

مدلسازی هوشمند منفرد (پرسپترون چند لایه) و ترکیبی (نروفازی) تخریب جنگل (محدوده: شهرستان ساری)

دریافت مقاله: ۹۷/۶/۱۹ پذیرش نهایی: ۹۸/۱۱/۲

صفحات: ۲۹۷-۳۱۳

سمیه مهرآبادی: کارشناسی ارشد سنجش از دور و GIS، فارغ التحصیل از دانشگاه تبریز، تبریز، ایران^۱

Email: somayeh.mehrabadi@yahoo.com

چکیده

روش‌های کلاسیک یا روشهای سخت بر دقیق بودن محاسبات، پایه‌گذاری شده‌اند درحالیکه دنیای واقعی بر نادقیق بودن مرزها و عدم قطعیت‌ها استوار است که بیشتر با روش‌های محاسبات نرم مطابقت دارد، که این روش‌ها نیز به تنهایی نقاط ضعف و قوتی دارند و برای رفع آنها تئوری پیوندزنی مطرح شد که با عنوان سیستم‌های ترکیبی هوشمند شناخته می‌شوند. در این تئوری دو یا چند روش هوشمند با یکدیگر ترکیب می‌شود تا کاستی‌ها و نواقص روش‌های منفرد رفع یا تعدیل گردد. در این مطالعه، تخریب جنگل با استفاده از شبکه عصبی پرسپترون و روش ترکیبی عصبی-فازی مدل‌سازی شده‌است. برای اینکار از تصاویر سنسور TM ماهواره لندست ۵ سال ۱۹۹۹ و سنسور OLI متعلق به لندست ۸ برای سال ۲۰۱۷ استفاده شد. از مناطق جنگلی تخریب شده و جنگل بدون تخریب در ۲۰۰ نقطه نمونه‌برداری شد. سپس ۷ فاکتور تخریب جنگل شامل: فاصله از عوارضی همچون (شهر-رودخانه-روستا-دریا-جاده)، ارتفاع و شیب برای ۲۰۰ نقطه محاسبه شد. برای ارزیابی عملکرد مدل‌ها از میانگین مربعات خطای استفاده شد که برای شبکه پرسپترون با سه الگوریتم Levenberg-Marquardt, Bayesian Regularization, Scaled Conjugate Gradient به ترتیب ۰,۰۵۳۵، ۰,۰۷۰۴ و ۰,۰۹۰۸ بدست آمد. MSE برای مدل عصبی-فازی با الگوریتم بهینه‌سازی و روش ترکیبی به ترتیب ۰,۰۱۹۰ و ۰,۰۱۰۲ محاسبه شد. تحلیل نتایج حاکی از عملکرد مطلوب مدل نروفازی در کاهش خطا و افزایش تعمیم‌پذیری می‌باشد. مدل نروفازی با تکیه بر قاعده عدم قطعیت شرایطی را ایجاد کرده که به واقعیت شباهت بیشتری داشته و نسبت به مدل پرسپترون در انتخاب داده‌ی مناسب موفق‌تر بوده‌است.

کلید واژگان: مدلسازی هوشمند، نروفازی، پرسپترون چند لایه، تخریب جنگل.

مقدمه

پروفسور زاده بنیان‌گذار تکنیک محاسبات نرم آنرا ترکیبی از روش‌ها به جهت مدل‌سازی و حل مسائل دنیای واقعی که نمی‌توانند (یا به‌سختی می‌توانند) با روش‌های سخت (ریاضی) مدل شوند معرفی می‌کند. (کاستلو^۱ و همکاران، ۲۰۰۵) چراکه اصل هدایت‌کننده محاسبات نرم بهره‌برداری از خاصیت عدم دقیق بودن جهت مهار کردن مساله و پایین آوردن هزینه راه حل است. روشهای سخت، برگرفته از رفتار ماشین هستند در حالی که شیوه‌های نرم به انسان و تدابیر اتخاذ شده از سوی ذهن او به منظور حل و فصل مسائل اختصاص پیدا می‌کنند. (منه‌اج، ۱۳۹۲) به عبارت دیگر، محاسبات نرم، مجموعه تکنیک‌های توسعه‌یافته در هوش مصنوعی^۲ و یادگیری ماشین^۳ می‌باشند که جهت مدل‌سازی و مطالعه پدیده‌های پیچیده (تحت تأثیر پدیده‌های بیرونی چندگانه) بکار می‌روند. (مهرآبادی و همکاران، ۱۳۹۴) تکنیک‌های هوش مصنوعی هر یک برای اهداف مشخص طراحی شده‌اند و نقاط ضعف و قوتی دارند که اگر به تنهایی استفاده شوند نمی‌توانند پاسخگوی کاملی برای پدیده‌ها در دنیای واقعی باشند. در مقابل روشهای ترکیبی^۴ هوشمند راه حل مناسبی برای همپوشانی این مدلها و رفع نقایص یکدیگر می‌باشند. بنابراین روش‌های ترکیبی یا پیوندزنی^۵ ایده مناسبی جهت غلبه بر ضعف‌های سیستم‌های منفرد است. بطور مثال با ترکیب دو روش شبکه عصبی و سیستم استنتاج فازی^۶ می‌توان مدلی را طراحی کرد تحت عنوان مدل نروفازی^۷ یا شبکه‌ی عصبی- فازی تطبیقی که در آن الگوریتم آموزشی شبکه عصبی تنظیم‌کننده پارامترهای فازی است. به این معنا که پارامترهای سیستم فازی بر اساس خطای شبکه‌ی عصبی تنظیم می‌شود و اینکار تاجایی ادامه می‌یابد تا مدل به شرایط بهینه^۸ و مناسب برسد. شبکه‌های عصبی مصنوعی^۹ ازجمله زیرمجموعه‌های محاسبات نرم است که با الگو برداری از مغز انسان الگوریتمی ارائه می‌کند که می‌تواند مانند انسان آموزش ببینند. این روشها با شناسایی الگوی رفتاری پدیده‌ها در طبیعت و ارائه مدلی مناسب از کنش و واکنش‌های موجود، به عنوان ابزار قدرتمندی جهت ارزیابی تغییرات در پدیده‌های پویا همچون جنگل‌ها مطرح می‌شوند.

از دهه ۱۹۵۰ ساختارهای گوناگون شبکه عصبی مصنوعی پیشنهاد و مورد استفاده قرار گرفت که پر کاربردترین آنها شامل شبکه‌های عصبی چندلایه انتشار به جلو است که تحت عنوان الگوریتم‌های پس انتشار خطا^{۱۰} شناخته می‌شوند. (روملهارت^{۱۱} و همکاران، ۱۹۸۶) شبکه‌های عصبی قادرند هر رابطه غیرخطی را بین متغیرهای وابسته و مستقل محاسبه کنند. (مس^{۱۲} و همکاران، ۲۰۰۴) در واقع آنها نوعی سیستم پردازش اطلاعات هستند که تعمیم‌یافته مدل‌های ریاضی و بر پایه‌ی زیست‌شناسی عصبی می‌باشند. (مهرآبادی و

1 Castillo

2 Artificial Intelligence

3 Machine Learning

4 Hybrid

5 Hybridization

6 Adaptive Neuro Fuzzy Inference system

7 Neuro Fuzzy

8 Optimal

9 Artificial Neural Network

10 Backpropagation

11 Rumelhart

12 Mas

همکاران، ۱۳۹۴) نصر و همکاران با هدف مدل‌سازی نیاز بیوشیمیایی اکسیژن گیاهان از شبکه عصبی پس انتشار خطا برای منطقه اسکندریه در مصر استفاده کردند. دقت بالای ۹۰٪ حاکی از قابلیت شبکه عصبی در پیش‌بینی عملکرد گیاهان و شبیه‌سازی رفتار غیرخطی آنها است. (نصر و همکاران، ۲۰۱۲) مس و همکاران در تحقیقی به ارزیابی نقشه ریسک تخریب با تخریب واقعی جنگل پرداختند که نتایج حاکی از ۶۹٪ صحت کلاس‌بندی شبکه سلول‌ها بود که این نتایج پتانسیل خوب شبکه عصبی پرسپترون در مدل‌سازی تغییر پوشش زمین را نشان می‌دهد. (مس و همکاران، ۲۰۰۴)

از جمله تحقیقات در حوزه روش‌های ترکیبی و فرا ابتکاری می‌توان به تحقیق سقط فروش و همکاران اشاره کرد که در آن عدم موفقیت روش‌های تجربی در ارائه راهکار مناسب جهت جلوگیری از بروز وقایع نامطلوب و ناخواسته پس از انفجار در معدن سنگ آهن دلکن بوده که ناشی از دخالت پارامترهای زیاد است. برای رفع این مشکل آنها از شبکه عصبی مصنوعی جهت پیش‌بینی و از الگوریتم کلونی مورچگان^۱ برای یافتن ترکیبی از داده‌های ورودی استفاده کردند تا عوارض نامطلوب ناشی از انفجار را به حداقل ممکن کاهش دهند. (سقط-فروش و همکاران، ۱۳۹۶) یتلمیزوی و همکاران پیشنهاد کردند که برای حل یک مساله محیطی باید مدل‌های مختلف هوش مصنوعی همزمان رفتارسازی شوند. آنها معتقدند روش‌های هوشمند قابلیت اجرایی ساده دارند و نیازی به تعریف روابط و معادلات پیچیده شیمیایی و ریاضات برای آنها نیست. (یتلمیزوی^۲ و همکاران، ۲۰۰۱) در تحقیقی دیگر پیش‌بینی روند تحول در جنگلداری با مقایسه مکانیزم‌های هوشمند محاسبات نرم (الگوریتم ژنتیک^۳، سیستم استنتاج فازی و برنامه‌نویسی^۴ ژنتیک) و سیستم اطلاعات جغرافیایی در سه منطقه ونزوئلا، فرانسه و گواتمالا انجام شد. مدل پیش‌بینی pre_ppcdam تخریب برای سال ۲۰۰۵ نسبت به ۲۰۰۲ انجام و نتایج مورد مقایسه قرار گرفت، نتایج حاکی از توان بالای روش‌های پیشنهادی آنها بود. (اسچالت^۵ و همکاران، ۲۰۰۹)

تقی‌زاده و همکاران با هدف پیش‌بینی شوری خاک در دو عمق ۳۰ و ۱۰۰ سانتیمتری از روش رگرسیون چند متغیره، شبکه عصبی، الگوریتم ژنتیک و نروفازی استفاده کردند که نتایج حاکی از برتری روش نروفازی بود. روش نروفازی در عمق ۳۰ سانتی‌متر ۱۷ درصد و در عمق ۱۰۰ سانتی‌متری ۱۱ درصد دقت بیشتری نسبت به روش رگرسیون داشته است. (تقی‌زاده مهرجردی و همکاران، ۱۳۹۲) مدل نروفازی نسبت به شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی مصرف انرژی کارایی بهتری داشته بطوریکه خطای استاندارد برای هر سه مدل به ترتیب ۰/۰۲، ۰/۰۲۱، ۰/۰۵ محاسبه شد که بهترین نتیجه متعلق به مدل نروفازی است. (بابایی میبدی و همکاران، ۱۳۹۱) به منظور پیش‌بینی یکساله خشکسالی شهر زاهدان از مدل عصبی- فازی و سری‌های زمانی استفاده شد. نتایج نشان داد هرچه بر تعداد قواعد فازی افزوده می‌شود مدل پیچیده‌تر شده و از کارایی آن کاسته می‌شود. نتایج پیش‌بینی حاکی از بی‌نظمی شدید در وقوع خشکسالی بود. (حسین‌پور نیکنام و همکاران، ۱۳۹۱) شبیه‌سازی دمای خاک با مدل نروفازی نشان داد دمای خاک و فاکتورهای آب و هوا با

1 Ant Colony Optimization algorithm

2 Yetilmezsoy

3 Genetic algorithm

4 Programming

5 Schultz

افزایش عمق خاک کاهش می‌یابد، و بین داده‌های خروجی مدل و مشاهدات واقعی در لایه‌های سطحی خاک سازگاری مناسب‌تری وجود دارد. (بهنیا و همکاران، ۲۰۱۷) تیتکانلو و همکاران از تئوری شواهد و ابزار فازی جهت مدل‌سازی عدم قطعیت در داده‌های نظرسنجی و قضاوت افراد در ارزیابی‌ها استفاده کردند. (ناهید تیتکانلو و همکاران، ۱۳۹۶)

اکبرزاده و همکاران از سه مدل نروفازی، شبکه عصبی مصنوعی و رگرسیون جهت تخمین فرسایش خاک استفاده کردند و نتایج نشان داد مدل نروفازی در تخمین فرسایش خاک نسبت به مدل عصبی مصنوعی و رگرسیون نتیجه بهتری ارائه کرده است. (اکبرزاده و همکاران، ۲۰۰۹) نیرثابتی و دیوبند تلاش کردند تا با ترکیب دو الگوریتم PSO^1 و GA^2 مشکل مینیمم محلی در شبکه نروفازی را با الگوریتم پس انتشار خطا رفع کنند. برای اینکار مدل نروفازی با چهار الگوریتم $PSO-GA-BP^3$ و الگوریتم ترکیبی $PSOGA$ آموزش دید که نتایج نشان داد الگوریتم ترکیبی $PSOGA$ در حل مشکل قرار گرفتن در شرایط مینیمم محلی موفق عمل کرده و کمترین خطا را بدست آورده که نتایج آن بدین شرح است، $PSOGA=0/02$ ، $BP=0/076$ ، $GA=0/127$ ، $PSO=0/07$ (نیرثابتی و دیوبند، ۲۰۱۵) الهموز و همکاران از روش آموزش Hybrid با هدف آموزش موبایل استفاده کردند که در آن مشکل تنظیم Rule ها توسط کاربر، رفع شده است. (الهموز^۴ و همکاران، ۲۰۱۲) نتایج تحقیق ییلدیریم و بایرامگل نیز نشان داد عملکرد الگوریتم Hybrid در آموزش شبکه نروفازی دقت بالاتری نسبت به سایر الگوریتم‌ها داشته است. (ییلدیریم^۵ و بایرامگل، ۲۰۰۶) در تحقیق حاضر مدل‌سازی تخریب جنگل در قالب مدل عصبی پرسپترون چندلایه^۶ بعنوان مدل منفرد، و مدل ترکیبی عصبی-فازی تطبیقی (نروفازی) برای شهرستان ساری اجرا شد. در این روش ترکیبی ضمن آموزش داده‌ها توسط شبکه عصبی، از یک سیستم استنتاج فازی برای حل مساله عدم قطعیت در رفتار جنگل استفاده شده است.

روش تحقیق

منطقه مورد مطالعه

هدف این تحقیق مدل‌سازی الگوی تخریب جنگل‌های شهرستان ساری، پر جمعیت‌ترین شهر (۵۰۴۲۹۸ نفر درگاه ملی آمار، سرشماری نفوس و مسکن ۱۳۹۵) و مرکز استان مازندران، می‌باشد. ساری در شمال ایران و بین دو ناحیه جغرافیای نوار جنوبی دریای خزر و رشته کوه البرز قرار دارد و به دلیل برخورداری از آب و هوای معتدل و نزدیکی به دریا و جنگل مورد توجه بسیاری از افراد با هدف گردشگری و سکونت قرار گرفته است. این شهرستان دربرگیرنده چهار مرکز شهری به نام‌های ساری، سورک، کیاسر و محمدآباد می‌باشد. شکل (۱) نقشه موقعیت جغرافیایی منطقه را مشخص می‌کند.

1 Particle Swarm Optimization

2 Genetic Algorithm


3 Back Propagation

4 Al-Hmouz

5 Yildirim

6 Multi-Layer Perceptron

7 <https://www.amar.org.ir>



شکل (۱). موقعیت جغرافیایی منطقه مورد مطالعه (شهرستان ساری)

داده‌ها

تصاویر ماهواره‌ای و داده‌های مورد استفاده در این تحقیق به این شرح است :

تصویر سنجنده TM لندست ۵ برای سال ۱۹۹۹ و تصویر سنجنده OLI ماهواره لندست ۸ برای سال ۲۰۱۷. قدرت تفکیک مکانی تصویر TM برای تمام باندها بجز باند ۶ برابر $۲۸/۵ * ۲۸/۵$ متر و برای باند ۶ برابر $۱۲۰ * ۱۲۰$ متر است. قدرت تفکیک رادیومتریک آن نیز ۸ بیت می‌باشد. قدرت تفکیک مکانی تصویر سنجنده OLI لندست ۸ برای باند ۱ تا ۷ و باند ۹ برابر ۳۰ متر، باند ۸ برابر ۱۵ متر و دو باند ۱۰ و ۱۱ که شامل محدوده طیفی مادون قرمز حرارتی هستند ۱۰۰ متر می‌باشد. قدرت تفکیک رادیومتریک این سنجنده ۱۲ بیت است. از این تصاویر با هدف کشف تغییرات طی ۱۸ سال و تولید نقشه جنگل و غیر جنگل منطقه استفاده شده است. از داده‌های به‌نگام شده سازمان نقشه‌برداری ایران در پیش‌پردازش تصاویر ماهواره‌ای و تولید پایگاه داده فضایی استفاده شده است. این نقشه‌ها برای محاسبه پارامترهایی همچون فاصله از (دریا، شهر، رودخانه، جاده و روستا) برای ۲۰۰ نقطه‌ی نمونه‌برداری شده، بکار گرفته شدند. ارتفاع و شیب نقاط نیز از لایه‌های مدل رقومی ارتفاع^۱ منطقه استخراج شدند. به این ترتیب پایگاه داده‌ای تولید شد که از آن بعنوان ورودی مدل پرسپترون چند لایه و نروفازی استفاده شد.

تعلق داده به بخش آموزش، تست و اعتبارسنجی در شبکه MLP توسط کاربر مشخص می‌شود که به ترتیب ۱۵-۷۰ درصد از کل داده می‌باشد. اما اینکه کدام داده به کدام بخش تعلق گیرد بطور خودکار و توسط

^۱ Digital Elevation Model

مدل عصبی تعیین می‌شود. در مقابل در شبکه عصبی-فازی تطبیقی همه این مراحل توسط کاربر تعیین می‌شود. درصد تعلق داده به بخشهای سه گانه آموزش، تست و داده‌های چک در مدل نروفازی به ترتیب ۱۴۰-۳۰-۳۰ ورودی از کل ۲۰۰ نمونه موجود انتخاب شده که جداگانه به مدل معرفی شدند. در این روش سعی شد تا در هر سه بخش داده‌ها از توازن مناسبی در مناطق تخریب شده و مناطق بدون تخریب برخوردار باشند. در جدول (۱) دامنه مقادیر (حداقل و حداکثر) محاسبه شده برای هفت پارامتر ارائه شده است.

جدول (۱). مقادیر کمینه و بیشینه محاسبه شده برای ۷ متغیر

مقادیر	ارتفاع (متر)	فاصله از دریا (متر)	فاصله از روستا (متر)	فاصله از رودخانه (متر)	فاصله از شهر (متر)	فاصله از جاده (متر)	شیب
حداکثر	۲۱۵۱	۸۷۵۳۱	۸۵۳۰	۳۹۸۲	۲۵۰۶۵	۱۶۳۳۵	۷۵
حداقل	۸۵	۲۸۲۹۹	۲۴۸	۱۴	۱۰۶۶	۲۳۵	۱


استخراج پوشش جنگلی

به منظور کاهش خطا در تحلیل تصاویر و استخراج بهینه داده از منطقه سعی شد تا تصویری انتخاب شود که پوشش ابر کمتری داشته باشد. تصاویر پس از انجام تصحیحات هندسی و رادیومتریک، با روش پیکسل پایه که اساسا برای تصاویر متوسط مقیاس طراحی شده‌اند طبقه‌بندی شدند. (شبان‌پور و همکاران، ۱۳۹۱) به این ترتیب تصاویر با روش نظارت شده و الگوریتم بیشترین شباهت^۱، به سه کلاس خاک، آب و گیاه دسته‌بندی شدند. و با تشکیل ماتریس خطا صحت عملیات طبقه‌بندی برای هر دو تصویر مورد ارزیابی قرار گرفت که نتایج حاکی از دقت بالای طبقه‌بندی بود. پارامتر دقت کلی برای سالهای ۱۳۸۷ و ۱۳۹۶ به ترتیب ۹۹/۲ و ۹۹/۷ بدست آمد.

پس از اطمینان از نتایج طبقه‌بندی، کلاس گیاه بعنوان پوشش گیاهی منطقه در محیط نرم‌افزار تحلیل مکانی GIS از سایر عوارض جدا شد. بعد از اینکار لایه جنگل نقشه‌های بهنگام شده سازمان نقشه‌برداری در دو مقیاس ۱/۵۰۰۰ و ۱/۲۵۰۰۰ جهت ارزیابی بصری خروجی طبقه‌بندی مورد استفاده قرار گرفت. سپس شاخص گیاهی تفاضلی نرمال شده^۲ با اعمال حد آستانه ($NDVI > 0.4$) برای لایه پوشش گیاهی محاسبه و به این ترتیب پوشش جنگل از پوشش گیاهی غیر جنگل همچون فضای سبز شهرها، چمن و... جدا شد. بدین ترتیب نقشه جنگل و غیر جنگل منطقه برای دو تصویر مذکور بدست آمد. به شکل (۲) مراجعه شود.

¹ Maximum Likelihood

² Normalized Difference Vegetation



شکل (۲). نقشه جنگل و غیر جنگل مستخرج از تصویر TM برای سال ۱۳۷۸ (سمت چپ) نقشه جنگل و غیر جنگل مستخرج از تصویر OLI برای سال ۱۳۹۶ (سمت راست)


پارامترهای تخریب جنگل

جنگل یک اکوسیستم پیچیده است که در درون خود و در ارتباط با دنیای بیرون تحت تأثیر عوامل متعددی می‌باشد. از سویی رشد و توسعه جوامع بشری در بخش صنعت، تجارت و گردشگری و وضعیت اقتصادی و فرهنگی برخی جوامع منجر به برداشت بی‌رویه از منابع جنگلی در دهه‌های اخیر شده‌است. در این مطالعه با توجه به شرایط اقتصادی، اجتماعی و فرهنگی منطقه و همچنین تحلیل مکانی تصاویر طبقه‌بندی شده با نقشه‌ی عوارض منطقه و با توجه به مطالعات پیشین در رابطه با علل تخریب جنگل‌ها، هفت فاکتور شامل (فاصله از (شهر-روستا-رودخانه-جاده و دریا) شیب و ارتفاع بعنوان متغیرهای تخریب جنگل انتخاب شد. از جمله مطالعاتی که در زمینه علل تخریب جنگل‌ها انجام شده می‌توان به مانیتورینگ جنگل‌های اندونزی اشاره کرد که نتایج حاکی از ارتباط جنگل‌زدایی با شیب و ارتفاع است. در این تحقیق مشخص شد بخش اعظم جنگل‌های باقیمانده در ارتفاع ۲۵۰ تا ۵۵۰ متر با شیب ملایم ۵-۱۸٪ می‌باشد. و تنها ۶٪ از جنگل‌های باقیمانده در ارتفاع زیر ۱۰۰ متر قرار دارند. (فیشرا، ۲۰۱۲) از علل کاهش جنگل در مرکز ایتالیا در ابعاد مکانی و زمانی، میتوان به فعالیت‌های استخراج چوب، آتش‌سوزی طبیعی، رفت‌وآمد کارکنان چوب‌بری، فرسایش خاک جنگل، گسترش مناطق شهری و واحدهای اداری اشاره کرد. (بورلی^۲ و همکاران، ۲۰۱۳) مدل‌سازی تخریب جنگل با رگرسیون لجستیک حکایت از معناداری برای پارامترهای شیب و فاصله از جاده و فاصله از اماکن مسکونی دارد. (پیرباوقار، ۲۰۱۵)

¹ Fisher

² Borrelli

در تحقیق حاضر به منظور تهیه داده مناسب برای مدل سازی و اندازه گیری متغیرهای تخریب تعداد ۲۰۰ نمونه از منطقه برداشت شد که از این تعداد ۱۰۰ نقطه از مناطقی است که طی سالهای ۱۳۷۸ الی ۱۳۹۶ در آنجا جنگل تخریب شده و ۱۰۰ نمونه نیز از جنگل بدون تخریب برداشت شده است. بدین ترتیب لایه نقطه‌ای برای ۲۰۰ نقطه تشکیل شد که تمامی هفت پارامتر مذکور در محیط GIS برای این نقاط اندازه گیری شد. برای این کار از لایه رقومی ارتفاع، لایه وکتوری عوارض شامل (شهر، روستا، جاده، رودخانه، دریا)، لایه شیب و جهت شیب منطقه استفاده شده است. شکل (۳) توزیع فضایی پارامترهای مذکور نسبت به نقاط نمونه برداری شده را نشان می دهد.



شکل (۳). لایه های ارتفاع، شیب و نمایش فضایی فاصله از عوارض (شهر، دریا، رودخانه، جاده)

مدل سازی

نمایش مجرد یا فیزیکی یک شیء یا سیستم از یک نگاه خاص را مدل گویند. (منهاج، ۱۳۹۳) در این تحقیق تخریب جنگل یک بار با شبکه عصبی پرسپترون چند لایه بعنوان یک مدل منفرد و بار دیگر با روش ترکیبی عصبی-فازی تطبیقی مدلسازی شد.

شبکه عصبی پرسپترون چند لایه

شبکه‌های عصبی مصنوعی، روش مطلوبی برای طبقه‌بندی کاربری و پوشش اراضی هستند و برای انواع داده‌ها در مقیاس‌های آماری مختلف قابل استفاده‌اند. (احمدی ندوشن و همکاران، ۱۳۸۸) در شبکه عصبی پرسپترون چند لایه پردازش داده توسط تابع فعال‌سازی یا تابع انتقال انجام می‌شود که تعیین می‌کند یک نورون با چه قدرتی و چه کیفیتی سیگنال را به نورون بعدی باید انتقال دهد. (مهرآبادی، ۲۰۱۸) در طراحی شبکه MLP در این مطالعه از تابع فعال‌سازی سیگموئید (تک قطبی که نتایج آن همیشه مثبت است) برای لایه پنهان و برای لایه خروجی از تابع خطی استفاده شده که یک تابع دو قطبی است و پاسخ‌های مثبت و منفی تولید می‌کند. تنظیم پارامترهای شبکه عصبی مساله اصلی در طراحی مدل است (بشیری و فرشیا ف گرنامه، ۲۰۱۱) و انتخاب الگوریتم آموزشی فاکتور تعیین کننده صحت و دقت شبکه‌ی عصبی است که به هدف کاربر وابسته است. (محمود و همکاران، ۲۰۰۷) در این مقاله برای طراحی شبکه پرسپترون چند لایه از سه الگوریتم آموزشی Levenberg-Marquardt, Bayesian Regularization, Scaled Conjugate Gradient استفاده شده‌است. پارامتر دیگری که در طراحی مدل بهینه، تعداد نورون لایه پنهان می‌باشد. بطوریکه اگر مدل در شرایط تطبیق همه مراحل آموزش باشد و با وجود کاهش زیاد خطا، کاهش تعداد نورون منجر به برازش نامناسب و اصطلاحاً برازش کم^۱ می‌شود. در مقابل افزایش تعداد نورون پدیده برازش بیش از حد^۲ را بدنبال دارد. (یتیلیمزوی و همکاران، ۲۰۰۱) ترکیب داده در بخش آموزش، تست و اعتبارسنجی فاکتور دیگر معماری شبکه پرسپترون است (مهرآبادی، ۲۰۱۸) که در این مقاله به ترتیب ۷۰-۱۵-۱۵ درصد از کل داده‌ها برای هر یک در نظر گرفته شد. در نهایت میانگین مربعات خطا^۳ بعنوان شاخص عملکرد مدل محاسبه شد.

مدل ترکیبی عصبی-فازی تطبیقی (نروفازی)

تعیین بهینه تعداد قواعد سیستم فازی یک چالش در طراحی این سیستم‌ها است. بویژه اگر با حجم بالایی از داده آموزشی مواجه باشیم، افزایش تعداد قواعد حجم محاسبات را بالا برده درحالی که بسیاری از این قوانین غیر ضروری بوده و عملاً کارایی ندارند. بنابراین سیستم فازی نیازمند استفاده از روشی است تا با تعریف کمترین تعداد قواعد فازی و کاهش توابع عضویت بتواند مدلی بهینه را ارائه دهد. شبکه عصبی-فازی روشی است جهت هوشمندسازی فرآیند تنظیم قواعد فازی و تعیین بهینه توابع عضویت در یک سیستم فازی، که برای اینکار از تکنیک یادگیری ماشین و داده کاوی^۴ استفاده می‌کند.

در پژوهش حاضر یک سیستم فازی طراحی شد که با دو الگوریتم بهینه‌ساز پس انتشار و ترکیبی آموزش داده می‌شود که شامل چهار مرحله اصلی به شرح زیر است. ۱- عملیات فازی‌سازی^۵ - ۲- استلزام^۶ یا ارزیابی قواعد^۷

¹ Underfitting

² Overfitting

³ Mean Square Error


⁴ Data Mining

⁵ Fuzzification

⁶ Implication

⁷ Rules

فازی ۳- مرحله نافازی سازی^۱ ۴- اعتبارسنجی مدل نروفازی. فازی سازی با روش تاکاگی-سوگنو (TSK) اجرا شد که در آن تعامل بین ورودی و خروجی یک رابطه فازی نیست بلکه تابعی است از ورودیها بر پایه ی خوشه بندی کاهشی^۲، که بر اساس شباهت بین ورودی ها آنها را دسته بندی کرده و قواعد را برای هر دسته تعریف می کند. به عبارت بهتر روش خوشه بندی با داده کاوی میان ورودی ها برای ایجاد قواعد سیستم فازی تصمیم گیری می کند. در شکل (۴) دیاگرام نحوه ایجاد قواعد (Rules) در یک سیستم فازی تاکاگی سوگنو ارائه شده است.



شکل (۴). دیاگرام مراحل ایجاد قواعد فازی در یک سیستم فازی تاکاگی سوگنو

پس از طراحی سیستم استنتاج فازی و آموزش آن در قالب یک مدل عصبی نوبت به اعتبارسنجی و ارزیابی مدل است که با داده های چک انجام می شود. میزان تعلق داده به بخش آموزش شامل ۱۴۰ نمونه، ۳۰ نمونه برای بخش تست و ۳۰ نمونه دیگر بعنوان داده چک در نظر گرفته شد که برای هر کدام نیمی از داده ها متعلق به مناطق تخریب شده و نیمی دیگر از مناطق بدون تخریب می باشد.

نتایج

نتایج شبکه عصبی پرسپترون چند لایه

در این مقاله شبکه عصبی پرسپترون سه لایه با یک لایه ورودی، یک لایه پنهان و یک لایه خروجی طراحی شد که به هر یک به ترتیب تعداد ۶، ۷ و ۱ نورون تعلق گرفت. شاخص عملکرد میانگین مربعات خطا برای سه الگوریتم بکار رفته در جدول (۲) ارائه شده است.


¹ Defuzzification

² Subtractive Clustering

جدول (۲). خطای بدست آمده در شبکه پرسپترون با سه الگوریتم انتخابی

الگوریتم آموزشی	MSE
Levenberg Marquardt	۰/۰۳۵۲۷
Bayesian Regularization	۰/۰۷۰۴۶۲
Scaled Conjugate Gradient	۰/۰۹۰۸۲۵

همانطور که در جدول ۲ مشاهده می‌شود الگوریتم آموزشی Levenberg-Marquardt در کمینه‌سازی خطا از دو الگوریتم دیگر موفق‌تر بوده است. اگرچه این الگوریتم برای حل مسائل ساده طراحی شده و در اجرای مدل زمان کمتری را صرف می‌کند، برای برازش الگوی داده پیچیده کارایی لازم را ندارد. (مهرآبادی، ۲۰۱۸) شکل (۵) نمودار خطای هر سه الگوریتم را نشان می‌دهد. منحنی خطای Levenberg-Marquardt به خوبی همگرا نشده و مدل از تعمیم‌پذیری پایینی برخوردار است. در مقابل خطای Bayesian Regularization مدلی با تعمیم‌پذیری مناسب را نشان می‌دهد. در الگوریتم Scaled Conjugate Gradient تعمیم‌پذیری درحالی حاصل شده‌است که مدل بیشترین خطا را دارد.



شکل (۵). نمودار MSE برای Levenberg-Marquardt, Bayesian Regularization, Scaled Conjugate Gradient

نتایج مدل عصبی-فازی تطبیقی (نروفازی)

در این روش خوشه‌بندی کاهشی با داده‌کاوی محل پیچیدگی قواعد را به نحو شایسته تشخیص داده و قواعد را استخراج می‌کند. با بررسی ارتباط متغیرها با پدیده تخریب مشخص شد پارامترهای همچون فاصله از عوارضی مانند جاده، شهر، دریا و رودخانه رابطه‌ی منفی با تخریب جنگل دارند. بطوریکه با کم شدن فاصله این عوارض از جنگل تخریب افزایش و با افزایش فاصله از این عوارض تخریب کاهش می‌یابد تا جایی که دیگر فاصله تاثیر نداشته و به وضعیت پایدار (در اینجا منظور جنگل بدون تخریب) می‌رسد. در رابطه با ارتفاع نیز نتایج مشابه فاکتور فاصله بود و با افزایش ارتفاع از حجم تخریب کاسته شده و تا جایی تخریب ادامه دارد که دیگر افزایش ارتفاع تاثیری بر کاهش پوشش جنگل ندارد. (در اینجا بدون تخریب) به همین خاطر برای پارامترهای مذکور از تابع عضویت نوع zmf^1 استفاده شد. در تحلیل شیب مشخص شد تخریب جنگل با کاهش شیب افزایش دارد و با افزایش آن تخریب روند کاهشی را دنبال می‌کند تا جایی که این افزایش شیب دیگر برای رویش گیاه مناسب نبوده و پوشش گیاهی حذف می‌شود. (ارتفاعات با شیب تند) بنابراین برای شیب از دو نوع تابع عضویت zmf و smf^2 استفاده شد.


سیستم فازی قواعد اولیه‌ای را تولید می‌کند که با ارزیابی درجه صحت قواعد ایجاد شده آنهایی که اضافه هستند یا اثر چندانی در تصمیم‌گیری‌ها ندارند حذف شده و آنهایی که بیشترین تطابق را با الگوی داده دارند انتخاب می‌شوند، که به این مرحله اعتبارسنجی قواعد فازی یا استلزام گویند. در این تحقیق صحت سنجی قواعد فازی با روش ضرب ممدانی انجام شد و در نهایت ۱۳ قاعده یا قانون فازی انتخاب شد. پس از آن نوبت به مرحله نافازی‌سازی می‌رسد که در این مرحله وزن‌های تولید شده توسط سیستم فازی نرمال‌سازی شده و وزن مناسب برای آن ایجاد می‌شود، سپس میانگین‌گیری وزنی یا همان قاعده مرکز ثقل اعمال شده و به این ترتیب خروجی وزن‌دار بدست می‌آید. در نهایت بالاترین وزن بدست آمده بعنوان خروجی در نظر گرفته شد، که به این مرحله جمع‌بندی^۳ گویند که با روش MAX اجرا شد. پس از آن سیستم فازی با دو روش بهینه‌ساز Backpropagation و Hybrid آموزش داده شد که هر دو الگوریتم تحت تاثیر تعداد قواعد فازی بوده و به روش انتخاب شده در طراحی سیستم فازی (در اینجا خوشه‌بندی کاهشی) وابسته است. نتایج دو الگوریتم با استفاده از شاخص میانگین مربعات خطا و مجذور میانگین مربعات خطا^۴ مورد ارزیابی قرار گرفت. نتایج این ارزیابی‌ها در جدول (۳) ارائه شده است.

جدول (۳). معماری مدل نروفازی با دو الگوریتم آموزشی و خطای محاسبه شده برای مدل نروفازی


الگوریتم بهینه‌سازی	مجذور میانگین مربعات خطا RMSE	میانگین مربعات خطا MSE	حد آستانه (حداکثر خطای قابل قبول)	مراحل آموزش مدل
Hybrid	۰/۱۰۱۴	۰/۰۱۰۲	۰/۰۰۱	۱۰۰
پس انتشار خطا	۰/۱۳۲۸	۰/۰۱۹۰	۰/۰۰۱	۱۰۰

¹ Z-Shaped Membership Function² S-Shaped Membership Function³ Aggregation⁴ Root Mean Square Deviation


مدل نروفازی با مجموعه داده آموزشی ایجاد شد و ارزیابی آن با داده‌های تست انجام شد و مدل توانست به بهینه‌سازی مطلوبی آنهم با اختلاف اندک خطا برای هر دو الگوریتم Backpropagation و Hybrid دست‌یابد. تفاوت این دو الگوریتم در نحوه محاسبه خطا است بطوریکه در روش پس انتشار وزن‌ها بطور تصادفی انتخاب و با توجه به خروجی تعریف شده وزن‌های جدید ایجاد می‌شوند. درحالیکه در روش ترکیبی علاوه بر تطبیق‌پذیری وزن‌ها با خروجی، فاکتور کمترین مربعات برای تنظیم وزن‌ها اعمال شده است. برای مشاهده نتایج به شکل‌های (۶ و ۷) مراجعه شود. در کنار داده تست اعتبارسنجی مدل با داده‌ی چک نیز انجام شد که برای دیدن نتایج آن می‌توانید به شکل‌های (۸ و ۹) مراجعه نمایید.



شکل (۶). خطای الگوریتم Hybrid




شکل (۷). خطای مدل با الگوریتم Backpropagation



شکل (۸). اعتبارسنجی مدل با الگوریتم Hybrid

همانطور که در شکل (۸) مشخص است خطای سیستم فازی و داده‌های چک برای الگوریتم Hybrid ثابت مانده است که این بیانگر عملکرد یکسان آنها می‌باشد. میانگین مربعات خطا برای داده چک برابر 0.9820 و

برای سیستم فازی آموزش دیده با الگوریتم ترکیبی برابر $0/0102$ بدست آمده است. از آنجا که فرض استفاده از داده چک بر کاهش خطا است، زمانی که مدل در شرایط برازش بیش از حد قرار می‌گیرد خطای داده چک بطور ناگهانی افزایش می‌یابد. همانطور که در تصویر مشاهده می‌شود خطا برای داده چک افزایش دارد اما این افزایش برای تمام مراحل آموزشی یکسان می‌باشد. بنابراین فرض قرار گرفتن در شرایط مینیمم محلی در مجموعه داده منتفی است. نکته‌ی دیگری که در تحلیل نتایج مدل نروفازی باید به آن توجه شود نسبت بین حجم داده با پارامترهای تنظیم مدل است بطوریکه خطای بالای داده‌های چک در الگوریتم Hybrid به دلیل تعداد نمونه کمتر نسبت با پارامترهای تنظیم مدل نروفازی است. ترکیب تعداد ۷ متغیر و ۱۳ تابع عضویت موجب شده تا پارامترهای تنظیم مدل نروفازی افزایش یابد.



شکل (۹). اعتبارسنجی مدل با الگوریتم Backpropagation

همانطور که در شکل (۹) مشخص است با اینکه خطای محاسبه شده برای داده چک از خطای الگوریتم Backpropagation بیشتر است اما از مرحله^۱ دوم به بعد روند رو به کاهش داشته و این حاکی از عملکرد مناسب مدل طراحی شده با الگوریتم پس انتشار است. در این آزمون مقدار میانگین مربعات خطا برای داده چک $0/2696$ و برای سیستم فازی آموزش دیده $0/0190$ بدست آمد.

نتیجه‌گیری

یکی از تفاوت‌های شبکه عصبی MLP و مدل نروفازی نحوه محاسبه خطای مدل است. در مدل پرسپترون چند لایه خطا با آموزش داده‌ها و تولید خروجی وزن‌دار و محاسبه اختلاف خروجی تولید شده با خروجی هدف، برآورد می‌شود. درحالی‌که در روش نروفازی از یادگیری ماشین و قابلیت سیستم‌های فازی برای تصمیم‌گیری در شرایط عدم قطعیت و ارزیابی عملکرد مدل استفاده می‌شود. در مدل ترکیبی سیستم فازی یاد می‌گیرد چگونه از بین قوانین و روابط متعددی که بین متغیرها برقرار می‌کند آنهایی را که بیشترین اثرگذاری را بر رفتار پدیده دارند از بین حجم بالای قواعدی ایجاد شده شناسایی و انتخاب کند. با این کار هزینه محاسباتی کاهش می‌یابد.

¹ Epoch

شاخص میانگین مربعات خطا (MSE) در مدل پرسپترون برای سه الگوریتم Levenberg-Marquardt و Bayesian Regularization و Scaled Conjugate Gradient به ترتیب ۰/۰۵۳۵۲۷، ۰/۰۷۰۴۶۲ و ۰/۰۹۰۸۲۵ بدست آمد. مدل نروفازی با دو شاخص RMSE و MSE با دو الگوریتم Hybrid و Backpropagation محاسبه شد که برای MSE به ترتیب ۰/۰۱۰۲ و ۰/۰۱۹۰ و برای شاخص RMSE به ترتیب ۰/۱۰۱۴ و ۰/۱۳۲۸ می باشد. بنابراین میتوان گفت مدل نروفازی قدرت بیشتری در کمینه سازی خطا نسبت به شبکه پرسپترون داشته است. روشهای ترکیبی به کاربر این امکان را می دهند تا در طراحی مدل هوشمند و بهینه آزادانه تر عمل نموده و با ترکیب تکنیک های مختلف هوش مصنوعی ایرادات وارده بر مدل های منفرد را برطرف کنند. از سیستم های ترکیبی هوشمند می توان برای پیش بینی سری های زمانی بویژه در زمینه منابع طبیعی استفاده کرد.

منابع

- احمدی ندوشن، مژگان؛ سفیانیان، علیرضا؛ خواجه الدین، سید جمال الدین. (۱۳۸۸). تهیه نقشه پوشش اراضی اراک با استفاده از روشهای طبقه بندی شبکه عصبی مصنوعی و حداکثر احتمال، نشریه پژوهشهای جغرافیای طبیعی، ۸۳-۸۹.
- بابایی میبدی، حمید؛ طحاری مهرجردی، محمدحسین؛ تقی زاده مهرجردی، روح الله. (۱۳۹۱). بررسی کارایی مدل های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش بینی مصرف انرژی کشور، نشریه پژوهشنامه اقتصادی (رویکرد اسلامی- ایرانی)، ۱(۴۶)، ۴۳-۶۴.
- تقی زاده مهرجردی، روح الله؛ سرمیدیان، فریدون؛ ثوابقی، علامرضا؛ امید، محمود؛ تومانیان، نورایر. (۱۳۹۲). مقایسه روش های نروفازی، الگوریتم ژنتیک، شبکه عصبی و رگرسیون چند متغیره در پیش بینی شوری خاک (مطالعه موردی: شهرستان اردکان)، نشریه مرتع و آبخیزداری، ۶۶(۲۰)، ۲۰۷-۲۲۲.
- حسین پور نیکنام، حسین؛ اژدری مقدم، مهدی؛ خسروی، محمود. (۱۳۹۱). پیش بینی خشکسالی یکساله با استفاده از مدل فازی-عصبی، سری های زمانی خشکسالی و شاخصهای اقلیمی (مطالعه موردی: زاهدان)، نشریه آب و فاضلاب، ۲۳(۲)، ۴-۵۱.
- سقطفروش، امیر؛ منجزی، مسعود؛ خادمی حمیدی، جعفر. (۱۳۹۶). بهینه سازی عملیات انفجار با استفاده از روش ترکیبی عصبی-مورچگان (مطالعه موردی: معدن سنگ آهن دلکن)، نشریه مدل سازی در مهندسی، ۱۵(۴۸)، ۲۶۹-۲۵۹.
- شبانای پور، مهرنوش؛ درویش صفت، علی اصغر؛ رفیعیان، امید؛ اعتماد، وحید. (۱۳۹۱) بررسی امکان تشخیص گونه های درختی در تصاویر هوایی رقومی به روش طبقه بندی شیء پایه، نشریه جنگل و فرآورده های چوب، مجله منابع طبیعی. ۲۱-۳۲.
- مهرآبادی، سمیه؛ فرنود احمدی، فرشید؛ روستایی، شهرام. « استفاده از تکنیک محاسبات نرم به منظور تلفیق قابلیت های سیستم اطلاعات جغرافیایی و سنجش از دور جهت پایش و پیش بینی تخریب جنگل (مطالعه موردی جنگلهای شمال ایران)»، کارشناسی ارشد، سنجش از دور و GIS، دانشگاه تبریز- (۱۳۹۴)

- منهاج، محمد باقر. (۱۳۹۳). **هوش محاسباتی**، دانشگاه صنعتی امیرکبیر، جلد ۱.
- ناهیدتیتکانلو، حسین؛ فکری، رکسانا؛ کرامتی، عباس. (۱۳۹۶). **مدلسازی عدم قطعیت در فرایند ارزیابی عملکرد کارکنان مبتنی بر تئوری شواهد و تئوری فازی**، نشریه مدل سازی در مهندسی، ۱۵(۵۱)، ۲۴-۳۴.
- Akbarzadeh A, Taghizadeh Mehrjardi R, Rouhipour H, Gorji M, and Refahi H.G. 2009. **Estimating of Soil Erosion Covered with Rolled Erosion Control Systems Using Rainfall Simulator (Neuro-fuzzy and Artificial Neural Network Approaches)**, Journal of Applied Sciences Research, 5(5), 505-514.
- Al-Hmouz A, Shen J, Member Senior I, Al-Hmouz R, and Yan J. 012. **Modeling and Simulation of an Adaptive Neuro-Fuzzy Inference System (ANFIS) for Mobile Learning**, IEEE Transactions On Learning Technologies, 5(3), 226-237.
- Bashiri M, and FarshbafGeranmayeh A. 2011. **Tuning the parameters of an artificial neural network using central composite design and genetic algorithm**, Scientia Iranica, 18(6), 1600-1608.
- Behnia M, Akbari Valani H, Bameri M, Jabalbarez B, and Eskandari Damaneh H. 2017. **Potential Assessment of ANNs and Adaptative Neuro Fuzzy Inference systems (ANFIS) for Simulating Soil Temperature at diffrent Soil Profile Depths**, International Journal of Advanced Biological and Biomedical Research, 6(1), 416-423.
- Borrelli P, Sandia Rondón A, Schütt B. 2013. **The use of Landsat imagery to assess large-scale forest cover changes in space and time, minimizing false-positive changes**, Applied Geography, 41, 147-157.
- Castillo O, Melin P, Kacprzyk J, Pedrycz W. 2005. **Soft Computing for Hybrid Intelligent Systems**, Springer.
- Fisher R. 2012. **Tropical forest monitoring, combining satellite and social data, to inform management and livelihood implications: Case studies from Indonesian West Timor**, International Journal of Applied Earth Observation and Geoinformation, 16, 77-84.
- Mahmoud O, Farhat A, Momoh J, and Salami E. 2007. **Lerning Algorithm Effect On Multilayer Feed Forward Artificial Neural Network Performance In Image Coding**, Journal of Engineering Science and Technology, 2(2), 188-199.
- Mas J.F, Puig H, Palacio J.L, Sosa-Lo'pez A. 2004. **Modelling deforestation using GIS and artificial neural networks**, Environmental Modelling & Software, 19(5), 461-471.
- Mehrabadi S. 2018. **Changes in Artificial Neural Network Learning Parameters and Their Impact on Modeling Error Reduction**, Journal of Algorithms and Computation, 50(2), 141 – 155.
- Nasr S.M, Moustafa Medhat A.E, Seif H.A.E, Kobrosy G. 2012. **Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT**, Alexandria Engineering Journal, 51(1), 37-43.
- Nayyer Sabeti S.M, and Deevband MR. 2015. **Hybrid Evolutionary Algorithms based on PSO-GA for Training ANFIS Structure**, IJCSI International Journal of Computer Science Issues, 12.
- Pir Bavaghar M. 2015. **Deforestation modelling using logistic regression and GIS**, Journal Of Forest Science, 61(5), 193–199.
- Rumelhart D. E, Hinton G. E, Williams R. J. 1986. **Learning Internal Representations By Error Propagation**, MIT Press Cambridge, 1, 318-362.
- Schultz R.E.O, Centeno T M, Selleron G, Delgado M.R, **A soft computing-based approach to spatio-temporal prediction**, International Journal of Approximate Reasoning, 50(1), 3-20.

- Yetilmezsoy K, Bestamin O, Mehmet C. 2011. **Artificial Intelligence-Based Prediction Models For Environmental Engineering**, ICS AS CR Istanbul, Turkey, 3(11), 193-218.
- Yildirim Y, and Bayramoglu M. 2006. **Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldak**, Chemosphere, 63(9), 1575 – 1582.