



ارائه یک روش چند معیاره تشخیص حریق مبتنی بر شبکه عصبی

حسن زعفرانی^{۱*}، علی عبدی^۲، احسان ایوبی^۳.

۱- گروه آموزشی مهندسی کامپیوتر- دانشکده مهندسی- دانشگاه فردوسی- مشهد- ایران.

۲- گروه مهندسی شیمی- نفت و پلیمر- دانشکده مهندسی- دانشگاه فردوسی- مشهد- ایران.

۳- گروه کامپیوتر- دانشکده مهندسی- دانشگاه آزاد واحد بیرجند- بیرجند- ایران

چکیده

عملکرد و نهایتاً بهینه‌سازی ساختار مطلوب شبکه انجام می‌شود که در این میان، آرایش‌های مختلف توابع فعال‌ساز (بالغ بر ۵۶۰ روش) مورد بحث و بررسی قرار گرفت و نهایتاً آرایش Tansig-Logsig با ورودی Mnf به عنوان بهترین آرایش با صحت ۹۹/۸٪ مورد پذیرش قرار گرفت.

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۱۲/۰۸

تاریخ پذیرش: ۱۴۰۴/۰۲/۱۰

انتشارخطا، پس واژه‌های کلیدی: شبکه عصبی، ماهواره، مدل آتش‌سوزی جنگل

ارزیابی شدت آتش‌سوزی جنگل‌ها و مراتع با استفاده از هوش مصنوعی و داده‌های ماهواره ای دارای اهمیت ویژه، جهت برنامه‌ریزی و مدیریت مراتع می‌باشد. استان خوزستان دارای آب و هوایی نسبتاً نیمه‌خشک است و هر ساله، تعداد زیادی حریق در آن گزارش می‌شود. داده‌های آتش‌سوزی شامل سطح سوخته‌شده و تعداد وقوع آتش‌سوزی می‌باشد. در حال حاضر، بیشتر برآوردها به‌صورت میدانی و با ابزارهای ساده نقشه‌برداری همچون GPS دستی، صورت می‌گیرد که علاوه بر هزینه‌بر بودن، دارای خطر بالایی نیز برای افراد می‌باشد. این در حالی است که تاکنون در مورد استفاده از دانش شبکه‌های عصبی، پژوهش‌های متعددی در علوم مختلف صورت پذیرفته است. در این پژوهش، پس از گردآوری اطلاعات منطقه و داده‌های ماهواره‌ای به دنبال برآورد سطح حریق به کمک هوش مصنوعی و مقایسه حالات متنوع شبکه‌های عصبی مصنوعی (Multi-

۱. مقدمه

فانک و همکاران [۷]، اقدام به تحلیل و بررسی تصاویر ماهواره‌ای و تهیه سری‌های زمانی به کمک شبکه‌های عصبی هوپ فیلد نمودند. کای و همکاران [۸]، توانسته‌اند از داده‌های ماهواره‌ای و اقلیمی، جهت تخمین محصول گندم در استرالیا با استفاده از هوش مصنوعی اقدام نمایند. جی و همکاران [۹]، در پژوهشی اقدام به تخمین رطوبت خاک و مقایسه عملکرد روش‌های مختلف هوش مصنوعی پرداختند. اردستانی و همکاران [۱۰]، به کمک شبکه‌های عصبی مصنوعی و رگرسیون لجستیک، به تحلیل و بررسی خطر سقوط درختان خطرآفرین، اقدام نموده‌اند.

صیادی و عساکره [۱۱]، با استفاده از مدل شبکه عصبی، به تحلیل و پیش‌بینی روزهای خشک در شهر تهران پرداخته‌اند. علی‌رغم پژوهش‌های صورت گرفته درخصوص کاربرد شبکه‌های عصبی مصنوعی، پارامترهای کنترلی آن کمتر مورد بررسی قرار گرفته است. این در حالی است که قدرت و موفقیت این نوع شبکه‌ها به شدت به توابع و پارامترهای کنترلی آن، همچون نوع توابع یادگیری، توابع فعال‌سازی، نرخ یادگیری و سایر پارامترهای آن بستگی دارد، لذا بررسی و بحث، راجع به آن نیازمند به کارگیری ساختارهای مختلف آن در داده‌های خاص مورد بررسی است. در این پژوهش به دنبال بررسی حالات و ساختارهای مختلف شبکه‌های عصبی مصنوعی در بررسی و تحلیل داده‌های ماهواره‌ای خواهیم بود.

۲. مواد و روش‌ها

۲-۱. شبکه‌های عصبی مصنوعی پیش‌خور

شبکه‌های عصبی پیش‌خور^۲ (FF) نیز از اعضای قدیمی خانواده شبکه‌های عصبی محسوب می‌شود و رویکرد مربوط به آن‌ها از دهه ۵۰ میلادی نشأت می‌گیرد. در اغلب مواقع، این نوع از شبکه‌های عصبی با استفاده از روش پس‌انتشار (Backpropagation) آموزش داده می‌شوند. این نوع از شبکه عصبی مصنوعی، داده‌ها را مستقیماً از جلو به عقب، بازپخش می‌کند. آموزش نورون‌های پیش‌خور، اغلب نیازمند بازگشت به عقب یا انتشار معکوس است که شبکه‌ای با مجموعه‌های متناظر ورودی‌ها و خروجی‌ها محسوب می‌شود. هنگامی که داده‌های ورودی به نورون (neuron) انتقال پیدا کردند، پردازش می‌شوند و یک خروجی تولید می‌شود. در این پژوهش از FF به عنوان معماری

آتش‌سوزی جنگل‌ها در کشورها، خطری جدی است و سالانه، تعداد زیادی آتش‌سوزی رخ می‌دهد. تفکیک درجات مختلف شدت سوختگی، برای بهبود مدیریت مناطق آسیب‌دیده از آتش، حیاتی است. در زمینه تشخیص حریق نیز به طور خاص، تلاش‌های زیادی صورت پذیرفته است. کوینتانو و همکاران [۱]، از یک روش در سه منطقه مطالعه مدیریت‌انه‌ای برای برآورد شدت سوختگی با استفاده از داده‌های ماهواره‌ای با وضوح متوسط استفاده نمودند. تصاویر پس از آتش‌سوزی Landsat 5 Mapper (TM) در چهار کسر تصویری: fraction images طبقه‌بندی شدند. آن‌ها در این پژوهش با استفاده از طبقه‌بندی نظارت شده (درخت تصمیم‌گیری) و استفاده از برخی شاخص‌ها، اقدام به طبقه‌بندی پیکسل‌ها نموده‌اند. ایشان در پژوهش دیگر خود [۲]، داده‌های خود را با داده‌های دمایی سطح زمین، تلفیق نمودند تا درک کامل‌تری نسبت به حریق داشته باشند.

بلنگور و همکاران [۳]، با کمک الگوریتمی مبتنی بر Reed-Xiaoli detector (RXD) اقدام به تشخیص آنومالی‌های حرارتی در تصاویر ماهواره‌ای Sentinel 2 پرداخته‌اند. این الگوریتم، خود را با شرایط پراکندگی محلی سازگار می‌کند و نسبت به تغییرات داده‌های ورودی، قوی است.

لنتایل و همکاران [۴]، در پژوهشی، اقدام به بررسی و تحلیل روش‌های تشخیص رايج حریق مبتنی بر شاخص‌های معمول ریاضی، همچون شاخص تراکم پوشش گیاهی پرداخته‌اند. در این پژوهش، جنگل‌های کاج سوخته‌شده در تپه‌های سیاه داکوتای جنوبی بررسی شده است، که برآورد از پوشش گیاهی سبز و قهوه‌ای (غیر فتوسنتزی) در پیش‌بینی یک پیکسل، یک سال پس از اقدامات میدانی پس از آتش‌سوزی است و مقایسه نسبت شاخص‌های مختلف سوختگی در آن صورت می‌گیرد. تاکنون در مورد استفاده از دانش شبکه‌های عصبی FB و داده‌های ماهواره‌ای، پژوهش‌های متعددی در علوم مختلف صورت پذیرفته است. سامارتینو و همکاران [۵]، در پژوهشی به بررسی حجم توده زیستی خاص در محدوده دریای مدیترانه به کمک شبکه عصبی مصنوعی پرداخته‌اند. نادای و همکاران [۶]، به کمک یک مدل مبتنی بر شبکه‌های عصبی مصنوعی، به بررسی تغییرات پوشش گیاهی جنگل پرداخته‌اند.

2. Feed Forward Neural Networks.

1. Feed Forward Back Propagation.


۲-۴. ماهواره Landsat8

ماهواره لندست (Landsat ۸) در تاریخ ۱۱ فوریه ۲۰۱۳ راه-اندازی شده است. این هشتمین ماهواره در برنامه ماهواره‌های لندست، و در این پژوهش، تصاویر ماهواره لندست ۸ در تاریخ ۲۰ آگوست ۲۰۱۷ پس از آتش‌سوزی آخذ گردید و پس از آماده‌سازی، ساختار کلی شبکه عصبی به شرح ذیل تعریف می‌گردد: تعداد ۱۰ ورودی شامل ۸ باند تصویر ماهواره‌ای و دو شاخصه NDVI و RVI که هر دو در مطالعات پوشش گیاهی، کاربرد زیادی دارند و کاملاً نوآورانه می‌باشد، استفاده گردید. ضمناً ۱۰ کلاس برای خروجی شامل ۹ کلاس پوششی (سنگ و خاک و آب) و یک کلاس آتش‌سوزی به عنوان خروجی برای شبکه تعریف گردید. برای هر کلاس، تعداد ۱۰۰ پیکسل انتخاب و در فرایند آموزش شبکه به کار گرفته شد که از این تعداد ۷۰٪ برای آموزش و ۳۰٪ برای ارزیابی پس از آموزش به کار گرفته شد.

جدول ۱: اطلاعات آخذ شده از میزان آتش‌سوزی (منابع طبیعی).

۵۸	۴۰۵۴۴۹	۳۵۱۲۶۲۹	ایده	۹۶/۰۵/۲۱	۹۶/۰۵/۲۱	۱۹:۰۰	۲۱:۳۰	جنگل طبیعی	۲۲
۵۹	۳۷۷۹۹۲	۳۵۴۸۹۴۸	ایده	۹۶/۰۵/۲۰	۹۶/۰۵/۲۰	۰۹:۳۰	۱۸:۳۰	جنگل دست کاشت	۷۰
۶۰	۳۸۰۰۱۵	۳۵۴۴۲۶۸	ایده	۹۶/۰۵/۲۲	۹۶/۰۵/۲۲	۲۱:۳۰	۰۲:۳۰	جنگل دست کاشت	۲۵

هدف مورد نظر و برای به‌دست آوردن نتیجه قابل قبول‌تر، الگوریتم MNF بر روی تصاویر اعمال شد. این تبدیل، یک تبدیل خطی است که برای مشخص کردن بُعد و حجم اصلی تصویر، جدا کردن نویز از دیگر اطلاعات و کاهش میزان پردازش در مرحله بعد استفاده می‌شود که تصویر آن در شکل (۱) نشان داده شده است.



شکل ۱: تصویر MNF شده منطقه ایده.

۲-۲. پیش‌پردازش

در این گام، از جنبه دوم نوآوری موضوع، داده‌ها به دو شکل وارد شبکه گردیده است که در مرحله اول، به شکل مستقیم و در مرحله دوم، پس از اعمال الگوریتم حذف نویز (MNF) وارد می‌گردد.

۲-۳. تبدیل کم‌ترین کسر نویز MNF

حجم وسیع داده‌های سنجش از دور در تصاویر چندطیفی و فراطیفی، اغلب باعث بروز مشکلاتی در تجزیه و تحلیل این تصاویر می‌شود. در این‌گونه تصاویر، پیکسل‌های تصویر با پس‌زمینه تصویر، مختلط است، بنابراین، تصاویر از وضوح کافی، برخوردار نمی‌باشد. لذا هدف، محقق را به خصوص در فرایند طبقه‌بندی تصاویر با مشکل مواجه می‌سازد و محقق در مواجه با پیکسل‌های مخلوط نخواهد توانست کلاس درست را اختصاص دهد و اغلب پیکسل‌های مخلوط در کلاس اشتباه قرار خواهد گرفت. یکی از روش‌های متداول برای رفع ابهام پیکسل‌های مخلوط روش MNF است که، در این مطالعه، این روش برای رفع مشکل پیکسل‌های مخلوط استفاده شده است. در این مرحله، برای تشخیص دقیق‌تر

ارزیابی بهترین شبکه

ضمناً سایر پارامترهای شبکه ثابت و یا مقادیر پیش فرض مورد پذیرش قرار گرفت که عبارتند از:

تعداد لایه مخفی: ۱ تابع یادگیری: LM تابع ارزیابی عملکرد شبکه: MSE تعداد Epoch: ۱۰۰ تعداد نورون: ۲ تا ۴۰ توابع فعال سازی: ترکیبی از Tansig، Logsig و Purlin تعداد ورودی: ۱۰ ورودی شامل ۸ مقدار مستقیم باندی (باندهای ۲ تا ۷ و ۹ و ۱۰) و شاخص NDVI (شاخص تراکم پوشش گیاهی) و شاخص RVI (شاخص نسبت پوشش گیاهی)


$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (3): \text{ شاخص تراکم پوشش گیاهی}$$

$$RVI = \frac{R_{RED}}{R_{NIR}} \quad (4): \text{ شاخص نسبت پوشش گیاهی}$$

در هر مرحله، صحت طبقه بندی ها با آماره صحت کل (Total accuracy) بررسی و گزارش می گردید. این نسبت از تقسیم تعداد پیکسل های درست تشخیص داده شده به کل تعداد پیکسل ها حاصل می گردد و معمولاً به شکل درصد ارائه می شود.

$$Accuracy = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}} \quad (5): \text{ صحت کل}$$

در ادامه مطابق شکل (۲) تصویر شبکه نمایش داده شده است.



شکل ۲: تصویر شبکه.

در ادامه در شکل (۳) فلوچارت الگوریتم پیشنهادی آمده است.

ضمناً کلیه داده های ورودی طبق رابطه (۱)، ابتدا بین ۰ تا ۱ نرمال شده و سپس در شبکه مورد استفاده قرار گرفتند.

$$X_{changed} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1): \text{ نرمال سازی خطی}$$

۵-۲. انتخاب معماری و آموزش شبکه

در این فاز، معماری FF، به عنوان معماری شبکه و همچنین از الگوریتم LM، جهت آموزش شبکه استفاده می گردد.

تکرار یا سیکل زمانی

پارامترهای شبکه، پس از یک دوره کامل ارائه، الگوهایی به دست می - آورد که در اصطلاح به این نوع تکرار یک سیکل (Epoch) می گویند که در این بررسی برای شبکه ۱۰۰ دور در نظر گرفته شد.

انتخاب آرایش FF

در این فاز، توابع مختلف انتقال، مورد ارزیابی قرار م گیرد. همچنین، با انتخاب هر تابع، تعداد نورون ها از ۲ تا ۴۰ نورون تغییر می کند و بهترین صحت آن ثبت می گردد.

ارزیابی شبکه FF

در این فاز جهت بررسی و آزمون اعتبار شبکه، به ارزیابی عملکرد آن ها پرداخته می شود. برای ارزیابی عملکرد شبکه، از روش میانگین مربعات خطا، استفاده گردید:


$$MSE = \frac{\sum_{i=1}^n (obs - calc)^2}{N} \quad (2): \text{ میانگین مربعات خطا}$$

تعداد خروجی: N

مقادیر محاسبه شده: Calc

مقادیر واقعی: Obs

بدین ترتیب، یک شبکه عصبی مصنوعی تولید می شود که ما در اینجا با بررسی مؤلفه های مختلف در پی دستیابی به بهترین شبکه جهت ارزیابی حریق به کمک تصاویر ماهواره ای هستیم.




شکل ۳: الگوریتم روش پیشنهادی

تابع Linear-Linear

به شدت، بهبود کسب گردید و در ۴ نورون، صحت به میزان ۷۰٪ می‌رسد. در ادامه، افزایش نورون‌ها تقریباً روند ثابتی را دنبال می‌کند. از ۸ نورون، تغییرات چندان در بهبود صحت صورت نمی‌پذیرد و به‌طور کلی، صحت از ۸۰٪ تجاوز نمی‌کند، لذا این روش در مقایسه با بقیه، نتایج ضعیفی دارد.

همان‌طور که در شکل (۴) مشخص است، نمودار نتایج حاصل از اعمال ساختار مختلف، از یک نورون تا ۴۰ نورون، ارائه گردیده است. در این میان، روش Linear-Linear در ابتدا، نتایج ضعیفی به همراه داشت. ابتدای امر با اعمال این تابع با افزایش تعداد نورون از ۱ تا ۴




شکل ۴: تابع Linear-Linear

تابع Tansig-Linear

بهبود می‌یابد و در ۱۰ نورون صحت به میزان ۹۰٪ می‌رسد. در ادامه، افزایش نورون‌ها، روند صعودی با شیب ملایم را دنبال می‌کند. از ۱۰ نورون تا ۴۰ نورون تغییر صحت با شیب ملایم به صورت افزایشی می‌باشد و صحت در ۴۰ نورون به حدود ۹۹٪ می‌رسد، لذا این روش در مقایسه با بقیه نتایج خوبی دارد.

و اما با بررسی این روش، با توجه به نمودار در شکل (۵) می‌توان گفت: این روش، توانایی قابل ملاحظه‌ای در پیش‌بینی آتش‌سوزی از خود نشان می‌دهد و مطابقت بسیار خوبی با نتایج دارد. با اعمال این تابع، با افزایش تعداد نورون از ۱ تا ۱۰ به شدت




شکل ۵: تابع Tansig-Linear.

تابع Logsig-Linear

این روش مطابق با شکل (۶) همانند روش tansig-linear و با اعمال این تابع با افزایش تعداد نورون از ۱ تا ۱۰ نورون نتایج شدت بهبود می‌یابد و در ۱۰ نورون صحت به میزان ۹۰٪ می‌رسد. در ادامه، افزایش نورون‌ها

روند صعودی با شیب ملایم را دنبال می‌کند. از ۱۰ نورون تا ۴۰ نورون تغییر صحت با شیب ملایم به صورت افزایشی می‌باشد و صحت در ۴۰ نورون به حدود ۹۹٪ می‌رسد، لذا این روش در مقایسه با بقیه نتایج قابل قبولی دارد.




شکل ۶: تابع Logsig-Linear

تابع Tansig- Tansig

در این تابع با افزایش نورون از ۱ تا ۴، صحت با رشد زیاد بهبود می‌یابد و به ۵۰٪ می‌رسد و در بازه بین ۴ تا ۵ نورون صحت در ۵۰٪ ثابت می‌ماند. در ادامه، با افزایش نورون از ۵ به ۹ صحت به ۸۸٪ می‌رسد و تغییرات صحت در بازه ۹ تا ۱۰ ثابت و از ۱۰ نورون تا ۱۱

صحت افزایش می‌یابد و به حدود ۹۲٪ می‌رسد. ولی پس از آن یک روند صعودی ملایم را در پیش می‌گیرد. فقط با افزایش نورون‌ها در نقطه ۲۰ صحت کاهش می‌یابد. در ادامه، افزایش نورون تا ۴۰ صحت به حدود ۹۹٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج نسبتاً قابل قبولی دارد




شکل ۷: تابع Tansig-Tansig.

تابع Tansig -Logsig

در بررسی این روش، با توجه به نمودار شکل (۸)، نتایج حاصل از اعمال ساختار مختلف در ابتدا نتایج ضعیفی به همراه داشت، اما خیلی سریع، بهبود واضحی در نتایج حاصل گردید. در ابتدا این تابع با افزایش نورون از ۱ تا ۲ صحت بهبود می‌یابد و در ۲ نورون صحت به میزان ۴۸٪ می‌رسد، ولی پس از آن یک روند نزولی را در پیش می‌گیرد و در وضعیت ۳ نورونی به صحت ۳۰٪ می‌رسد. در ادامه، با

افزایش نورون صحت روند افزایشی در پیش می‌گیرد و در نورون ۴ به صحت ۸۲٪ می‌رسد. با ادامه، این روال و افزایش نورون‌ها تا ۴۰ روندی نوسانی ملاحظه گردید و از طرفی، در برخی نقاط مانند: ۵، ۱۲، ۲۴، ۲۸، ۳۴ و ۳۸ حتی با افزایش نورون‌ها، صحت کاهش می‌یابد. ضمناً تغییرات صحت از ۴ نورون تا ۴۰ نورون، روند چشم‌گیری در افزایش به همراه ندارد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.




شکل ۸: تابع Tansig-Logsig

تابع Logsig-Tansig

در ابتدا این تابع با افزایش نورون از ۱ تا ۲ صحت بهبود می‌یابد و در ۲ نورون صحت به میزان ۴۸٪ می‌رسد، ولی پس از آن یک روند نزولی را در پیش می‌گیرد و در وضعیت ۳ نورونی به صحت ۳۰٪ می‌رسد. در ادامه با افزایش نورون صحت روند افزایشی در پیش می‌گیرد و در نورون ۴ به صحت ۸۲٪ می‌رسد. با ادامه این روال و

افزایش نورون‌ها تا ۴۰ روندی نوسانی ملاحظه گردید و از طرفی در برخی نقاط مانند: ۵، ۱۲، ۲۴، ۲۸، ۳۴ و ۳۸ حتی با افزایش نورون‌ها صحت کاهش می‌یابد. ضمناً تغییرات صحت از ۴ نورون تا ۴۰ نورون روند چشم‌گیری در افزایش به همراه ندارد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.




شکل ۹: تابع Tansig-Logsig.

تابع Logsig-Tansig

این روند نوسانی با افزایش نورون‌ها ادامه می‌یابد. در بازه ۲۱ تا ۲۵ نورونی صحت ثابت و در حدود ۷۸٪ است. ضمناً تغییرات صحت از ۹ نورون تا ۳۹ نورون بین ۳۰٪ تا ۹۸٪ متغیر است، ولی در ۴۰ نورون صحت کاهش یافته و به ۵۲٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.

این تابع با افزایش نورون از ۱ تا ۲ صحت کاهش می‌یابد و در ۲ نورون صحت به میزان ۱۰٪ می‌رسد، ولی پس از آن یک روند صعودی را در پیش می‌گیرد و در وضعیت ۸ نورونی به صحت ۶۸٪ می‌رسد. در ادامه، با افزایش نورون صحت با روند نزولی در ۹ نورون به ۳۰٪ می‌رسد. افزایش نورون مجدد صحت را به حالت افزایشی در می‌آورد، در صورتی که در ۱۰ نورون صحت به ۸۸٪ می‌رسد.




شکل ۱۰: تابع Logsig-Tansig

تابع Logsig-Logsig

صحت از ۶ نورون تا ۳۷ نورون بین ۴۰٪ تا ۸۲٪ متغیر است و در ۴۰ نورون صحت به ۵۰٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.

در ابتدا این تابع با افزایش نورون از ۱ تا ۴ صحت بهبود می‌یابد و در ۴ نورون صحت به میزان ۵۵٪ می‌رسد، ولی پس از آن یک روند نزولی را در پیش می‌گیرد و در وضعیت ۵ نورونی به صحت ۵۲٪ می‌رسد. در ادامه، با افزایش نورون صحت روند افزایشی در پیش می‌گیرد و در نورون ۶ به صحت ۸۲٪ می‌رسد. با ادامه این روال و افزایش نورون‌ها تا ۴۰، روندی نوسانی را ملاحظه کردید. از طرفی، در برخی نقاط مانند: ۷، ۱۲، ۱۷، ۲۴، ۳۵ و ۳۷ حتی با افزایش نورون‌ها صحت کاهش یافت. ضمناً تغییرات




شکل ۱۱: تابع Logsig – Logsig.

ثابت است. سیر تغییرات صحت در بازه ۵ تا ۷ نورون افزایش می‌یابد و به ۷۸٪ می‌رسد و در ادامه، افزایش نورون‌ها روند ثابتی را دنبال می‌کند. از ۸ نورون تغییرات چندان در بهبود صحت صورت نمی‌پذیرد. به طور کلی، صحت از ۷۸٪ تجاوز نمی‌کند، لذا این روش در مقایسه با بقیه، نتایج ضعیفی دارد.

فاز دوم با اعمال MNF

تابع MNF Linear-Linear

همان‌طور که در نمودار شکل (۱۲) مشخص است، با اعمال این تابع با افزایش تعداد نورون از ۱ تا ۴ به شدت بهبود می‌یابد و در ۴ نورون صحت به میزان ۷۰٪ می‌رسد و تا ۵ نورون تغییر صحت




شکل ۱۲: تابع MNF Linear-Linear.

گردید. با اعمال این تابع، با افزایش تعداد نورون از ۱ تا ۱۰ به شدت بهبود می‌یابد و در ۱۰ نورون صحت به میزان ۹۰٪ می‌رسد. در ادامه، افزایش نورون‌ها روند صعودی با شیب ملایمی را دنبال می‌کند و در ۴۰ نورون به حدود ۹۹٪ می‌رسد. لذا این روش در مقایسه با بقیه، نتایج قابل قبولی دارد.

تابع MNF Tansig-Linear

و اما با بررسی این روش، با توجه به نمودار شکل (۱۳) و پس از اعمال الگوریتم حذف نویز، در ابتدا با نتایج ضعیفی روبه‌رو شد که کم‌کم با افزایش تعداد نورون، نتایج قابل قبولی حاصل




شکل ۱۳: تابع MNF Tansig-Linear

۹ نورون صحت به میزان ۹۰٪ می‌رسد. نورون‌ها در بازه بین ۹ تا ۱۱ صحت ثابتی در حدود ۹۰٪ دارند. در ادامه، افزایش نورون‌ها صحت روند صعودی با شیب ملایمی را دنبال می‌کند و در ۴۰ نورون به حدود ۹۹٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج نسبتاً قابل قبولی دارد.

تابع MNF Logsig-Linear

با بررسی این روش، با توجه به نمودار شکل (۱۴) و پس از اعمال الگوریتم حذف نویز، به نتایج قابل قبولی رسید. در این تابع، با افزایش تعداد نورون از ۱ تا ۹ بشدت بهبود می‌یابد و در




شکل ۱۴: تابع MNF Logsig-Linear

افزایش نورون‌ها از ۶ تا ۹ نورون، صحت روند صعودی در پیش می‌گیرد و به ۹۰٪ می‌رسد، سپس نورون‌ها در فواصل ۹ تا ۱۱ صحت ثابت ۹۰٪ دارند. تابع از ۱۱ تا ۴۰ نورون با شیب ملایم، روند صعودی را دنبال می‌کند و در ۴۰ نورون به ۹۸٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج نسبتاً قابل قبولی دارد.

تابع MNF Tansig-Tansig

در این روش، با توجه به نمودار شکل (۱۵) و پس از اعمال الگوریتم حذف نویز، در این تابع با افزایش تعداد نورون از ۱ تا ۹ بشدت بهبود می‌یابد و در ۶ نورون صحت به میزان ۶۷٪ می‌رسد. نورون‌ها در بازه بین ۶ تا ۷ صحتی با روند نزولی در حدود ۶۰٪ دارند. در ادامه




شکل ۱۵: تابع MNF Tansig-Tansig.

با افزایش نورون صحت روند نوسانی افزایشی در پیش می‌گیرد. با ادامه این روال و افزایش نورون‌ها تا ۴۰ ملاحظه شد در برخی نقاط مانند: ۷، ۹، ۱۱، ۱۶، ۲۸، ۲۵، ۲۲، ۳۴ و ۳۸ حتی با افزایش نورون‌ها روند نوسانی گردید. ضمناً تغییرات صحت از ۶ تا ۴۰ نورون به حدود ۹۹٪ منتهی می‌گردد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی دارد که می‌توان گفت با آرایش ۱۳ نورون توانسته سریعتر از الباقی روش‌ها و با دقتی بالغ بر ۹۹،۸٪ صحت در تشخیص عمل بنماید.

تابع MNF Tansig-Logsig

در بررسی این روش، با توجه به نمودار شکل (۱۶) و پس از اعمال الگوریتم حذف نویز، در ابتدا این تابع با افزایش نورون از ۱ تا ۲ صحت بهبود می‌یابد و در ۲ نورون صحت به میزان ۵۵٪ می‌رسد، پس از آن روند صعودی را در بازه ۲ تا ۳ نورون مشاهده می‌شود که صحت به ۶۳٪ می‌رسد. افزایش نورون بین بازه ۳ تا ۶ با روند صعودی و افزایش صحت تا ۹۰٪ پیش می‌رود. در ادامه،




شکل ۱۶: تابع MNF Tansig-Logsig.

به ۹۰٪ می‌رسد. باره دیگر نورون‌ها در بازه ۱۰ تا ۱۳ روند صحتشان کاهش می‌یابد و به ۶۲٪ می‌رسد. این روند نوسانی با افزایش نورون‌ها ادامه می‌یابد و از طرفی، در برخی نقاط مانند: ۱۹، ۲۳، ۳۰، ۳۴، ۳۷ و ۴۰ با افزایش نورون‌ها صحت کاهش می‌یابد. در بازه ۳۰ تا ۳۴ نورونی صحت ثابت و در حدود ۶۲٪ است. ضمناً تغییرات صحت از ۱۳ نورون تا ۳۹ نورون بین ۶۲٪ تا ۹۸٪ متغیر است و در ۴۰ نورون صحت به ۶۸٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.

تابع MNF Logsig-Tansig

با بررسی این روش، با توجه به نمودار شکل (۱۷) این تابع با افزایش نورون از ۱ تا ۶ صحت به شدت افزایش می‌یابد و در ۶ نورون صحت به میزان ۶۸٪ می‌رسد، ولی پس از آن یک روند صعودی را در پیش می‌گیرد و در وضعیت ۸ نورونی به صحت ۶۸٪ می‌رسد. در ادامه، با افزایش نورون صحت با روند نزولی در ۷ نورون به ۶۵٪ می‌رسد. افزایش نورون مجدد صحت را به حالت افزایشی در می‌آورد به صورتی که در ۱۰ نورون صحت




شکل ۱۷: تابع MNF Logsig-Tansig.

پس از آن یک روند نوسانی را در پیش می‌گیرد. با افزایش نورون‌ها در برخی نقاط مانند: ۹، ۱۶، ۲۴ و ۳۵ صحت کاهش می‌یابد. ضمناً تغییرات صحت از ۸ نورون تا ۴۰ نورون روند چشم‌گیری در افزایش به همراه ندارد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی دارد.

تابع MNF Logsig-Logsig


با بررسی این روش، با توجه به نمودار شکل (۱۸) و پس از اعمال الگوریتم حذف نویز، با افزایش نورون از ۱ تا ۸ به شدت بهبود می‌یابد و در ۸ نورون صحت به میزان ۹۰٪ می‌رسد، ولی



شکل ۱۸: تابع MNF Logsig-Logsig.

۳- انتخاب بهترین آرایش حاصل شده

پس از بررسی آرایش‌های مختلف و متنوع پارامتری شبکه عصبی، نهایتاً نتایج ذیل حاصل گردید.




شکل ۱۹: مقایسه حالات مختلف شبکه.

هوشمند حریق را بیشتر می‌کند. نتایج شبیه‌سازی نشان داد روش Tansig-Logsig (MNF) بر روی مجموعه داده ماهواره‌ای لندست-۸ به نتایج قابل قبول و بالاتر از تحقیقات مشابه رسیده است که جهت ارزیابی این موضوع با روش‌ها و الگوریتم‌های دیگر در این حیطه از نظر میزان صحت تشخیص حریق مطابق جدول ۲ مورد مقایسه قرار می‌گیرد.

این پژوهش با هدف بهینه‌سازی و ارزیابی یک سیستم مبتنی بر شبکه عصبی جهت کمک به تشخیص آتسوزی انجام شده است. سیستم ارائه‌شده در این مطالعه، نتایج حاصل حاکی از تنوع پاسخ‌های شبکه با توجه به ساختارهای متنوع شبکه عصبی است. بر این اساس، این روش می‌تواند ابزار بسیار مناسبی جهت کمک به محیط زیست و منابع طبیعی و جامعه بشری برای تشخیص حریق قرار بگیرد. استفاده از چنین روش‌های دقیق و سریعی، امید عملی کردن سامانه تشخیص

جدول ۲: معرفی روش‌ها و الگوریتم‌های قبلی و میزان صحت تشخیص حریق.

شماره	نام روش	نام مقاله	سال	صحت
-	FB(Tansig-Logsig(MNF))	ارائه یک روش چند معیاره تشخیص حریق مبتنی بر شبکه عصبی (پژوهش جاری)	۲۰۲۱	۹۹/۸٪
[۱۲]	Deep Learning	FireDS-IoT: A Fire Detection System for Smart Home Based on IoT Data Analytics	۲۰۱۸	۹۳/۱۵٪
[۱۳]	Deep Learning-Fuzzy	Dependable Fire Detection System with Multifunctional Artificial Intelligence Framework	۲۰۱۹	۹۵٪
[۱۴]	svm-neural network	Predictive modeling of wildfires: A new dataset and machine learning approach	۲۰۱۹	۹۸/۳۳٪
[۱۵]	random forest	Detection and Monitoring of Forest Fires Using Himawari-8 Geostationary Satellite Data in South Korea	۲۰۱۹	۹۳٪
[۱۶]	Deep Learning	Aerial imagery pile burn detection using deep learning: The FLAME dataset	۲۰۲۱	۹۲٪
[۱۷]	svm-PSO	A Fire Detection Algorithm Based on Tchebichef Moment Invariants and PSO-SVM	۲۰۱۸	۹۸/۱۸٪
[۱۸]	neural network	Early Fire Detection Based on Aerial 360-Degree Sensors, Deep Convolution Neural Networks and Exploitation of Fire Dynamic Textures	۲۰۲۰	۹۶/۶٪
[۱۹]	Deep Learning	A deep learning approach for early wildfire detection from hyperspectral satellite images	۲۰۱۹	۹۴٪
[۲۰]	Deep Learning	Saliency Detection and Deep Learning-Based Wildfire Identification in UAV Imagery	۲۰۱۸	۹۸٪
[۲۱]	FF	Fire Detection in Video Stream by Using Simple Artificial Neural Network	۲۰۱۸	۹۳٪
[۲۲]	Deep learning	Forest Fire Detection Using a Rule-Based Image Processing Algorithm and Temporal Variation	۲۰۱۸	۹۶/۶۳٪
[۲۳]	svm-PSO	Forest fire detection on LANDSAT images using support vector machine	۲۰۲۱	۹۸/۴۱٪
[۲۴]	classification	Fire Detection Method Based on Depth wise Separable Convolution and YOLOv۳	۲۰۲۱	۹۸٪
[۲۵]	(SSD) algorithm	A Visual Real-time Fire Detection using Single Shot MultiBox Detector for UAV-based Fire Surveillance	۲۰۲۱	۹۲/۷۰٪
[۲۶]	Neural Network	Analysis for Fire Detection System for Improvement in Accuracy	۲۰۲۰	۸۵٪
[۲۷]	neural network	Forest Fire Detection Using Combined Architecture of Separable Convolution and Image Processing	۲۰۲۱	۹۸/۱۰٪
[۲۸]	decision tree	Forest fire detection system based on wireless sensor network	۲۰۰۹	۹۱٪
[۲۹]	FF	Multi-sensor information fusion detection system for fire robot through back propagation neural network	۲۰۲۰	۹۲/۷٪
[۳۰]	SVM	A smart approach for fire prediction under uncertain conditions using machine learning	۲۰۲۰	۷۸٪
[۳۱]	M-learning	Machine learning algorithm for fire detection using color correlogram	۲۰۱۹	۹۶/۹۷٪
[۳۲]	GIS	Forest Fire Risk Assessment Using GIS Science-A Case Study of South India	۲۰۲۱	۹۶/۳٪



شکل شماره ۲۰: مقایسه میزان صحت روش پیشنهادی در مقایسه با دیگر مطالعات

۴. نتیجه گیری

تابعی مطابق با شکل (۵-۱) مورد مقایسه قرار گرفت که نتایج حاصل از این مقایسه‌ها، نشان می‌دهد که الگوریتم MNF Tansig-Logsig از دقت بالایی پس از اعمال تابع حذف نویز برخوردار است و دقت ۹۹/۸٪ که تفاوت معناداری با حالت بدون اعمال نویز و دیگر شبکه‌های بررسی شده را داشت و با توجه به اینکه با کمترین تعداد نوروں به بهترین صحت دست یافت، به عنوان بهترین شبکه انتخاب گردید. از طرفی توابع Tansig-Linear و Logsig-Linear نیز می‌توانند به خوبی در خصوص تشخیص حریق اقدام نمایند. همچنین، به طور کلی، در سایر روش‌ها با اعمال تابع MNF تغییر خاصی در بهبودی نتایج حاصل نگردید و نهایتاً جهت مقایسه با بررسی بهترین شبکه پیشنهادی با سایر مطالعات صورت گرفته مشخص گردید، نتایج شبکه پیشنهادی در تشخیص حریق به نسبت، نتایج قابل قبول و بالاتری را ارائه می‌نماید

تشخیص سوختگی برای بهبود مدیریت مناطق آسیب‌دیده از آتش، امری حیاتی است. در این پژوهش، از یک روش مبتنی بر مخلوط در منطقه مورد مطالعه، برآورد شدت سوختگی با استفاده از داده‌های ماهواره‌ای با وضوح متوسط صورت گرفته است و رویکردی در جهت بررسی عملکرد شبکه عصبی مصنوعی FF در تشخیص حریق ارائه می‌کند. هدف اصلی این پژوهش، ارائه یک روش چند منظوره تلفیقی مبتنی بر شبکه عصبی در تشخیص و طبقه‌بندی داده‌های حریق و همچنین بررسی آرایش‌های مختلف شبکه عصبی و اثربخشی برخی از پارامترهای کنترلی و بررسی اثر نویز، در بهبود شبکه و از طرفی تخمین مناطق سوخته شده بود. در خصوص نوآوری، علاوه بر استفاده از داده‌های مستقیم باندی ماهواره لندست دو شاخص NDVI و RVI که هر دو در مطالعات پوشش گیاهی، کاربرد زیادی دارند و کاملاً نوآورانه می‌باشد، استفاده گردید. نکته دیگری که می‌توان آن را به عنوان نوآوری این تحقیق دانست، اعمال تابع حذف نویز، قبل از ورودی به شبکه، جهت برآورد سطح حریق به کمک هوش مصنوعی و مقایسه حالات متنوع شبکه‌های عصبی مصنوعی و بالا بردن سطح عملکرد و نهایتاً بهینه‌سازی ساختار مطلوب شبکه اعلام نمود.

منابع

[2]. C. Quintano, A. Fernández-Manso, & D. A. Roberts, "Multiple Endmember Spectral Mixture Analysis (MESMA) to map burn severity levels from Landsat images in Mediterranean countries," Remote Sensing of Environment, vol. 136, pp. 76-88, 2013

[1]. C. Quintano, A. Fernandez-Manso, & D. A. Roberts, "Burn severity mapping from Landsat MESMA fraction images and Land Surface Temperature," Remote Sensing of Environment, vol. 190, pp. 84-95, 2017.

جهت پیاده‌سازی این محتوا از نرم‌افزار Matlab استفاده شده که پس از پیاده‌سازی و ارزیابی معیارهای مختلف از توابع انتقال تا تعداد نوروں‌ها، نهایتاً نتایج به‌دست آمده از ۷ نوع ترکیب

- [15]. E. Jang, Y. Kang, J. Im, D. W. Lee, J. Yoon & S. K. Kim, "Detection and monitoring of forest fires using Himawari-8 geostationary satellite data in South Korea," *Remote Sensing*, vol. 11, No. 3, 2019.
- [16]. A. Shamsoshoara, F. Afghah, A. Razi, L. Zheng, P. Z. Fulé & E. Blasch, "Aerial Imagery Pile burn detection using Deep Learning: the FLAME dataset. *Computer Networks*," vol. 193, 2021.
- [17]. Y. Bian, M. Yang, X. Fan, & Y. Liu, "A fire detection algorithm based on Tchebichef moment invariants and PSO-SVM. *Algorithms*," vol. 11, No. 6, 2018.
- [18]. P. Barmpoutis, T. Stathaki, K. Dimitropoulos, & N. Grammalidis, "Early fire detection based on aerial 360-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures," *Remote Sensing*, vol. 12, No. 19, pp. 31-77, 2020.
- [19]. N. T. Toan, P. T. Cong, N. Q. V. Hung & J. Jo, "A deep learning approach for early wildfire detection from hyperspectral satellite images," In 2019 7th International Conference on Robot Intelligence Technology and Applications (RiTA), pp. 38-45, IEEE, 2019.
- [20]. Y. Zhao, J. Ma, X. Li, and J. Zhang, "Saliency detection and deep learning-based wildfire identification in UAV imagery," *Sensors*, vol. 18, no. 3, p. 712, 2018.
- [21]. P. Janku, Z. K. Oplatková, T. Dulik, P. Snopek, & L. Liba, "Fire detection in video stream by using simple artificial neural network," In *Mendel*, Vol. 24, No. 2, pp. 55-60, 2018.
- [22]. M. A. Mahmoud and H. Ren, "Forest Fire Detection Using a Rule-Based Image Processing Algorithm and Temporal Variation," *Mathematical Problems in Engineering*, vol. 1, pp. 7612487, 2018.
- [23]. P. Chanthiya, & V. Kalaivani, "Forest fire detection on LANDSAT images using support vector machine. *Concurrency and Computation: Practice and Experience*," PP. 62-80, 2021.
- [24]. Y. Y. Qin, J. T. Cao & X. F. Ji, "Fire Detection Method Based on Depthwise Separable Convolution and YOLOv3," *International Journal of Automation and Computing*, vol. 18, No. 2, pp. 300-310, 2021.
- [25]. A. Q. Nguyen, H. T. Nguyen, V. C. Tran, H. X. Pham & J. Pestana, "A Visual Real-time Fire Detection using Single Shot MultiBox Detector for UAV-based Fire Surveillance," In 2020 IEEE Eighth International Conference on Communications and Electronics (ICCE), pp. 338-343, IEEE, 2021.
- [26]. A. M. Pathak & D. S. Chaware, "Analysis for Fire Detection System for Improvement in Accuracy," *International Journal of Advanced Research in Engineering and Technology*, vol. 11, No. 9, 2020.
- [3]. M. A. Belenguer-Plomer, M. A. Tanase, A. Fernandez-Carrillo, & E. Chuvieco, "Burned area detection and mapping using Sentinel-1 backscatter coefficient and thermal anomalies," *Remote Sensing of Environment*, vol. 233, pp. 111-345, 2019.
- [4]. L. B. Lentile, Z. A. Holden, A. M. Smith, M. J. Falkowski, A. T. Hudak, P. Morgan, & N. C. Benson, "Remote sensing techniques to assess active fire characteristics and post-fire effects," *International Journal of Wildland Fire*, vol. 15, No. 3, pp. 319-345, 2006.
- [5]. M. Sammartino, S. Marullo, R. Santoleri, & M. Scardi, "Modelling the Vertical Distribution of Phytoplankton Biomass in the Mediterranean Sea from Satellite Data: A Neural Network Approach," *Remote Sensing*, vol. 10, No. 10, 2018.
- [6]. S. Nandy, R. Singh, S. Ghosh, T. Watham, S. P. S. Kushwaha, A. S. Kumar & V. K. Dadhwal, "Neural network-based modelling for forest biomass assessment," *Carbon Management*, vol. 8, No. 4, pp. 305-317, 2017.
- [7]. C. H. Fung, M. S. Wong & P. W. Chan, "Spatio-Temporal Data Fusion for Satellite Images Using Hopfield Neural Network," *Remote Sensing*, vol. 11, No. 18, 2019.
- [8]. Y. Cai, K. Guan, D. Lobell, A. B. Potgieter, S. Wang, J. Peng & B. Peng, "Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches," *Agricultural and Forest Meteorology*, vol. 274, pp. 144-159, 2019.
- [9]. L. Ge, R. Hang, Y. Liu & Q. Liu, "Comparing the performance of neural network and deep convolutional neural network in estimating soil moisture from satellite observations," *Remote Sensing*, vol. 10, No. 9, 2018.
- [۱۰]. ق. اردستانی، م. نافیان و بهمنی، "مدل سازی خطر سقوط درختان خطر آفرین با کاربرد شبکه عصبی مصنوعی و رگرسیون لجستیک در فضای سبز شهری"، محیط شناسی، سال ۴، شماره ۴۵، ص. ۶۱۶-۶۳۰، ۲۰۲۰.
- [۱۱]. ج. عساکره، ف. صیادی، "تحلیل و پیش بینی روزهای خشک با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه تهران)"، نشریه جغرافیا و برنامه ریزی، سال ۲۱، شماره ۶۰، ص. ۱۶۱-۱۷۷، ۱۳۹۳.
- [12]. S. K. Bhoi, S. K. Panda, B. N. Padhi, M. K. Swain, B. Hembram, D. Mishra, & P. M. Khilar, "Fireds-iot: A fire detection system for smart home based on iot data analytics," In 2018 International Conference on Information Technology (ICIT), pp. 161-165, IEEE, 2018.
- [13]. J. H. Park, S. Lee, S. Yun, H. Kim & W. T. Kim, "Dependable fire detection system with multifunctional artificial intelligence framework," *Sensors*, vol. 19, No. 9, 2019.
- [14]. Y. O. Sayad, H. Mousannif & H. Al Moatassime, "Predictive modeling of wildfires: A new dataset and machine learning approach," *Fire safety journal*, vol. 104, pp. 130-146, 2019.

[27]. S. Dutta, & S. Ghosh, "Forest Fire Detection Using Combined Architecture of Separable Convolution and Image

Processing," In 2021 1st International Conference on Artificial Intelligence and Data Analytics (CAIDA), pp. 36-41, IEEE, 2021.

[28]. J. Zhang, W. Li, Z. Yin, S. Liu, and X. Guo, "Forest fire detection system based on wireless sensor network," in 2009 4th IEEE conference on industrial electronics and applications, IEEE, pp. 520-523, 2009.

[29]. J. Zhang, Z. Ye & K. Li, "Multi-sensor information fusion detection system for fire robot through back propagation neural network," Plos one, vol. 15, No. 7, 2020.

[30]. R. Sharma, S. Rani & L. Memon, "A smart approach for fire prediction under uncertain conditions using machine learning," Multimedia Tools and Applications, vol. 79, No. 37, pp. 28155-28168, 2020.

[31]. J. B. Maheen and R. Aneesh, "Machine learning algorithm for fire detection using color correlogram," in 2019 2nd international conference on intelligent computing, instrumentation and control technologies (ICICICT), 2019, vol. 1, pp. 1411-1418, 2019.

[32]. G. Godson, O. M. Faizan, and S. Sanjeevi, "Forest fire risk assessment using GIS science—A case study of South India," Geographic Information Science for Land Resource Management, pp. 283-300, 2021

Presenting a multi-criteria fire detection method based on neural networks

Hassan Zaaferani^{1*}, Ali Abdi², Ehsan Ayoubi³

1- Department of Computer Engineering - Faculty of Engineering - Ferdowsi University of Mashhad – Mashhad- Iran.

2- Department of Chemical, Petroleum and Polymer Engineering - Faculty of Engineering - Ferdowsi University of Mashhad - Mashhad – Iran.

3- Department of Computer Engineering - Faculty of Engineering - Birjand Azad University - Birjand – Iran.

Abstract

Assessing the severity of forest and rangeland fires using artificial intelligence and satellite data is of particular importance for rangeland planning and management. Khuzestan Province has a relatively semi-arid climate and a large number of fires are reported there each year. Fire data includes the burned area and the number of fire occurrences. Currently, most estimates are made in the field and with simple mapping tools such as handheld GPS, which, in addition to being costly, also pose a high risk to individuals. This is while numerous studies have been conducted in various sciences on the use of neural network knowledge. In this research, after collecting regional information and satellite data, fire level estimation is carried out using artificial intelligence and comparing various modes of artificial neural networks (Multi-layer Feedforward backpropagation) and increasing the performance level and finally optimizing the desired network structure. In the meantime, various arrangements of activation functions (over 560 methods) were discussed and examined, and finally the Tansig-Logsig arrangement with Mnf input was accepted as the best arrangement with an accuracy of 99.8%.

Keywords: Neural Network, Satellite, Error backpropagation model, Forest fire