

مدل‌سازی زوال درختان بلوط با استفاده از شبکه‌های عصبی مصنوعی

علی اصغر آل‌شیخ^۱

سعید مهری^۲

تاریخ دریافت مقاله: ۹۶/۰۶/۲۵

تاریخ پذیرش مقاله: ۹۶/۱۰/۱۶

چکیده

جنگل‌های زاگرس بیشترین تأثیر را در تأمین آب، حفظ خاک و تعدیل آب و هوای کشور دارد. با این وجود بخش قابل توجهی از این جنگل‌ها دچار پدیده‌ی زوال درختان بلوط شده است. مشخص نبودن پارامترهای مؤثر در زوال و نحوه‌ی ارتباط پارامترها، از جمله عواملی هستند که باعث سخت‌تر شدن شناخت و مدل‌سازی این پدیده می‌شود. هدف این پژوهش تعیین پارامترهای تأثیرگذار برای مدل‌سازی زوال درختان بلوط و مدل‌سازی این پدیده با استفاده از شبکه‌های عصبی مصنوعی در استان لرستان است. در این پژوهش، پارامترهای دما، بارش، ارتفاع، شیب، جهت، نوع خاک و میزان ریزگردها به‌عنوان پارامترهای اولیه انتخاب شدند. همچنین از عملگرهای ضرب، لگاریتم، تبدیلات هذلولی و آنالیز مؤلفه‌های اصلی برای ترکیب پارامترها استفاده شد. به دلیل معلوم نبودن نحوه‌ی ارتباط و میزان اثر هر پارامتر، از شبکه‌های عصبی مصنوعی برای مدل‌سازی پدیده زوال استفاده شد. در مجموع ۳۸۵ ترکیب مختلف از پارامترهای اولیه، با استفاده از عملگرهای فوق تولید و در سه معماری پیش‌خور با سه لایه پنهان، احتمالاتی و معماری ماشین بردار پشتیبان در شبکه‌های عصبی، (در مجموع تعداد ۱۱۵۵ شبکه‌ی عصبی) ارزیابی شد. نتایج ارزیابی نشان داد معماری احتمالاتی ($R=0/87$) با ورودی‌های ارتفاع، جهت، شیب، ریزگرد، نوع خاک و مؤلفه‌ی اصلی (بارش و دما) بهترین عملکرد را در مدل‌سازی زوال درختان بلوط دارد. با توجه به نتایج، استفاده از شبکه‌های عصبی مصنوعی احتمالاتی در شرایط عدم قطعیت و وجود دانش جزئی از پدیده، توصیه می‌شود. همچنین نتایج نشان دادند که استفاده از مؤلفه‌ی اصلی پارامترهای دما و بارش، استرس ناشی از خشکی را بهتر مدل می‌کند. استفاده از ترکیب بهینه‌ی پارامترها، در مدل احتمالاتی نسبت به ترکیب عادی، باعث افزایش ۰/۰۵ ضریب همبستگی شد.

واژه‌های کلیدی: آنالیز مؤلفه‌های اصلی، بلوط، جنگل‌های زاگرس، زوال، شبکه عصبی مصنوعی، ماشین بردار پشتیبان.

۱- استاد، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران. (نویسنده مسئول) alesheikh@kntu.ac.ir
۲- دانشجوی دکتری مهندسی سیستم اطلاعات مکانی (GIS)، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران. sa.mehri20@yahoo.com

مقدمه

محیطی است. اولین چالش در زمینه مدل‌سازی زوال درختان بلوط تعیین پارامترهای محیطی بهینه برای مدل‌سازی است؛ چالش دیگر، انتخاب روش مدل‌سازی است. زیرا ارتباط پارامترهای محیطی پیچیده و غیرخطی بوده (Lek et al. 1996) و مکانیسم و نحوه‌ی ارتباط پارامترها (Ahmadi et al. 2014) نیز نامشخص است. نوآوری تحقیق حاضر تعیین پارامترهای مؤثر در زوال درختان بلوط از طریق مرور تحقیقات مرتبط با آفات، بیماری‌ها و عوامل ایجاد ضعف و زوال در درختان بلوط و همچنین تعیین پارامترهای بهینه برای مدل‌سازی زوال درختان بلوط است. طبق تحقیقات منتشر شده تا هنگام نگارش این مقاله، استفاده از شبکه‌های عصبی مصنوعی به شیوه این مقاله، در مدل‌سازی درختان بلوط برای اولین بار مطرح می‌گردد.

در تحقیقات موجود، برای مدل‌سازی پدیده‌ی زوال، غالباً از زمین‌آمار (احمدی و همکاران، ۱۳۹۵؛ Köhl & Gertner, 1997) و تحلیل سلسله مراتبی استفاده شده است (Ahmadi et al. 2014). از دهه ۱۹۹۰ میلادی، برای مدل‌سازی فرایندهایی با پیچیدگی‌های بالا، از هوش مصنوعی استفاده شد. شبکه‌های عصبی مصنوعی، مبتنی بر هوش مصنوعی بوده و نسبت به مدل‌های ریاضی سنتی دو مزیت دارد: (۱) در مرحله‌ی آموزش، مدل تخمین زده می‌شود؛ (۲) می‌توان با آموزش دوباره شبکه با داده‌های بهتر، مدل را بهبود داد. در شبکه‌ها عصبی مصنوعی، مدل مناسب در مرحله‌ی یادگیری، از طریق ارائه‌ی مثال و بدون نیاز به درک فرایندهای داخلی تعیین می‌شود (بیات و همکاران، ۱۳۹۵). در این روش، برخلاف روش‌های دیگر مانند زمین‌آمار، هیچ فرضی درباره توزیع اولیه‌ی داده‌ها وجود ندارد. شبکه‌های عصبی قادرند داده‌ها و اطلاعات مختلف که از منابع مختلفی تهیه شده‌اند را با هم ترکیب کنند (Rosa, 2013).

ویژگی‌های شبکه‌های عصبی و چالش‌های موجود در مدل‌سازی این پدیده (مشخص نبودن ارتباط بین پارامترها، وزن هر پارامتر، تهیه شدن اطلاعات و داده‌ها از منابع مختلف با ویژگی‌های متفاوت) سبب شد تا در این تحقیق از این روش برای مدل‌سازی پدیده زوال درختان بلوط

رویشگاه زاگرس از شمال غربی کشور تا استان فارس در منطقه‌ای به طول ۱۳۰۰ و عرض متوسط ۲۰۰ کیلومتر گسترده شده است (طالبی و همکاران، ۱۳۸۵) و حدود ۴۰ درصد از کل جنگل‌های ایران را شامل می‌شود (عطارد و همکاران، ۱۳۹۴). این زیستگاه علاوه بر اینکه بیشترین تأثیر را در حفظ خاک دارد، حدود ۴۵ درصد آب کشور را نیز تأمین می‌کند (Taghimollaei & Karamshahi, 2017).

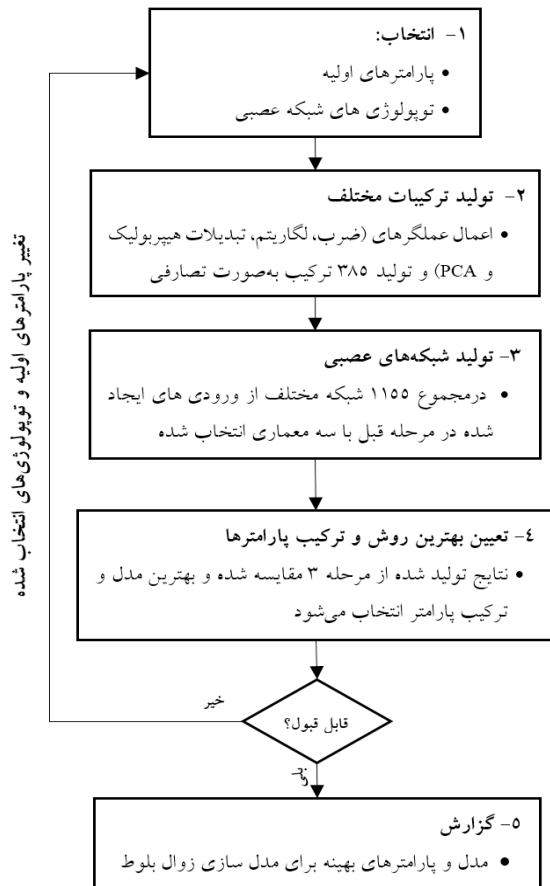
سازند جنگلی بلوط (Quercus) مهم‌ترین و گسترده‌ترین سازند جنگلی ایران و زاگرس است. گونه‌های مختلف بلوط زاگرس را به دو بخش تقسیم می‌کنند. زاگرس شمالی رویشگاه ویژه بلوط دارمازو (Q. infectoria) است؛ که البته گونه‌های ویول یا بلوط لبنانی (Q. libani) و بلوط ایرانی (Q. brantii) نیز در این منطقه مشاهده می‌شود. زاگرس جنوبی رویشگاه ویژه بلوط ایرانی است. عوامل متعدد طبیعی و انسانی باعث خسارت به جنگل‌های زاگرس شده است (طالبی و همکاران، ۱۳۸۵). کاهش منابع آبی و فرسایش خاک پیامدهای ناشی از تخریب این جنگل‌ها هستند که جبران آن‌ها تقریباً به دور از توان انسان است. زوال بلوط از مشکلات اساسی در جنگل‌های بلوط بوده (حسینی و همکاران، ۲۰۰۴؛ ۱۳۹۲، Jönsson) و در بیشتر نقاط جهان مانند اروپا (Ferreira et al. 2000, Costa et al. 2010) امریکای شمالی (Kabrick et al. 2008, Costa et al. 2010) شایع است. در ایران، این پدیده در سال ۱۳۸۷ در جنگل‌های استان‌های ایلام و لرستان گزارش شد (میرابوالفتحی، ۱۳۹۲). گستره‌ی وسیعی از جنگل‌های زاگرس دچار زوال شده است (کریمی و همکاران، ۱۳۹۶؛ عزیری و همکاران، ۱۳۹۴)؛ بنابراین داشتن مدل مناسب به‌منظور پیش‌بینی این پدیده و همچنین به‌عنوان ابزاری جهت پشتیبانی تصمیم‌گیری ضروری است (Köhl & Gertner 1997).

پدیده زوال با کاهش قدرت درخت، افزایش تنش‌های کاراندام‌شناسی (Physiological stress) و تهاجم آفات و بیماری‌های مختلف، شایع می‌گردد (حسینی، ۱۳۹۰؛ حسینی و همکاران، ۲۰۰۰؛ ۱۳۹۲، Ferreira et al.). زوال تابع پارامترهای

جدول ۱) پارامترهای محیطی اولیه و اثر آن‌ها بر درخت بلوط

پارامتر	اثرات سو در درخت	تحقیقات
دما	کاهش رطوبت در دسترس و ایجاد تنش خشکی مرگ‌ومیر دانه‌های مولد گسترش بیماری زغالی	(Ahmadi et al. 2014; Corcobado et al. 2014; Martín García et al. 2015; عطار و همکاران 139، عطار و همکاران 139)
ریز گرد	اختلال در فتوسنتز و کاهش قدرت درخت	(Ahmadi et al., 2014)
بارش	مساعد شدن شرایط رشد و گسترش بیماری زغالی کاهش رطوبت در دسترس و ایجاد تنش خشکی مرگ‌ومیر دانه‌های مولد و تغییر الگوی پراکنش افزایش فشار رقابتی رشد قارچ‌های بیماری‌زا	(Jönsson, 2004; Kabrick et al. 2008; Costa et al. 2010; Corcobado et al. 2014; Godinho et al. 2016; Ahmadi et al. 2014; حسینی و همکاران، 2016؛ عطار و همکاران، 1394؛ عزیری و همکاران، 1394)
ارتفاع	کاهش رطوبت در دسترس و ایجاد تنش خشکی تغییر الگوی پراکنش کاهش قدرت درخت افزایش فشار رقابتی	(حسینی، 1390؛ کرمی و همکاران، 1394؛ مهدوی و همکاران، 1394)
شیب	مساعد شدن شرایط رشد و گسترش بیماری زغالی کاهش میزان رطوبت و ایجاد تنش خشکی افزایش رشد قارچ‌های بیماری‌زا تغییر الگوی پراکنش کاهش قدرت درخت افزایش فشار رقابتی	(Costa et al. 2010; Ahmadi et al. 2014); کرمی و همکاران، 1395؛ مهدوی و همکاران، 1394؛ احمدی و همکاران، 1395)
جهت	کاهش میزان رطوبت و ایجاد تنش خشکی کاهش میزان نور در دسترس درخت افزایش رشد قارچ‌های بیماری‌زا تغییر الگوی پراکنش درختان کاهش میزان تجدید درختان تضعیف ویژگی کمی و قدرت درخت تغییر ویژگی‌های خاک افزایش فشار رقابتی	(Costa et al. 2010; Ahmadi et al. 2014; حسینی، 1390؛ حسینی و همکاران، 1392؛ مهدوی و همکاران، 1394؛ احمدی و همکاران، 1395)
نوع خاک	کاهش میزان رطوبت و ایجاد تنش خشکی کاهش قدرت درخت تغییر الگوی پراکنش کامبود مواد مغذی مورد نیاز درخت	(Jönsson, 2004; Kabrick et al. 2008; Costa et al. 2010; Godinho et al. 2016; مهدوی و همکاران، 1394)

استفاده گردد. بهترین مدل و ترکیب شناسایی و گزارش شد.



استان لرستان نیز به دلیل دارا بودن حدود یک میلیون و ۲۳۰ هزار هکتار جنگل و شایع بودن پدیده مرگ‌ومیر درختان بلوط در جنگل‌های این استان (عزیری و همکاران، ۱۳۹۴؛ میرابوالفتحی، ۱۳۹۲)، به عنوان منطقه‌ی مطالعاتی انتخاب شد. در این تحقیق سه معماری پیش‌خور با سه لایه پنهان، احتمالاتی و معماری ماشین بردار پشتیبان در شبکه‌های عصبی مصنوعی بررسی شد. به منظور تعیین اثرگذارترین پارامترهای محیطی در زوال درختان بلوط ابتدا تحقیقات موجود در رابطه با بیماری‌ها و آفات که باعث زوال درختان بلوط می‌شوند بررسی شد که نشان داد در مجموع هفت پارامتر محیطی شامل، میزان ریزگردها، دما، میزان بارش، ارتفاع، شیب، جهت و نوع خاک در زوال درختان بلوط یا ایجاد بیماری‌ها و یا تشدید آفاتی که باعث مرگ‌ومیر درختان بلوط می‌شوند، اثرگذار هستند.

این هفت پارامتر به عنوان پارامترهای اولیه انتخاب و در فرایند تعیین پارامترهای با اثرگذاری بالا (پارامترهای بهینه‌ی مدل‌سازی) استفاده شدند. در جدول یک، پارامترهای اولیه و اثرات سوء تغییر هر پارامتر در حیات درختان بیان شد.

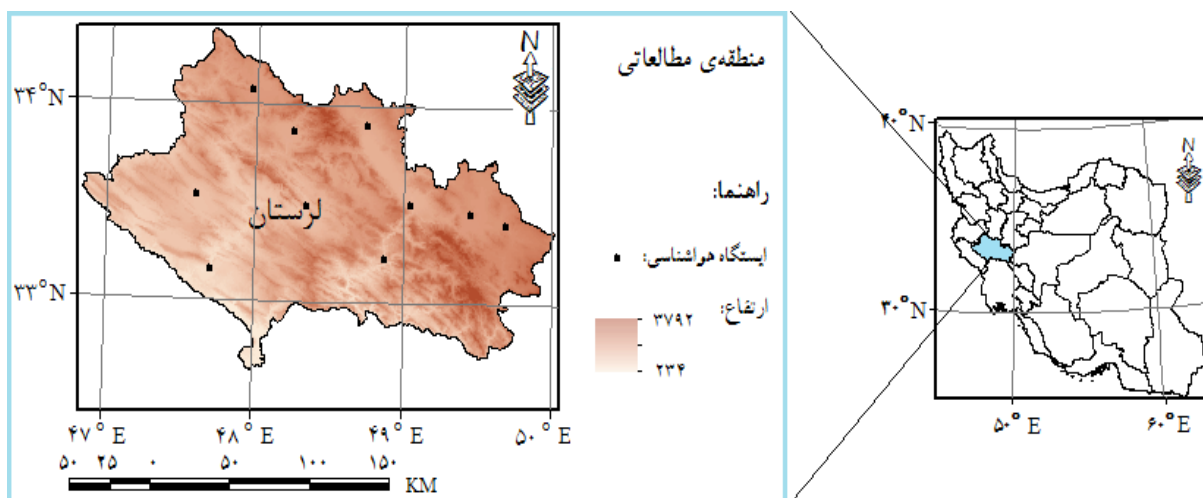
مواد و روش‌ها

تحقیق حاضر در پنج مرحله کلی انجام شده است (نگاره ۱). ابتدا پارامترهای اولیه تحقیق با بررسی تحقیقات مختلف مرتبط با درختان بلوط انتخاب شد. همچنین سعی شد تا با مروری جامع بر تحقیقات مرتبط با عوامل بیماری‌زا و آفات، تمامی پارامترهای محیطی که در ایجاد یا تشدید این عوامل مؤثر است شناسایی گردد. با بررسی معماری‌های مختلف سه معماری از شبکه‌های عصبی انتخاب شد. در مرحله بعد با استفاده از عملگرهای ضرب، لگاریتم، توابع هیپربولیک و PCA تعداد ۳۸۵ ترکیب مختلف از پارامترهای انتخاب و تولید شد. در مرحله سوم ۱۱۵۵ شبکه مختلف با استفاده از ورودی‌های تولید شده در مرحله دوم با سه معماری انتخاب گردیده، آموزش ارزیابی و صحت‌سنجی انجام شد. سپس

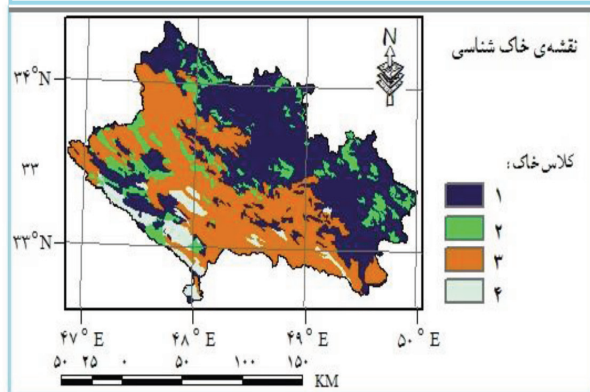
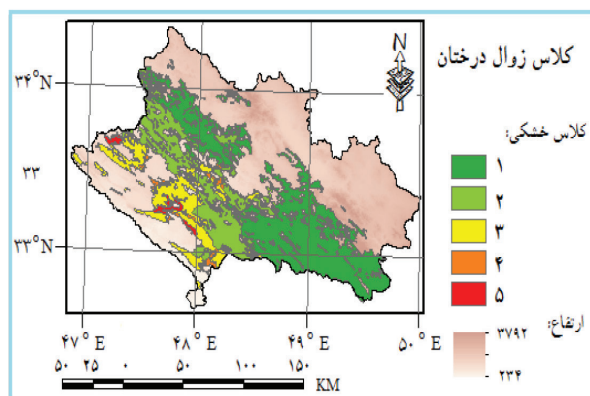
نگاره ۱: مراحل اجرای تحقیق

منطقه و داده‌های تحقیق

استان لرستان به عنوان محدوده‌ی مورد مطالعه انتخاب شده است (نگاره ۲). این استان با دارا بودن حدود یک میلیون و ۲۳۰ هزار هکتار جنگل، در محدوده‌ی طول جغرافیایی ۵۱° ۴۱' تا ۵۱° ۲۶' درجه‌ی شرقی و عرض جغرافیایی ۳۷° ۲۳' تا ۳۲° ۳۴' درجه‌ی شمالی قرار دارد. مساحت استان ۲۸۵۵۹ کیلومترمربع است. حداقل ارتفاع منطقه ۲۳۴ متر و حداکثر ارتفاع منطقه ۳۷۹۲ متر از سطح دریا است. بلوط ایرانی گونه‌ی غالب جنگل‌های این استان است (میرابوالفتحی، ۱۳۹۲). در این تحقیق از مدل ارتفاعی رقومی، داده‌های ایستگاه‌های هواشناسی (نگاره ۲) که شامل داده‌های دما،



نگاره ۲: محدوده‌ی استان لرستان به همراه مدل ارتفاعی رقومی و ایستگاه‌های هواشناسی



نگاره ۳: نقشه زوال درختان و خاک‌شناسی در استان لرستان

انتخاب پارامترهای بهینه

با توجه به بررسی نتایج تحقیقات مختلف، هفت پارامتر ارتفاع (H)، شیب (S)، جهت (A)، دما (T)، بارش (P)، ریز گردها (Ar)، و نوع خاک (ST)، به‌عنوان پارامترهای اولیه که

بارش، رطوبت هوا و میزان گرد و غبار است، استفاده شد. همچنین از نقشه‌ی زوال درختان بلوط استان لرستان که توسط سازمان جنگل‌ها و مراتع تهیه شده است و نقشه خاک‌شناسی استان (نگاره ۳) نیز در این تحقیق استفاده شد. توضیح مربوط به کلاس‌های خاک‌شناسی در جدول ۲ و طبقات مختلف خشکیدگی در جدول ۳ بیان شده است.

جدول ۲: طبقه‌بندی خاک‌های استان لرستان

نوع خاک	کلاس خاک
خیلی کم عمق و سنگی	۱
عمیق تکامل نیافته از مارن‌های گچی و نمکی	۲
کم عمق تا نیمه عمیق، سنگ‌ریزه‌ای، آهکی و مارنی	۳
کم عمق، سنگ‌ریزه‌ای، آهکی و مارنی	۴

جدول ۳: مشخصات کلاس‌های زوال درختان بلوط در

استان لرستان		
کلاس	درصد زوال	مساحت کلاس (درصد از کل)
فاقد زوال	کمتر از ۰/۱	۵۳/۸۴
زوال کم	۰/۱ - ۲۵	۲۶
زوال متوسط	۲۵/۱ - ۵۰	۱۶/۰۷
زوال زیاد	۵۰/۱ - ۷۵	۲/۲۸
زوال خیلی زیاد	۷۵/۱ - ۱۰۰	۱/۸۱

با حاصل اعمال وزن‌ها در ورودی‌ها بوده و حاصل آن نیز برابر با خروجی (مقدار تولیدشده) نرون مصنوعی است.

$$\text{Out} = f(\text{net}) \quad \text{رابطه‌ی (۱)}$$

معماری شبکه‌ی عصبی مصنوعی بیانگر نحوه‌ی اتصال نرون‌ها است. انتخاب صحیح معماری به دلیل تأثیر در کارایی شبکه، اهمیت فراوانی داشته و از چالش‌های استفاده از شبکه‌های عصبی است (Sammut & Webb, 2011). شناخته شده‌ترین معماری در شبکه‌های با آموزش نظارت‌شده، شبکه سه لایه پیش‌خور پس انتشار (Back-propagation, BP) است (نگاره ۴).

این شبکه که در دهه‌ی ۱۹۷۰ میلادی توسعه داده شده است، تمامی مقادیر ورودی را به تمامی نرون‌های لایه‌ی پنهان و تمامی نرون‌های لایه خروجی را نیز به تمامی نرون‌های لایه پنهان متصل می‌کند (Sammut & Webb, 2011). این معماری قدرت محاسباتی بالایی دارد (Cilimkovic, 2015). تعداد لایه‌های پنهان، به صورت سعی و خطا تعیین می‌گردد (بیات و همکاران، ۱۳۹۵).

از نظر تئوری برای انتخاب تعداد لایه‌های پنهان محدودیتی وجود ندارد؛ اما در عمل از دو یا حداکثر چهار لایه پنهان استفاده می‌گردد. افزایش تعداد لایه‌های پنهان باعث افزایش حجم محاسبات شده (Cilimkovic, 2015) و الزاماً باعث افزایش دقت شبکه نخواهد شد. برای حفظ کارایی شبکه در تمامی موارد (حتی زمانی که ورودی به آن معرفی نمی‌شود)، یک نود بایاس در لایه ورودی و لایه‌های پنهان (نود با برچسب ۱ در نگاره ۵) در نظر گرفته می‌شود (Rosa 2013).


آموزش شبکه با تعدیل وزن‌ها (W) و به منظور تعیین مدل بهینه انجام می‌شود (بیات و همکاران، ۱۳۹۵). دو شیوه‌ی نظارت‌شده و نظارت نشده برای آموزش شبکه‌ها وجود دارد. آموزش نظارت‌شده با ورودی‌هایی انجام می‌شود که مقدار خروجی آن‌ها معلوم است.

روش پس انتشار خطا یک روش نظارت‌شده پرکاربرد و ساده در آموزش شبکه‌های عصبی است (Rojas, 2013). در این روش تابع فعال‌ساز همواره باید مشتق‌پذیر باشد (مانند

در زوال درختان بلوط مؤثر هستند، انتخاب شدند. مشکل مطرح در استفاده از این پارامترها، مشخص نبودن نحوه‌ی اثر این پارامترها در پدیده‌ی زوال است. همچنین به دلیل وابستگی میان پارامترها (برای نمونه وابستگی دما به ارتفاع) تضمینی وجود ندارد که استفاده از تمام این پارامترها منجر به مدل‌سازی مناسب‌تر خواهد شد.

شبکه‌های عصبی مصنوعی و معماری این شبکه‌ها


بخش عمده‌ای از روش‌ها و مدل‌های موجود، در حوزه‌ی هوش مصنوعی در حقیقت تقلیدی از سیستم‌های طبیعی هستند. روش شبکه عصبی مصنوعی، در سال ۱۹۸۶ و با هدف تقلید از نحوه‌ی عملکرد سلول‌های عصبی مغز انسان توسعه داده شد (Rosa, 2013). این شبکه‌ها از تعداد زیادی واحد پردازشی ساده به نام نرون (Neuron) درست شده‌اند که می‌توان برای انجام محاسبات برنامه‌ریزی کرد و آموزش داد. هر نرون (نگاره ۴)، شامل آرایه‌ی ورودی‌ها ($X = x_1, x_2, \dots, x_n$)؛ وزن‌ها (W)، بلوک جمع (Summation Block) و تابع فعال‌سازی (Activation Function) است (Radi & Hindawi 2013).



نگاره ۴: معماری یک نرون مصنوعی

بلوک جمع، وزن‌ها را بر روی ورودی‌ها اعمال کرده و تابع فعال‌سازی جمع‌های وزن‌دار را (خروجی بلوک جمع) به سیگنال خروجی تبدیل می‌کند. شبکه عصبی نگاشتی از داده‌های ورودی به داده‌های خروجی است. تابع فعال‌سازی غیرخطی، ویژگی انتقال نرون‌های طبیعی و رفتار غیرخطی را بهتر مدل می‌کند (Cilimkovic, 2015).

در رابطه‌ی ۱ مقدار ورودی تابع فعال‌سازی net، برابر



نگاره ۶: معماری چندلایه برای شبکه‌های عصبی احتمالاتی (Specht 1990).

$$P(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_n^d} K\left(\frac{x - x_i}{h_n}\right) \quad \text{رابطه (۳)} \quad (\text{Parzen, 1962})$$

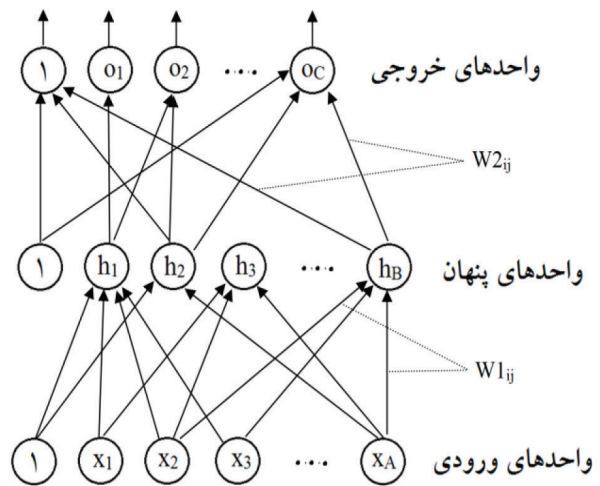
در رابطه‌ی فوق x_i ها نمونه‌های آموزشی، h_n پهنای باند یا عرض پنجره (عرض کرنل) است که بزرگ‌تر از صفر است. h_n بر اساس تعداد نمونه‌های آموزشی انتخاب می‌گردد. K تابع کرنل است؛ در برآوردگر پارزن، تابع گوسی یک کرنل پرکاربرد است. در صورتی که از تابع گوس به‌عنوان کرنل برای رابطه‌ی ۳ استفاده کنیم به رابطه‌ی ۴ می‌رسیم.

$$P(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{(h\sqrt{2\pi})^d} \exp\left(-\frac{1}{2}\left(\frac{x - x_i}{h}\right)^2\right) \quad \text{رابطه (۴)} \quad (\text{Parzen 1962})$$

در رابطه‌ی ۳ پارامتر h برابر با مقدار انحراف معیار تابع گوسی است. در مقسم (Classifier) پارزن ابتدا PDF هر کلاس بر اساس رابطه‌ی ۴ و با استفاده از نمونه‌های آموزشی

تابع سیگموئید، رابطه‌ی ۲). شبکه باید قادر باشد تا برای داده‌های جدید که در فرایند آموزش از آن‌ها استفاده نشده است، خروجی صحیح تولید کند (Radi & Hindawi, 2013). در شبکه‌های پیش‌خور در صورتی که تعداد واحد‌های پنهان به‌درستی تعیین شود، می‌تواند هر نوع تابعی را تقریب بزند (Sammut & Webb, 2011).

$$f(\text{net}) = \frac{1}{1 + e^{(-\text{net})}} \quad \text{رابطه (۲)}$$



نگاره ۵: معماری چندلایه برای شبکه‌های عصبی مصنوعی سه لایه (Rosa 2013).

معماری دوم استفاده شده در این تحقیق معماری احتمالاتی (Probabilistic neural network, PNN) است که نمای کلی آن در نگاره ۶ نشان داده شده است. معماری احتمالاتی (نگاره ۶) بر پایه برآوردگر پارزن (Parzen Estimators) توسعه داده شده است (Specht 1990). برآوردگر پارزن یک روش غیر پارامتریک بوده و از آن برای محاسبه‌ی تابع چگالی احتمال (Probability Density Functions, PDF) که در تئوری بیز (Bayesian theory) مورد نیاز است، استفاده می‌شود. برای برآورد تابع چگالی احتمال هر کلاس $P(x)$ از رابطه‌ی ۳ استفاده می‌شود.

محاسبه شده و سپس بر اساس رابطه‌ی ۵ تقسیم‌بندی انجام می‌گیرد.

$$p_k f_k > p_j f_j \quad \forall k \neq j \quad \text{رابطه‌ی (۵)}$$

در رابطه‌ی فوق p_k احتمال پیشین (Prior probability) وقوع عضوی از کلاس k است و p_k برابر با PDF برآورد شده‌ی کلاس k است. معماری احتمالاتی از تئوری بیز استفاده می‌کند (Tran et al. 2006). یک شبکه‌ی احتمالاتی با استفاده از نمونه‌های آموزشی یاد می‌گیرد که چگونه مقدار PDF را تقریب بزند. در اصل PNN شبکه‌ای است که میزان PDF نمونه‌های آموزشی را برآورد می‌کند. این معماری چهار لایه دارد. در لایه‌ی ورودی تعداد نرون‌ها برابر با تعداد پارامترهای ورودی است (Tran et al. 2006). در لایه‌ی الگو، تعداد نرون‌ها برابر است با مجموع نرون‌هایی که برای نمایش الگوهای هر یک از کلاس‌های خروجی (که در این تحقیق شامل پنج کلاس زوال است)، استفاده می‌شود. در هر واحد موجود در لایه الگو، مقدار بردار X ، در بردار وزن‌ها W ، ضرب نقطه‌ای (Dot product) شده و بردار الگو Z تولید می‌گردد (رابطه‌ی ۶). در این معماری یک عملگر غیرخطی (رابطه‌ی ۷) به‌جای تابع سیگموئید روی Z_i اعمال می‌گردد.

$$Z_i = X \cdot W_i \quad \text{رابطه (۶) (Specht, 1990)}$$

$$\exp [(Z_i - 1)/h^2] \quad \text{رابطه (۷) (Specht, 1990)}$$

در صورتی که فرض شود بردارهای X و W_i نرمال شده هستند رابطه‌ی هشت و رابطه‌ی هفت معادل هم خواهد شد.

$$\exp [-(W_i - X)^t (W_i - X)/2h^2] \quad \text{رابطه (۸)}$$

(Specht 1990)

رابطه‌ی هشت همانند رابطه‌ی چهار است. با این تفاوت که رابطه‌ی ۸ تک متغیره است؛ بنابراین برای اینکه بتوان از آن استفاده کرد باید به فرم چند متغیره گسترش داده شود (رابطه ۹).

رابطه (۹) (Specht 1990)

$$P_A(x) = \frac{1}{(2\pi)^{p/2} h^2} \frac{1}{m} \sum_{i=1}^m \exp \left[-\frac{(X - X_{Ai})^t (X - X_{Ai})}{2h^2} \right]$$

در رابطه‌ی ۹ پارامتر i تعداد کل الگوها را بیان می‌کند. پارامتر m برابر با کل نمونه‌های آموزشی استفاده شده است. نمونه‌ی i ام از کلاس A با پارامتر X_{Ai} نشان داده شده است. انحراف معیار نمونه‌های هر کلاس برابر با h و پارامتر p برابر با تعداد ورودی‌های شبکه عصبی است (Tran et al. 2006).


لایه‌ی خروجی این معماری شامل نرون‌های باینری است که ورودی‌ها را به کلاس‌های موردنظر منتسب می‌کند. در لایه‌ی خروجی $PA(x)$ از رابطه‌ی ۹ برای کلاس‌های مختلف و به ازای هر ورودی محاسبه می‌گردد. مقادیر محاسبه شده، مقایسه شده و ورودی به کلاسی منتسب می‌گردد که مقدار $PA(x)$ برای آن کلاس بیشترین است. این معماری پایداری بالا، پیچیدگی آموزش پایین داشته و به سرعت همگرا شده و این امکان را فراهم می‌کند که الگوهای جدید از هر کلاس تشخیص داده شود (Sun et al. 2016).

معماری بردار پشتیبان (Support Vector Neural Network, SVNN) با استفاده از کرنل اداترون^۱ پیاده‌سازی می‌گردد. این کرنل ابتدا داده‌های ورودی را به فضای با ابعاد بالاتر منتقل و سپس داده‌ها را به کلاس‌های موردنظر تقسیم‌بندی می‌کند. این روش برای داده‌هایی که ارتباطات پیچیده دارند، مناسب است. می‌توان اثبات کرد که استفاده از کرنل اداترون منجر به تولید نتایج بهینه، کاهش تعداد اجراها و همگرایی سریع می‌شود. با توجه به پیچیدگی ارتباطات پارامترهای مؤثر در زوال درختان بلوط، در این تحقیق از این معماری نیز استفاده شد.

داده‌های ایستگاه‌های هواشناسی شامل دما، بارش، نوع خاک، گردوغبار ماهیت نقطه‌ای داشته و گسسته هستند، این داده‌ها ابتدا درونیابی و سپس نقشه‌ی معیارها تولید شد.

جدول ۴: هشت نمونه از ورودی های تولید شده برای استفاده در شبکه های عصبی و نتایج اعمال در معماری های مختلف

R (ML)	R (SVNN)	R (PNN)	ورودی ها
۰/۷۰	۰/۷۸	۰/۸۲	H, S, A, T, P, Ar, ST
۰/۷۶	۰/۸۲	۰/۸۷	H, S, A, PCA(T, P), Ar, ST PCA(H, S), Product(T,
۰/۵۴	۰/۵۳	۰/۵۶	P) PCA(H, S), P, Ar,
۰/۷۵	۰/۷۲	۰/۷۳	Log(ST)
۰/۷۲	۰/۸۰	۰/۷۵	PCA(H, S, A, T)
۰/۵۵	۰/۶۳	۰/۵۹	PCA(Product(Ar, ST), H, S, A)
۰/۴۶	۰/۶۳	۰/۵۵	PCA(H, S), PCA(P, T), PCA(A, ST)
۰/۵۵	۰/۵۸	۰/۶۵	Hyp(H), PCA(P, T), Log(A), ST



نگاره ۷: نمودار میله ای نتایج حاصل از هشت نمونه از مدل های اجرا شده در این تحقیق، محور افقی: شماره مدل متناظر با جدول چهارم؛ محور عمودی: میزان R

با توجه به نگاره ۷، در مدل سازی پدیده های پیچیده که تعداد و نحوه ی ارتباط پارامترهای مختلف، به صورت قطعی مشخص نیست (و در مورد پدیده دانش جزئی وجود دارد)، استفاده از ترکیبات مختلف پارامترها به عنوان ورودی مدل، به منظور شناسایی بهترین مدل اهمیت دارد و می تواند باعث افزایش دقت مدل سازی گردد. نتایج این تحقیق نشان داد که استفاده از ترکیب بهینه در دقت نهایی تأثیر مثبت خواهد داشت که این نتیجه با نتایج تحقیق (بیات و همکاران، ۱۳۹۵)، سازگاری دارد.

استفاده از مدل ارتفاعی رقومی لایه های شیب و جهت تولید گشت. تمامی لایه های رقومی با اندازه پیکسل زمینی یکسان (۳۰ متر) تولید شدند.

در مدل سازی های اکولوژیکی، باید تعداد نمونه های آموزشی بالا بوده و به طور کامل منطقه را پوشش دهند تا بتوان درک صحیحی از پدیده ی مورد مطالعه ایجاد کرد (Köhl & Gertner, 1997)؛ برای آموزش، آزمون و اعتبارسنجی شبکه های عصبی، ۱۰۰۰۰ پیکسل (از مجموع پنج کلاس) انتخاب و ۷۰ درصد آن برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد نیز برای اعتبارسنجی شبکه ها استفاده شد. نقشه ی زوال استفاده شده شامل پنج کلاس است که تعداد نمونه های هر کلاس برابر انتخاب شد (جدول ۳، ستون ۴). برای جلوگیری از بیش برآزش (Overtraining) شبکه ی عصبی مصنوعی از تکنیک اعتبارسنجی متقابل (Cross Validation) استفاده شد.

برای آزمون سه معماری انتخاب شده و ۳۸۵ ترکیب ایجاد شده از متغیرهای ورودی، در مجموع ۱۱۵۵ شبکه ی مختلف اجرا شد. برای مقایسه ی نتایج تولید شده از شاخص R استفاده گشت. هر قدر میزان R بزرگ تر باشد، نشانگر دقت بالای مدل است (Lek et al. 1996).

ارزیابی نتایج

بعد از اجرای تمامی ۱۱۵۵ شبکه ی تولید شده، نتایج شبکه ها با هم مقایسه شد که فقط ۸ نمونه از بهترین نتایج تولید شده در جدول ۴ ارائه شده است. طبق نتایج، شبکه ی احتمالاتی با پارامترهای ورودی ارتفاع، جهت، شیب، مؤلفه ی اصلی دما و بارش، ریز گرد و نوع خاک به عنوان بهترین مدل و مؤثرترین پارامترها در زوال درختان بلوط شناسایی شدند (سطر دوم در جدول ۴).

همچنین به منظور مقایسه ی دقیق تر، نتایج مدل های فوق در نمودار میله ای ترسیم شد (نگاره ۷). در این تحقیق نیز عملکرد احتمالاتی بهتر ارزیابی شد که با نتایج تحقیق Sun و همکاران (۲۰۱۶)، سازگاری دارد.

مدل‌سازی است. دو پارامتر دما و بارش اثر مستقیم در میزان رطوبت در دسترس درخت دارند؛ بنابراین با توجه به نتایج می‌توان گفت برای مدل‌سازی اثرات رطوبت باید از مؤلفه‌ی اصلی این دو پارامتر در عوض هر دوی آنها استفاده نمود.

نتایج این مطالعه نشان داد که استفاده از عملگر PCA باعث افزایش ۰/۰۵ شاخص R شد که نشان از بهبود عملکرد مدل دارد، بنابراین استفاده از ترکیبات مختلف پارامترهای ورودی در مدل‌سازی پدیده‌ها با پیچیدگی پارامترهای ورودی باعث بهبود دقت مدل‌سازی می‌گردد. همچنین بر اساس نتایج، افزایش تعداد پارامترهای ورودی مدل الزاماً باعث افزایش دقت مدل نهایی نخواهد شد. بعلاوه، روش شبکه‌ی عصبی با معماری احتمالاتی بهترین عملکرد را در مدل‌سازی زوال درختان بلوط از خود نشان داد. بر طبق نتایج، برای مدل‌سازی با استفاده از شبکه‌های عصبی حتماً باید معماری‌های مختلف را مورد بررسی قرار داد زیرا تمام معماری‌ها عملکرد یکسان از خود نشان نمی‌دهند. همچنین زمانی که پارامترهای مؤثر به طور صریح مشخص نیست، بهتر است ترکیبات مختلف از پارامترها با عملگر PCA ایجاد و در هر معماری مورد سنجش قرار گیرد.

برای تحقیقات آتی توصیه می‌گردد تا پارامترهای نزدیکی به مراکز جمعیت و عمق آب زیرزمینی در منطقه نیز در مدل‌سازی زوال استفاده گردد. همچنین پیشنهاد می‌گردد که اطلاعات کمی درختان شامل سن، قطر تنه، بزرگی اشکوب، ارتفاع و مشخصات سایر درختچه‌ها و یا درختانی که در کنار درختان بلوط وجود دارد نیز به عنوان پارامترهای مؤثر به فرایند مدل‌سازی وارد گردد.

منابع و مأخذ

۱. احمدی، زاهدی امیری، مروی مهاجر؛ شهرام، قوام‌الدین، محمدرضا، ۱۳۹۵، تهیه نقشه خشکیدگی بلوط ایرانی (*Quercus brantii Lindl*). با استفاده از روش زمین‌آمار در دشت برم استان فارس، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۲۴(۳)، ۵۴۰-۴۳۹.

مقایسه‌ی نتایج این تحقیق با تحقیق (کرمی و همکاران ۱۳۹۶) نشان می‌دهد که شبکه‌های عصبی مصنوعی در مطالعات مربوط به زوال درختان بلوط عملکرد مناسبی دارند. در تحقیق فوق‌الذکر، از تصاویر ماهواره‌ی World View 2 برای طبقه‌بندی خشکیدگی جنگل‌های زاگرس استفاده شد که طبق نتایج این تحقیق شبکه عصبی مصنوعی با صحت کلی ۷۲/۸۳ بیشترین دقت را نسبت به روش‌های بیز ساده، حداکثر احتمال و نزدیک‌ترین همسایگی، کسب کرد.

نتایج جدول ۴ نشان داد که استفاده از ترکیب پارامتر دما و بارش با استفاده از آنالیز مؤلفه‌های اصلی و کاهش تعداد پارامتر نتایج بهتری نسبت به حالتی دارد که از آنها به صورت مستقل استفاده گردد. این یافته نشان می‌دهد که مؤلفه‌ی اصلی این دو پارامتر بهتر می‌تواند اثر خشک‌سالی و تنش آبی را مدل کند، زیرا این دو پارامتر به صورت مستقیم در ایجاد تنش خشک‌سالی نقش دارند.

نتیجه‌گیری

مدل‌سازی زوال درختان بلوط به دلیل تعداد پارامترهای مؤثر در زوال و نحوه‌ی ارتباط پارامترها، امری پیچیده است. از این رو در این پژوهش ابتدا تمامی پارامترهایی که در ایجاد بیماری‌ها و آفات که خود از علل مرگ‌ومیر درختان بلوط است، شناسایی شد. با بررسی تحقیقات در مورد بیماری‌ها، آفات و علل ایجاد آنها، تعداد هفت پارامتر به عنوان پارامترهای مؤثر در زوال درختان بلوط شناسایی شد. از مجموع ۱۱۵۵ مدل اجرا شده که با استفاده از ترکیبات مختلف ورودی‌های اولیه با سه معماری شبکه عصبی مصنوعی، معماری احتمالاتی با توجه به شاخص R بهترین عملکرد را داشت ($R=0/87$). استفاده از مؤلفه‌ی اصلی پارامترهای دما و بارش، عملکرد مدل را ۰/۰۵ بهبود بخشید. مقایسه‌ی نتایج مدل‌های اجرا شده نشان می‌دهد که استفاده از مؤلفه‌ی اصلی پارامترهای دما و بارش، در مدل باعث بهبود دقت تمامی سه معماری انتخاب شده می‌گردد؛ این امر نشان‌دهنده‌ی اثر بالای این پارامترها در عملکرد

(مطالعه موردی: جنگل های شهرستان ایلام)، دو فصلنامه علمی-پژوهشی تحقیقات حمایت و حفاظت جنگل ها و مراتع ایران، تهران، ۱۳(۱)، ۴۵-۳۴.

۹. مهدوی، میرزایی زاده، نیکانژاد، کرمی؛ علی، وحید، مریم، امید، ۱۳۹۴، بررسی و پیش بینی زوال درختان بلوط با استفاده از مدل رگرسیون لجستیک (مطالعه موردی: جنگل های بیوره ملکشاهی- ایلام)، دو فصلنامه علمی-پژوهشی تحقیقات حمایت و حفاظت جنگل ها و مراتع ایران، تهران، ۱۳(۱)، ۳۳-۲۰.

۱۰. مهدی فر، ثاقب طالبی؛ داریوش، خسرو، ۱۳۸۵، مشخصات کمی و کیفی و خصوصیات رویشگاهی دارمازو (*Quercus infectoria Oliv.*) در منطقه شینه استان لرستان، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۱۴(۳)، ۲۰۶-۱۹۳.

۱۱. میرابوالفتحی، منصوره، ۱۳۹۲، شیوع بیماری زغالی درختان بلوط و آزاد در جنگل های زاگرس و البرز، بیماری های گیاهی، ۲(۲)، ۲۶۳-۲۵۷.

12. Ahmadi, R., H. Kiadaliri, A. Mataji and S. Kafaki., 2014. Oak forest decline zonation using AHP model and GIS technique in Zagros Forests of Ilam Province. *Journal of Biodiversity and Environmental Sciences (JBES)*, 4(3): 141-150.

13. Cilimkovic, M., 2015. Neural networks and back propagation algorithm. Institute of Technology Blanchardstown, Blanchardstown Road North Dublin, 15.

14. Corcobado, T., E. Cubera, E. Juárez, G. Moreno and A. Solla., 2014. Drought events determine performance of *Quercus ilex* seedlings and increase their susceptibility to *Phytophthora cinnamomi*. *Agricultural and Forest Meteorology*, 192: 1-8.

15. Costa, A., H. Pereira and M. Madeira., 2010. Analysis of spatial patterns of oak decline in cork oak woodlands in Mediterranean conditions. *Annals of Forest Science*, 67(2): 204.

16. Ferreira, F., T. Oszako and C. Delatour., 2000. The cork oak condition in Portugal, Recent advances on oak

۲. بیات، نمیرانیان، رشیدی، بابایی؛ محمود، امید، منوچهر، سجاد، ۱۳۹۵، کارایی روش شبکه عصبی مصنوعی در برآورد موجودی سرپای توده های جنگلی، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۲۴(۲)، ۲۲۶-۲۱۴.

۳. حسینی، احمد، ۱۳۹۰، بررسی میزان آلودگی درختان به سوسک های چوب خوار و ارتباط آن با شرایط رویشگاهی در جنگل های بلوط ایرانی (*Quercus brantii*) در استان ایلام، دو فصلنامه علمی-پژوهشی تحقیقات حمایت و حفاظت جنگل ها و مراتع ایران، تهران، ۹(۱)، ۶۶-۵۳.

۴. حسینی، حسینی، رحمانی، آزادفر؛ احمد، سید محسن، داوود، ۱۳۹۲، مقایسه خصوصیات محیط های رقابتی توده های سالم بلوط ایرانی و توده های متأثر از زوال بلوط در استان ایلام، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۲۱(۴)، ۶۱۶-۶۰۶.

۵. طالبی، ثاقب طالبی، جهانبازی گوجانی؛ محمود، خسرو، حسن، ۱۳۸۵، بررسی نیاز رویشگاهی و برخی خصوصیات کمی و کیفی بلوط ایرانی (*Quercus brantii* Lindl.) در جنگل های استان چهارمحال و بختیاری، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۱۴(۱)، ۷۹-۶۷.

۶. عزیزی، میری، محمدی، پورهایمی؛ قاسم، مرتضی، مهدی، ۱۳۹۴، واکاوی زوال جنگل های استان ایلام و ارتباط آن با تغییرات بارش، فصلنامه علمی - پژوهشی تحقیقات جنگل و صنوبر ایران، تهران، ۲۳(۳)، ۵۱۵-۵۰۲.

۷. عطارد، صادقی، طاهری سرتشنیزی، ساروئی، عباسیان، مسیح پور، کردستمی، دریکوندی؛ پدرام، سید محمد معین، فریدون، سعید، پریسا، مهرانوش، فرشته، آرش، ۱۳۹۴، دو فصلنامه علمی-پژوهشی تحقیقات حمایت و حفاظت جنگل ها و مراتع ایران، تهران، ۱۳(۲)، ۱۱۲-۹۷.

۸. کرمی، کاوسی، بابانژاد؛ جلیل، محمدرضا، منوچهر، ۱۳۹۶، بررسی امکان تهیه نقشه شدت خشکیدگی جنگل های بلوط زاگرس با استفاده از داده های ماهواره ای Worldview-2

27. Sammut C, Webb GI., 2016. Encyclopedia of Machine Learning and Data Mining. Springer, US, 1335p.
28. Specht, D. F., 1990. Probabilistic neural networks. Neural networks, 3(1): 109-118.
29. Sun, X.-y., F.-n. Kang, M.-m. Wang, J.-p. Bian, J.-l. Cheng and D. H. Zou., 2016. Improved probabilistic neural network PNN and its application to defect recognition in rock bolts. International Journal of Machine Learning and Cybernetics, 7(5): 909-919.
30. Tran, D., A. Ng, B. Perera, S. Burn and P. Davis., 2006. Application of probabilistic neural networks in modelling structural deterioration of stormwater pipes. Urban Water Journal, 3(3): 175-184.
31. Taghimollaie, Y., Karamshahi, A., (2017). Sudden Oak Death in Iran forests, International Journal of Forest, Soil and Erosion (IJFSE), 7(1): 6-10.
- health in Europe, Selected papers from a conference held in Warsaw, Poland, 1999, Instytut Badawczy Leśnictwa (Forest Research Institute), 22-24.
17. Godinho, S., N. Guiomar, R. Machado, P. Santos, P. Sá-Sousa, J. P. Fernandes, N. Neves and T. Pinto-Correia., 2016. Assessment of environment, land management, and spatial variables on recent changes in montado land cover in southern Portugal. Agroforestry Systems, 90(1): 177-192.
18. Jönsson, U., 2004. Phytophthora species and oak decline – can a weak competitor cause significant root damage in a nonsterilized acidic forest soil?. New Phytologist, 162(1): 211-222.
19. Kabrick, J. M., D. C. Dey, R. G. Jensen and M. Wallendorf., 2008. The role of environmental factors in oak decline and mortality in the Ozark Highlands. Forest Ecology and Management, 255(5-6): 1409-1417.
20. Köhl, M. and G. Gertner., 1997. Geostatistics in evaluating forest damage surveys: considerations on methods for describing spatial distributions. Forest Ecology and Management, 95(2): 131-140.
21. Lek, S., M. Delacoste, P. Baran, I. Dimopoulos, J. Lauga and S. Aulagnier., 1996. Application of neural networks to modelling nonlinear relationships in ecology. Ecological Modelling, 90(1): 39-52.
22. Martín García, J., A. Solla, T. Corcobado, E. Siasou and S. Woodward., 2015. Influence of temperature on germination of *Quercus ilex* in *Phytophthora cinnamomi*, *P. gonapodyides*, *P. quercina* and *P. psychrophila* infested soils. Forest Pathology, 45(3): 215-223.
23. Parzen, E., 1962. On estimation of a probability density function and mode. The annals of mathematical statistics, 33(3): 1065-1076.
24. Radi, A. and S. K. Hindawi, 2013. Applying Artificial Neural Network Hadron-Hadron Collisions at LHC. INTECH Open Access Publisher, Croatia, 256p.
25. Rojas, R., 2013. Neural networks: a systematic introduction, Springer-Verlag, New York, 476p.
26. Rosa, J. L. G., 2013. Biologically Plausible Artificial Neural Network, 25-52. (In): Suzuki, K., (Ed). Artificial Neural Networks - Architectures and Applications. InTech, China, p256.