست الکترونیک: i.ghajar@guilan.ac.ir

۲- دانشیار، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران

۳- استادیار، گروه جنگل‌داری، دانشکده منابع طبیعی، دانشگاه گیلان، صومعه‌سرا، ایران

تاریخ دریافت: ۹۳/۰۸/۱۸

تاریخ پذیرش: ۹۴/۰۵/۰۳

چکیده

پژوهش پیش‌رو با استفاده از روش خوشه‌بندی کاهنده در سیستم عصبی - فازی تطبیقی به ارایه مدلی برای برآورد میزان خطای جهت افت درخت در قطع هدایت شده می‌پردازد. بدین منظور ۹۵ اصله درخت در پارسل ۲۰۷ سری دو حوضه آبخیز ناو توسط اکیب عملیات قطع و صرف‌نظر از مهارت اره موتورچی‌ها، قطع شدند. اختلاف جهت پیش‌بینی شده و جهت افت واقعی درختان به‌عنوان خطای افت اندازه‌گیری شد. با در نظر گرفتن ۱۲ عامل به‌عنوان عامل‌های مؤثر در میزان خطای افت و با به‌کارگیری دو نوع الگوریتم یادگیری، دو نوع تابع استنتاج و پنج نوع تابع عضویت برای متغیرهای ورودی، مدل‌های مختلف عصبی - فازی با روش خوشه‌بندی کاهنده ساخته و ارزیابی شدند. نتایج نشان داد که تابع عضویت دوزنقه‌ای در ترکیب با سیستم استنتاج سوگنو مرتبه یک و الگوریتم یادگیری پس انتشار خطا بهترین عملکرد را در میان کلیه ترکیبات مورد نظر داشته‌اند. تحلیل حساسیت مدل نشان داد که مهم‌ترین عامل‌ها به ترتیب شیب زمین، زاویه سطح بن‌بری و بن‌زنی در امتداد حاشیه برش، قطر و زاویه دهانه بن‌زنی بوده‌اند و بقیه عامل‌ها تأثیر کمتری داشته‌اند. نتایج برآورد مدل نشان داد که گمان گروه قطع در تعیین انتخاب جهت افت درخت در شرایط پرشیب‌تر به واقعیت نزدیک‌تر بود. به‌علاوه، افزایش قطر درخت و باز کردن بیش از حد دهانه بن‌زنی با افزایش خطای قطع همراه بود.

واژه‌های کلیدی: اره موتوری، تابع عضویت، سوگنو، سیستم استنتاج عصبی - فازی تطبیقی، قطع، محاسبات نرم.

مقدمه

در کلیه سیستم‌های بهره‌برداری موجود ایران درخت باید قطع شود. قطع دستی به‌وسیله اره موتوری همچنان روش رایج در جنگل‌های شمال ایران است. قطع یکی از اجزای عملیات بهره‌برداری است که در صورت عدم اجرای صحیح می‌تواند تخریب جدی بر توده باقیمانده برجای گذارد. استفاده از فنون صحیح کار که شامل اجزای صحیح عملیات قطع باشد، می‌تواند از این خسارات جلوگیری کند. انحراف این اجزا از شکل درست می‌تواند منجر به افتادن

درخت در جهت نادرست و در نتیجه تخریب توده و زادآوری شود (FAO, 2004). یکی از اهداف در عملیات قطع، قرار دادن درخت (بینه‌ها) در جهت مناسب نسبت به مسیر چوبکشی است، اما چالش دیگر، تلاش برای انتخاب جهت انداختن درخت به نحوی است که کمترین خسارت به توده سرپا وارد شود، اگرچه چنین خسارتی اجتناب‌ناپذیر است (Cedergren et al., 2002). روش صحیح قطع در موقعیت‌ها و ابعاد مختلف تمایل درخت و جهت انداختن آن و اجزای آن به‌طور کامل توسط Sarikhani (۲۰۰۱) و

مناسب قطع را پس از طراحی مسیر چوبکشی و با آگاهی از موقعیت آن روی تنه درخت مشخص و عملیات قطع را به درستی اجرا کرد (Pinard, 1994; Nikooy, 2007; Shourmij, 2009). آنچه که به عنوان خطا در عملیات قطع هدایت شده مطرح است، تفاوت بین جهت از پیش تعیین شده قطع و جهت واقعی افتادن درخت است. نتایج تحقیق Krueger (۲۰۰۴) در ارزیابی توانایی گروه کاری در قطع هدایت شده نشان داد که به طور میانگین ۳۵/۲ درجه بین جهت پیش‌بینی شده و آنچه در واقعیت اتفاق افتاده است، تفاوت وجود داشت. براساس تحقیق وی، افزایش قطر موجب افزایش خطا شده و این افزایش در میان گونه‌های مختلف متفاوت بود. همچنین این خطا در میان گروه‌های مختلف قطع نیز متفاوت بود (Krueger, 2004). Ershadifar و همکاران (۲۰۱۱) با اندازه‌گیری خطای افت درختان در عملیات قطع هدایت شده در جنگل شفارود به این نتیجه رسیدند که مقایسه میانگین خطای قطع گروه‌های قطع با میانگین استاندارد ۲۰ درجه (Cedergren et al., 2002) اختلاف معنی‌دار دارد و گروه‌های قطع موفق به قطع هدایت شده نشده‌اند.

یکی از راه‌های ارزیابی میزان تأثیر عامل‌های مختلف مؤثر بر خطای قطع، مدل‌سازی اندازه خطا و در نتیجه یافتن اندازه تأثیر هر متغیر بر تغییرات اندازه خطا است. در مدل‌های تجربی پس از جمع‌آوری داده‌ها و آزمایش معنی‌داری آماری، رابطه بین متغیرهای اندازه‌گیری شده به دست می‌آید. در این میان مدل‌سازی و بهینه‌سازی‌های عددی به‌طور گسترده‌ای در پژوهش‌های مربوط به جنگل و حوضه آبخیز به‌کار رفته‌اند. رایج‌ترین تکنیک برای مدل‌سازی عملیات و پدیده‌های فیزیکی در مهندسی جنگل رگرسیون حداقل مربعات معمولی است (Magagnotti & Spinelli, 2012). ابزارهای مدل‌سازی عددی مانند رگرسیون خطی چندگانه به‌ویژه هنگامی مناسب هستند که دانش قبلی درباره نوع روابط بین داده‌ها و خطی بودن یا غیرخطی بودن فضای مسأله وجود داشته باشد و همچنین مجموعه داده‌ها تا حد امکان از داده‌های پرت تهی باشد.

Lotfalian (۲۰۱۲) و همچنین مبانی فیزیکی نیروهای مؤثر بر افت درخت توسط Lotfalian (۲۰۱۲) تشریح شده است. بیشتر منابع موجود در ارتباط با عملیات قطع، معطوف به برآورد میزان تولید و هزینه در عملیات قطع با اهر موتوری (Brock et al., 1986; Lortz et al., 1997; Holmes et al., 2002; Wang et al., 2004; Nikooy, 2009; Behjou et al., 2007)، برآورد زمان قطع و عامل‌های مؤثر بر آن (Karaman & Caliskan, 2009) و ارزیابی خسارات بر توده جنگل (Froese & Han, 2006; Nikooy et al., 2010) بوده است. کاهش شدت برداشت، اگرچه خسارات را کاهش می‌دهد، اما نادیده گرفتن این موضوع که درختان باید در جهت از پیش تعیین شده انداخته شوند، خود موجب تخریب بیشتر است (Appanah & Weinland, 1990). آنچه که باعث افتادن درختان در یک مسیر قابل پیش‌بینی می‌شود، میزان گشتاوری است که حول محور لولای برش تولید می‌شود که رابطه مستقیم با برآیند نیروهای محرک (نیروی ناشی از وزن تاج درخت + تنه) دارد (Lotfalian, 2012). تعیین جهت افت درختان هنگامی مطرح می‌شود که عملیات قطع به وسیله اهر موتوری انجام می‌گیرد و پس از آن به کمک سیستم‌های زمینی و یا هوایی چوب خارج می‌شود (Lotfalian, 2012). مشخص کردن جهت قطع روی تنه درخت می‌تواند راهنمای مناسبی برای کارگر اهر موتوری برای انتخاب جهتی باشد که درخت با کمترین خسارت به توده باقیمانده بیفتد و همچنین سرعت عملیات چوبکشی را بیشتر کند (Conway, 1982). اهمیت قطع هدایت شده تنها در کاهش خسارت (سلامتی توده) نیست. جهت افتادن درخت به دلیل تمایل درخت، سلامتی درخت و گروه کار و همچنین تسهیل عمل چوبکشی اهمیت دارد (Lotfalian, 2012). مطالعات پیشین نشان داده است که انداختن و هدایت درخت در جهت مناسب ضمن کاهش خسارت به تنه اصلی و خسارت به توده باقیمانده و زادآوری، موجب کاهش زمان چوبکشی نیز شده است (Naghdi et al., 2007). برخی پژوهشگران گزارش کرده‌اند که می‌توان جهت

متغیرهای مهم‌تر در این عملیات جلب کند. این آگاهی، مهندسی قطع را برای گروه قطع امکان‌پذیر می‌کند. اثرات مثبت غیرمستقیم چنین دقتی بر سرعت و هزینه عملیات چوبکشی (که در آن زمان کل کار چوکربند و وینچینگ کاهش می‌یابد)، نمایان خواهد شد.

مواد و روش‌ها

منطقه مورد مطالعه

پژوهش پیش‌رو در پارسل ۲۰۷ سری دو حوضه آبخیز ناو بین طول‌های جغرافیایی "۴۸°۴۴'۳۶" و "۴۸°۴۹'۵۸" شرقی و عرض‌های جغرافیایی "۳۷°۴۲'۳۱" و "۳۷°۴۴'۳۳" شمالی انجام شد. مساحت پارسل ۵۴ هکتار است که ۴۱ هکتار آن قابل بهره‌برداری و ۱۳ هکتار آن حفاظتی است. حداقل ارتفاع پارسل ۵۴۰ متر، حداکثر ارتفاع آن ۸۵۰ متر و میانگین ارتفاع بیشتر بخش‌های پارسل ۷۵۰ متر بالاتر از سطح دریای آزاد است. جهت عمومی پارسل شمالی، تعداد درخت در هکتار ۲۳۲ درخت و حجم سرپای آن ۲۷۳ مترمکعب در هکتار است. تیپ جنگل در پارسل، راش - ممرز است (Ershadifar et al., 2011).

روش پژوهش

جمع‌آوری و تقسیم داده‌ها

برای انجام این پژوهش ۹۵ درخت از کل درختان نشانه‌گذاری شده در پارسل مورد مطالعه به‌طور تصادفی انتخاب شدند. مناسب‌ترین جهت افتادن درخت با مشاوره ناظر طرح و گروه‌های قطع، تعیین و آزمون آن ثبت شد. به‌منظور راهنمایی گروه قطع جهت افت درخت با رنگ آبی روی کنده درخت علامت‌گذاری شد. برای کاهش احتمال خطا، همه درختان روی کنده و تنه شماره‌گذاری شدند. هیچ نیرویی برای افتادن درخت در جهت دلخواه بر درخت اعمال نشد. پس از عملیات قطع در فصل زمستان، آزمون واقعی افت درخت ثبت شد. به‌صورت قراردادی، آزمون به‌صورت یک خط مستقیم از مرکز کنده به مرکز تنه در فاصله پنج متر از بن‌بری اندازه‌گیری شد. برای اندازه‌گیری خطا، تفاوت میان آزمون از پیش تعیین‌شده و واقعی افت

در بررسی پدیده‌های مختلف در علوم منابع طبیعی، روابط پیچیده حاکم بر فضای متغیرهای ورودی و خروجی، استفاده از تکنیک‌های مرسوم عددی را دچار چالش می‌کند و گاهی استفاده از تکنیک‌های انعطاف‌پذیرتر را ضروری می‌کند. روش‌های محاسباتی نرم از جمله روش‌های رایجی هستند که می‌توانند چنین نقش‌هایی را ایفا کنند و به‌منظور آزمایش رفتار سیستم‌های پیچیده به‌کار روند.

با الهام از تئوری فازی (Zadeh, 1965)، Jang (۱۹۹۳) یک روش ترکیبی با عنوان عصبی- فازی را به‌منظور استفاده حداکثر از کارایی تئوری فازی و شبکه عصبی مصنوعی ارایه کرد. به‌طور کلی سیستم‌های عصبی- فازی همان سیستم‌های فازی هستند که تنظیم ویژگی‌های آنها (از جمله حدود توابع عضویت و قواعد فازی) به‌وسیله شبکه عصبی و مجموعه‌ای از داده‌های آموزشی انجام می‌شود (Andrews et al., 1995). در این میان سیستم استنتاج عصبی- فازی تطبیقی یا ANFIS (Adaptive Neuro-Fuzzy Inference System) از روش‌های مطلوب پژوهشگران بوده است. آنچه که به‌عنوان مهم‌ترین نوآوری Jang (۱۹۹۳) در ارایه ANFIS مطرح است، توان به‌کارگیری سیستم‌های استنتاج سوگنو (Sugeno & Kang, 1988) با شبکه عصبی است که امکان کاربرد عملی ANFIS را برای مدل‌سازی در فضاهای غیرخطی می‌دهد (Roger & Sun, 1993). در این سیستم، داده‌های آموزشی هستند که پارامترهای توابع عضویت را تنظیم می‌کنند. ANFIS الگوی داده‌های ورودی را یاد می‌گیرد و سپس پارامترهای بخش‌های مختلف را با توجه به خطای داده شده در تعداد دورهای محاسبات لازم تنظیم می‌نماید.

پژوهش پیش‌رو براساس اطلاعات برخی عامل‌های مؤثر در جهت افتادن درخت و با استفاده از ANFIS به ارایه مدلی پرداخته است که بتواند تغییرات این خطا را به نحو مناسبی توصیف کند. این پژوهش می‌تواند برای نشان دادن میزان تأثیر عامل‌های مختلف مؤثر در خطای قطع مفید باشد و به‌خصوص توجه گروه قطع را به تنظیم دقیق

یک سیستم استنتاج فازی به کار می‌گیرد. توضیح جامع درباره ساختار ANFIS در تحقیق Ghajar و همکاران (۲۰۱۲) موجود است. در طراحی ANFIS، انتخاب سیستم استنتاج یک موضوع اساسی است. تاکنون سیستم‌های استنتاج مختلفی تولید و ارایه شده است که هر کدام براساس نوع استدلال فازی و قواعد به کار گرفته شده فازی، از یکدیگر متفاوت بوده‌اند (Mamdani & Assilian, 1974; Tsukamoto, 1979; Takagi & Sugeno, 1983). در این پژوهش از سیستم استنتاج عصبی - فازی تطبیقی Sugeno (Jang, 1993) استفاده شد که از سیستم استنتاج Sugeno استفاده می‌کند. به دلیل افزایش مشکل آفرین تعداد کل قواعد فازی در نتیجه تعداد زیاد متغیرهای مستقل، از روش خوشه‌بندی کاهنده برای مدل‌سازی استفاده شد. بخش نتیجه سیستم استنتاج Sugeno هم یک تابع درجه صفر و هم یک تابع درجه یک است که هر دو در این پژوهش استفاده شدند. در ANFIS پارامترهای مدل با دو روش پس انتشار خطا (به تنهایی) و روش ترکیبی (ترکیب با حداقل مربعات خطا) تنظیم می‌شوند که هر دو روش بهینه‌سازی استفاده شده‌اند. توضیح در این رابطه در Ghajar و Najafi (۲۰۱۴) موجود است. مدل‌های ANFIS در نرم‌افزار Matlab 2011 ساخته شد. به منظور ارزیابی قدرت تعمیم‌دهی (صحت‌سنجی) و همچنین اعتبار مدل، سه معیار ضریب تبیین (R^2)، مجذور میانگین مربعات خطا ($RMSE$) و میانگین قدر مطلق خطا (MAE) به کار گرفته شد (رابطه‌های ۱ تا ۳).

$$R^2 = \left[\frac{\sum_{i=1}^n (X_i^o - \bar{X}^o)(X_i^p - \bar{X}^p)}{\sqrt{\sum_{i=1}^n (X_i^o - \bar{X}^o)^2} \sqrt{\sum_{i=1}^n (X_i^p - \bar{X}^p)^2}} \right]^2 \quad \text{رابطه (۱)}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i^o - X_i^p)^2} \quad \text{رابطه (۲)}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i^o - X_i^p| \quad \text{رابطه (۳)}$$

درخت به‌عنوان خطا در نظر گرفته شد. عامل‌های مؤثر در نظر گرفته شده در خطای قطع شامل شیب زمین (Conway, 1982; Cedergren et al., 2002) به‌وسیله شیب‌سنج سونتو، انحراف درخت از حالت قائم (تمایل) (Conway, 1982) به‌وسیله شاقول و نقاله، قطر برابر سینه (Sobhani & Naeijnoori, 2006; Nikooy, 2007) به‌وسیله خط‌کش دو بازو، ارتفاع درخت به‌وسیله متر، زاویه دهانه بن‌زنی به‌وسیله نقاله، مساحت سطح بن‌زنی و بن‌بری (Conway, 1982; Siadati, 1997; Sarikhani, 2001) به‌وسیله شبکه نقاط و زوایای این سطوح در جهت موازی و عمود بر حاشیه برش به‌وسیله هیپسومتر و سطح پوسیدگی نیز به‌وسیله شبکه نقاط برای هر درخت اندازه‌گیری شدند و در فرم‌های مربوطه ثبت شدند.

به‌منظور جلوگیری از وراآموزی (حفظ کردن داده‌ها) و ارزیابی قدرت تعمیم‌دهی مدل با به‌کارگیری روش Cross-validation (Stone, 1974)، داده‌ها به سه مجموعه تقسیم شدند: ۱- مجموعه آموزشی که برای تنظیم وزن اتصالات در شبکه عصبی، توابع عضویت و پارامترهای مدل استفاده شد، ۲- مجموعه اعتبارسنجی که عملکرد مدل را در طول فرآیند آموزش پایش می‌کند، تعداد دورهای لازم برای فرآیند آموزش را تعیین می‌کند و باعث توقف آن می‌شود تا از وراآموزی جلوگیری کند، ۳- مجموعه آزمون که برای ارزیابی عملکرد و قدرت تعمیم‌دهی ANFIS آموزش‌یافته استفاده می‌شود. در این پژوهش ۷۰ درصد داده‌ها برای آموزش، ۲۰ درصد برای فرآیند اعتبارسنجی و ۱۰ درصد به‌عنوان مجموعه آزمون استفاده شد. طبق تنظیماتی که در برنامه انجام شد، به‌ازای هر ترکیب از الگوریتم‌های یادگیری، انواع استنتاج و انواع توابع عضویت متغیرهای ورودی، تقسیم داده‌ها به سه بخش به‌طور تصادفی انجام شد.

سیستم استنتاج عصبی - فازی تطبیقی (ANFIS)

سیستم عصبی - فازی تطبیقی Jang (۱۹۹۳) ترکیبی از شبکه عصبی مصنوعی و تئوری فازی است که فرآیند یادگیری طراحی شده در ساختار شبکه‌های عصبی را در

روش خوشه‌بندی کاهنده برای ساخت مدل استفاده شد، از میان مدل‌های مختلف ساخته‌شده، مدلی که بهترین نتایج را داشت، به‌عنوان مدل بهینه برای فرآیند تحلیل حساسیت به‌کار گرفته شد تا میزان تأثیر عامل‌های مختلف بر خطای قطع بررسی شود.

نتایج

نتایج مدل‌سازی میزان خطای قطع در جدول‌های ۱ و ۲ نشان داده شده است.

که n تعداد داده‌ها و X_i^p و X_i^o به ترتیب مقدارهای مشاهده‌شده و پیش‌بینی‌شده برای الگوی نام هستند. عملکرد بهتر مدل، هنگامی است که R^2 به یک و دیگر معیارها به صفر نزدیک‌تر باشند. Shahn و همکاران (۲۰۰۸) بیان کرده‌اند که هدف از صحت‌سنجی آن است که تضمین نماید مدل، به‌جای آنکه به‌طور ساده‌ای روابط ورودی-خروجی داده‌های آموزشی را حفظ نماید، قدرت تعمیم‌دهی در محدوده تعیین‌شده به‌وسیله داده‌های آموزشی را به‌طور نیرومندی داشته باشد. این موضوع به‌وسیله یک مجموعه مستقل از داده‌های آزمون که در فرآیند مدل‌سازی حضور نداشته است، انجام می‌شود. از آنجایی‌که در این مطالعه،

جدول ۱- نتایج الگوریتم پس انتشار خطا در مدل‌سازی خطای قطع

نوع تابع عضویت					شاخص‌های آماری	تابع استنتاج	الگوریتم آموزش
گوسی دو	گوسی	زنگوله‌ای	دوزنقه‌ای	مثلی			
۰/۹۹۹۸	۰/۹۹۹۹	۰/۹۹۹۹	۰/۹۹۹۹	۰/۹۹۹۹	R^2 آموزش		
۰/۹۷۷۴	۰/۹۸۱۹	۰/۹۶۱	۰/۹۶۸۸	۰/۹۴۶	R^2 اعتبارسنجی		
۱	۰/۹۵۶۶	۰/۹۸۴۵	۰/۹۹۹۱	۰/۹۹۹۸	R^2 آزمون		
۰/۰۰۲۷	۰/۰۰۲۹	۰/۰۰۲۶	۰/۰۰۲۵	۰/۰۰۲۶	RMSE آموزش	۳	
۰/۰۰۲۱۴	۰/۰۰۳۴۴	۰/۰۰۳۵۳	۰/۰۰۳۹۲	۰/۰۰۵۱۶	RMSE اعتبارسنجی	۳	
۰/۰۰۰۲	۰/۰۰۳۴۵	۰/۰۰۳۲۵	۰/۰۰۰۶۸	۰/۰۰۰۲۳	RMSE آزمون	۳	
۰/۰۰۰۲۲	۰/۰۰۰۱۸	۰/۰۰۰۱۹	۰/۰۰۰۱۳	۰/۰۰۰۱۶	MAE آموزش		
۰/۰۰۰۶	۰/۰۰۱۵۸	۰/۰۰۱۵۲	۰/۰۰۱۴۷	۰/۰۰۲۰۷	MAE اعتبارسنجی		
۰/۰۰۰۱۲	۰/۰۰۱۲۹	۰/۰۰۱۲۳	۰/۰۰۰۲۷	۰/۰۰۰۱۷	MAE آزمون		
۰/۹۹۹۹	۰/۹۹۹۹	۰/۹۹۹۸	۰/۹۹۹۹	۰/۹۹۹۹	R^2 آموزش		
۰/۹۳۰۴	۰/۹۹۸۸	۰/۹۷۵۵	۰/۰۹۶۶۶	۰/۹۱۰۹	R^2 اعتبارسنجی		
۰/۹۴۹۹	۰/۹۹۹۲	۰/۹۵۰۵	۱	۱	R^2 آزمون		
۰/۰۰۰۲۶	۰/۰۰۰۲۷	۰/۰۰۰۳	۰/۰۰۰۳	۰/۰۰۰۲۵	RMSE آموزش	۳	
۰/۰۰۴۷۲	۰/۰۰۰۶۹	۰/۰۰۳۲۴	۰/۰۰۳۳۵	۰/۰۰۷۹۲	RMSE اعتبارسنجی	۳	
۰/۰۰۸۹۵	۰/۰۱	۰/۰۰۳۰۶	*	۰/۰۰۰۱۴	RMSE آزمون	۳	
۰/۰۰۰۱۷	۰/۰۰۰۱۹	۰/۰۰۰۱۷	۰/۰۰۰۱۷	۰/۰۰۰۱۸	MAE آموزش		
۰/۰۰۱۶۲	۰/۰۰۰۲۹	۰/۰۰۱۱	۰/۰۰۱۲۹	۰/۰۰۳۷۷	MAE اعتبارسنجی		
۰/۰۰۶۰۵	۰/۰۰۰۴۷	۰/۰۰۱۰۷	*	۰/۰۰۰۱۱	MAE آزمون		

پس انتشار خطا

* صفرهای درون جدول با تقریب چهار رقم اعشار هستند.

جدول ۲- نتایج الگوریتم ترکیبی در مدل‌سازی خطای قطع

نوع تابع عضویت					شاخص‌های آماری	نوع استنتاج	الگوریتم آموزش
گوسی دو	گوسی	زنگوله‌ای	دوزنقه‌ای	مثلثی			
۱	۱	۱	۱	۱	R^2 آموزش		
۰/۹۶۱۷	۰/۹۱۶۹	۰/۹۸۸۴	۰/۹۴۶۶	۰/۹۵۷۹	R^2 اعتبارسنجی		
۰/۹۰۴۹	۰/۹۵۰۷	۰/۹۶۶۶	۰/۹۵۶۹	۰/۹۸۱۶	R^2 آزمون		
.	RMSE آموزش		
۰/۰۲۳۷	۰/۰۴۷۸	۰/۰۲۳	۰/۰۴۸۵	۰/۰۳۸۶	RMSE اعتبارسنجی	تابع درجه صفر	
۰/۰۵۴۵	۰/۰۵۱۵	۰/۰۳۳	۰/۰۴۴۳	۰/۰۳۸۶	RMSE آزمون		
.	MAE آموزش		
۰/۰۰۷۷	۰/۰۱۸۶	۰/۰۰۶۳	۰/۰۰۲	۰/۰۱۲۸	MAE اعتبارسنجی		
۰/۰۳۰۸	۰/۰۱۷۲	۰/۰۱۱	۰/۰۲۱۷	۰/۰۱۳۴	MAE آزمون		
					ترکیبی		
۱	۱	۱	۱	۱	R^2 آموزش		
۰/۹۸۴۳	۰/۹۸۶۷	۰/۴۳۷۴	۰/۹۷۸۲	۰/۴۶۳۳	R^2 اعتبارسنجی		
۰/۹۷۸۶	۰/۹۰۷۲	۰/۹۲۰۹	۰/۹۳۰۲	۰/۴۰۵۸	R^2 آزمون		
.	RMSE آموزش		
۰/۰۲۱۱	۰/۰۱۹۷	۰/۱۰۵	۰/۰۳	۰/۱۵۰۸	RMSE اعتبارسنجی	$\frac{R^2}{\sqrt{N}}$	
۰/۰۳۰۷	۰/۰۴۰۹	۰/۰۸۲۸	۰/۰۴۰۶	۰/۱۵۷۳	RMSE آزمون		
.	MAE آموزش		
۰/۰۰۴۸	۰/۰۰۶۴	۰/۰۵۴۸	۰/۰۱۰۲	۰/۰۸۶۲	MAE اعتبارسنجی		
۰/۰۱۰۲	۰/۰۱۵۹	۰/۰۳۶۴	۰/۰۱۳۵	۰/۰۸۶۶	MAE آزمون		

توابع به‌ویژه تابع گوسی دو بهترین عملکرد را داشته‌اند. میزان $RMSE$ و MAE در این تابع نیز کمتر از بقیه توابع به‌دست آمد، اما بهترین نتیجه به‌کارگیری الگوریتم یادگیری پس انتشار و تابع استنتاج درجه یک برای متغیر خروجی، هنگامی به‌دست آمد که توابع عضویت مثلثی و دوزنقه‌ای برای متغیرهای ورودی استفاده شد. از میان این توابع، تابع دوزنقه‌ای خطای کمتری را در برآورد مقادیر متغیر وابسته از خود نشان داد و میزان $RMSE$ و MAE آن کمتر از بقیه توابع بود.

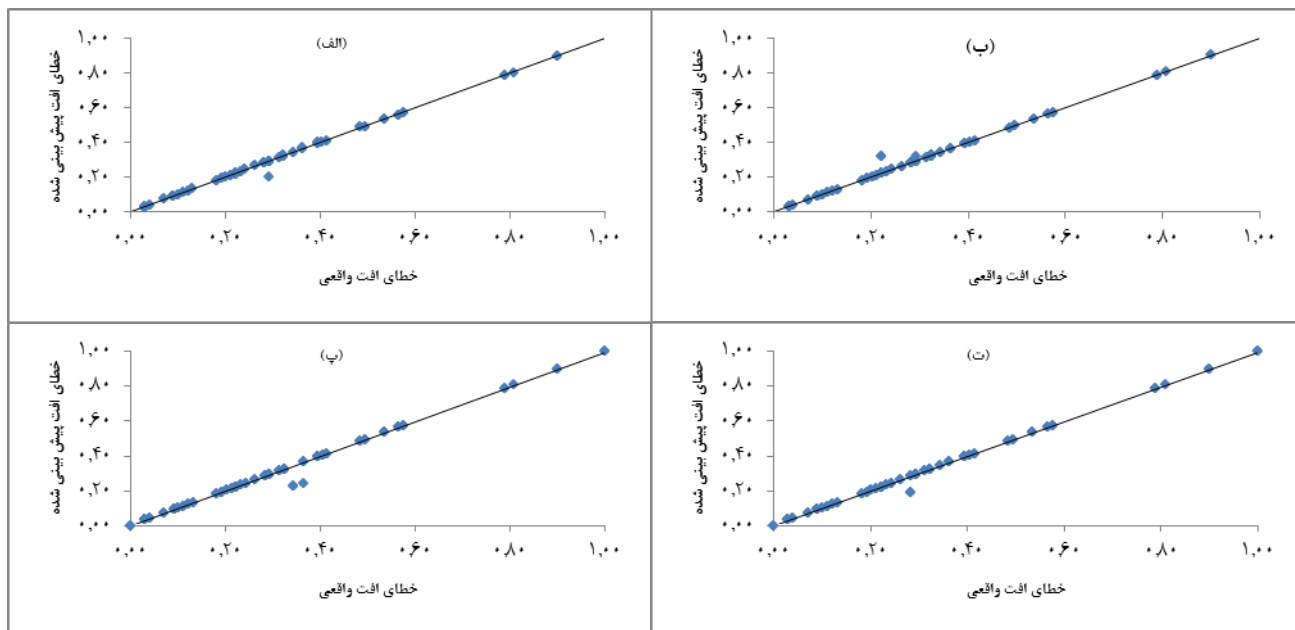
جدول ۲ نتایج به‌کارگیری الگوریتم ترکیبی در مدل‌سازی و پیش‌بینی مقادیر متغیر خروجی را نشان می‌دهد. یکی از عناصر دیداری قدرت برازش هر مدل، نمودار پلات کردن محاسبات مدل به‌ازای هر نمونه در برابر مقدار واقعی آن نمونه است که میزان قدرت پیش‌بینی مدل را

آماره‌های موجود در هر کدام از جدول‌های ۱ و ۲ در دو بخش کلی ارائه شده‌اند. بخش اول نتایج مدل‌ها با استفاده از تابع عضویت درجه صفر و بخش دوم نتایج استفاده از تابع عضویت درجه یک برای متغیر خروجی را نشان می‌دهد. در هر بخش، نتایج استفاده از پنج نوع تابع عضویت برای مجموعه متغیرهای ورودی به‌تفکیک داده‌های آموزشی، اعتبارسنجی و آزمون نشان داده شده است. معیار برتری مدل‌ها، نزدیک بودن و بیشتر بودن ضریب‌های تبیین هر سه دسته داده به‌خصوص داده‌های آزمون و کمترین اختلاف میان خطاهای (مجذور میانگین مربعات خطا و میانگین قدر مطلق خطا) داده‌های آموزشی، اعتبارسنجی و آزمون بود (Kermani, 2007).

نتایج مندرج در جدول ۱ نشان می‌دهد که با استفاده از الگوریتم پس انتشار خطا و تابع استنتاج درجه صفر، همه

انتشار خطا و ترکیبی به‌زای کل نمونه‌ها را در مقابل مقادیر واقعی خطای افت درخت نشان می‌دهد.

نشان می‌دهد. شکل ۱ مقادیر پیش‌بینی‌شده به‌وسیله مدل‌های ANFIS آموزش‌یافته به‌وسیله الگوریتم‌های پس

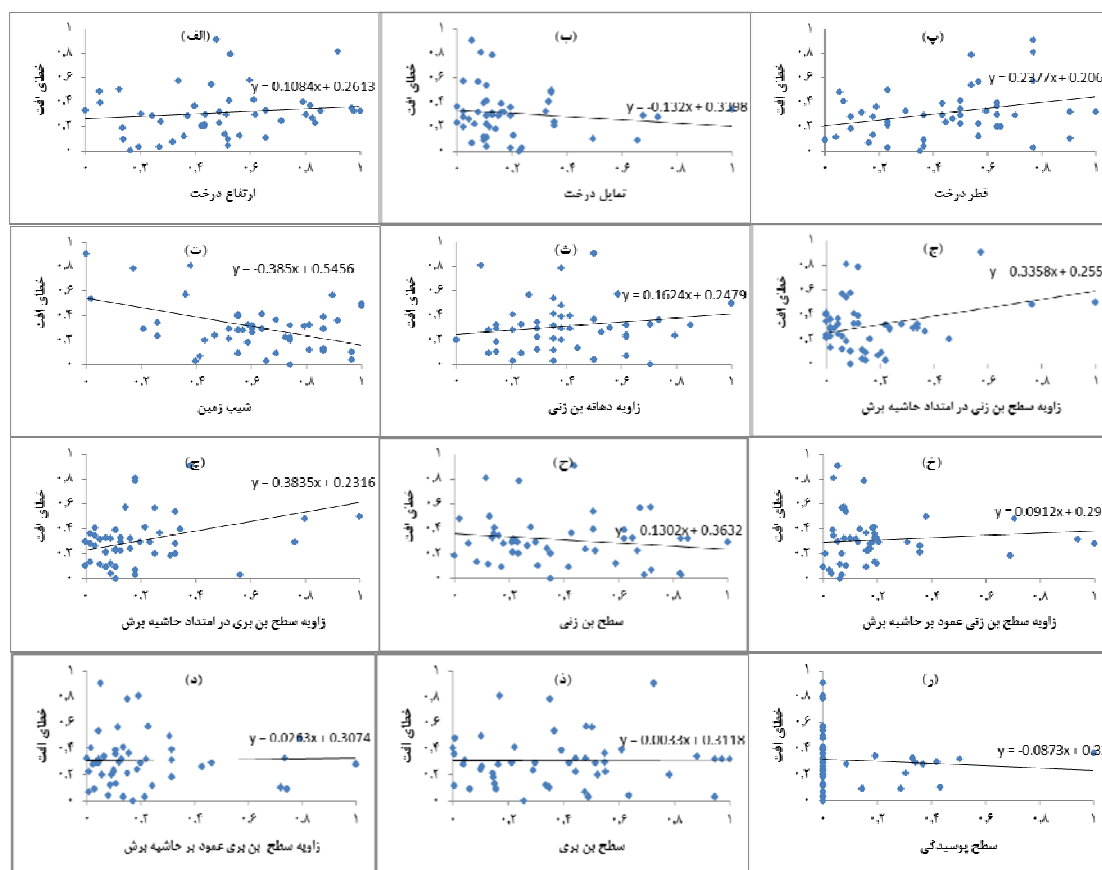


شکل ۱- مقادیر پیش‌بینی‌شده در مقابل مقادیر واقعی خطای افت درخت در مدل ANFIS آموزش‌یافته به‌وسیله الگوریتم‌های پس انتشار خطا (الف) و (ب) و ترکیبی (پ و ت)

دهانه بن‌زنی، تمایل درخت، مساحت سطح بن‌زنی و ارتفاع درخت بودند. با افزایش قطر و ارتفاع درخت و زاویه دهانه بن‌زنی، خطای افت افزایش پیدا کرد و با افزایش تمایل و مساحت سطح بن‌زنی، این خطا کاهش یافت. عامل‌های باقیمانده مورد بررسی شامل زاویه سطح بن‌زنی عمود بر حاشیه برش، مساحت سطح پوسیده، سطح بن‌بری عمود بر حاشیه برش و مساحت سطح بن‌بری در رده‌های پایانی قرار گرفتند. در میان عامل‌های اخیر، زاویه سطح بن‌زنی در جهت عمود بر حاشیه برش و مساحت سطح پوسیده، تأثیر بسیار کمی را بر خطا نشان دادند و دو عامل آخر تقریباً بی‌تأثیر بودند. افزایش زاویه سطح بن‌زنی در جهت عمود بر حاشیه برش، با افزایش خطای افت و افزایش سطح پوسیدگی، با کاهش خطای افت همراه بود.

تحلیل حساسیت

شکل ۲ تغییرات خطای افت محاسبه‌شده به‌وسیله مدل بهینه را نسبت به تغییرات هر یک از متغیرهای ورودی به‌طور مجزا نشان می‌دهد. شیب خط برازش در هر پلات می‌تواند نشانه‌ای از میزان تأثیر تغییر هر متغیر در تغییر متغیر خروجی باشد، به‌طوری‌که هرچه این شیب بیشتر باشد نشان می‌دهد که تأثیر آن متغیر در افزایش یا کاهش خطای افت بیشتر است. طبق نتایج به‌دست‌آمده از این نمودارها به‌ترتیب شیب زمین، زوایای سطح بن‌بری و بن‌زنی موازی با حاشیه برش، بیشترین تغییرات خطای افت را سبب شده‌اند. با افزایش شیب زمین، خطای افت کاهش پیدا کرد و با افزایش زوایای سطح بن‌بری و بن‌زنی در امتداد حاشیه برش، خطای افت افزایش یافت. عامل‌های مؤثر بعدی، قطر درخت، زاویه



شکل ۲- تحلیل حساسیت تغییرات خطای قطع به تغییرات متغیرهای مستقل مورد بررسی

بحث

زیاد به دلیل وراآموزی باشد، هم مقدار خطا بسیار زیاد به دست می آید و هم مقادیر پیش بینی مدل خارج از دامنه متغیر خروجی (صفر و یک) خواهد شد. شکل ۱ نشان می دهد که نتیجه خروجی مدل بین صفر و یک بود. موقعیت نقاط در نمودارهای شکل ۱ نشان می دهد که مقادیر محاسبه شده توسط مدلها با مقادیر واقعی خطای افت درخت تطابق به نسبت زیادی داشته است. غیر از تابع عضویت مثلثی در هنگام استفاده از الگوریتم یادگیری ترکیبی و تابع استنتاج درجه یک که نتیجه تقریباً نامناسبی را از نظر شاخصهای آماری به دست داد، بقیه ترکیبات توابع عضویت در قالب هر دو نوع الگوریتم یادگیری، نتایج قابل قبولی را ارائه دادند. جدا از شاخصهای آماری ارائه شده برای دادههای آموزشی، نتایج مدل سازی برای بخش دادههای اعتبارسنجی نشان داد که ضریبهای تبیین این بخش به طور تصادفی افزایش نیافته است، زیرا تحلیل این

نتایج به دست آمده از ارزیابی عملکرد مدل عصبی- فازی ساخته شده، دامنه مناسبی از پارامترهای آماری R^2 و $RMSE$ را نشان داد. نتایج پژوهش پیش رو پس از ۵۰ بار تکرار چرخه مدل سازی، ارزیابی مدل و برقراری این شرط که ضریب تبیین برای هر سه دسته داده بیشتر از ۰/۹ (به عنوان شرط توقف) باشد، به دست آمد. از این رو است که آزمایش اکثر ترکیبات توابع عضویت و انواع الگوریتمهای یادگیری پاسخ مناسبی را در برداشته اند و بیشتر مدل های ساخته شده قادر بودند بیشتر از ۹۰ درصد تغییرات متغیر وابسته (خطای قطع) را توصیف کنند. مقدار ضریب تبیین زیاد به دو دلیل نمی تواند به دلیل وراآموزی باشد. اول این که از مجموعه دادههای اعتبارسنجی استفاده شده است که این دادهها با ارزیابی همزمان فرآیند آموزش، مانع از حفظ کردن دادهها توسط مدل می شوند و دوم این که اگر ضریب تبیین

نیز با تأثیری نزدیک به عامل شیب، بیشترین تأثیر این بار منفی را در خطای افت نشان داد. همچنین زاویه سطح بن‌بری در امتداد حاشیه برش نیز سومین عامل مؤثر در خطای افت بود. تأثیر دو عامل اخیر نشان‌دهنده این موضوع است که قرار دادن دقیق افقی تیغه اره موتوری هنگام برش سطح بن‌زنی و همچنین بن‌بری می‌تواند در کاهش خطا بسیار مؤثر باشد. شیب خط برآزش مربوط به عامل قطر درخت نیز نشان می‌دهد که با افزایش قطر درخت، خطا نیز افزایش یافته است و عامل قطر، هرچند خارج از اختیار گروه قطع است، جزء عامل‌های مهم در خطا بوده است. این نتیجه با نتیجه تحقیق Krueger (۲۰۰۴) و Nikooy و همکاران (۲۰۱۳) همسو است. در مطالعه آنها نیز افزایش قطر با افزایش خطای گروه‌های قطع همراه بود. اهمیت تمایل درخت و مساحت سطح بن‌زنی در خطای افت هر چند کم، اما تقریباً یکسان برآورد شد. نکته قابل توجه آنکه با افزایش هر دو عامل، خطا کاهش یافت. از این نتیجه شاید بتوان چنین استنباط کرد که به دلیل تمایل درخت، گمان گروه‌های قطع در مورد جهت افتادن و انتخاب جهت افت درختان مختلف به درستی اتفاق افتاده است. افزایش مساحت سطح بن‌زنی به احتمال زیاد به دلیل آنکه باعث ایجاد حاشیه برش طولانی‌تری می‌شود، موجب ایجاد تکیه‌گاه قوی‌تر برای درخت و کاهش خطا شده است. تأثیر عامل‌های دیگر بسیار کم یا ناچیز بود و اطلاعات به‌دست‌آمده چندان قابل بحث و استناد نیست؛ از جمله این‌که تغییرات میزان خطای افت با توجه به تغییرات زاویه سطح بن‌بری عمود بر حاشیه برش و همچنین مساحت سطح بن‌بری نزدیک به صفر بود. یا این‌که با افزایش سطح پوسیدگی خطا کاهش یافته که چندان با حقایق علمی سازگار نیست. به دلیل اثرات متقابل عامل‌های مؤثر و همچنین تعداد کم درختان دارای پوسیدگی در نمونه‌های پژوهش پیش‌رو، چندان به تغییرات عامل‌ها نمی‌توان اعتماد کرد، اما می‌توان بیان کرد که چند عامل مهم نخست بیان‌شده در بخش نتایج و بحث نشان‌دهنده تغییرات قابل تأمل در اندازه خطای افت درخت بوده‌اند.

داده‌ها به صورت همزمان با آموزش ANFIS، منجر به قطع به‌موقع فرآیند آموزش و جلوگیری از ورآموزی و افزایش صحت مدل‌ها شد. دلیل این موضوع مقدار مناسب مقادیر ضریب تبیین برای داده‌های آزمون بود که ANFIS در هنگام آموزش آنها را ندیده بود. براساس رابطه‌های ۱ تا ۳، هنگامی که ضریب تبیین افزایش می‌یابد، اندازه انواع خطا (MAE و $RMSE$) کاهش می‌یابد. هر دو نوع خطا، هنگامی که متغیر خروجی مورد نظر پیوسته باشد، مطلوب هستند (Twomey & Smith, 1997). یکی از ویژگی‌های اصلی پارامتر $RMSE$ وزن دادن بسیار زیاد به نقاط پرت است (Bermejo & Cabestany, 2001)، به همین دلیل، در برآورد $RMSE$ ، توجه بیشتری به خطاهای بزرگ می‌شود. در مقابل، MAE بر خطاهای کوچک تأکید می‌کند و اثرات خطاهای بزرگ را حذف می‌کند.

هرچند تجربه نشان می‌دهد که تأثیر عامل‌های مختلف مورد بررسی در اندازه خطای افت درخت در عملیات قطع هدایت‌شده به‌طور پیچیده و با اثرات متقابل عامل‌ها است، اما تحلیل حساسیت خطای افت نسبت به تغییر عامل‌ها می‌تواند اطلاعات جدیدی را در اختیار گروه‌های عملیاتی قطع قرار دهد. بررسی این تغییرات با پلات کردن میزان خطای افت برآوردشده به‌وسیله مدل بهینه با هر یک از متغیرهای ورودی استانداردشده بین صفر و یک انجام شد تا قابل مقایسه باشند (شکل ۲). با توجه به نتایج به‌دست‌آمده از تحلیل حساسیت که تأثیر هر عامل بر تغییرات خطای افت درخت را به‌طور جداگانه بررسی کرده است، شیب زمین موجب بیشترین اثر منفرد بر خطای قطع بود و این عامل بیشترین تأثیر مثبت را در پیش‌بینی گروه‌های مختلف قطع در پژوهش پیش‌رو داشت. تأثیر مثبت شیب در اندازه خطا می‌تواند به دلیل تمایل درخت ناشی از شیب زمین و اطمینان بیشتر افراد گروه و ناظران از جهت افت حتمی درخت باشد، بنابراین این کاهش خطا به احتمال زیاد به دلیل انتخاب هوشمندانه جهت افت و نتیجه بدهی قطع از دیدگاه گروه قطع بوده است تا رعایت دقیق اصول قطع درخت. زاویه سطح بن‌زنی موازی با حاشیه برش

- Felling and skidding costs associated with thinning a commercial Appalachian hardwood stand in northern West Virginia. *Northern Journal of Applied Forestry*, 3: 159-163.
- Cedergren, J., Falck, J., Garcia, A., Goh, F. and Hagner M., 2002. Feasibility and usefulness of directional felling in a tropical rain forest. *Journal of Tropical Forest Science*, 14(2): 179-190.
 - Conway, S., 1982. *Logging Practices: Principles of Timber Harvesting Systems*. Miller Freeman, San Francisco, 416p.
 - Ershadifar, M., Nikooy, M. and Naghdi, R., 2011. Ability assessment of felling crew in directional felling in west forest of Guilan province. *Iranian Journal of Forest*, 3(2): 169-176 (In Persian).
 - FAO, 2004. *Reduced Impact Logging in Tropical Forests: Literature Synthesis, Analysis and Prototype Statistical Framework*. Forest Harvesting and Engineering Program, Rome.
 - Froese, K. and Han, H.S., 2006. Residual stand damage from cut-to-length thinning of a mixed conifer stand in northern Idaho. *Western Journal of Applied Forestry*, 21(3): 142-148.
 - Ghajar, I. and Najafi, A., 2014. Modeling the landslide susceptibility of a mountain forest using adaptive neuro-fuzzy inference system (ANFIS) for forest road planning. *Iranian Journal of Forest and Poplar Research*, 22(3): 509-526 (In Persian).
 - Ghajar, I., Najafi, A., Torabi, S.A., Khomehchiyan, M. and Boston, K., 2012. An adaptive network-based fuzzy inference system for rock share estimation in forest road construction. *Croatian Journal of Forest Engineering*, 33(2): 313-328.
 - Holmes, T.P., Blat, G.M., Zweede, J.C., Pereira, R., Barreto, P., Boltz, F. and Bauch, R., 2002. Financial and ecological indicators of reduced impact logging performance in the eastern Amazon. *Forest Ecology and Management*, 163: 93-110.
 - Jang, J.S., 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3): 665-685.
 - Karaman, A. and Caliskan, E., 2009. Affective factors weight estimation in tree felling time by artificial neural networks. *Expert Systems with Applications*, 36: 4491-4496.
 - Kermani, B.G., 2007. Modeling oligonucleotide probes for SNP genotyping assays using an
- با توجه به نتایج به دست آمده، تابع عضویت ذوزنقه‌ای برای متغیرهای ورودی در ترکیب با سیستم استنتاج سوگنو درجه یک و الگوریتم یادگیری پس انتشار خطا، بهترین پاسخ و عملکرد را نشان دادند. چنان‌که تشریح شد، به جز تابع عضویت مثلثی در ترکیب با استنتاج سوگنو مرتبه یک و روش بهینه‌سازی ترکیبی که نتیجه به نسبت ضعیفی را در تعداد تکرارهای مورد آزمایش در پژوهش پیش‌رو ارائه کرد، بیشتر مدل‌ها با تنظیمات دیگر نیز پاسخ‌های مناسبی را از نظر شاخص‌های آماری ارائه کردند. قابلیت تکرارپذیری در روش‌های مدل‌سازی تصادفی هدایت‌شده مانند ANFIS و تولید پاسخ‌های مختلف در دفعات مختلف اجرای برنامه، راه را برای آزمایش مدل‌سازی و ارزیابی آن به دفعات هموار می‌سازد. تولید وزن‌ها و بایاس‌های تصادفی برای شبکه عصبی موجود در ساختار ANFIS این شانس را به پژوهشگر می‌دهد که با هر بار اجرای برنامه، انتظار پاسخ مناسبی را داشته باشد. این نتایج پس از ۵۰ بار اجرای برنامه برای هر ترکیب به دست آمد. بدیهی است با در نظر گرفتن سناریوهای مختلف در مدل‌سازی می‌توان نتایج متفاوت و به احتمال زیاد بهتری را به دست آورد.

References

- Andrews, R., Diederich, J. and Tickle, A., 1995. A survey and critique of techniques for extracting rules from trained artificial neural networks. *Knowledge-Based Systems*, 8: 373-389.
- Appanah, S. and Weinland, G., 1990. Will the management systems for hill dipterocarp forests stand up?. *Journal of Tropical Forest Science*: 3(2): 140-158.
- Behjou, F.K., Majnounian, B., Dvorak, J., Namiranian, M., Saeed, A. and Fegghi, J., 2009. Productivity and cost of manual felling with chainsaw in Caspian forests. *Journal of Forest Science*, 55(2): 96-100.
- Bermejo, S. and Cabestany, J., 2001. Oriented principal component analysis for large margin classifiers. *Neural Networks*, 14(10): 1447-1461.
- Brock, S.M., Jones, K.D. and Miller, G.W., 1986.

- networks in geological engineering. *Electronic Journal of Geotechnical Engineering Bouquet*, 8: 1-26
- Shourmij, Y., 2009. Economical-environmental evaluation of felling component in two logging methods (traditional and planned) (the case study of district 3 .Nav-Asalem). M.Sc. thesis, Faculty of Natural Resources, University of Guilan, 91p (In Persian).
 - Siadati, M., 1997. *Correct Methods of Tree Felling*. Exploitation and Business Office of Forests. Published by Forests, Range and Watershed Management Organization, Tehran, 76p (In Persian).
 - Sobhani, H. and NaeijNouri, A., 2006. *Instruction of Determining Accumulation Places and Skidding Trail Networking*. Published by Forests, Range and Watershed Management Organization, Tehran, 221p (In Persian).
 - Stone, M., 1974. Cross-validatory choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B*, 36(2): 111-147.
 - Sugeno, M. and Kang, G.T., 1988. Structure identification of fuzzy model. *Fuzzy Sets Systems*, 28:15-33.
 - Takagi, T. and Sugeno, M., 1983. Derivation of fuzzy control rules from human operator's control action: 55-60. In: Sanchez, E., (Ed.). *Fuzzy Information, Knowledge Representation and Decision Analysis: Proceedings of the IFAC Symposium*. Oxford Press, Marseille, France.
 - Tsukamoto, Y., 1979. An approach to fuzzy reasoning method: 137-149. In: Gupta, M.M., Ragade, R.K. and Yager, R.R., (Eds.). *Advances in Fuzzy Set Theory and Applications*. Elsevier Press, Amsterdam.
 - Twomey, J.M. and Smith, A.E., 1997. Artificial neural networks for civil engineers: 44-64. In: Kartam, N., Flood, I. and Garrett, J.H., (Eds.). *Validation and Verification*. ASCE Press, New York.
 - Wang J., Charlie L., McNeel J. and Baumgras J., 2004. Productivity and cost of manual felling and cable skidding in central Appalachian hardwood forests. *Forest Products Journal*, 53: 47-53.
 - Zadeh, L.A., 1965. Fuzzy sets. *Information and Control*, 8: 338-353.
 - adaptive neuro-fuzzy inference system. *Sensors and Actuators*, 121: 462-468.
 - Krueger, W., 2004. Effects of future tree flagging and skid trail planning on conventional diameter-limit logging in a Bolivian tropical forest. *Forest Ecology and Management*, 188: 381-393.
 - Lortz, D., Kluender, R., McCoy, W., Stokes, B. and Klepac J., 1997. Manual felling time and productivity in southern forests. *Forest Products Journal*, 47: 59-63.
 - Lotfalian, M., 2012. *Logging*. Published by Ayiizh, Tehran, 488p (In Persian).
 - Magagnotti N. and Spinelli, R., 2012. *Good Practice Guidelines for Biomass Production Studies*. CVR Ivalsa, Sesto Fiorentino, 50p.
 - Mamdani, E.H. and Assilian, S., 1974. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1): 1-13.
 - Naghdi, R., Bagheri, I., Taheri Abkenar, K. and Akef, M., 2007. Evaluation of damage to stands (trees and regeneration) resulted from implementing log exploitation method in Shafaroud, Guilan. *Iranian Journal of Natural Resources*, 60(3): 931-947 (In Persian).
 - Nikooy, M., 2007. *Optimization of production costs and reducing logging damages in Caspian forests*. Ph.D. thesis, Faculty of Natural Resources, University of Tehran, Karaj, 214p (In Persian).
 - Nikooy, M., Naghdi, R. and Ershadifar, M., 2013. Survey of directional felling and analysis of effective factors on felling error (case study; Iranian Caspian forests). *Caspian Journal of Environmental Science*, 11(2): 177-184.
 - Nikooy, M., Rashidi, R. and Kocheiki, G., 2010. Residual trees injury after selective cutting in broadleaf forest in Shafaroud. *Caspian Journal of Environmental Science*, 8(2): 173-179.
 - Pinard, M.A., 1994. The reduced-impact logging project. *Tropical Forest Update*, 4(3): 11-12.
 - Roger, J.S. and Sun, C., 1993. Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Transaction Neural Network*, 4: 156-159.
 - Sarikhani, N., 2001. *Forest Utilization*. Tehran University Press, Tehran, 776p (In Persian).
 - Shahin, M.A., Jaksa, M.B. and Maier, H.R., 2008. State of the art of artificial neural

A neuro-fuzzy model of error in directional felling operation using the subtractive clustering method

I. Ghajar^{1*}, R. Naghdi² and M. Nikooy³

1* - Corresponding author, Assistant Prof., Department of Forestry, Faculty of Natural Resources, University of Guilan, Some`eh Sara, Iran. Email: i.ghajar@guilan.ac.ir

2- Associate Prof., Department of Forestry, Faculty of Natural Resources, University of Guilan, Some`eh Sara, Iran

3- Assistant Prof., Department of Forestry, Faculty of Natural Resources, University of Guilan, Some`eh Sara, Iran

Received: 09.11.2014

Accepted: 25.07.2015

Abstract

The study presents models of error estimation in trees' directional felling according to several effective factors using the subtractive clustering in the Adaptive Neuro-Fuzzy Inference System. A total number of 95 trees in the compartment 207 of 2nd district of Nav watershed in Guilan province were felled by felling group and regardless to the group's skill, using manual chainsaw. The difference between predicted and real falling direction of trees was measured as felling error. To generate models, twelve independent variables were assumed to be the effective factors, and the two types of learning algorithm (LA), two inference types (IT) and five types of membership function (MF) for input variables were applied through the subtractive clustering method in the ANFIS. Results indicated that the trapezoidal type of MF in combination with the first-order type of Sugeno IT and the back propagation LA had the best performance among all combinations of setting parameters. The sensitivity analysis of the optimal model showed that the model was very sensitive to the changes in terrain slope, the angles of backcut and undercut surfaces and DBH, respectively. Results also revealed that felling group properly predicted the fall direction and performed the directional felling in the steeper terrain. In addition, the increase of DBH and opening too much the undercut notch have accompanied with the increase of felling error.

Keywords: Chainsaw, membership function, Sugeno, ANFIS, cutting, soft computing.