نشریه تحلیل فضایی مخاطرات محیطی، سال سوم، شماره ٤، زمستان ۱۳۹۵

صفحات ٤٨- ۳۵

مدل‌سازی ریسک سقوط درختان چنار خطرآفرین در فضای سبز شهری

علی جهانی [۱]، استادیار گروه محیط‌زیست طبیعی و تنوع زیستی، دانشکده محیط‌زیست، کرج، ایران.

دریافت مقاله:۳۱ /۱۳۹۵/۰۲ پذیرش نهایی: ۱۳۹۵/۰۹/۰۵

چکیده

مدیریت درختان خطرآفرین به بررسی احتمال خطر درختان در محیط‌های طبیعی و انسان ساخت می‌پردازد. از آنجاییکه درختان خطرآفرین در فضای سبز شهری از اهمیت بالایی برخوردارند، شناسایی و کمی‌سازی شدت ریسک این درختان اجتناب‌ناپذیر است و فقط در این صورت امکان مدیریت ریسک و انجام اقدامات پیشگیرانه و به موقع فراهم می‌گردد. در این مطالعه در مجموع ۲۰۰ درخت چنار خطرآفرین با ساختار ناپایدار در شهر کرج شناسایی و اطلاعات مربوط به ویژگی‌های عمومی و عیوب آنها ثبت گردید و شدت ریسک آنها با توجه به سال آسیب‌پذیری ارزیابی شد. در این تحقیق به کمک الگوریتم آموزشی پس انتشار خطا در محیط شبکه‌های عصبی مصنـوعی، شدت ریسک سقوط درختان چنار خطرآفرین (دو کلاسه شدت خطرآفرینی بر اساس سقوط اجزا در سال اول و دوم) بر اساس مقادیر کمی مشخصه‌های عمومی و عیوب درختان شبیه‌سازی شد. بر اساس نتایج آنالیز حساسیت قطر تاج، طول تاج درخت، انحراف تنه درخت و قطر یقه درخت به ترتیب بیشترین تاثیر را در طبقه‌بندی شدت ریسک درختان خطرآفرین داشته‌اند. صحت مدل با مقایسه خروجی آن و شاخص‌های محاسبه شده شامل ضریب تعیین (۰/۸۷ کلاس یک و ۰/۹ کلاس دو)، میانگین خطای مطلق (۰/۱۷ کلاس یک و ۰/۱۸ کلاس دو) و میانگین مربعات خطا (۰/۰۸۴ کلاس یک و ۰/۰۸۵ کلاس دو) سنجیده شد. مدل شبکه عصبی مصنوعی با دقت بالا در کلاسه بندی شدت ریسک چنارهای خطرآفرین در اکوسیستم‌های شهری، مدل SFHR را به عنوان یک مدل پیش‌بینی در ارزیابی احتمال سقوط درختان چنار معرفی نمود.

واژه های کلیدی: کرج، درختان خطرآفرین، شبکه‌های عصبی مصنـوعی، SFHR.

۱. نویسنده مسئول: Email: Ajahani@ut.ac.ir

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

مقدمه

درختان طبیعی و دست کاشت در محیط زیست شهری در مواجهه با شرایط سخت محیطی و محدودیت‌های اکولوژیکی هستند. با توجه به فشارهای محیطی و محدودیت‌ها در تامین نیازهای رویشی، درختان در محیط شهری به حداکثر پتانسیل طبیعی رویشی خود دست نمی‌یابند و عمدتا با آسیب‌های طبیعی و انسانی مواجه می‌شوند (Harris, ۱۹۹۲; Jim, ۱۹۹۳; Burton, ۲۰۰۲; Sieghardt et al., ۲۰۰۵; Tello et al., ۲۰۰۵; Jim, ۲۰۰۵; Pellissier et al., ۲۰۱۰). در واقع تعداد اندکی از درختان به حداکثر سن، بیوماس و ابعاد خود دست می‌یابند. هنگامی احتمال سقوط یک درخت یا در هم شکستن اجزای آن می‌رود نیاز به مدیریت خطر بیش از پیش احساس می‌گردد. مدیریت درختان خطرآفرین به بررسی احتمال خطر درختان در محیط می‌پردازد. در تعریف درختان خطرآفرین به درختان کاملا خشکیده یا در حال خشکیدن، اجزای خشکیده درختان زنده یا درختان زنده به شدت ناپایدار در محیط که می‌تواند ناشی از آسیب‌های ساختاری یا عوامل دیگر باشد اطلاق می‌شود و این درختان ریسک بالایی را در تهدید امنیت جانی شهروندان یا اموال آنها در محیط زیست شهری به همراه دارند (Mortimer and Kane, ۲۰۰۴; Duryea et al., ۲۰۰۷). از آنجاییکه درختان خطرآفرین در فضای سبز شهری از اهمیت بالایی برخوردارند، شناسایی و کمی‌سازی شدت ریسک این درختان اجتناب‌ناپذیر است و فقط در این صورت امکان مدیریت ریسک و انجام اقدامات پیشگیرانه و به موقع فراهم می‌گردد.

اگرچه هرس کردن و سایر اقدامات نگهداری درختان از اصول پایه‌ای و اجرایی مدیریت فضای سبز شهری است اما هنوز مدل‌ها و روش‌های جامعی در شناسایی درختان خطرآفرین جهت بررسی و انجام اقدامات پیشگیرانه لازم ارائه نشده است. جهت پیشگیری از خطرات جانی برای شهروندان و اموال عمومی، مدل‌سازی ریاضی جهت پیش‌بینی احتمال خطر، انجام اقدامات به موقع و کاهش پتانسیل خطر امری ضروری است (Sani et al., ۲۰۱۲). متک و برلورت (۱۹۹۴) روش VTA-Method را جهت ارزیابی ویژگی های بیولوژیکی و مکانیکی درختان و شناسایی درختان خطرآفرین معرفی کردند. در این روش ویژگی‌های بیولوژیکی و مکانیکی درختان عمدتا به صورت بصری اندازه‌گیری می‌شود و برخی ابزارها جهت ارزیابی‌های دقیق‌تر مورد استفاده قرار می‌گیرد.

امروزه تحقیقات گسترده‌ای در زمینه مدل‌سازی زیست محیطی و ابزارهای سیستم‌های پشتیبان تصمیم‌گیری انجام گرفته است (Argent et al., ۲۰۰۹; Elmahdi & McFarlane, ۲۰۰۹; Jahani et al., ۲۰۱۶; Twery et al., ۲۰۰۵) اما این تحقیقات کمتر بر حل مشکلات تصمیم‌گیری در مدیریت فضای سبز شهری متمرکز شده‌اند. این تحقیق به استفاده و کاربرد شبکه عصبی مصنوعی در مدل‌سازی شدت ریسک سقوط درختان چنار خطرآفرین با استفاده از ارزیابی میدانی مشخصه‌های ساختاری و سلامتی درختان خطرآفرین در فضای سبز شهری می‌پردازد. اهداف این تحقیق عبارتند از: ۱. مدل‌سازی شدت ریسک سقوط درختان چنار در فضای سبز شهری جهت شناسایی متغیرهای اثرگذار بر آن. ۲. آنالیز حساسیت مدل و الویت‌بندی متغیرهای اثرگذار بر شدت ریسک سقوط درختان چنار ۳. بررسی روند تغییرات شدت ریسک متاثر از متغیرهای مدل با شدت اثرگذاری بالا.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

داده ها و روش کار

کرج یکی از شهرهای کوه‌پایه‌ای ایران می‌باشد که در دامنه رشته کوه‌های البرز و در بلندای ۱۳۰۰ متری از سطح دریا واقع شده است. شهر کرج در گذشته‌ای نه چندان دور، با توجه به آب و هوای مناسب و وجود منابع آبی چون رودخانه کرج، باغ شهری زیبا و سبز با درختان چنار کهن و بی‌شمار بوده است که آثار آن هنوز هم در شهر به چشم می‌خورد. در طی ۴۰ سال اخیر و با هجوم جمعیت از سراسر ایران به این شهر، رفته رفته باغ‌های آن تخریب و با مناطق مسکونی و راه‌ها جایگزین گردید. در حال حاضر صدها درخت چنار (Platanus orientalis Linn.) در فضای سبز شهری کرج به دلیل عوامل طبیعی و انسانی در حال خشکیدگی و نابودی هستند لذا ارزیابی و مدیریت ریسک درختان خطرآفرین در الویت برنامه‌ریزی و مدیریت فضای سبز شهری کرج قرار دارد. یکی از مشکلات فضای سبز شهر کرج وجود درختان چنار با پتانسیل ریسک بالا در آسیب به شهروندان و اموال عمومی است. از اینرو شناسایی و ارزیابی شدت ریسک درختان چنار خطرآفرین در الویت مدیریت فضای سبز شهر کرج قرار دارد (سازمان پارک‌ها و فضای سبز شهر کرج، ۱۳۹۲: ۲۵۷).

عموما درختان آسیب دیده با ساختار شکننده مشکلات مدیریتی، احتمال سقوط و خطرات جانبی را چندین برابر می‌کنند (Jim & Zhang, ۲۰۱۳). در مطالعات میدانی این پژوهش ۲۰۰ اصله درخت چنار جهت ارزیابی شدت ریسک سقوط از بین درختان کهنسال و خطرآفرین شهر کرج انتخاب شدند. بر اساس مطالعات پیشین (Jim and Zhang, ۲۰۱۳) جهت انتخاب یک درخت به عنوان درخت خطرآفرین معیارهای زیر درنظر گرفته شد: ۱. ابعاد بزرگ رویشی ۲. درختان با فرم غیرمعمول ۳. درختان با سن بالای صد سال و ۴. درختان کهنسال با ارزش اکولوژیکی، تاریخی یا فرهنگی. بر این اساس در تابستان ۱۳۹۲ مشخصه‌های کمی از درختان منتخب با استفاده از فرم مخصوص طراحی شده ثبت گردید. از آنجاییکه استفاده از داده‌های کمی موجب افزایش دقت مدل‌سازی شده و آنالیز یافته‌ها را تسهیل می‌کند در این تحقیق اندازه‌گیری متغیرها به صورت کمی صورت پذیرفت. متغیرهای مورد بررسی در درختان خطر آفرین که شدت ریسک سقوط درختان را تحت تاثیر قرار می‌دهند به ترتیب زیر است (Sreetheran et al., ۲۰۱۱): ۱. مشخصه‌های عمومی درخت: ارتفاع درخت (TH) به متر، قطر برابر سینه (DBH) به سانتی‌متر، قطر یقه (BD) به سانتی‌متر ، طول تاج درخت (VLC) به متر و قطر تاج (CS) به متر (قطر تاج با اندازه‌گیری میانگین دو قطر عمود برهم تاج به دست آمد). ۲. عیوب درخت: پوسیدگی تنه درخت (ID) به درصد، طول شکاف روی تنه (LC) به متر، خشکیدگی تاج (CD) به درصد و انحراف تنه (DL) از حالت عمود به درجه. ۳. شدت ریسک سقوط درختان چنار خطرآفرین (SFHR[1]): ۲۰۰ درخت مورد مطالعه به ترتیب یک و دو سال پس از بررسی اولیه مورد ارزیابی مجدد قرار گرفتند و ساختار درخت با عکس تهیه شده در بررسی اولیه مورد مقایسه قرار گرفت. برخی درختان در سال اول و برخی درختان در سال دوم دچار آسیب دیدگی شدید و از دست دادن شاخه‌های اصلی شدند. لذا درختانی که در سال اول آسیب دیدند با شدت ریسک بالا و درختانی که در سال دوم آسیب دیدند با شدت ریسک کمتر ارزیابی شدند.

در بررسی سیستم‌های هوش مصنوعی، شبکه‌های عصبی مصنوعی به عنوان ابزاری قدرتمند در زمینه‌های علوم و مهندسی شناخته می‌شوند. شبکه عصبی مصنوعی با کاربرد وسیع در مدل‌سازی فرآیندهای پیچیده در محیط زیست امروزه در تشخیص تابع، پردازش داده‌ها و طبقه‌بندی به تکامل توسعه دست یافته‌اند (Jambunathan et al., ۱۹۹۶; Sreekanth et al., ۱۹۹۸; Paliwal et al., ۲۰۰۱; Hussain et al., ۲۰۰۲; Sablani et al., ۲۰۰۲; Boillereaux et al.,

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

۲۰۰۳). در واقع یک شبکه عصبی مصنوعی به عنوان یک ابزار محاسباتی شناخته شده و از تعداد زیادی نورون متصل به یکدیگر و با عملکرد موازی تشکیل شده است. هر نورون اطلاعات را دریافت کرده و با انجام یکسری محاسبات به خروجی قابل انتقال به نورون بعدی دست می‌یابد (Callan, ۱۹۹۹). در این پژوهش نیز از شبکه عصبی مصنوعی به عنوان یک ابزار با قدرت یادگیری از نمونه‌های مورد استفاده در آموزش استفاده می‌شود.

ساختار یا توپولوژی شبکه عصبی مصنوعی با تعیین تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تابع محرک (کنترل کننده خروجی هر نرون)، روش آموزش، الگوریتم تصحیح وزن‌ها و نوع مدل یا تابع، تعیین می‌شود. در این تحقیق به کمک یک الگوریتم مناسب در محیط شبکه‌های عصبی مصنوعی در نرم‌افزار MATLAB R۲۰۱۳b، شدت ریسک سقوط درختان چنار خطرآفرین (دو کلاسه شدت خطرآفرینی بر اساس سقوط اجزا در سال اول و دوم) بر اساس مقادیر کمی مشخصه های عمومی و عیوب درختان شبیه‌سازی شد. در این تحقیق لایه ورودی شامل متغیرهای عمومی درختان و متغیرهای عیوب درختان است که در واقع برابر با ۹ عامل به عنوان ورودی‌های شبکه عصبی است که در محدوده ۰/۹- تا ۰/۹ و با استفاده از رابطه ۱ نرمال شدند.

رابطه۱

$$NData(i) = \left[\frac{U-L}{Max(i)-Min(i)} * Data(i)\right] + \left[U - (\frac{U-L}{Max(i)-Min(i)} * Max(i))\right]$$

به طوریکه NData(i) داده نرمال شده، U حد بالای محدوده نرمال‌سازی(۰/۹)، L حد پایین محدوده نرمال‌سازی (۰/۹-)، Max(i) حداکثر ارزش داده‌ها، Min(i) حداقل ارزش داده‌ها و Data(i) داده غیرنرمال است.

یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی در شبکه عصبی مصنوعی، مدل پرسپترون چندلایه یا به اختصار MLP[۲] می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است. در این ساختار، تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصلند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می‌دهد (Jahani et al., ۲۰۱۶). شکل ۱ شمای یک شبکه پرسپترون یک لایه را نشان می‌دهد. به سادگی می‌توان استنباط نمود که تعداد نورون‌های هر لایه، مستقل از تعداد نرون‌های دیگر لایه-ها می‌باشد. توجه به این نکته حائز اهمیت است که در شکل ۱، هر دایره تجمیع شده عمل جمع و آستانه‌گذاری (عبور از تابع غیرخطی سیگموئید) است.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

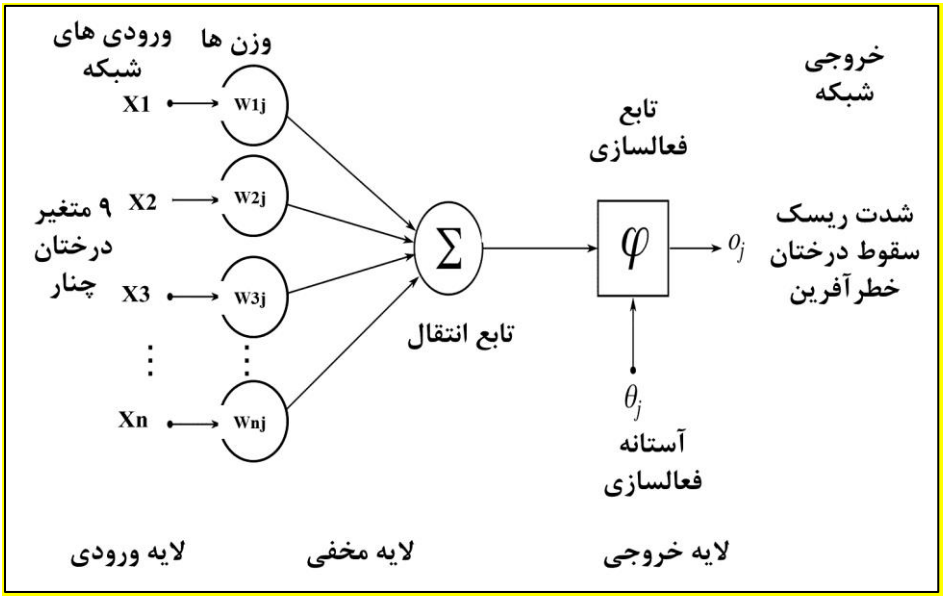

شکل ۱: شبکه پرسپترون با یک لایه مخفی

یکی از مشکلات پیش‌بینی با شبکه‌های عصبی، برازش بیش از حد[۳] است. این مشکل وقتی بروز می‌کند که خطای آموزش شبکه در حد بسیار پایین و خطای آزمون شبکه زیاد باشد که در این حالت مدل با داده‌های آموزش به خوبی همگرا شده است اما کاربرد مدل در داده‌های جدید که در آموزش استفاده نشده است نتایج خوبی ندارد. جهت استفاده از روش توقف زود هنگام برای آموزش شبکه، ابتدا ۲۰۰ درخت مورد بررسی به طور تصادفی به سه دسته آموزش شبکه (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون شبکه (۱۵ درصد) تقسیم شدند. تعداد لایه‌های پنهان و تعداد نرون‌های هر لایه به روش آزمون و خطا مورد بررسی قرار گرفت. در این پژوهش، ترکیب مختلفی از لایه‌ها و نرون‌های مختلف همراه با انواع توابع فعال‌سازی (لایه‌های پنهان و خروجی) برای بهینه‌سازی شبکه مورد استفاده قرار گرفت. در مرحله اول بهینه‌سازی شبکه هوشمند عصبی از یک لایه پنهان با تعداد ۴ تا ۲۰ نرون که به طور تصادفی انتخاب گردیدند، عمل بهینه‌شدن شبکه انجام شد و در مرحله دوم با همان تعداد نرون در دو لایه پنهان قدرت شبکه تخمین زده شد. تعداد ورودی‌ها برابر با ۲۰۰ نمونه با ۹ متغیر و تعداد خروجی‌ها شامل ۲ طبقه یا کلاس شدت ریسک درختان خطرآفرین می باشد. ۳۰ نمونه برای آزمون نتایج شبکه عصبی طراحی شده استفاده شد.

در تعیین ساختار بهینه شبکه‌های عصبی قانون تایید شده‌ای وجود ندارد و معیار مناسب و جامعی جهت تعیین تعداد نرون‌ها و لایه‌ها و نوع توابع فعال‌سازی وجود نداشته و عموما بر اساس آزمون و خطا جهت دستیابی به بالاترین میزان دقت تعیین می‌شوند (دهقانی *و همکاران*، ۱۳۸۹). در لایه‌های مخفی شبکه از تعداد نرون‌های متفاوتی استفاده شده و تعداد بهینه آنها برای حداقل نمودن خطا تعیین گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه داشت که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشند و به این منظور از ۴ تا ۲۰ نرون استفاده گردید. همچنین افزایش لایه‌های مخفی از یک لایه به دو و سه لایه و آزمون توابع محرک مختلف خطی و تانژانتی استفاده شد. متداول‌ترین الگوریتم یادگیری در شبکه‌های عصبی پرسپترون چند لایه الگوریتم آموزشی پس انتشار خطا (BP[۴]) است (دهقانی *و همکاران*، ۱۳۸۹). از طرفی مدل‌سازی اولیه در این تحقیق نشان داد الگوریتم آموزشی پس انتشار خطا نتایج دقیق‌تری ارائه می‌کند.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]
[DOI: 10.18869/acadpub.jsaeh.3.4.35]

الگوریتم آموزشی پس انتشار خطا (BP)، مقدار تابع خطا را کاهش داده و آن را از یک لایه به لایه پیشین آن انتشار می-دهد. آموزش شبکه با استفاده از جفت ورودی-خروجی به کار گرفته شده در این مرحله صورت می‌گیرد به طوری که پس از آموزش اگر هر یک از این ورودی‌ها را به شبکه اعمال کنیم خروجی به دست آمده از شبکه نزدیک به خروجی مطلوب باشد.

شاخص کارایی این شبکه با استفاده از رابطه ۲ محاسبه می‌شود.

رابطه ۲

$$V = \frac{۱}{۲}\sum_{n=۱}^{N}(\mathrm{t}_n - a_n^M)^T(\mathrm{t}_n - a_n^M)$$

که در رابطه ۲، a_n^M خروجی شبکه به ورودی nام است و $\mathrm{t}_n - a_n^M$ خطای این خروجی است.

در این روش پس از محاسبه خطای پیش بینی (شاخص کارایی)، وزنهای سیناپسی از آخرین لایه به سوی نخستین لایه به تدریج طوری تغییر می کنند که خطای پیش گویی کمتر شود. این الگوریتم تغییرات ΔW_{ji} را که وزن اتصالات بین نورون های i و j هستند به صورت رابطه ۳ می‌دهد.

رابطه ۳

$$\Delta W_{ji(k+۱)} = \eta\delta_j X_i + \mu\Delta W_{ji(k)}$$

که در رابطه ۳ η نرخ یادگیری، δ_j فاکتوری بر اساس موقعیت نرونها، $\Delta W_{ji(k+۱)}$ و $\Delta W_{ji(k)}$ تغیرات وزن در دوره K+۱ و K، و در نهایت μ ضریب مومنتوم می باشد.

مومنتوم در واقع نوعی اینرسی حرکتی برای تغییر وزن ها ایجاد می کند که سبب می شود با تعداد نمونه های کمتر و در زمان کمتری سیستم به مرحله هم گرایی برسد. به این ترتیب، بر خلاف تأثیر نرخ یادگیری، تأثیر مومنتوم عملاً برروی اتصالات سیناپسی مختلف متفاوت بوده و تنها میزان حداکثر مجاز آن برای کل سیستم یکسان است. در تحقیق حاضر نیز فرآیند آموزش شبکه با الگوریتم آموزشی پس انتشار خطا انجام گرفت.

صحت مدل با مقایسه خروجی آن و شاخص‌های محاسبه شده شامل ضریب تعیین ($R^۲$)، میانگین خطای مطلق ($MAE^۵$) ، میانگین مربعات خطا ($MSE^۶$) و ریشه میانگین مربعات خطا ($RMSE^۷$) سنجیده شد (روابط ۲ تا ۵).

رابطه ۴

$$MSE = \frac{\sum_{i=1}^{n}(O_i - P_i)^2}{n}$$

رابطه ۵

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|O_i - P_i\right|$$

رابطه ۶

$$R^2 = \frac{\sum_{i=1}^{n}(O_i - O_{ave})(P_i - P_{ave})}{\sqrt{\sum_{i=1}^{n}(O_i - O_{ave})\sum_{i=1}^{n}(P_i - P_{ave})}}$$

رابطه ۷

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(O_i - P_i)^2}{n}}$$

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

که در این روابط O_i: داده اندازه‌گیری‌شده، P_i: داده برآوردشده، O_{ave}: میانگین داده‌های اندازه‌گیری‌شده، P_{ave}: میانگین داده‌های برآوردشده، n: تعداد داده‌ها می باشد.

ارزیابی بهترین برازش شبکه برای یافتن بهترین توپولوژی شبکه مناسب، از طریق معیارهای فوق انجام گردید که هدف کمینه نمودن میانگین مربعات خطا و میانگین مربعات خطای مطلق (درصد) می‌باشد.

جهت انجام آنالیز حساسیت و محاسبه حساسیت خروجی شبکه (SFHR) به هریک از متغیرهای مدل اقدام به ثابت نگه داشتن تمام متغیرها برابر با میانگین آنها شد و متغیر مورد نظر در دامنه انحراف معیار (با ۱۰۰ گام در دامنه انحراف معیار) تغییر داده شد و با برآورد و شبیه‌سازی SFHR، انحراف معیار خروجی‌های مدل محاسبه گردید. این فرآیند برای یکایک متغیرهای ورودی انجام شده و حساسیت نتایج مدل به تک تک متغیرها تعیین شد.

شرح و تفسیر نتایج

در منطقه مورد مطالعه در مجموع ۲۰۰ درخت چنار خطرآفرین با ساختار ناپایدار و متزلزل شناسایی و اطلاعات مربوط به ویژگی‌های عمومی و عیوب آنها ثبت گردید و شدت ریسک آنها با توجه به سال آسیب‌پذیری ارزیابی شد. مجموعا ۹۳ پایه درخت چنار در کلاس یک (شدت ریسک بالا) و ۱۰۷ پایه درخت چنار در کلاس دو (شدت ریسک کم) قرار گرفتند. ویژگی‌های مورد آزمون جهت دستیابی به ساختار بهینه شبکه عصبی در جدول ۱ نشان داده شده است.

جدول۱: ویژگی‌های مورد آزمون جهت دستیابی به ساختار بهینه شبکه عصبی

ویژگی‌های ساختاری شبکه	لایه پنهان اول	لایه پنهان دوم	لایه خروجی
نوع شبکه	MLP	MLP	MLP
تابع انتقال	Hyperbolic tangent, Sigmoid tangent, Linear Hyperbolic tangent, Linear	Hyperbolic tangent, Sigmoid tangent, Linear Hyperbolic tangent, Linear	Hyperbolic tangent, Sigmoid tangent, Linear Hyperbolic tangent, Linear
الگوریتم بهینه‌سازی	Gradient descent	Gradient descent	Gradient descent
دوره یادگیری	۱۰۰۰	۱۰۰۰	۱۰۰۰
ضریب مومنتوم	۰/۷-۰/۹	۰/۷-۰/۹	۰/۷-۰/۹
تعداد نورون‌ها	۴-۲۰	۴-۲۰	۲
نرمال‌سازی	۰/۹- تا ۰/۹	۰/۹- تا ۰/۹	۰/۹- تا ۰/۹

همچنین پس از آزمون شبکه‌های حاصل از ساختارهای گوناگون، نتایج حاصل از بهینه‌سازی شبکه عصبی به همراه بهترین توپولوژی به دست آمده در جدول ۲ نشان داده شده است.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

جدول۲: نتایج ساختار بهینه مدل شبکه عصبی مصنوعی برای ارزیابی شدت ریسک درختان خطرآفرین

ویژگی‌های ساختاری شبکه	لایه پنهان اول	لایه خروجی
نوع شبکه	MLP	MLP
تابع انتقال	Hyperbolic tangent	Hyperbolic tangent
الگوریتم بهینه‌سازی	Gradient descent	Gradient descent
دوره یادگیری	**۱۰۰۰**	**۱۰۰۰**
ضریب مومنتوم	**۰/۷**	**۰/۷**
تعداد نورون‌ها	**۴**	**۲**
نرمال‌سازی	**۰/۹- تا ۰/۹**	**۰/۹- تا ۰/۹**

در آموزش شبکه عصبی می‌توان از ترکیبات مختلف لایه‌های پنهان و با تعداد نورون مختلف استفاده نمود، اما بررسی ضرایب تعیین (R^2) به دست آمده میزان خطای شبکه در پیش‌بینی را نشان می‌دهد و توپولوژی (ساختار شبکه) بکار رفته با بیشترین مقدار ضریب تعیین، بهترین عملکرد شبکه عصبی در پیش‌بینی و مدل‌سازی را نشان می‌دهد. با توجه به نتایج شبکه‌های آموزش داده شده شبکه با یک لایه پنهان و ۴ نرون در هر لایه با تابع انتقال تانژانت هیپربولیک با توجه به بیشترین مقدار ضریب تبیین (معادل ۰/۹ و ۰/۹۲ به ترتیب در کلاسه‌های اول و دوم)، بهترین عملکرد بهینه‌سازی توپولوژی را نشان می‌دهد. با توجه به ضریب تبیین شبکه مطلوب و همسانی ضرایب تبیین آموزش، اعتبارسنجی و آزمون داده‌ها به انضمام حداقل میزان MSE آزمون داده‌ها (جدول۳) دقت شبکه عصبی در پیش‌بینی شدت ریسک چنارهای خطرآفرین از سطح بسیار مطلوبی برخوردار است. از بین کلیه مدل‌های حاصل از آزمون و خطا، مدل بهینه با حداکثر قطعیت و حداقل خطا نیز بر این اساس انتخاب گردید. باید توجه داشت در آزمون و خطای ساختارهای مختلف شبکه عصبی گاها نتایجی نزدیک به هم حاصل می‌شود که از نقاط ضعف شبکه عصبی در تعیین دقیق‌ترین مدل است اما میزان اثرگذاری متغیرها در خروجی مدل بسیار نزدیک به هم است و اختلاف جزئی در دقت ساختارهای مختلف ناشی از وزن‌دهی تصادفی اولیه خواهد بود. نتایج نشان می‌دهند که دقت شبکه عصبی در پیش‌بینی کلاس دو درختان خطرآفرین بیشتر از کلاس یک است. علت این امر را می‌توان در انتخاب تعداد نمونه بیشتر در کلاس دوم و تنوع عوامل اثرگذار بر سقوط درخت در سال اول (کلاس یک) که مورد بررسی قرار نگرفته‌اند (مثلا اثر فعالیت‌های مختلف انسانی) دانست.

جدول۳: نتایج ساختارهای مدلهای شبکه عصبی مصنوعی در مرحله آزمون برای ارزیابی شدت ریسک درختان خطرآفرین

مرحله	R^2 class۲	R^2 class۱	MAE class۲	MAE class۱	MSE class۲	MSE class۱	RMSE class۲	RMSE class۱
آموزش	۰/۹۲	۰/۹۰	۰/۱۷	۰/۱۶	۰/۰۵۵	۰/۰۶۵	۰/۲۳۴	۰/۲۵۵
اعتبارسنجی	۰/۹۳	۰/۹۱	۰/۱۶	۰/۱۵	۰/۰۶۱	۰/۰۶۴	۰/۲۴۷	۰/۲۵۳
آزمون	۰/۹۰	۰/۸۷	۰/۱۸	۰/۱۷	۰/۰۸۵	۰/۰۸۴	۰/۲۹۱	۰/۲۹

شبکه در ده دوره اجرا گردید و در بالاترین دقت (کمترین میانگین مربعات خطا) آموزش شبکه در اپوک ۱۰۰۰ و آزمون شبکه در اپوک ۲۲۱ (با عامل توقف ضریب مومنتم) متوقف گردیدند. جدول۴ ماتریس آشفتگی حاصل از آزمون شبکه در کلاسه‌بندی را نشان می‌دهد.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

جدول۴: ماتریس آشفتگی آزمون شبکه عصبی بهینه

پیش‌بینی شده / حقیقی	کلاس۱	کلاس۲
کلاس۱	۱۴	۰
کلاس۲	۳	۱۳
درصد صحت	۸۲/۳۵	۱۰۰
درصد خطا	۱۷/۶۵	۰

با توجه به ضریب تعیین شبکه مطلوب (جدول۳) دقت شبکه عصبی در پیش‌بینی شدت ریسک درختان خطرآفرین از سطح بسیار مطلوبی برخوردار است. جداول ۳ و ۵ نشان می‌دهند که دقت شبکه عصبی در پیش‌بینی شدت ریسک درختان خطرآفرین در کلاسه شدت ریسک بالا کمتر از کلاسه شدت ریسک کم است.

شکل‌های ۲ و ۳ نتایج مربوط به آنالیز حساسیت متغیرهای بکارگرفته شده برای مدل‌سازی و ضریب تأثیرگذاری هر یک از متغیرهای کاربردی در پیش‌بینی هریک از کلاسه‌های شدت ریسک درختان خطرآفرین را نشان می‌دهد. ضریب حساسیت به دست آمده، دامنه تغییرات خروجی مدل در تغییر هریک از متغیرها را در دامنه انحراف معیار نشان می-دهد.

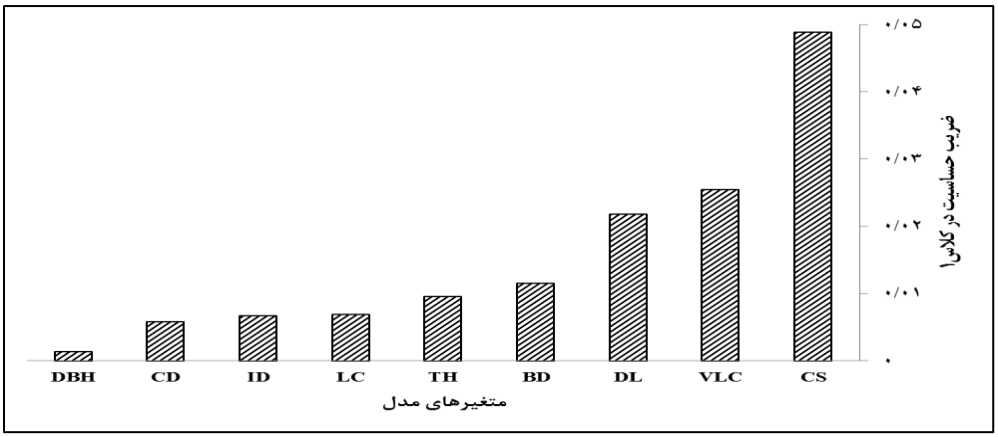

شکل۲: دضریب تأثیرگذاری متغیرهای کاربردی در پیش‌بینی کلاس۱ (شدت ریسک بالا)

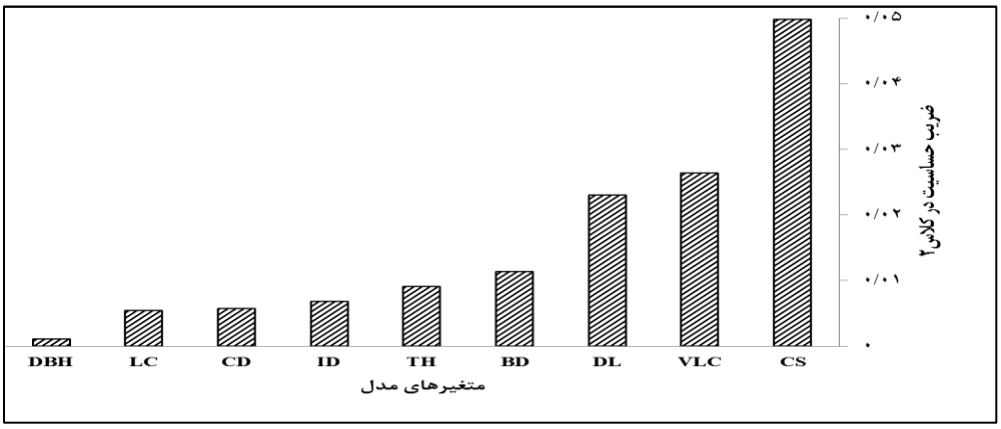

شکل۳: ضریب تأثیرگذاری متغیرهای کاربردی در پیش‌بینی کلاس۲ (شدت ریسک کم)

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

ترهو و هالاکسلا (۲۰۰۵) ویژگی های درختان خطرآفرین را در چند گونه درختی تعیین نمودند. قارچزدگی بن درخت و شکاف در طول ساقه در درختان نمدار، شاخه‌های چنگالی و قارچزدگی در درختان افرا، و تخریب و پوسیدگی در ساقه در درختان توس به عنوان متغیرهای اثرگذار در میزان پایداری و افزایش احتمال سقوط درختان شناسایی شدند. نویسندگان متاسفانه مدلی جهت ارزیابی و پیش‌بینی شدت ریسک سقوط درختان ارائه ندادند. همچنین جیم و زانگ (۲۰۱۳) تحقیقاتی را جهت تعیین سلامت و ساختار درختان کهنسال هنگ کنگ انجام دادند. آنها ۳۰ معیار عیوب درختان را در چهار گروه ریشه، تنه، شاخه‌ها و تاج درخت طبقه‌بندی نموده و جهت ارزیابی درختان خطرآفرین معرفی کردند. SFHR نیز مدلی جامع جهت ایجاد ارتباط بین عیوب درختان و شدت ریسک سقوط آنها جهت ارزیابی درختان چنار خطرآفرین ارائه می‌نماید. SFHR برخلاف تحقیقات اشاره شده مدل جامعی را جهت پیش‌بینی زمان آسیب‌پذیری درختان با کاربرد در مدیریت فضای سبز شهری ارائه می‌دهد. بر اساس نتایج آنالیز حساسیت قطر تاج، طول تاج درخت، انحراف تنه درخت و قطر یقه درخت به ترتیب بیشترین تاثیر را در طبقه‌بندی شدت ریسک درختان خطرآفرین در کلاس ۱ و ۲ داشته‌اند.

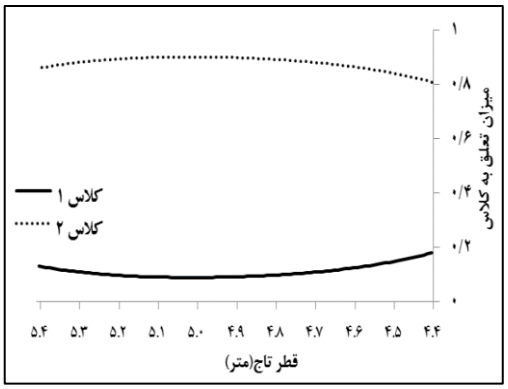

الف. نمودار روند تغییرات تعلق درخت به کلاس‌های شدت ریسک بر حسب تغییرات قطر تاج

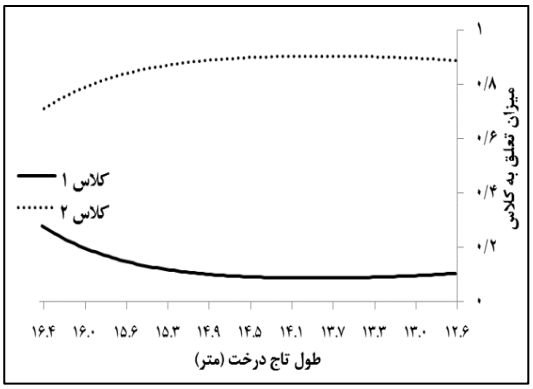

ب. نمودار روند تغییرات تعلق درخت به کلاس‌های شدت ریسک بر حسب تغییرات طول تاج

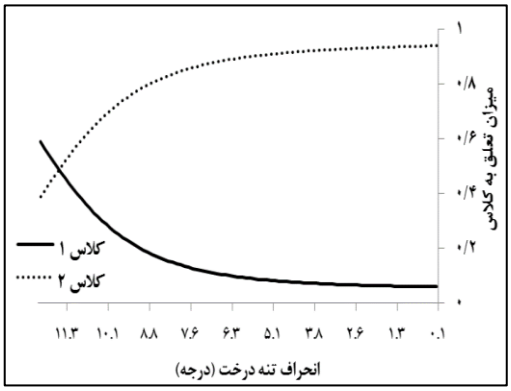

ج. نمودار روند تغییرات تعلق درخت به کلاس‌های شدت ریسک بر حسب تغییرات انحراف تنه درخت

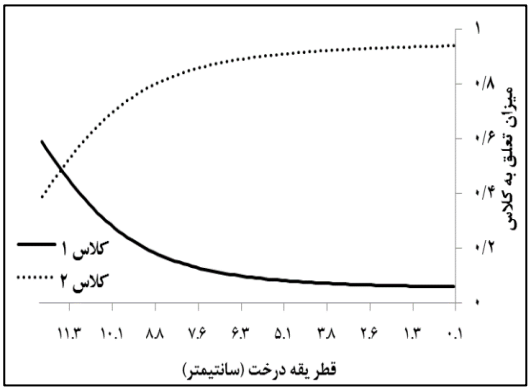

د. نمودار روند تغییرات تعلق درخت به کلاس‌های شدت ریسک بر حسب تغییرات قطر یقه درخت

شکل۴: نمودار روند تغییرات تعلق درخت به کلاس‌های شدت ریسک بر حسب تغییرات متغیرهای اثرگذار

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

شکل ۴ الف نشان می‌دهد که با افزایش قطر تاج درختان احتمال تعلق درخت به کلاس ۱ به صورت غیرخطی افزایش می‌یابد و به همان میزان از احتمال تعلق به کلاس ۲ کاسته می‌شود (افزایش شدت ریسک درختان خطرآفرین). شکل ۴ ب نشان می‌دهد که با افزایش طول تاج درختان احتمال تعلق درخت به کلاس ۱ به صورت غیرخطی افزایش می‌یابد و به همان میزان از احتمال تعلق به کلاس ۲ کاسته می‌شود (افزایش شدت ریسک درختان خطرآفرین). شکل ۴ ج نشان می‌دهد که با افزایش انحراف تنه درختان احتمال تعلق درخت به کلاس ۱ به صورت غیرخطی افزایش می‌یابد و به همان میزان از احتمال تعلق به کلاس ۲ کاسته می‌شود (افزایش شدت ریسک درختان خطرآفرین). همچنین شکل ۴ د نشان می‌دهد که با افزایش قطر یقه درختان احتمال تعلق درخت به کلاس ۱ به صورت غیرخطی افزایش می‌یابد و به همان میزان از احتمال تعلق به کلاس ۲ کاسته می‌شود (افزایش شدت ریسک درختان خطرآفرین).

پورهاشمی *و همکاران* (۱۳۹۱) خشکیدگی شاخه و سرشاخه و ضعف ساختاری را به عنوان مهمترین معیارهای درختان خطرآفرین چنار در شهر تهران معرفی نمودند. در تحقیق حاضر و بر اساس نتایج آنالیز حساسیت مدل SFHR، قطر تاج، طول تاج درخت، انحراف تنه درخت و قطر یقه درخت به ترتیب بیشترین تاثیر را در طبقه‌بندی شدت ریسک درختان خطرآفرین داشته‌اند که با معیارهای مربوط به تاج درخت در تحقیقات پورهاشمی *و همکاران* (۱۳۹۱) همخوانی دارد.

نتیجه‌گیری

امروزه مسئولیت‌های مدیریت شهری موجب شده است بسیاری از سازمان‌ها موظف به شناسایی درختان خطرآفرین و انجام اقدامات لازم باشند (Curie, ۱۹۹۱; Matheny and Clark, ۱۹۹۴; Mynors, ۱۹۹۳). اتخاذ تصمیم مبنی بر قطع یک درخت می‌تواند چالش‌های بسیاری را در سطح جامعه ایجاد نماید مخصوصا زمانی که درختان کهنسال مورد هدف قرار می‌گیرند. از این رو مدیریت فضای سبز شهری نیاز به ابزاری معتبر جهت ارزیابی پایداری درختان خطرآفرین، شناسایی و مدیریت آنها دارد (Terho and Hallaksela, ۲۰۰۵). مدل شبکه عصبی مصنوعی در مرحله آزمون و با بکارگیری نمونه‌هایی که در مدل‌سازی استفاده نشده است با دقت ۸۷/ ۰ و ۰/۹ به ترتیب در کلاسه‌های اول و دوم در کلاسه‌بندی شدت ریسک چنارهای خطر آفرین در اکوسیستم‌های شهری، مدل SFHR را به عنوان یک مدل پیش‌بینی کاربردی در ارزیابی احتمال سقوط درختان چنار معرفی نمود. SFHR ارتباط معنی‌داری را بین متغیرهای عمومی و عیوب درخت با شدت ریسک سقوط درختان چنار طی دو سال آینده نشان می‌دهد. عملکرد این مدل به عنوان یک سیستم پشتیبان تصمیم‌گیری در مدیریت فضای سبز شهری شناخته می‌شود که مورد استفاده تصمیم‌گیران جهت شناسایی و مدیریت درختان چنار خطرآفرین می‌باشد. البته SFHR همچون سایر مدل‌های تصمیم‌گیری به شدت به محیط مورد مطالعه وابسته است و کاربرد آن در سایر اکوسیستم‌ها نیاز به بازآموزی شبکه عصبی مصنوعی دارد. البته با توجه به قابلیت این شبکه عملیات بازآموزی با نمونه‌های کمتر و سرعت عمل بسیار بالاتری صورت گرفته و ضریب تعیین جدیدی به دست می‌آید (Jahani et al., ۲۰۱۶). همچنین بر اساس نتایج آنالیز حساسیت، نویسندگان اعتقاد دارند مدیران فضای سبز شهری اقدامات اصلاحی خود را بر روی درختان چنار با قطر و طول تاج بالا و انحراف تنه زیاد از محور اصلی متمرکز نمایند.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

یادداشت‌ها

۱. Sycamore Failure Hazard Risk
۲. Multi-layer perceptron
۳. Over-training
۴. Back Propagation
۵. Mean Absolute Error
۶. Mean Squared Error
۷. Root Mean Squared Error

منابع

پورهاشمی، مهدی؛ اسماعیل خسروپور و مازیار حیدری. ۱۳۹۱. ارزیابی خطرآفرینی درختان چنار (Platanus orientalis Linn.) خیابان ولیعصر تهران. *مجله جنگل ایران*، **۴(۳)**: ۲۶۵-۲۷۵.

دهقانی، امیر احمد؛ مهدی پیری، موسی حسام و نوید دهقانی. ۱۳۸۹. تخمین تبخیر روزانه از تشت تبخیر با استفاده از سه شبکه عصبی پرسپترون چندلایه، تابع پایه شعاعی و المانی. *مجله پژوهش های حفاظت آب و خاک*، **۱۷(۲)**: ۴۹-۶۷.

سازمان پارکها و فضای سبز شهر کرج، ۱۳۹۲. *گزارش طرح جامع فضای سبز کرج*. شهرداری کرج. ۷۸۵ص.

Argent, R. M.; J. M. Perraud, J. M. Rahman, R. B. Grayson, and G. M. Podger. ۲۰۰۹. "A new approach to water quality modelling and environmental decision support systems." Environmental Modelling & Software **۲۴(۷)**: ۸۰۹-۸۱۸.

Boillereaux, L.; C. Cadet and A. Le Bail. ۲۰۰۳. Thermal properties estimation via real time neural network learning. Journal of Food Engineering **۵۷**: ۱۷-۲۳.

Burton, E. ۲۰۰۲. Measuring urban compactness in UK towns and cities. Environment and Planning B **۲۹**, ۲۱۹–۲۵۰.

Callan, R. ۱۹۹۹. The Essence of Neural Networks. Upper Saddle River, New Jersey: Prentice Hall.

Curie, M. ۱۹۹۱. Whose responsibility? Arboricultural Journal **۱۵**, ۲۳۵–۲۴۱.

Duryea, M.L.; E. Kampf, and R.C., Littell. ۲۰۰۷. Hurricanes and the urban forest: I. Effects on southeastern United States coastal plain tree species. Arboricult. Urban For., **۳۳**, ۸۳–۹۷.

Elmahdi, A. and D. McFarlane. ۲۰۰۹. A decision support system for sustainable groundwater management. Case study: Gnangara Sustainability Strategy - Western Australia. International Congress on Modeling and Simulation, Australia Modeling and Simulation Society of Australia and New Zealand.

Harris, R.W. ۱۹۹۲. Arboriculture: Integrated Management of Landscape Trees, Shrubs, and Vines, ۲nd edn. Prentice-Hall, Englewood Cliffs, NJ, ۶۷۴ pp.

Hussain, M.A.; M. Safiur, and C.W. Rahman. ۲۰۰۲. Prediction of pores formation (porosity) in foods during drying: generic models by the use of hybrid neural network. Journal of Food Engineering **۵۱**: ۲۳۹-۲۴۸.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

Jahani, A.; J. Feghhi, M. F. Makhdoum, and M. Omid. ۲۰۱۶. Optimized forest degradation model (OFDM): an environmental decision support system for environmental impact assessment using an artificial neural network. Journal of Environmental Planning and Management, **۵۹**(**۲**): ۲۲۲-۲۴۴.

Jambunathan, K.; S.L. Hartle, S. Ashforth-Frost, and V.N. Fontana. ۱۹۹۶. Evaluating convective heat transfer coefficients using neural networks. International Journal of Heat Mass Transfer **۳۹** (**۱۱**): ۲۳۲۹-۲۳۳۲.

Jim, C.Y. ۱۹۹۳. Soil compaction as a constraint to tree growth in tropical and subtropical urban habitats. Environmental Conservation **۲۰**, ۱۳۵-۱۴۹.

Jim, C.Y. ۲۰۰۵. Monitoring the performance and decline of heritage trees in urban Hong Kong. Journal of Environmental Management **۷۴**, ۱۶۱–۱۷۲.

Jim, C.Y., and H. Zhang. ۲۰۱۳. Defect-disorder and risk assessment of heritage trees in urban Hong Kong. Urban Forestry & Urban Greening **۱۲**: ۵۸۵–۵۹۶.

Matheny, N.P., and J.R. Clark. ۱۹۹۴. A Photographic Guide to the Evaluation of Hazard Trees in Urban Areas. International Society of Arboriculture, Urbana, Illinois.

Mattheck, C., and H. Breloer. ۱۹۹۴ FIELD GUIDE FOR VISUAL TREE ASSESSMENT (VTA). Arboricultural Journal: The International Journal of Urban Forestry **۱۸** (**۱**), ۱-۲۳.

Mortimer, M.J., and B. Kane. ۲۰۰۴. Hazard tree liability in the United States: uncertain risks for owners and professionals. Urban For. Urban Green., **۲**. ۱۵۹–۱۶۵.

Mynors, C. ۱۹۹۳. Trees and the law. Arboricultural Journal **۱۷**, ۴۱۳–۴۲۳.

Paliwal, J. Visen, N.S. and D.S. Jayas. ۲۰۰۱. Evaluation of neural network architectures for cereal grain classification using morphological features. Journal of Agricultural Engineering **۷۹** (**۴**): ۳۶۱-۳۷۰.

Pellissier, V.; F. Roze, and P. Clergeau. ۲۰۱۰. Constraints of urbanization on vegetation dynamics in a growing city: a chronological framework in Rennes (France). In: Muller, N., Werner, P., Kelcey, J.G. (Eds.), Urban Biodiversity and Design. Black- well, Oxford, UK, pp. ۲۰۶–۲۲۶.

Sablani, S.S.; O.D. Baik, and M. Marcotte. ۲۰۰۲. Neural networks for predicting thermal conductivity of bakery products. Journal of Food Engineering **۵۲**: ۲۹۹-۳۰۴.

Sani, L.; R. Lisci, M. Moschi, D. Sarri, M. Rimediotti, M. Vieri, and S. Tofanelli. ۲۰۱۲. Preliminary experiments and verification of controlled pulling tests for tree stability assessments in Mediterranean urban areas, Biosystems Engineering, **۱۱۲**(**۳**): ۲۱۸–۲۲۶.

Sieghardt, M.; E. Mursch-Radlgruber, E. Paoletti, E. Couenberg, A. Dimitrakopoulus, F. Rego, A. Hatzistathis, and T.B. Randrup. ۲۰۰۵. The abiotic urban environment: impact of urban growing conditions on urban vegetation. In: Konijnendijk, C.C., Nilsson, K., Randrup, T.B., Schipperijn, J. (Eds.), Urban Forests and Trees. Springer, Heidelberg, pp. ۲۸۱–۳۲۳.

Sreekanth, S. Ramaswamy, H.S. and S.S. Sablani. ۱۹۹۸. Prediction of sychrometric parameters using neural networks. Drying Technology **۱۶** (**۳-۵**): ۸۲۵-۸۳۷.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]

Sreetheran, M.; M. Adnan, and A.K. Khairil Azuar. ۲۰۱۱. Street tree inventory and tree risk assessment of selected major roads in Kuala Lumpur, Malaysia. Arboricul- ture and Urban Forestry **۳۷**, ۲۲۶–۲۳۵.

Tello, M.L.; M. Tomalak, R. Siwecki, J. Gáper, E. Motta, and E. Mateo-Sagasta. ۲۰۰۵. Biotic urban growing conditions – threats, pests and diseases. In: Konijnendijk, C.C., Nilsson, K., Randrup, T.B., Schipperijn, J. (Eds.), Urban Forests and Trees: A Reference Book. Springer, Heidelberg, pp. ۳۲۵–۳۶۵.

Terho, M., and A.M. Hallaksela. ۲۰۰۵. Potential hazard characteristics of Tilia, Betula, and Acer trees removed in the Helsinki City Area during ۲۰۰۱–۲۰۰۳. Urban Forestry & Urban Greening **۳**:۱۱۳–۱۲۰.

Twery, J.; D. Peter, and A. Scott. ۲۰۰۵. NED-۲: A decision support system for integrated forest ecosystem management. Computers and Electronics in Agriculture **۴۹**: ۲۴-۴۳.

[Downloaded from isharat.khu.ac.ir on 2026-10-28]

[DOI: 10.18869/acadpub.jsaeh.3.4.35]