نشریه پژوهش‌های علوم و فناوری چوب و جنگل
جلد بیست و چهارم، شماره سوم، ۱۳۹۶
http://jwfst.gau.ac.ir

مدل‌سازی ارزیابی کیفیت زیباشناختی منظر جنگل با استفاده از شبکه عصبی مصنوعی

علی جهانی*
استادیار گروه محیط‌زیست طبیعی و تنوع زیستی، دانشکده محیط‌زیست، کرج، ایران
تاریخ دریافت: ۱۳۹۵/۰۳/۱۰؛ تاریخ پذیرش: ۱۳۹۶/۰۴/۰۸

چکیده

سابقه و هدف: با توجه به کاهش روزافزون قابلیت برداشت چوب از جنگل‌های هیرکانی نیاز به برنامه‌ریزی برای استفاده از سایر قابلیت‌های بوم‌سازگان‌های جنگلی همچون طبیعت‌گردی بیشتر از گذشته احساس می‌شود. برنامه‌ریزی طبیعت‌گردی نیاز به اطلاعات کافی درباره جذابیت‌های اکولوژیکی، ساختار و عناصر منظر طبیعی دارد. از طرفی ارزیابی صحیح از وضعیت مناظر مختلف در یک منطقه مستلزم داشتن اطلاعات کافی در مورد معیارهای تأثیرگذار و همچنین نوع، نحوه و میزان اثرگذاری هر یک از این معیارها در درک کاربر از کیفیت منظر است. تعیین نقاطی که از نظر ساختار منظر، کیفیت بالایی دارند گام اول در جهت بالا بردن کیفیت زیباشناختی آن‌ها و حفاظت از بوم‌سازگان طبیعی می‌باشد. در این مطالعه تلاش جهت ارزیابی کیفیت زیباشناختی منظر جنگل با استفاده از ترکیب دیدگاه جامع کمی و روش مدل‌سازی شبکه عصبی مصنوعی جهت تعیین مؤثرترین عناصر عینی منظر در افزایش کیفیت زیباشناختی ذهنی منظر است.

مواد و روش‌ها: پژوهش حاضر در سه بخش پاتم، نمخانه و گرازبن جنگل آموزشی پژوهشی خیرود دانشکده منابع طبیعی دانشگاه تهران (با تنوع بالا در کیفیت منظر) انجام شد. در منطقه جنگلی مورد مطالعه در مجموع ۲۰۰ منظر با ساختار متنوع از نظر پوشش درختی و ترکیب منظره‌ها شناسایی و اطلاعات مربوط به عناصر و ویژگی‌های منظر ثبت گردید و کیفیت زیباشناختی با دید ناظر ارزیابی شد. در این تحقیق به‌منظور مدل‌سازی ارزیابی کیفیت زیباشناختی منظر جنگل، ویژگی‌های ساختاری و عناصر هریک از مناظر ثبت و اقدام به طبقه‌بندی کیفیت زیباشناختی منظر در سه کلاس کیفیت زیباشناختی ضعیف (۱)، مطلوب (۲) و عالی (۳) گردید. به‌منظور پردازش داده‌ها با ابزار هوشمند شبکه عصبی، از شبکه پرسپترون چندلایه استفاده شد.

یافته‌ها: با توجه به ضرایب تبیین آزمون شبکه معادل ۰/۸۸، ۰/۸۹۶ و ۰/۹۶۹ در طبقه‌بندی کلاس‌های ۱ تا ۳، دقت شبکه عصبی در پیش‌بینی کیفیت زیباشناختی منظر جنگل از سطح بسیار مطلوبی برخوردار است. بر اساس نتایج آنالیز حساسیت ترکیب منظر، تنوع منظر درختی و پوشش درختان قطور به‌ترتیب بیشترین تأثیر را در طبقه‌بندی مناظر جنگل در کلاس ۱ و ۲ داشته‌اند. از طرفی تنوع منظر درختی، ترکیب منظر و موقعیت دید به‌ترتیب بیشترین تأثیر را در طبقه‌بندی مناظر در کلاس ۳ از خود نشان دادند.

*مسئول مکاتبه:

نتیجه‌گیری: شناسایی تأثیرگذارترین عناصر بر کیفیت زیباشناختی منظر جنگل، مشخص می‌سازد که جهت مدیریت و برنامه‌ریزی منظر جنگل و دستیابی به نقاط چشم‌انداز با کیفیت منظر مطلوب از دیدگاه کاربر یا ناظر توجه به ترکیب منظر و تنوع بالا در منظره‌های موجود، تنوع منظر درختی با تنوع بالا در گونه‌های درختی توده و همچنین حضور درختان قطور و کهنسال در الویت قرار می‌گیرد. تحقیق حاضر روش نوینی را در ارزیابی کیفیت زیباشناختی منظر جنگل ارائه می‌کند و مدل حاصله علاوه‌بر ارائه معیارهای کاربردی در ارزیابی کیفیت منظر جنگل، به‌عنوان یک سامانه پشتیبان تصمیم‌گیری با قابلیت استفاده در بوم‌سازگان‌های جنگلی مشابه شناخته می‌شود.

واژه‌های کلیدی: کیفیت زیباشناختی منظر جنگل، شبکه عصبی مصنوعی، پرسپترون چندلایه، ترکیب منظر

مقدمه

با توجه به کاهش روزافزون قابلیت برداشت چوب از جنگل‌های هیرکانی نیاز به برنامه‌ریزی برای استفاده از سایر قابلیت‌های بوم‌سازگان‌های جنگلی همچون طبیعت‌گردی بیشتر از گذشته احساس می‌شود. برنامه‌ریزی طبیعت‌گردی نیاز به اطلاعات کافی درباره جذابیت‌های اکولوژیکی، ساختار و عناصر منظر طبیعی دارد (۳۵). در عمل جایگاه، ارزش و نقش چشم‌اندازها در طبیعت، جهت برنامه‌ریزی و جذب گردشگران کمتر مورد توجه قرار می‌گیرد. در واقع می‌توان گفت که اهمیت کیفیت زیباشناختی منظر تأثیر بسیار زیادی در استفاده تفرجی از منطقه دارد و همچنین نباید نقش کیفیت زیباشناختی منظر را در طراحی و ساخت جاده‌های جنگلی نادیده گرفت. بنابراین تعیین نقاطی که از نظر ساختار منظر، کیفیت بالایی دارند گام اول در جهت بالا بردن کیفیت زیباشناختی آن‌ها و حفاظت از بوم‌سازگان طبیعی منطقه می‌باشد (۲٤، ۲۸).

کیفیت منظر شامل دامنهٔ وسیعی از عوامل محیطی، اکولوژیکی، اجتماعی، فرهنگی و فیزیولوژیکی است (۱۳). به‌طور کلی دو دیدگاه متفاوت در زمینهٔ ارزیابی کیفیت منظر و چشم‌اندازهای طبیعی وجود دارد، که دیدگاه اول در برگیرنده اصولی برای طراحی محیط می‌باشد و دیدگاه دوم اصول ادراکی را شامل می‌شود (۳۹). از طرفی ارزیابی صحیح از وضعیت مناظر مختلف در یک منطقه مستلزم داشتن اطلاعات کافی در مورد معیارهای تاثیرگذار و همچنین نوع، نحوه و میزان اثرگذاری هر یک از این معیارها در درک کاربر از کیفیت منظر است. کندال و همکاران (۲۰۱۲) مطالعات گسترده‌ای را در ارتباط با ترجیحات انسان‌ها از گیاهان و شاخص‌های گیاهی منظر که تأثیر معناداری در درک زیبایی دارند انجام دادند و به ویژگی‌های متعددی از گیاهان که اثر بسزایی در درک زیبایی افراد دارند دست یافتند (۱۸). زیباشناختی منظر اغلب به مناطق تفریحی یا چشم‌اندازهایی مربوط می‌شود که به دقت طراحی و به گونه‌ای هنرمندانه ساخته شده‌اند و تداعی کننده نقاشی منظراند و بنابراین ادراک را با هنرهای زیبا مرتبط می‌سازند (۲۲). شیپرین و همکاران (۲۰۱۰) و کیناست و همکاران (۲۰۱۲) در مطالعات خود دریافتند که فراوانی بازدید از مناظر طبیعی متناسب با ویژگی‌ها و کیفیت منظر تغییر می‌کند (۳۲، ۲۰). در واقع بازدیدکنندگان قادر به درک منظر طبیعی و منظر انسان ساخت بوده و براساس کیفیت منظرسازی تصمیم به استفاده تفرجی از مناطق می‌گیرند (۱۷، ۲٦). این بدان معناست که بازدیدکنندگان توانایی به‌خصوصی در ارزیابی کیفیت زیباشناختی منظر دارند.

معیارهای متعددی در ارزیابی کیفیت زیباشناختی محیط تأثیر دارند و ایجاد رابطه بین ارزیابی کیفی و ذهنی منظر با معیارها و متغیرهای عینی اثرگذار بر آن، پیچیدگی بالایی داشته و جهت دستیابی به دقت بالا، کشف روابط پیچیده و امکان به‌کارگیری متغیرهای متعدد، در این پژوهش از شبکه عصبی مصنوعی به‌عنوان روش مدل‌سازی معتبر در فرآیندهای پیچیده استفاده شد. مطالعات بسیاری هم بر قابلیت و دقت بالاتر شبکه عصبی مصنوعی نسبت به مدل‌های رگرسیونی اذعان دارند (۳٦، ۲۱). برای مدل‌سازی ارزیابی کیفیت زیباشناختی منظر جنگل در زیست‌بوم‌های مختلف از تکنیک‌های مختلفی استفاده شده است (۱۱، ۱۳، ۱٦). در پژوهش حاضر با توجه به تعداد ورودی‌های مختلف در قالب متغیرهای توصیفی و برای حذف خطاهای محاسباتی و تحلیلی که در مدل‌سازی کلاسیک همانند تحلیل رگرسیون بسیار رایج است، از تکنیک شبکه عصبی مصنوعی استفاده شده است (۱، ۲، ۵، ۱٦، ۲۷).

تاکنون شبکه‌های عصبی در مطالعات گسترده‌ای در زمینه محیط زیست به‌کار گرفته شده‌اند (۱۵، ۲۳، ٤۱) که عمدتا کاربرد شبکه‌های عصبی در کشف روابط بین اجزای بوم‌سازگان، کمی کردن آن‌ها و ارائه مدل‌های ارزیابی و تصمیم‌گیری در محیط زیست می‌باشد. در اینجا سؤال اصلی این است که مردم در ارتباط با مناظر جنگلی، زیبایی را چگونه ارزیابی می‌کنند و یا چگونه منظری را زیبا می‌دانند؟ عناصر تأثیرگذار بر زیبایی منظر جنگل از دیدگاه بیننده چه متغیرهایی است؟ و شبکه عصبی مصنوعی تا چه میزان قابلیت مدل‌سازی درک کاربر از زیبایی منظر را دارد؟ مقاله حاضر تلاش دارد پاسخی علمی برای سوالات مطرح شده ارائه دهد. هدف از این مقاله مدل‌سازی ارزیابی کیفیت زیباشناختی منظر جنگل با استفاده از شبکه عصبی مصنوعی به‌منظور کشف روابط حاکم در ساختار منظر و ارتباط عناصر منظر با کیفیت زیباشناختی آن است. نتایج حاصل، عناصر عینی بوم‌سازگان جنگلی با ارزش زیباشناختی بالا را جهت برنامه‌ریزی گردشگری، مسیریابی جاده‌های جنگلی و سایر فعالیت‌های مرتبط طرح جنگلداری مشخص کرده و خروجی‌های بهینه حاصل از مدل‌سازی شبکه عصبی مصنوعی در قالب کارافزار دیجیتالی قابل استفاده در سیستم‌های رایانه‌ای می‌تواند قابل استفاده در بخش‌های اجرایی مدیریت جنگل محسوب شوند.

مواد و روش‌ها

منطقه مورد مطالعه: پژوهش حاضر در سه بخش پاتم، نمخانه و گرازبن جنگل آموزشی پژوهشی خیرود دانشکده منابع طبیعی دانشگاه تهران (با تنوع بالا در کیفیت منظر) انجام شد. جنگل آموزش و پژوهشی خیرود در ۷ کیلومتری شرق شهرستان نوشهر بین ۳٦ درجه و ۲۷ دقیقه و ۳٦ درجه و ٤۰ دقیقه عرض شمالی و ۵۱ درجه و ۳۲ دقیقه و در حوزه اداره کل منابع طبیعی نوشهر در منطقه خیرود واقع شده است (شکل ۱).

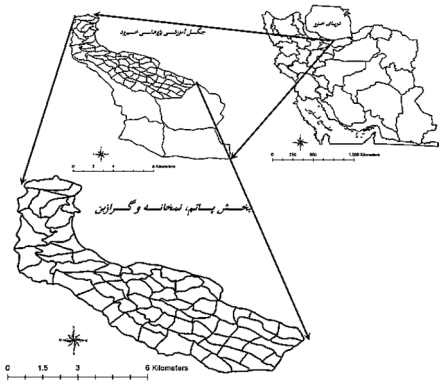

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه.
Figure 1. Geographic location of study area.

از ویژگی اصلی و جذاب این منطقه می‌توان به ادغام دو عنصر سنگ و گیاه در منطقه‌ای کوهستانی،

تنوع گونه‌های گیاهی و تنوع عناصر طبیعی و مصنوعی منظر اشاره کرد. منطقه مورد مطالعه در طبقه‌بندی اقلیمی آمبرژه در اقلیم خیلی مرطوب و با زمستان‌های خیلی خنک قرار می‌گیرد و بر اساس طبقه‌بندی کوپن منطقه مذکور در اقلیم معتدل گرم قرار می‌گیرد. از نظر اقلیمی منطقه بدون فصل خشک است، لیکن تیرماه حساس‌ترین زمان برای بروز خشکی می‌باشد و هر چند سال یک بار به‌مدت کوتاهی دوره خشکی رخ می‌دهد. بر اساس آمار هواشناسی سال ۱۳۹۳ ایستگاه نوشهر، میانگین سالانه درجه حرارت هوا ۱٦/۸٦ درجه سانتی‌گراد و گرم‌ترین ماه سال مرداد با میانگین ۲۷/۵ و سردترین ماه سال بهمن با میانگین ٦/۳ درجه سانتی‌گراد است. بارندگی سالانه برابر با ۱٤۰۹/۱ میلی‌متر در سال ۱۳۹۳ و پرباران‌ترین ماه سال مهر ماه با میانگین ۵۵٤/۱ میلی‌متر و کم باران‌ترین ماه سال مرداد با میانگین ۱۰ میلی‌متر می‌باشد.

روش

در این مطالعه تلاش جهت ارزیابی کیفیت زیباشناختی منظر جنگل با استفاده از ترکیب دیدگاه جامع کمی و روش مدل‌سازی شبکه عصبی مصنوعی جهت تعیین مؤثرترین عناصر عینی منظر در افزایش کیفیت زیباشناختی ذهنی منظر است. در انجام این پژوهش، به‌صورت میدانی بازدیدی از مناطق مختلف جنگل مورد مطالعه به‌منظور تعیین نقاط چشم‌انداز صورت گرفت. نقاط چشم‌انداز بر اساس انتخاب انواع مناظر موجود در منطقه مورد مطالعه است (از جمله انواع پوشش درختی، انواع جاده‌ها و مسیرها، نمای روستا، دریا، رودخانه و دامنه‌های سنگی) به‌طوری‌که در مجموعه تصاویر منتخب، تنوع معیارهای مورد بررسی در این مطالعه (که در ادامه به تشریح هریک پرداخته شده است) دیده شود و این مجموعه تصاویر شامل معیارها با درجات، ارزش‌ها و کمیت‌های مختلف است. پس از تعیین نقاط چشم‌انداز، ویژگی‌های هریک از مناظر (به‌عنوان معیارهای کیفیت زیباشناختی منظر) در جدول تعیین کیفیت منظر درج گردید. معیارهای مذکور (با ذکر منابع) عبارتند از:

سیمای منظر: اگر زاویه دید کمتر از ۳۰ درجه باشد سیمای منظر «کانونی یا کلاس ۱» محسوب می‌گردد و اگر بین ۳۰ تا ۱۲۰ درجه باشد سیمای منظر «بسته یا کلاس ۲» و بیشتر از ۱۲۰ درجه، سیمای منظر «پانورامیک یا کلاس ۳» نامیده (۱٦).

فاصله دید: اگر فاصله دید نسبت به نقطه تعیین شده ۱ تا ٤۰۰ متر باشد، فاصله دید «پیش یا کلاس ۱»، ٤۰۰ متر تا ۸ کیلومتر، فاصله دید «متوسط یا کلاس ۲» و بیش از ۸ کیلومتر «پس یا کلاس ۳» در نظر گرفته می‌شود (۱٦).

موقعیت دید: اگر منظره تعیین شده در پائین قرار گرفته باشد موقعیت نسبت به آن نقطه «مادون یا کلاس ۱»، اگر هم سطح باشد «معمولی یا کلاس ۲» و اگر نقطه تعیین شده در بالا قرار گرفته باشد موقعیت دید «ماورا یا کلاس ۳» می‌باشد (۱٦).

ترکیب منظر: تعداد منظره‌های قابل مشاهده در یک منظر یا سیمای سرزمین شامل جنگل، روستا، دریا، رودخانه، دامنه سنگی، جاده و مسیر مالرو (۱٦).

درصد اختصاص یافته به هریک از منظره‌ها در سیمای سرزمین شامل: جنگل (۱۱)، روستا (۱۱، ۹)، دریا، رودخانه (۲۷)، دامنه سنگی (۷)، جاده و مسیر مالرو (۲۹) که در تصویر منظر با استفاده از شبکه نقطه چین اندازه‌گیری می‌شود.

درصد پوشش درختان در منظر (۱، ۲۷) در سه طبقه کم قطر (قطر زیر ۲۰ سانتی‌متر)، قطر متوسط (قطر ۲۰ تا ۱۰۰ سانتی‌متر) و قطور (قطر بیش از یک

متر) که در تصویر منظر با شبکه نقطه چین برآورد می‌شود.

درصد پوشش گونه‌های درختی در منظر (۱، ۳٤) شامل ۵ کلاس: راش، بلوط، ممرز، انجیلی و سایر گونه‌ها که در تصویر منظر با شبکه نقطه چین برآورد می‌شود. با توجه به اطلاعات میدانی ثبت شده برای هر تصویر (عکاسی معمولی با دوربین عکاسی) در هنگام عکسبرداری، امکان تشخیص گونه بر روی عکس فراهم گردید.

تنوع منظر درختی (۲۹، ۳۰) که شامل تعداد گونه‌های درختی در منظر است.

تحقیقات اخیر (۲) نشان داده است که در ارزیابی کیفیت زیباشناختی منظر هنوز توجه جدی به عناصر زیباشناختی در درک زیبایی منظر معطوف می‌گردد. هرچند با عکس و به‌صورت کیفی نمی‌توان زیباشناختی را به‌صورت دقیق تعیین کرد اما در اغلب موارد از روش ارزیابی ذهنی منظر از روش‌های ثبت دیداری همچون عکس‌ها، اسلایدها و فیلم‌های کوتاه در ارائه تصویری از منظر استفاده می‌گردد (٤۰). لذا در پژوهش حاضر با تهیه عکس از مناظر اقدام به ارزیابی کیفیت زیباشناختی منظر جنگل به‌صورت کیفی با روش ارزیابی ذهنی (Subjective assessment) منظر در سه دسته ارزش کیفیت زیباشناختی ضعیف، مطلوب و عالی از دیدگاه عمومی ۲۰۰ ناظر گردید.

به‌منظور پردازش داده‌ها با کمک ابزار هوشمند شبکه عصبی، از شبکه پرسپترون چندلایه[1] استفاده شد. سایر شبکه‌ها نیز مورد بررسی قرار گرفت اما از آن‌جایی‌که نتایج بسیار ضعیف و غیرقابل ارائه به‌دست آمد لذا شبکه پرسپترون چندلایه مورد استفاده قرار گرفت و از ارائه نتایج سایر شبکه‌ها با توجه به محدودیت کمی مقاله صرف نظر شد. شبکه پرسپترون چندلایه یکی از متداول‌ترین و شناخته‌شده‌ترین انواع شبکه‌های عصبی است. این امر، به‌طور عمده به‌این دلیل است که پیاده‌سازی یک نگاشت بین ورودی‌ها و خروجی‌ها می‌تواند به‌صورت یک تقریب زننده تابعی عمل کند. شبکه پرسپترون چندلایه از مجموعه داده‌های ورودی، چندین لایه مخفی و یک لایه خروجی تشکیل شده است. لایه‌های مخفی از واحدهای پردازشی به نام نورون تشکیل شده‌اند (۳۷). در این تحقیق به‌منظور مدل‌سازی ارزیابی کیفیت زیباشناختی منظر جنگل، معیارهای منتخب در هریک از مناظر ثبت و اقدام به طبقه‌بندی کیفیت زیباشناختی منظر جنگل در سه کلاس شامل کلاس یک، ارزش کیفیت زیباشناختی ضعیف، کلاس دو، ارزش کیفیت زیباشناختی مطلوب و کلاس سه ارزش کیفیت زیباشناختی عالی گردید.

نرم‌افزار Neuro Solutions 5 برای طراحی و ارزیابی شبکه‌های عصبی مصنوعی مختلف استفاده شد. قبل از به‌کارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمالیزه شود زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به‌دلیل دامنه تغییرات خروجی توابع فعالیت به‌کار گرفته شده در لایه میانی، این امر ضروری به‌نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نخواهد شد (٤). زمانی‌که از توابع فعالیت تانژانتی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها ۰/۹ است (۳۸). در این راستا کلیه داده‌های ورودی و خروجی در محدوده ۰/۹ تا ۰/۹- و با استفاده از رابطه ۱ استانداردسازی شدند.

رابطه ۱
$$NData(i) = \left[\frac{U-L}{Max(i)-Min(i)} * Data(i)\right] + \left[U - \left(\frac{U-L}{Max(i)-Min(i)} * Max(i)\right)\right]$$

به‌طوری‌که N Data(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.

برای آموزش شبکه، ابتدا ۲۰۰ نمونه موردنظر به‌طور تصادفی به سه دسته آموزش شبکه (۶۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون شبکه (۲۵ درصد) تقسیم شدند. با اختصاص حجم بیشتری از نمونه‌ها به آزمون شبکه می‌توان از قابلیت پیش‌بینی شبکه در نمونه‌های جدید اطمینان حاصل کرد لذا ترکیب به‌کار گرفته شده در این تحقیق در سایر مطالعات نیز استفاده شده است (۱۹).

در تعیین ساختار بهینه شبکه‌های عصبی قانون تأیید 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 (۳۰، ۷). 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 به‌این منظور از ٤ تا ۳۰ نرون استفاده گردید. همچنین افزایش لایه‌های مخفی از یک لایه به دو و سه لایه و آزمون توابع محرک مختلف خطی و تانژانتی (رابطه ۲ تا ٤) با الگوریتم آموزشی پس انتشار خطا (لونبرگ مارکوارت (LM)) مورد استفاده قرار گرفت.

رابطه ۲ $$tanh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$$

رابطه ۳ $$tansig(x) = \frac{2}{[1 + \exp(-2x_j)] - 1}$$

رابطه ٤ $$Purelin(x) = f(x) = x$$

به‌منظور طراحی ساختار بهینه، شبکه عصبی برای الگوهای متعددی اجرا شد و توابع تحریک مختلف در لایه پنهان آزمون گردید. سپس از بین حالت‌های مختلف، ساختاری که در آن بیشترین ضریب تبیین و کمترین خطا وجود داشت، انتخاب شد.

صحت مدل با مقایسه خروجی پیش‌بینی شده مدل و میزان حقیقی کیفیت زیباشناختی منظر صورت گرفت. شاخص‌های مورد استفاده جهت مقایسه شامل ضریب تبیین (R^2)، میانگین خطای مطلق (MAE[۲])، میانگین مربعات خطا (MSE[۳]) و ریشه میانگین مربعات خطا (RMSE[٤]) می‌باشند (روابط ۵ تا ۸). مقدار بالاتر ضریب تبیین و پایین‌تر میانگین خطای مطلق، میانگین مربعات خطا و ریشه میانگین مربعات خطا نشان دهنده دقت بالاتر مدل خواهد بود.

رابطه ۵ $$MSE = \frac{\sum_{i=1}^{n}(O_i - P_i)^2}{n}$$

رابطه ٦ $$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n}\left|O_i - P_i\right|$$

رابطه ۷ $$R^2 = \frac{\sum_{i=1}^{n}(O_i - O_{ave})(P_i - P_{ave})}{\sqrt{\sum_{i=1}^{n}(O_i - O_{ave})\sum_{i=1}^{n}(P_i - P_{ave})}}$$

رابطه ۸ $$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(O_i - P_i)^2}{n}}$$

که در این روابط: O_i: داده اندازه‌گیری‌شده، P_i: داده پیش‌بینی‌شده، O_{ave}: میانگین داده‌های اندازه‌گیری‌شده، P_{ave}: میانگین داده‌های پیش‌بینی‌شده و n: تعداد داده‌ها است.

ارزیابی بهترین برازش شبکه برای یافتن بهترین توپولوژی شبکه مناسب، از طریق معیارهای فوق انجام گردید که هدف کمینه نمودن میانگین مربعات

1- Multilayer Perceptron

2- Mean Absolute Error
3- Mean Squared Error
4- Root Mean Squared Error

خطا و میانگین مربعات خطای مطلق (درصد) و نزدیکی نتایج در مراحل آموزش (٦٠ درصد)، اعتبارسنجی (١٥ درصد) و آزمون (٢٥ درصد) می‌باشد. آنالیز حساسیت به‌منظور تعیین اثر هریک از متغیرها بر خروجی مدل انجام پذیرفت. برای این منظور انحراف معیار و میانگین هر یک از متغیرهای مدل محاسبه شد. سپس جهت محاسبه حساسیت خروجی شبکه (مدل ارزیابی کیفیت زیباشناختی جنگل) به هریک از متغیرهای مدل، اقدام به ثابت نگه داشتن تمام متغیرها برابر با میانگین آن‌ها شد و متغیر موردنظر در دامنه انحراف معیار (با ١٠٠ گام در دامنه انحراف معیار) تغییر کرد و با پیش‌بینی و شبیه‌سازی کیفیت زیباشناختی، انحراف معیار خروجی‌های مدل محاسبه شد. این فرآیند برای تک تک متغیرهای ورودی انجام شده و حساسیت نتایج مدل به تک تک ورودی‌ها تعیین گردید.

نتایج و بحث

در منطقه جنگلی مورد مطالعه در مجموع ٢٠٠ منظر با ساختار متنوع از نظر پوشش درختی و ترکیب منظره‌ها شناسایی و اطلاعات مربوط به عناصر و ویژگی‌های منظر ثبت گردید و کیفیت زیباشناختی با دید ناظر ارزیابی شد. مجموعا ٤٩ منظر در کلاس یک (ارزش کیفیت زیباشناختی ضعیف)، ١٠٢ منظر در کلاس دو (ارزش کیفیت زیباشناختی مطلوب) و ٤٩ منظر در کلاس سه (ارزش کیفیت زیباشناختی عالی) قرار گرفتند. متوسط هریک از متغیرها در قالب ماتریس ورودی و همچنین متوسط مقادیر پاسخ در جدول ١ ارائه شده است.

جدول ١- میانگین متغیرهای مورد استفاده در مدل‌سازی شبکه عصبی مصنوعی.

Table 1. The mean of variables in neural network modeling.

متغیر ورودی (Input vairable)	میانگین±اشتباه معیار Mean± Standard (error)	متغیر ورودی (Input vairable)	میانگین±اشتباه معیار Mean± Standard (error)	کلاس خروجی (Output class)	تعداد (N)
ترکیب منظر (Landscape composition)	2.95±0.06	منظر مسیر مالرو (درصد) (Trail view)	4.05±0.36	کلاس ١ (Class 1)	49
موقعیت دید (View situation)	1.76±0.04	پوشش درختان قطور (درصد) (Thick trees)	29.32±1.52	کلاس ٢ (Class 2)	102
سیمای منظر (زاویه) (Landscape angle)	2.15±0.05	پوشش درختان قطر متوسط (درصد) (Semi thick trees)	42.55±1.44	کلاس ٣ (Class 3)	49
فاصله دید (Landscape distance)	1.9±0.5	پوشش درختان کم‌قطر (درصد) (Slim trees)	28.52±1.05		
منظر جنگل (درصد) (Forest view)	57.1±1.07	پوشش راش (درصد) (*Fagus orientalis* cover)	21.4±1.83		
منظر دریا (درصد) (Sea view)	5.52±0.56	پوشش بلوط (درصد) (*Quercus castanafolia* cover)	11.95±1.14		
منظر رودخانه (درصد) (River view)	7.22±0.74	پوشش ممرز (درصد) (*Carpinus betulus* cover)	40.47±1.28		
منظر دامنه سنگی (درصد) (Rock hillside view)	10.32±0.97	پوشش انجیلی (درصد) (*Parrotia persicas* cover)	17±1.27		
منظر روستا (درصد) (Village view)	5.17±0.51	پوشش سایر گونه‌ها (درصد) (Other species cover)	9.47±0.3		
منظر جاده (درصد) (Road view)	8.5±0.81	تنوع منظر درختی (Trees scene diversity)	4.1±0.04		

پس از آزمون شبکه‌های حاصل از ساختارهای گوناگون، بهترین نتایج حاصل از بهینه‌سازی شبکه عصبی به‌همراه بهترین توپولوژی به‌دست آمده در جدول ۲ نشان داده شده است. مدل ۵ با توجه به دقت بالاتر به‌عنوان ساختار بهینه شبکه عصبی و بهترین توپولوژی انتخاب گردید.

در آموزش شبکه عصبی می‌توان از ترکیبات مختلف لایه‌های پنهان و با تعداد نورون مختلف استفاده نمود، اما بررسی ضرایب تبیین (R^2) به‌دست آمده در نهایت میزان خطای شبکه در پیش‌بینی را نشان می‌دهد. توپولوژی (ساختار شبکه) به‌کار رفته با بیشترین مقدار ضریب تبیین و نزدیکی دقت نتایج (ضریب تبیین و حداقل مجذور مربعات خطا) در سه دسته داده آموزش، اعتبارسنجی و آزمون، بهترین عملکرد شبکه عصبی در پیش‌بینی و مدل‌سازی را نشان می‌دهد. بر اساس مطالعات واحدی (۲۰۱۶) همبستگی بالا بین ورودی‌ها و خروجی در روش شبکه عصبی مصنوعی موجب افزایش دقت و اطمینان در نتایج پیش‌بینی شده توسط مدل می‌گردد (۳۷). با توجه به نتایج شبکه‌های آموزش داده شده (جدول ۲) شبکه با سه لایه پنهان و ۸ نرون در هر لایه با تابع انتقال تانژانت هیپربولیک با توجه به بیشترین مقدار ضریب تبیین، بهترین عملکرد بهینه‌سازی توپولوژی را نشان می‌دهد. مطالعات حق‌وردی و همکاران (۲۰۱۱) نیز به قابلیت بالای تابع تانژانت هیپربولیک نسبت به تانژانت سیگموئید و خطی در ارائه نتایج دقیق‌تر شبکه و خطای کمتر آن اشاره دارد که با نتایج تحقیق حاضر هم راستا است (۱۲). نتایج نشان داد با افزایش لایه‌های مخفی تا سه لایه دقت نتایج بالاتر رفته و میزان خطای شبکه کاهش می‌یابد. از طرفی با افزایش تعداد نورون‌ها در لایه‌های مخفی خطای شبکه کاهش می‌یابد و با توجه به این‌که معیار انتخاب تعداد نرون، حداقل گشتن خطا می‌باشد، نتایج نشان داد که تعداد ۸ نرون برای سه لایه میانی قابل پیشنهاد است. آرایش نهایی شبکه ۳-۸-۸-۸-۲۰ به‌دست آمد که شامل ۲۰ متغیر ورودی، سه لایه مخفی هریک با ۸ نورون و ۳ کلاس کیفیت زیباشناختی منظر جنگل به‌عنوان خروجی می‌باشد. تاکنون از روش شبکه عصبی مصنوعی در ارزیابی کیفیت زیباشناختی منظر استفاده نشده است و سایر مطالعات انجام گرفته با این روش نیز نتایج مختلفی را در ساختار مدل مناسب پیش‌بینی متغیر هدف ارائه نموده‌اند (۱۵، ۲۳، ۴۰). نتایج حاصل از بهینه‌سازی شبکه عصبی در جدول ۲ نشان داده شده است. بالاترین دقت شبکه در مرحله آموزش با ضریب تبیین ۰/۸۸ در کلاس یک، ۰/۹۰۶ در کلاس دو و ۰/۹۷۱ در کلاس سه کیفیت زیباشناختی جنگل به‌دست آمد و کمترین دقت مربوط به داده‌های اعتبارسنجی است. نتایج حاصل مدل‌سازی می‌تواند بسیار متغیر باشد اما ناگی و همکاران (۲۰۰۲) در پژوهشی که انجام دادند به‌این نکته اشاره کردند که شبکه‌های عصبی مصنوعی زمانی که آگاهی از طبیعت مسأله زیاد نباشد؛ اما تعداد داده‌های موجود از مسأله برای آموزش کافی باشد کارکرد مطلوبی خواهد داشت. از نظر آن‌ها شبکه‌های عصبی مصنوعی در پیش‌بینی مسائل طبیعی و اکولوژیکی بر دیگر روش‌های متداول برتری دارد (۲۵).

تعداد ورودی‌ها با ۲۰ متغیر و تعداد خروجی‌ها شامل ۳ طبقه یا کلاس کیفیت زیباشناختی منظر جنگل می‌باشد. ۵۰ نمونه (۲۵ درصد کل داده‌ها) برای آزمون نتایج شبکه عصبی طراحی شده استفاده شد. بر اساس نتایج ماتریس آشفتگی نتایج در نمونه‌های آزمون (جدول ۳) می‌توان دریافت که خطای شبکه در نمونه‌های آزمون تنها یک مورد در طبقه‌بندی کلاس یک کیفیت زیباشناختی جنگل رخ داده است و سایر کلاسه‌ها به درستی پیش‌بینی و طبقه‌بندی شده‌اند.

جدول ۲- نتایج ساختار مدل‌های شبکه عصبی مصنوعی برای ارزیابی کیفیت زیباشناختی منظر.

Table 2. The results of structure of artificial neural network models in test phase for evaluation of aesthetic quality of landscape.

MSE class1	MSE class2	MSE class3	MAE class1	MAE class2	MAE class3	RMSE class1	RMSE class2	RMSE class3	R^2 class1	R^2 class2	R^2 class3	داده‌ها (Data)	ساختار توابع شبکه (تعداد نورون‌ها)- دوره یادگیری (Architecture of network Function (number of neurons))-Epoch	مدل (Model)
0.044	0.03	0.023	0.133	0.072	0.232	0.21	0.173	0.152	0.55	0.87	0.853	آموزش (Training)		
0.041	0.039	0.029	0.111	0.099	0.285	0.202	0.197	0.17	0.65	0.82	0.841	اعتبارسنجی (Validation)	Tanh(10)-557	۱(1)
0.049	0.029	0.024	0.165	0.076	0.301	0.221	0.17	0.155	0.50	0.88	0.78	آزمون (Test)		
0.048	0.033	0.032	0.131	0.076	0.121	0.219	0.182	0.179	0.68	0.791	0.732	آموزش (Training)		
0.051	0.029	0.029	0.143	0.096	0.112	0.226	0.17	0.17	0.65	0.851	0.745	اعتبارسنجی (Validation)	Purelin(6), Purelin(6)-231	۲(2)
0.048	0.038	0.038	0.131	0.11	0.143	0.219	0.195	0.195	0.68	0.741	0.65	آزمون (Test)		
0.033	0.028	0.026	0.311	0.281	0.266	0.182	0.167	0.161	0.71	0.83	0.881	آموزش (Training)		
0.029	0.026	0.028	0.299	0.266	0.271	0.17	0.161	0.167	0.74	0.881	0.853	اعتبارسنجی (Validation)	Tansig(9),Tansig(9)-121	۳(3)
0.034	0.027	0.03	0.305	0.273	0.281	0.184	0.164	0.173	0.7	0.86	0.839	آزمون (Test)		
0.037	0.029	0.012	0.119	0.142	0.119	0.192	0.17	0.109	0.841	0.89	0.941	آموزش (Training)		
0.039	0.034	0.028	0.164	0.151	0.131	0.197	0.184	0.167	0.832	0.861	0.901	اعتبارسنجی (Validation)	Tanh(8),Tanh(8)-732	٤(4)
0.041	0.039	0.029	0.169	0.164	0.142	0.202	0.197	0.17	0.821	0.831	0.89	آزمون (Test)		
0.023	0.028	0.007	0.07	0.097	0.053	0.152	0.167	0.084	0.88	0.906	0.971	آموزش (Training)		
0.029	0.035	0.012	0.096	0.145	0.121	0.17	0.187	0.109	0.83	0.851	0.933	اعتبارسنجی (Validation)	Tanh(8),Tanh(8),Tanh(8)-1000	٥(5)
0.024	0.029	0.009	0.076	0.104	0.061	0.155	0.17	0.095	0.88	0.896	0.969	آزمون (Test)		

جدول ۳- ماتریس آشفتگی آزمون شبکه عصبی بهینه.

Table 3. Confusion matrix of optimized neural network in test phase.

کلاس ۳ Class 3	کلاس ۲ Class 2	کلاس ۱ Class 1	پیش‌بینی شده/ حقیقی Output/Target
0	0	12	کلاس ۱ Class1
0	23	1	کلاس ۲ Class2
14	0	0	کلاس ۳ Class3

شکل ۲ اختلاف درجه تعلق به کلاس‌های مختلف در خروجی شبکه و درجه تعلق حقیقی را نشان می‌دهد. درجه تعلق حقیقی هر کلاس برابر با یک است و خروجی شبکه دقت بالایی در پیش بینی کلاسه‌های مختلف را نشان می‌دهد. با توجه به نتایج ماتریس آشفتگی در طبقه‌بندی نهایی تنها نمونه هفدهم از کلاس یک با درجه تعلق کمتر از ۰/۲ در کلاسه صحیح قرار نگرفته است.

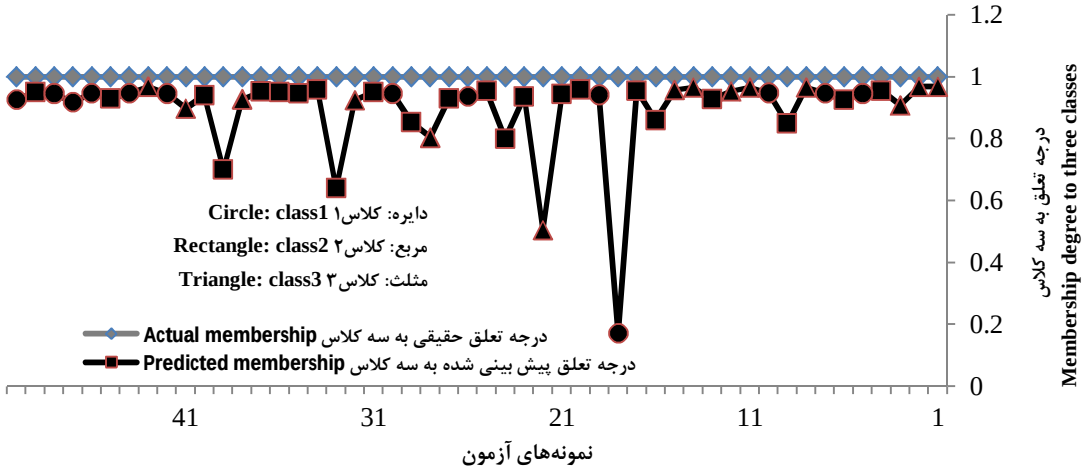

شکل ۲- اختلاف درجه تعلق حقیقی و پیش‌بینی شده در سه کلاس کیفیت زیباشناختی منظر جنگل.

Figure 2. The difference of actual and predicted membership degree in three classes of aesthetic quality of forest landscape.

با توجه به ضریب تبیین شبکه مطلوب و ضرایب تبیین همسانی آموزش، اعتبار و آزمون داده‌ها به انضمام حداقل میزان MSE آزمون داده‌ها (جدول ۲) دقت شبکه عصبی در پیش‌بینی کیفیت زیباشناختی منظر جنگل از سطح بسیار مطلوبی برخوردار است. دلیل این امر سیستم پردازش گسترده و موازی و در نظر گرفتن تبدیل‌های غیرخطی در مدل شبکه عصبی مصنوعی است (۸). 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.

جدول‌های ۲ و ۳ نشان می‌دهند که دقت شبکه عصبی در پیش‌بینی کیفیت زیباشناختی منظر در کلاسه‌های کیفیت زیباشناختی مطلوب و عالی بیشتر از کلاسه ضعیف است. علت این امر را می‌توان در انتخاب تعداد نمونه بیشتر در کلاس مطلوب، دقت نظر بیشتر ارزیابان در دستیابی به هدف شناسایی مناظر با کیفیت بالا و تنوع عوامل اثرگذار بر مناظر نامطلوب یا ضعیف که مورد بررسی قرار نگرفته‌اند (مثلا اثر فعالیت‌های مختلف انسانی) دانست. امروزه مدل‌سازی با شبکه عصبی مصنوعی در محیط‌های طبیعی در مطالعات بسیاری از جمله مدیریت منابع آب (۳) و ارزیابی محیط (۱۵) با موفقیت چشم‌گیری همراه بوده است. نتایج این پژوهش نیز نشان داد که شبکه عصبی مصنوعی طراحی شده قابلیت خوبی در مدل کردن کیفیت زیباشناختی منظر در مدیریت و برنامه‌ریزی منظر جنگل مورد مطالعه دارد. همچنین مدل شبکه عصبی پرسپترون با سه لایه مخفی و ۸ نرون و تابع انتقال تانژانت هیپربولیک توانست با کاربرد حجم کمی از داده‌ها دانش الگوریتم بین عناصر و ساختار منظر و کیفیت زیباشناختی آن را با دقت بالایی بیابد.

شکل‌های ۳ تا ۵ نتایج مربوط به آنالیز حساسیت متغیرهای به‌کارگرفته شده برای مدل‌سازی و ضریب تأثیرگذاری هر یک از متغیرهای کاربردی در پیش‌بینی هریک از کلاسه‌های کیفیت زیباشناختی منظر جنگل را نشان می‌دهد.

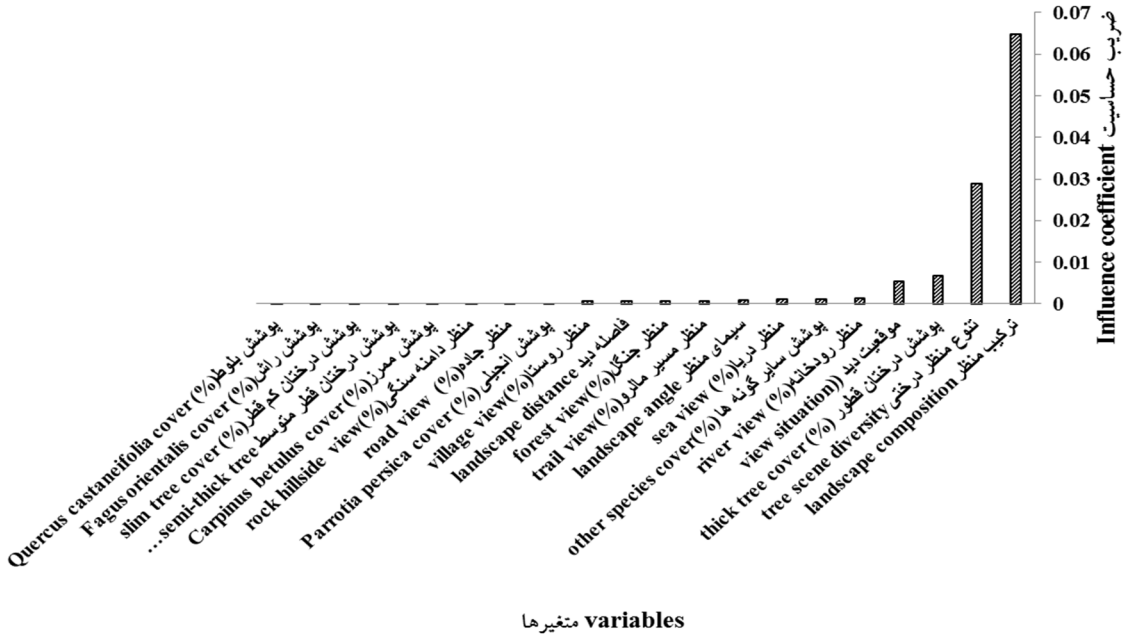

شکل ۳- ضریب تأثیرگذاری متغیرهای کاربردی در پیش‌بینی کلاس ۱ (کیفیت زیباشناختی منظر جنگل ضعیف).

Figure 3. Influence coefficient of applied variables in class1 prediction (weak aesthetic quality of forest landscape).

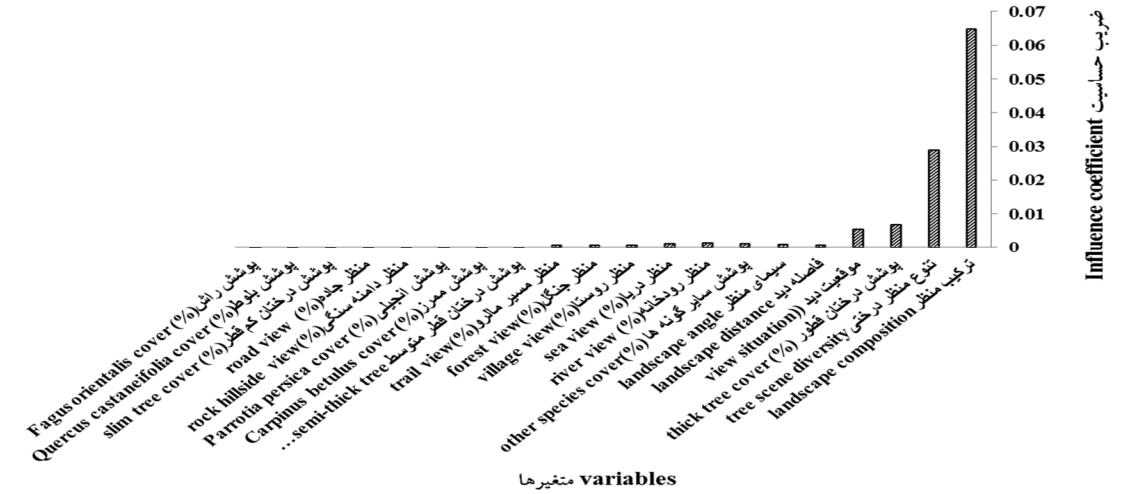

شکل ٤- ضریب تأثیرگذاری متغیرهای کاربردی در پیش‌بینی کلاس ۲ (کیفیت زیباشناختی منظر جنگل مطلوب).

Figure 4. Influence coefficient of applied variables in class 2 prediction (desirable aesthetic quality of forest landscape).

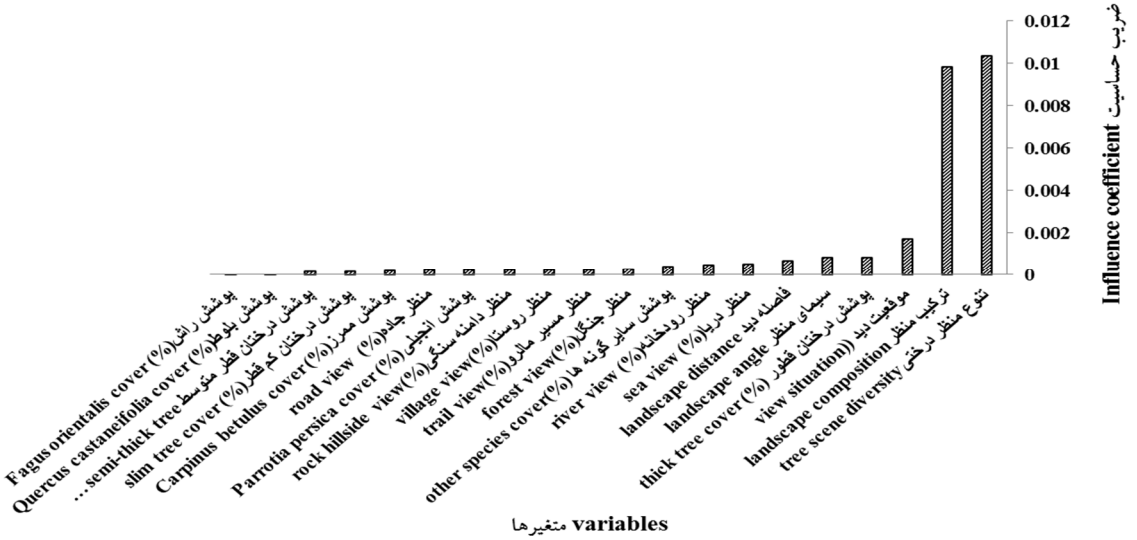

شکل ٥- ضریب تأثیرگذاری متغیرهای کاربردی در پیش‌بینی کلاس ۳ (کیفیت زیباشناختی منظر جنگل عالی).

Figure 5. Influence coefficient of applied variables in class 3 prediction (extremely desirable aesthetic quality of forest landscape).

بر اساس نتایج آنالیز حساسیت ترکیب منظر، تنوع منظر درختی و پوشش درختان قطور به‌ترتیب بیشترین تأثیر را در طبقه‌بندی مناظر جنگل در کلاس ۱ و ۲ داشته‌اند. از طرفی تنوع منظر درختی، ترکیب منظر و موقعیت دید به ترتیب بیشترین تأثیر را در طبقه‌بندی مناظر در کلاس ۳ از خود نشان دادند. آنالیز حساسیت انجام شده و شناسایی تأثیرگذارترین عناصر بر کیفیت زیباشناختی منظر جنگل، مشخص می‌سازد که جهت مدیریت و برنامه‌ریزی منظر جنگل و دستیابی به نقاط چشم‌انداز با کیفیت منظر مطلوب از دیدگاه کاربر یا ناظر توجه به ترکیب منظر و تنوع بالا در منظره‌های موجود، تنوع منظر درختی با تنوع بالا در گونه‌های درختی توده و همچنین حضور درختان قطور و کهنسال در الویت قرار می‌گیرد. مطالعات پیشین همچون جهانی و همکاران (۲۰۱۱) تأکید دارند که موقعیت چشم‌انداز، تنوع و ترکیب منظر نقش

مؤثری در درک بازدیدکنندگان از منظر جنگل دارند (۱۶) و ارزیابی کیفیت زیباشناختی منظر به‌عنوان موضوعی ذهن‌گرا یا غیرعینی شناخته می‌شود. مناظر طبیعی جنگل هر یک به نوبه خود از زیبایی غیرقابل انکاری برخوردار است اما برخی معیارها در ساختار منظر جنگل موجب می‌گردد تا کاربران بر اساس درک از زیبایی خود، تجربه بصری متفاوتی را داشته باشند. در این راستا و طبق نتایج به‌دست آمده در مناظر با کیفیت زیباشناختی عالی، ویژگی‌های ساختاری منظر شامل تنوع منظر درختی، ترکیب منظر و موقعیت دید از معیارهای ارزیابی کیفیت زیباشناختی منظر جنگل در چشم ناظر می‌باشند. جاکوت (۲۰۰۵) معتقد است ارتباط بین اجزا نوعی زیبایی به‌وجود می‌آورد که بسیار فراتر از آن‌گونه زیبایی است که از خود اجزا ناشی می‌شود که تأکیدی بر ترکیب منظر به‌عنوان عامل اصلی در ارزیابی کیفیت منظر عالی دارد (۱٤). لذا در برنامه‌ریزی و مدیریت منظر جنگل با توجه به هدف طرح جنگلداری، توجه به درک کاربران از محیط باید در الویت قرار گیرد. اکوتوریست‌ها در مناطق جنگلی انتظارات به‌خصوصی دارند که عدم توجه به آن‌ها موجب نارضایتی و معضلات مدیریتی خواهد شد و آثار منفی روانی و آسایش عمومی را در پی خواهد داشت. وجود منظره‌های گوناگون همچون درختان، دریا، روستا، رودخانه، دامنه سنگی و انواع جاده‌ها و مسیرها، همچنین تنوع گونه‌های درختی و حضور درختان کهنسال و قطور در ساختار سیمای سرزمین موجب افزایش قابلیت منطقه جهت مدیریت گردشگری شده و این مسئله باید در فرایند برنامه‌ریزی جنگل‌ها در نظر گرفته شود. یکی از اصول مهم و شناخته شده در طراحی راه‌های جنگلی (به‌ویژه در کشورهای پیشرفته) رعایت زیبایی و حفظ منظره طبیعی در سرزمین است. در طراحی لازم است به زیبایی و تعادل اکولوژیک جنگل توجه گردد که در پژوهش سپهوند (۲۰۰۵) نیز نقاط خوش منظر جهت بالا بردن کاربری گردشگری جاده‌های جنگلی انجام شده است (۳۳). واحدی (۲۰۱۷) تأکید دارد که در مدل‌سازی در بوم‌سازگان‌های پیچیده توجه به روابط بین ورودی و خروجی مدل (مثلا روابط بیولوژیکی و اکولوژیکی) امری ضروری است تا همبستگی بین ورودی‌ها و خروجی مدل قابل تفسیر منطقی بوده و صرفا تصادفی حاصل نشده باشد (۳۷). نتایج آنالیز حساسیت و تفسیر منطقی الویت‌بندی متغیرهای اثرگذار بر کیفیت زیباشناختی منظر جنگل در این تحقیق (متکی بر یافته‌های سایر مطالعات) نیز حاکی از ارتباط منطقی بین ورودی‌ها و خروجی مدل شبکه عصبی مصنوعی است. مدل بهینه حاصل شده در این پژوهش بر دو مساله تأکید دارد. اولا شبکه عصبی مصنوعی به‌عنوان یک روش مدل‌سازی معتبر در بخش ارزیابی کیفیت زیباشناختی منظر و کشف روابط پیچیده مابین متغیرهای عینی منظر و کیفیت ذهنی زیباشناختی آن قابلیت کاربرد دارد و نتایج دقیقی ارائه می‌دهد. بر اساس نظر اسچاپ (۱۹۹۸) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد (۳۱). همچنین مطالعات مرتبط در مدل‌سازی در بوم‌سازگان‌های طبیعی نیز بر قابلیت بالای شبکه‌های عصبی MLP در حل معادلات پیچیده و غیرخطی در بوم‌سازگان‌ها و پدیده‌های طبیعی اشاره دارند (٦، ۱۰، ٤۲) که نتایج این تحقیق نیز آن را تأیید می‌کند. دوما مدل حاصله در چارچوب نرم‌افزار Neuro Solutions 5 قابلیت ارزیابی کیفیت زیباشناختی منظر را در بخش اجرا در بوم‌سازگان جنگلی فراهم می‌کند. کاربر یا مدیر جنگل می‌تواند با استفاده از اطلاعات طرح جنگلداری و ارزیابی میدانی متغیرهای معرفی شده، اقدام به ارزیابی و نقشه‌سازی کیفیت منظر در

سطح جنگل نماید و پیش‌بینی حاصله امکان برنامه‌ریزی جهت استفاده از کارکرد زیباشناختی جنگل را فراهم خواهد آورد.

نتیجه‌گیری کلی

نتایج این پژوهش نشان داد شبکه با سه لایه پنهان و ۸ نرون در هر لایه با تابع انتقال تانژانت هیپربولیک به ضریب تبیین ۰/۸۸ در کلاس یک، ۰/۸۹۶ در کلاس دو و ۰/۹۶۹ در کلاس سه کیفیت زیباشناختی منظر جنگل در مرحله آزمون دست یافت که حاکی از قابلیت کاربرد مدل حاصل در بوم‌سازگان‌های مشابه است. درواقع نتایج نشان داد روش ANN با آرایش ۳–۸–۸–۸–۲۰ و اعمال قانون آموزش گرادیان کاهشی و تابع محرک تانژانت هیپربولیک، در پیش‌بینی کیفیت زیباشناختی منظر جنگل در شرایط بوم‌سازگانی مورد مطالعه، نتایج مطلوبی ارائه می‌نماید. تابع تانژانت هیپربولیک نسبت به تانژانت سیگموئید و خطی نتایج دقیق‌تری ارائه کرده و قابلیت بالاتری را در مدل کردن کیفیت زیباشناختی منظر نشان داده است. همچنین نزدیکی ضریب تبیین در سه دسته آموزش، اعتبارسنجی و آزمون حاکی از عدم بیش برازش مدل و همگرایی مدل با داده‌های آموزش شبکه است (۴۳) لذا می‌توان به نتایج حاصله اطمینان نمود. تحقیق حاضر روش نوینی را در ارزیابی کیفیت زیباشناختی منظر جنگل ارائه می‌کند و مدل حاصله علاوه‌بر ارائه معیارهای کاربردی در ارزیابی کیفیت منظر جنگل، به‌عنوان یک سیستم پشتیبان تصمیم‌گیری با قابلیت استفاده در بوم‌سازگان‌های جنگلی مشابه شناخته می‌شود. امروزه چگونگی ارتباط بین این‌گونه مناظر با فعالیت‌های جنگلداری و ایجاد تنوع مناسب از نظر ترکیب منظر در کنار ویژگی‌های دیداری و زیباشناختی مسائل مهمی است که جهت حداکثر استفاده از توان بالقوه بوم‌سازگان‌های جنگلی باید مورد توجه قرار گیرد.

منابع

1. Akbar, K.F., Hale, W.H.G., and Headley, A.D. 2003. Assesment of scenic beauty of roadside vegetation in northern Engeland. Landscape and Urban Planning., 63: 139-144.
2. Arriaza, M., Canas-Ortega, J.F., Canas-Madueno, J.A., and Ruiz-Aviles, P. 2004. Assessing the visual quality of rural landscapes. Landscape Urban Plan. 69(3): 115–125.
3. Arsene, C.T.C., Gabrys, B., and Al-Dabass, D. 2012. Decision Support System for Water Distribution Systems Based on Neural Networks and Graphs Theory for Leakage Detection. Expert Systems with Applications, 39(4): 13214_13224.
4. Azadeh A., Ghaderi, S.F., and Sohrabkhani, S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. Applied Mathematics and Computation, 186: 1753-1761.
5. Beza, B. 2010. The aesthetic value of a mountain landscape: A study of the Mt. Everest Trek. Landscape and Urban Planning, 97: 306–317.
6. Daryaee, M., Kashefipour, M., Ahadiyan, J., and Ghobadiyan, R. 2010. Modeling the Compression Index of Fine Soils Using Artificial Neural Network and Comparison with the other Empirical Equations. Journal of Water and Soil, 24(4): 659-667. (In Persian)
7. Dehghani, A.A., Piri, M., Hesam, M., and Dehghani, N. 2010. Estimation of Daily Pan Evaporation By Using MLP, RBF and Recurrent Neural Networks. J. of Water and Soil Conservation, Vol. 17(2): 49-67. (In Persian)

8. Dehghani, A.A., Malek Mohammadi, M., and Hezarjaribi, A. 2010. Estiamtion of Suspended Sediment Load in Behesht Abad River by Using Artifitial Neural Network. J. of Water and Soil Conservation, Vol. 17(1): 159-168.
9. Franco, D., Franco, D., Mannino, I., and Zanett, G. 2003. The impact of agroforestry networks on scenic beauty estimation: The role of a landscape ecological network on a socio-cultural process. Landscape and Urban Planning, 62: 119–138.
10. Ghabaei Sough, M., Mosaedi, A., Hesam, M., and Hezarjaribi, A. 2010. Evaluation Effect of Input Parameters Preprocessing in Artificial Neural Networks (Anns) by Using Stepwise Regression and Gamma Test Techniques for Fast Estimation of Daily Evapotranspiration. Journal of Water and Soil, 24(3): 610-624. (In Persian)
11. Gundersen, V., and Frivold, L. 2008. Public preferences for forest structures: a review of quantitative surveys from Finland, Norway and Sweden. Urban Forestry and Urban Greening, 7: 241–258.
12. Haghverdi, A., Mohammadi, K., Mohseni Movahed, S.A., Ghahraman, B., and Afshar, M. 2011. Estimation of Soil Salinity Profile in Tabriz Irrigation and Drainage Network Using SaltMod and ANN Models. Journal of Water and Soil, 25(1): 174-186. (In Persian)
13. Irani Behbahani, H., Morteza, F., Khalighi, N., and Ghodrati, E. 2012. A censure to landscape visual assessment methods. 2nd Environment planning and management conference. Sept. 13-14 Tehran, Iran, Pp: 43–52. (In Persian)
14. Jacquette, D. 2005. The Philosophy of Schopenhauer. Chesham press, UK.
15. Jahani, A., Feghhi, J., Makhdoum, M.F., and Omid, M. 2016. 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, 59(2): 222-244.
16. Jahani, A., Makhdoum, M., Feghhi, J., and Etemad, V. 2011. Determining of landscape quality and look out points for ecotourism land use (Case study: Patom District of Kheyrud Forest). Journal of Environment Researches, 2(3): 13-20. (In Persian)
17. Jim, C.Y., and Chen, W.Y. 2006. Perception and attitude of residents toward urban green spaces in Guangzhou (China). Environmental Management, 38(3): 338–349.
18. Kendal, D., Williams, K.J.H., and Williams, N.S.G. 2012. Plant traits link people's plant preferences to the composition of their gardens. Landscape and Urban Planning, 105(2): 34–42.
19. Khosravi, M., Salajegheh, A., Mahdavi, M., and Mohseni Saravi, M. 2010. The determination of the best activation function of output layer in neural network for peak water flow prediction. Iran-Watershed Management Science and Engineering, 4(12): 51-64. (In Persian)
20. Kienast, F., Degenhardt, B., Weilenmann, B., Wäger, Y., and Buchecker, M. 2012. GIS assisted mapping of landscape suitability for nearby recreation. Landscape and Urban Planning, 105(4): 385–399.
21. Kumara, R., Aggarwalb, R.K., and Sharmaa, J.D. 2015. Comparison of regression and artificial neural network models for estimation of global solar radiations. Renewable and Sustainable Energy Reviews, 52: 1294–1299.
22. Laghaii, B. 2009. Landscape design with plants. Parks and Tehran green space organization Press. Tehran. 201p. (In Persian)
23. Maier, H., Jain, R.A., Dandy, G.C., and Sudheer, K.P. 2010. Methods Used for the Development of Neural Networks for the Prediction of Water Resource Variables in River Systems: Current Status and Future Directions. Environmental Modelling and Software 25(8): 891-909.
24. Makhdoum, M. 2011. Design engineering of national and forest parks. Markaz Nashr Daneshgahi Press. Tehran. 94p. (In Persian)
25. Nagy, H.M., Watanabe, K., and Hirano, M. 2002. Prediction of sediment concentration in rivers using artificial neural network model. J Hydraulic Engineering, 128: 588-594.

26. Özgüner, H., and Kendle, A.D. 2006. Public attitudes towards naturalistic versus designed landscapes in the city of Sheffield (UK). Landscape and Urban Planning, 74(2): 139–157.
27. Pflüger, Y., Rackham, A., and Larned, S. 2010. The aesthetic value of river flows: An assessment of flow preferences for large and small rivers. Landscape and Urban Planning 95: 68–78.
28. Phua, M., and Minowa, M. 2004. GIS- based Multi- criteria decision making approach to forest conservation planning at a Land Scale: a Case study in the kinabalu Area, Sabah, Malaysia, Landscape and urban planning, 12(3): 73-77.
29. Ranjbar, E., and Rais Esmaili, F. 2010. Quality assessment of urban walk ways in Iran. Honar-ha-ye Ziba Memari Va Shahrsazi, 83: 42-93. (In Persian)
30. Rezaei, A., Mahdavi, M., Luxe, K., Feiznia, S., and Mahdian, M.H. 2007. Regional Peak Flows Modelling of Sefid rood Dam's Sub Basins Using Artificial Neural Network. Journal of Water and Soil Siences. 11(1): 25-40. (In Persian)
31. Schaap, M.G., and Leij, F.J. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. Soil and Tillage Research., 47: 37–42.
32. Schipperijn, J., Ekholm, O., Stigsdotter, U.K., Toftager, M., Bentsen, P., Kamper- Jorgensen, F., and Randrup, T.B. 2010. Factors influencing the use of green space: Results from a Danish national representative survey. Landscape and Urban Planning, 95(3): 130–137.
33. Sepahvand, A. 2005. Quantitative and qualitative Investigation on roads networks of Patom district. Forest and Rangeland Journal. 67(2): 23-34. (In Persian)
34. Swinnen, E., Eerens, H., Lissens, G., and Canters, F. 2001. Sub-pixel land cover classification with SPOT-VEGETATION. In: Proceedings of IGARSS 2001, Sydney, Australia, July 2001, p. 3.
35. Tailor, T. 2008. Journal of Forest management, general information and request for public comments, 23(1): 112-114.
36. Tosuna, E., Aydinb, K., and Bilgilib, M. 2016. Comparison of linear regression and artificial neural network model of a diesel engine fueled with biodiesel-alcohol mixtures. Alexandria Engineering Journal, 55(4): 3081–3089.
37. Vahedi, A.A. 2017. Monitoring soil carbon pool in the Hyrcanian coastal plain forest of Iran: Artificial neural network application in comparison with developing traditional models. Catena 152: 182–189. Vakil-Baghmisheh M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana. (In Persian)
38. Wu, Y., Bishop, I., Hossian, H., and Sposito, V. 2006. Using GIS in Landscape Visual Quality assessment, Applied GIS, 2(3): 1-20.
39. Yang, Y.C., and Kung, F.H. 1994. Modeling scenic beauty of squirrel-damaged Cryptomeria (Cryptomeria japonica) stands before and after dead-tree disposal. J. Jpn. For. Soc. 76(4): 298–307.
40. Yijun, L., Jiali, T., Hongfen, J., Guangping, Z., and Zhimin, Y. 2010. Artificial Neural Networks Applied in Environmental Quality Assessment. Chengdu: 3rd IEEE International Conference on Computer Science and Information Technology (ICCSIT). Agu. 5-6 Tehran, Iran, Pp: 156–157.
41. Zare Abyaneh, H., Ghasemi, A., Bayat varkeshi, M., and Marofi, S. 2009. Assessment of Artificial Neural Network (ANN) in prediction of garlic evapotranspiration (ETC) with lysimeter in Hamedan. Journal of Water and Soil, 23(3): 176-185. (In Persian)
42. Zoqi, M., and Ghavidel, A. 2009. Neural Network Modeling and Prediction of Methane Fraction in Biogas from Landfill Bioreactors. J. Health and Environ: 2(2): 140-149. (In Persian)

Gorgan University of Agricultural Sciences and Natural Resources
J. of Wood & Forest Science and Technology, Vol. 24 (3), 2017
http://jwfst.gau.ac.ir

Aesthetic quality evaluation modeling of forest landscape using artificial neural network

***A. Jahani**
Assistant Prof., Dept., of Natural Environment and Biodiversity, Karaj, Iran
Received: 05/16/2016; Accepted: 05/14/2017

Abstract

Background and objectives: Considering decreasing trend in wood harvesting potential of Hyrcanian forests, we need to plan for utilization of other ecosystem services, such as ecotourism, more than past. For ecotourism planning, comprehensive information of ecological beauty and natural landscape structure should be summarized. On the other hand, accurate evaluation of different landscapes in a region requires comprehensive information of affective criteria, and its impact on user perception of landscape quality. Locating lookouts, which have high quality in landscape structure, is known as the first step to promote aesthetic quality of landscape and protection of natural ecosystems. This research aims to evaluate aesthetic quality of forest landscape using quantitative comprehensive approach and artificial neural network modeling for determination of the most effective landscape visual parameters in subjective aesthetic quality promotion of landscape.

Materials and methods: The study area is three districts (with high diversity in landscape quality) of Khyrud research educational forest managed by Natural Resources College of University of Tehran, which is named Patom, Namkhaneh and Gorazbon. In study forest, totally 200 landscapes, with different structure of tree cover and view composition, were selected to record landscapes characteristics. Landscape quality which is in the eyes of beholder, was evaluated in 200 studied landscapes.

In this study, in order to model the aesthetic quality evaluation of forest landscape, structural features and landscape parameters were recorded and aesthetic quality of landscape was classified in three classes of weak(1), desirable(2) and extremely desirable(3) Multilayer Perceptron network was used to data processing with artificial neural network.

Results: Considering network coefficients of determination (Test samples) which is 0.88, 0.896, 0.969 in 1 to 3 classes, the accuracy of artificial neural network in aesthetic quality evaluation of landscape is assessed in extremely desirable level. Sensitivity analysis prioritizes landscape composition, tree diversity and thick trees view respectively to achieve class 1 and 2 in quality of forest landscape. On the other hand, tree diversity, landscape composition and view point respectively play a significant role in class 3 in quality of forest landscape.

Conclusion: Results of the most effective variables on aesthetic quality of forest landscape, proved that landscape composition with higher diversity in its scenes, diversity in tree views with higher tree species and also thick and old trees in landscape should be a priority for forest landscape planning and management to achieve lookouts with higher quality of landscape in the eyes of beholders. This research prepared a new method for aesthetic quality evaluation of forest landscape and the introduced model is known as an environmental decision support system in forest ecosystems with an application in similar forests. Also practical criteria in aesthetic quality evaluation of forest landscape were introduced.

Keywords: Aesthetic quality of forest landscape, Artificial neural network, Multilayer Perceptron, Landscape composition

*Corresponding author: