توسعه پایدار و ساختمان هوشمند
https://sdsb.buqaen.ac.ir

جلد ۱، شماره ۱، بهار ۱۴۰۳

ارائه یک روش چند معیاره تشخیص حریق مبتنی بر شبکه عصبی

حسن زعفرانی[1*]، علی عبدی[2]، احسان ایوبی[3].

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

ارزیابی شدّت آتش‌سوزی جنگل‌ها و مراتع با استفاده از هوش مصنوعی و داده‌های ماهواره ای دارای اهمیت ویژه، جهت برنامه-ریزی و مدیریت مراتع می‌باشد. استان خوزستان دارای آب و هوایی نسبتاً نیمه‌خشک است و هر ساله، تعداد زیادی حریق در آن گزارش می-شود. داده‌های آتش‌سوزی شامل سطح سوخته‌شده و تعداد وقوع آتش‌سوزی می باشد. 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 متعدّدی 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 متنوّع شبکه‌های عصبی مصنوعی (Multi-layer Feedforward backpropagation) و بالا بردن سطح 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: ۱۴۰۲/۱۲/۰۸
تاریخ پذیرش: ۱۴۰۳/۰۲/۱۰

واژه‌های کلیدی: شبکه ع صبی، ماهواره، مدل پس انت شار خطا، آتش‌سوزی جنگل.

* نویسنده مسئول، پست الکترونیکی: zaaferani@mail.um.ac.ir

Digital Object Identifier https://doi.org/۱۰,۲۲۰۳٤/sdsb.۱,۱,۲۹
THIS WORK IS LICENSED UNDER CC BY-NC ٤,٠ INTERNATIONAL LICENSE.
© ۲۰۲٤ BOZORGMEHR UNIVERSITY OF QAENAT, IRAN

۱. مقدّمه

آتش‌سوزی جنگل‌ها در کشورها، خطری جدی است و سالانه، تعداد زیادی آتش‌سوزی رخ می‌دهد. تفکیک درجات مختلف شدّت سوختگی، برای بهبود مدیریت مناطق آسیب‌دیده از آتش، حیاتی است. در زمینهٔ تشخیص حریق نیز به طور خاص، تلاش‌های زیادی صورت پذیرفته است. کوینتانو و همکاران [۱]، از یک روش در سه منطقه مطالعه مدیترانه‌ای برای برآورد شدّت سوختگی با استفاده از داده‌های ماهواره‌ای با وضوح متوسط استفاده نمودند. تصاویر پس از آتش‌سوزی Landsat ۵ 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 ۲ پرداخته‌اند. این الگوریتم، خود را با شرایط پراکندگی محلّی سازگار می‌کند و نسبت به تغییرات داده‌های ورودی، قوی است.

لنتایل و همکاران [۴]، در پژوهشی، اقدام به بررسی و تحلیل روش‌های تشخیص رایج 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[۱] 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. نادی و همکاران [۶]، به کمک یک مدل مبتنی بر شبکه‌های عصبی مصنوعی، به بررسی تغییرات پوشش گیاهی جنگل پرداخته‌اند.

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 شدّت 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

شبکه‌های عصبی مصنوعی پیش‌خور

شبکه‌های عصبی پیش‌خور (FF)[۲] 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. هنگامی‌که داده‌های ورودی به نورون (neuron) انتقال پیدا کردند، پردازش می‌شوند و یک خروجی تولید می‌شود. در این پژوهش از FF به عنوان معماری شبکه استفاده شده است. پیش‌سو بودن به این معناست که نرون‌های مصنوعی در لایه‌های متوالی قرار گرفته است و خروجی خود را رو به جلو می‌فرستد. واژهٔ پس‌انتشار نیز

۱. Feed Forward Back Propagation

۲. Feed Forward Neural Networks

به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شود تا وزن‌ها را اصلاح کند و پس از آن، مجدداً ورودی مسیر پیش‌سوی خود تا خروجی را تکرار کند.

ماهواره Landsat۸

ماهواره لندست (Landsat ۸) ۸ در تاریخ ۱۱ فوریه ۲۰۱۳ راه‌اندازی شده است. این هشتمین ماهواره در برنامه ماهواره‌های لندست، و ۲۰۱۷ پس از آتش‌سوزی أخذ گردید و پس از آماده‌سازی، ساختار کلّی شبکه عصبی به شرح ذیل تعریف می‌گردد: تعداد۱۰ ورودی شامل ۸ باند تصویر ماهواره‌ای و دو شاخصهٔ NDVI و RVI که هردو 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 وآب) 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 تعداد۷۰٪ برای آموزش و ۳۰٪ برای ارزیابی پس از آموزش به کار گرفته شد.

هفتمین ماهواره‌ای است که با موفقیت به مدار رسیده است. این ماهواره که در اصل (LDCM)[۳] نامیده می‌شود، محصول همکاری بین ناسا و سازمان زمین‌شناسی ایالات متحده (USGS) است؛ با بازنشستگی لندست ۵ در اوایل سال ۲۰۱۳، ماهواره لندست ۷ به عنوان تنها ماهواره موجود از سری ماهواره‌های لندست بر روی مدار وجود داشت.

در این پژوهش، تصاویر ماهواره لندست ۸ در تاریخ ۲۰ آگوست

جدول(۱-۱): اطلاعات أخذ شده از میزان آتش‌سوزی (منابع طبیعی)

۵۸	۴۰۵۴۴۹	۳۵۱۲۶۲۹	ایذه	۹۶/۰۵/۲۱	۹۶/۰۵/۲۱	۱۹:۰۰	۲۱:۳۰	جنگل طبیعی	۳۲
۵۹	۲۷۷۹۹۲	۳۵۴۸۹۴۸	ایذه	۹۶/۰۵/۲۰	۹۶/۰۵/۲۰	۰۹:۳۰	۱۸:۳۰	جنگل دست کاشت	۷۰
۶۰	۲۸۰۰۱۵	۳۵۴۴۲۶۸	ایذه	۹۶/۰۵/۲۲	۹۶/۰۵/۲۲	۲۱:۳۰	۰۲:۳۰	جنگل دست کاشت	۲۵

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)[۲] وارد می‌گردد.

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 پس‌زمینهٔ 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 محقّق 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. دراین مرحله، برای تشخیص دقیق‌تر هدف مورد نظر و برای به‌دست آوردن نتیجهٔ قابل قبول‌تر، الگوریتم MNF بر روی تصاویر اعمال شد. این تبدیل، یک تبدیل خطی است که برای مشخص‌کردن بُعد و حجم اصلی تصویر، جداکردن نویز از دیگر اطلاعات و کاهش میزان پردازش در مرحلهٔ بعد استفاده می‌شود که تصویرآن در شکل(۱-۱) نشان داده شده است.

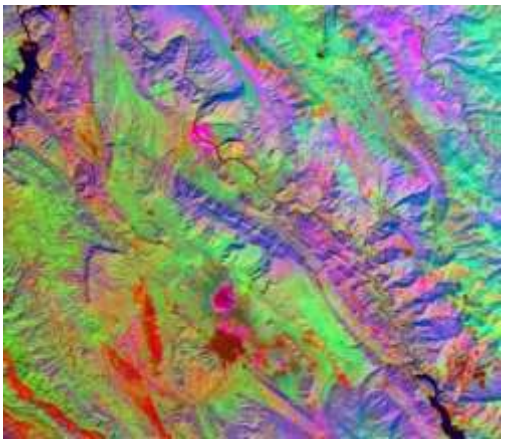

شکل(۱-۱): تصویر MNF شده منطقه ایذه.

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

۲. Minimum Noise Fraction

۳. Landsat Data Continuity Mission

رابطه (۱-۱) نرمال‌سازی خطی

$$X_{changed} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

انتخاب معماری و آموزش شبکه

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

تکرار یا سیکل زمانی

پارامترهای شبکه، پس از یک دوره کامل ارائه، الگوهایی به دست می‌آورد که در اصطلاح به این نوع تکرار یک سیکل (Epoch) می‌گویند 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 نورون‌ها از۲ تا ۴۰ نورون تغییر می‌کند و بهترین صحت آن ثبت می‌گردد.

ارزیابی شبکه FF

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

رابطه (۲-۱): میانگین مربعات خطا

$$MSE = \frac{\sum_{1}^{n}(obs - calc)^2}{N}$$

تعداد خروجی:N

مقادیر محاسبه شده:Calc

مقادیر واقعی: Obs

بدین ترتیب، یک شبکه عصبی مصنوعی تولید می‌شود که ما در اینجا با بررسی مؤلفه‌های مختلف در پی دستیابی به بهترین شبکه جهت ارزیابی حریق به کمک تصاویر ماهواره‌ای هستیم.

ارزیابی بهترین شبکه

ضمناً سایر پارامترهای شبکه ثابت و یا مقادیر پیش‌فرض مورد پذیرش قرارگرفت که عبارتند از :

تعداد لایه مخفی:۱ تابع یادگیری: LM تابع ارزیابی عملکرد شبکه: MSE تعداد Epoch:۱۰۰ تعداد نورون: از ۲ تا ۴۰ توابع فعال‌سازی: ترکیبی از Tansig، Logsig و Purlin تعداد ورودی :۱۰ ورودی شامل ۸ مقدار مستقیم باندی (باندهای ۲ تا ۷ و ۹ و۱۰) و شاخص NDVI۱ (شاخص تراکم پوشش گیاهی) و شاخص RVI ۲ (شاخص نسبت پوشش گیاهی)

رابطه (۳-۱): شاخص تراکم پوشش گیاهی

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

رابطه (۴-۱): شاخص نسبت پوشش گیاهی

$$RVI = \frac{R_{RED}}{R_{NIR}}$$

در هر مرحله، صحت طبقه‌بندی‌ها با آماره صحت کل (Total accuracy) بررسی و گزارش می‌گردید. این نسبت از تقسیم تعداد پیکسل‌های درست تشخیص داده شده به کل تعداد پیکسل‌ها حاصل می‌گردد و معمولاً به شکل درصد ارائه می‌شود.

رابطه (۵-۱): صحت

$$\text{Accuracy} = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}}$$

درادامه مطابق شکل(۲-۱) تصویر شبکه نمایش داده شده است.

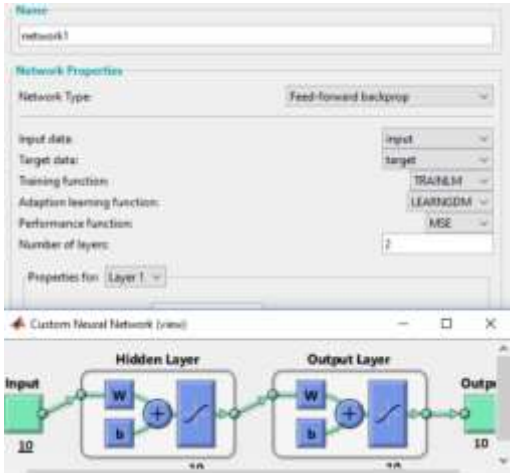

شکل(۲-۱): تصویر شبکه.

در ادامه در شکل (۳-۱) فلوچارت الگوریتم پیشنهادی آمده **است**.

۱. Normalized Differences Vegetation Index

۲. Ratio Vegetation Index

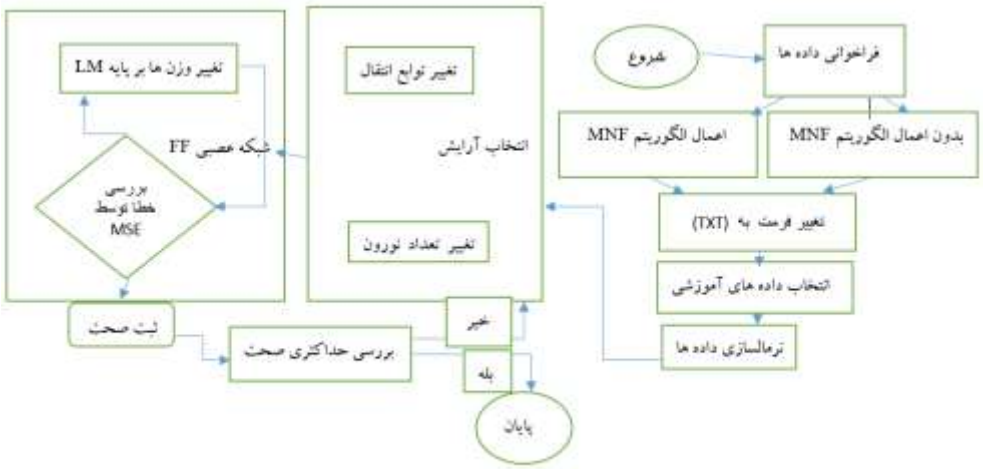

شکل(۳-۱): الگوریتم روش پیشنهادی

ت

۳. بحث وارزیابی

در مطالعه فعلی، در جهت انتخاب شبکه مطلوب، از کلّی‌گویی پرهیز و در این راستا ابتدا بالغ بر ۵۶۰ روش و به عبارتی ساختار مختلف شبکه‌ای ارزیابی شد که معیار صحت برای سنجش و ارزیابی کلّی مورد استفاده قرارگرفت که در بهترین حالت، مقدار این معیار نزدیک به ۱۰۰ و در بدترین حالت، مقدار آن۲۰ بود؛ بنابراین، هرچه این مقدار به ۱۰۰ نزدیک‌تر می‌شد، بهتر بود. در ادامه، به تشریح روش‌های بررسی شده پرداخته می‌شود.

فاز اول بدون اعمال MNF

تابع Linear-Linear

همان‌طور که در شکل (۴-۱) مشخص است، نمودار نتایج حاصل از اعمال ساختار مختلف، از یک نورون تا۴۰ 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 تا۴ به‌شدت، 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 نمی-پذیرد و به‌طور کلّی، صحت از ۸۰٪ تجاوز نمی‌کند، لذا این روش در مقایسه با بقیه، نتایج ضعیفی دارد.

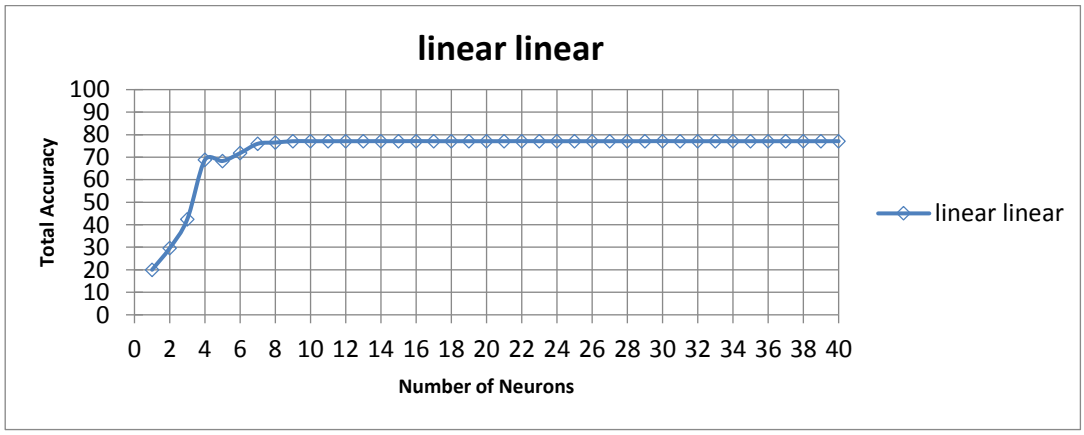

شکل(۴-۱): تابع Linear-Linear

تابع Tansig-Linear

و اما با بررسی این روش، با توجّه به نمودار در شکل (۵-۱) 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 شدّت 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.

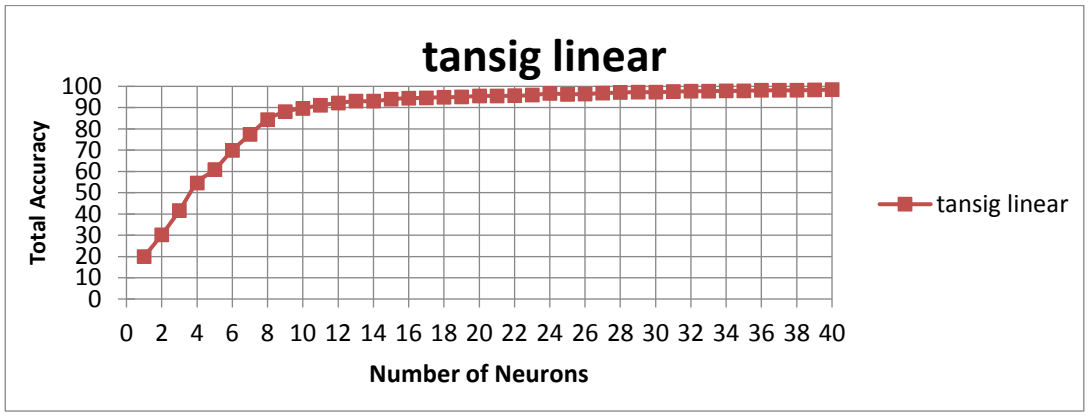

شکل(۵-۱): تابع Tansig-Linear.

تابع Logsig-Linear

این روش مطابق با شکل (۶-۱) همانند روش tansig-linear و با اعمال این تابع با افزایش تعداد نورون از ۱ تا ۱۰ نورون نتایج شدّت 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 تا۴۰ 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.

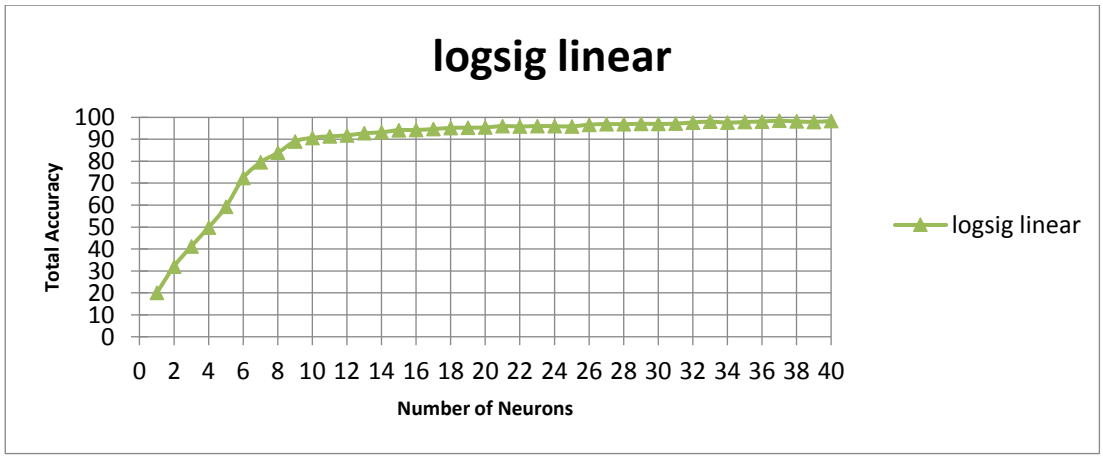

شکل(۶-۱): تابع Logsig-Linear

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 در۵۰٪ ثابت می‌ماند. در ادامه، با افزایش نورون از۵ به ۹ صحت به ۸۸٪ می‌رسد و تغییرات صحت در بازه ۹ تا۱۰ ثابت و از ۱۰نورون تا ۱۱ صحت افزایش

می‌یابد و به حدود۹۲٪ می‌رسد. ولی پس از آن یک روند صعودی ملایم را در پیش می‌گیرد. فقط با افزایش نورون‌ها در نقطهٔ ۲۰ صحت کاهش می‌یابد. در ادامه، افزایش نورون تا۴۰ صحت به حدود ۹۹٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج نسبتاً قابل قبولی دارد.

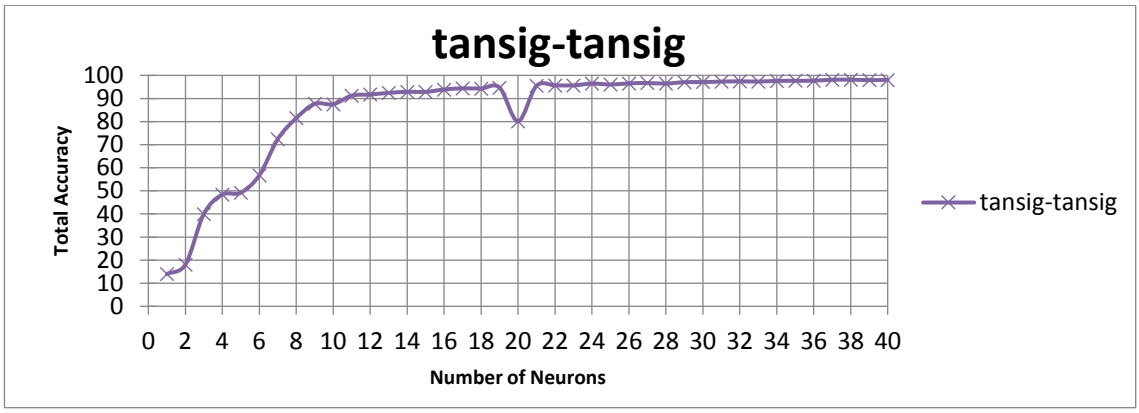

شکل(۷-۱): تابع Tansig-Tansig.

تابع Tansig -Logsig

در بررسی این روش، با توجّه به نمودار شکل (۸-۱)، 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 حتّی 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.

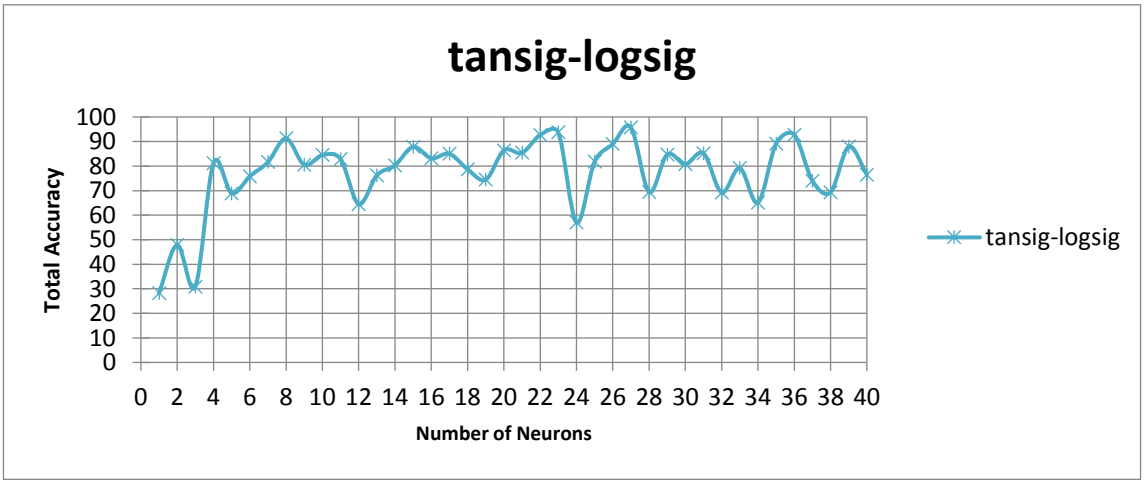

شکل(۸-۱): تابع Tansig-Logsig.

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 ۳۸حتی 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.

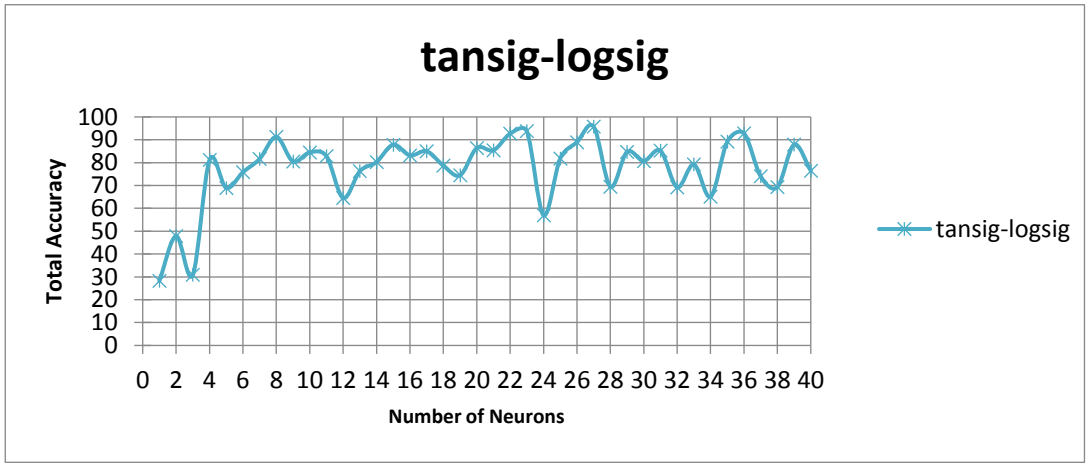

شکل(۸-۱): تابع Tansig-Logsig.

تابع Logsig- Tansig

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، درصورتی که در ۱۰ نورون صحت به ۸۸٪ می‌رسد. 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٪تا۹۸٪ متغیر است، ولی در ۴۰ نورون صحت کاهش یافته و به ۵۲٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.

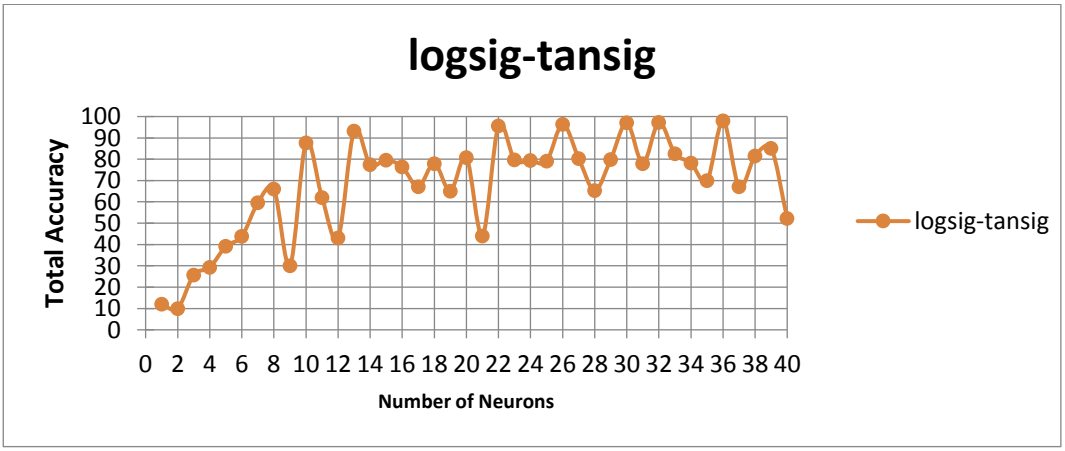

شکل(۹-۱): تابع Logsig -Tansig.

تابع Logsig-Logsig

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 و۳۷حتی با افزایش نورون‌ها صحت کاهش یافت. ضمناً تغییرات صحت از ۶ نورون تا ۳۷ نورون بین ۴۰٪تا۸۲٪ متغییر است و در ۴۰ نورون صحت به ۵۰٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی ندارد.

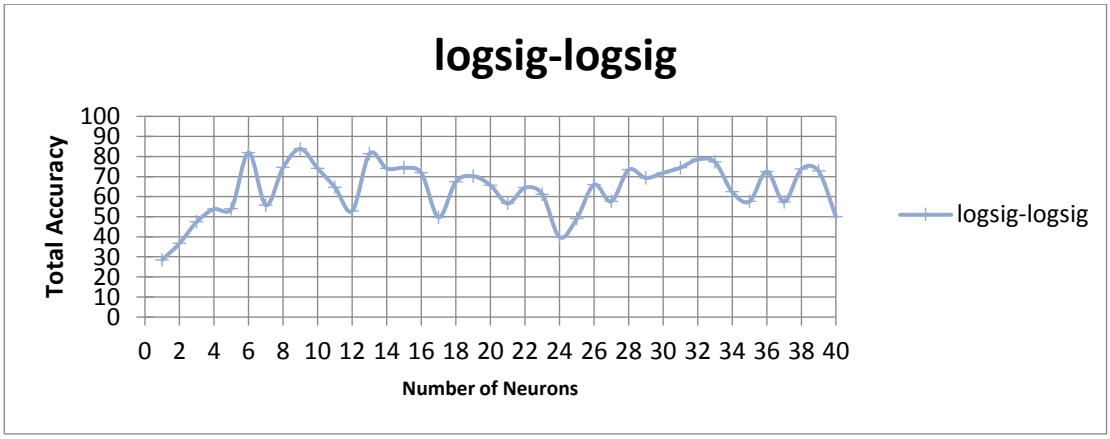

شکل(۱۰-۱): تابع Logsig – Logsig.

فاز دوم با اعمال MNF

تابع MNF Linear-Linear

همان‌طور که در نمودار شکل (۱۱-۱) مشخص است، با اعمال این تابع با افزایش تعداد نورون از۱ تا ۴ به‌شدت بهبود می‌یابد و در ۴ نورون صحت به میزان ۷۰٪ می‌رسد و تا ۵ نورون تغییر صحت ثابت است. سیر تغییرات صحت در بازه ۵ تا ۷ نورون افزایش می‌یابد و به۷۸٪ می‌رسد و در ادامه، افزایش نورون‌ها روند ثابتی را دنبال می‌کند. از ۸ نورون تغییرات چندان در بهبود صحت صورت نمی‌پذیرد. به طور کلّی، صحت از ۷۸٪ تجاوز نمی‌کند، لذا این روش در مقایسه با بقیه، نتایج ضعیفی دارد.

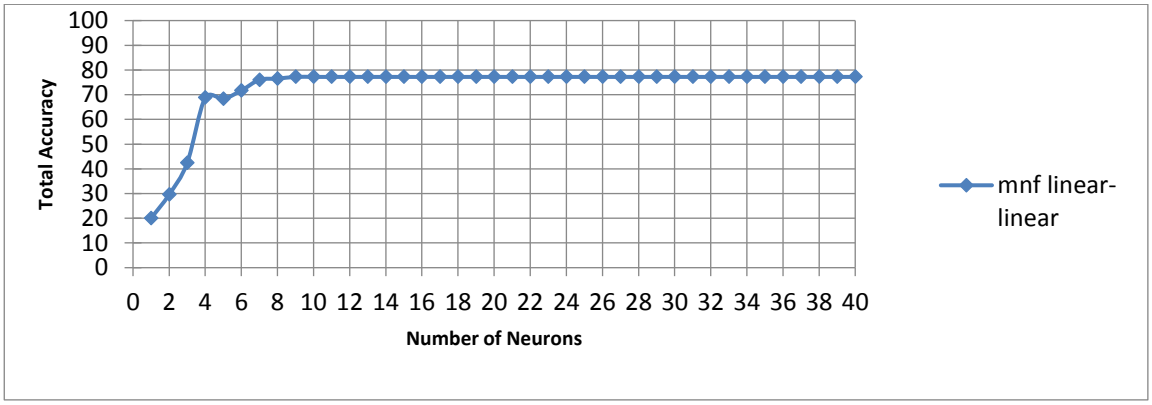

شکل(۱۱-۱): تابع MNF Linear-Linear.

تابع MNF Tansig-Linear

و اما با بررسی این روش، با توجّه به نمودار شکل (۱۲-۱) و پس از اعمال الگوریتم حذف نویز، در ابتدا با نتایج ضعیفی روبه‌رو شد که کم‌کم با افزایش تعداد نورون، نتایج قابل قبولی حاصل گردید. با اعمال این تابع، با افزایش تعداد نورون از۱ تا۱۰ به‌شدت بهبود می‌یابد و در ۱۰ نورون صحت به میزان ۹۰٪ می‌رسد. 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 قابل قبولی دارد.

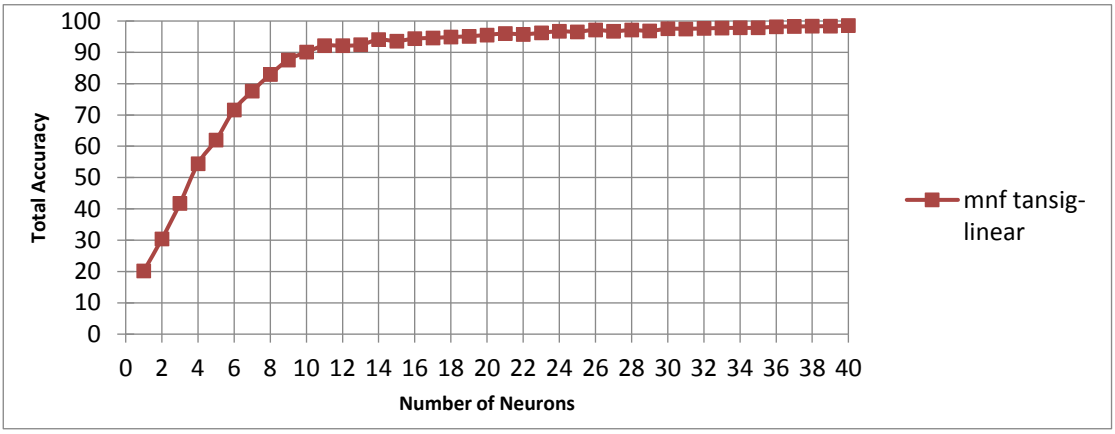

شکل(۱۲-۱): تابع MNF Tansig-Linear

تابع MNF Logsig-Linear

با بررسی این روش، با توجّه به نمودار شکل (۱۳-۱) و پس از اعمال الگوریتم حذف نویز، به نتایج قابل قبولی رسید. در این تابع، با افزایش تعداد نورون از ۱ تا۹ بشدت بهبود می‌یابد و در 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.

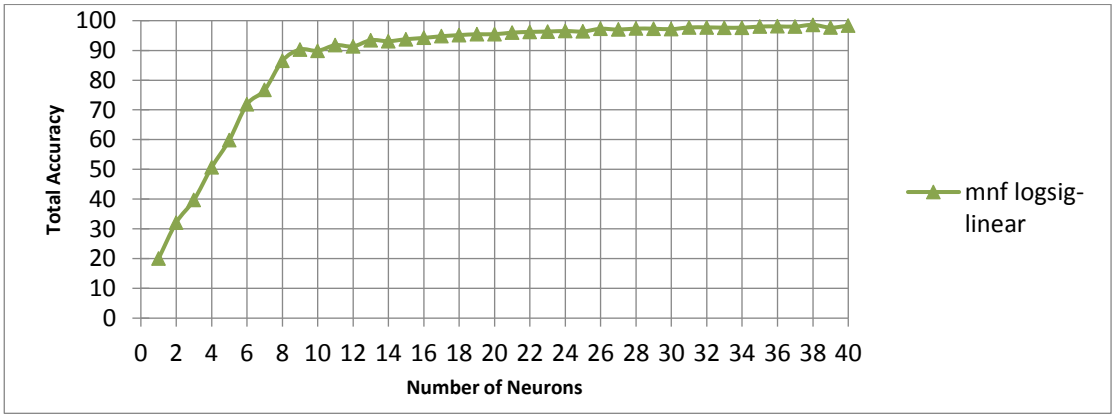

شکل(۱۳-۱): تابع MNF Logsig-Linear

تابع MNF Tansig-Tansig

در این روش، با توجّه به نمودار شکل (۱۴-۱) و پس از اعمال الگوریتم حذف نویز، در این تابع با افزایش تعداد نورون از ۱ تا۹ 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 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 در۴۰ نورون به ۹۸٪ می‌رسد، لذا این روش در مقایسه با بقیه، نتایج نسبتاً قابل قبولی دارد.

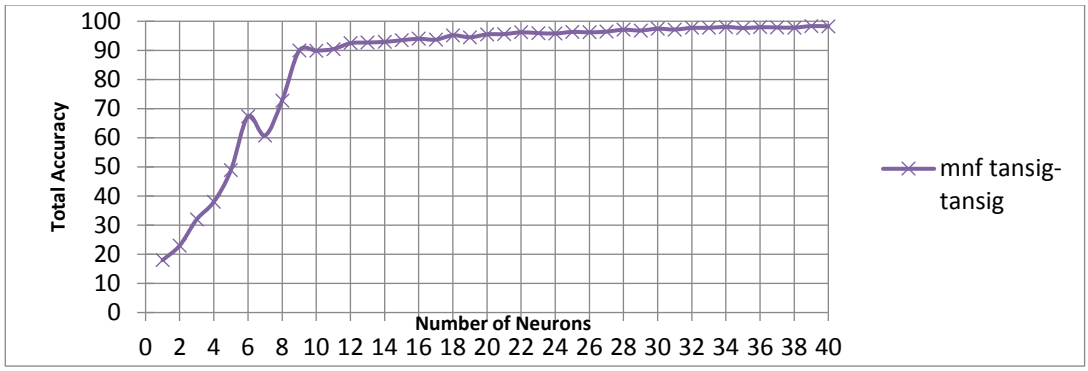

شکل(۱۴-۱): تابع MNF Tansig-Tansig.

تابع MNF Tansig-Logsig

در بررسی این روش، با توجّه به نمودار شکل (۱۵-۱) و پس از اعمال الگوریتم حذف نویز، در ابتدا این تابع با افزایش نورون از ۱ تا ۲ صحت بهبود می‌یابد و در ۲نورون 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 تا۹۰٪ پیش می‌رود. در ادامه، با افزایش نورون صحت روند نوسانی افزایشی در پیش می‌گیرد. با ادامه این روال و افزایش نورون‌ها تا۴۰ ملاحظه شد در برخی نقاط مانند: ۷،۹، ۱۱،۱۶، ۲۲،۲۵،۲۸، ۳۴ و۳۸ 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 بر۹۹،۸٪ صحت در تشخیص عمل بنماید.

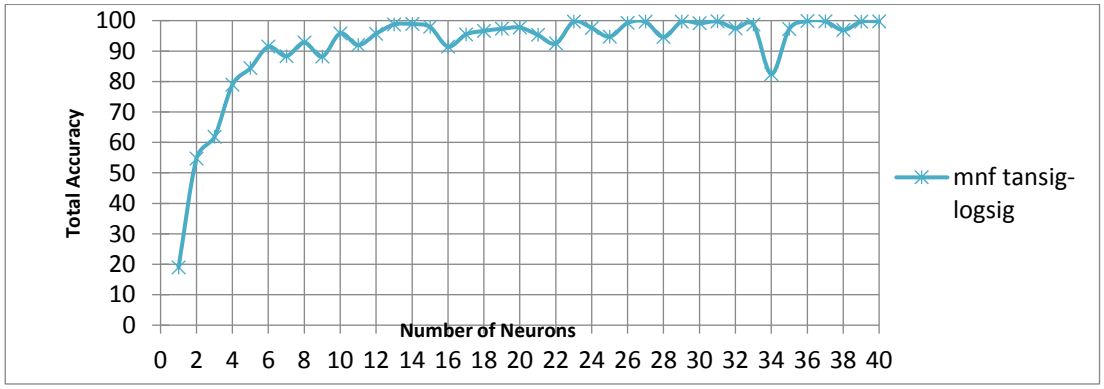

شکل(۱۵-۱): تابع MNF Tansig-Logsig.

تابع MNF Logsig-Tansig

با بررسی این روش، با توجّه به نمودار شکل (۱۶-۱) این تابع با افزایش نورون از ۱ تا ۶ صحت به‌شدت 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 به ۹۰٪ می‌رسد. باره دیگر نورون-ها در بازه ۱۰تا ۱۳روند 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 و۴۰ 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.

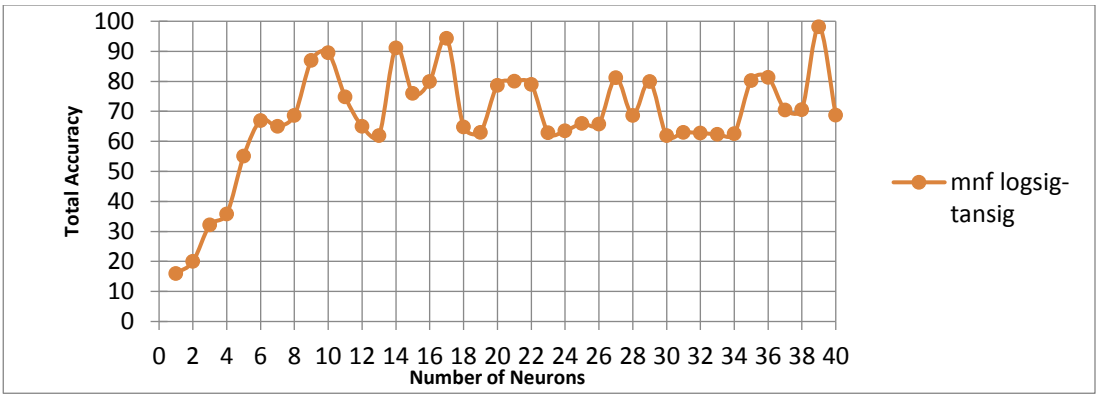

شکل(۱۶-۱): تابع MNF Logsig-Tansig.

تابع MNF Logsig-Logsig

با بررسی این روش، با توجّه به نمودار شکل (۱۷-۱) و پس از اعمال الگوریتم حذف نویز، با افزایش نورون از ۱ تا ۸ به‌شدت بهبود می‌یابد و در ۸ نورون صحت به میزان ۹۰٪ می‌رسد، ولی پس از آن یک روند نوسانی را در پیش می‌گیرد. با افزایش نورون‌ها در برخی نقاط مانند: ۹، ۱۶، ۲۴و ۳۵ صحت کاهش می‌یابد. ضمناً تغییرات صحت از۸ نورون تا ۴۰ نورون روند چشم‌گیری در افزایش به همراه ندارد، لذا این روش در مقایسه با بقیه، نتایج قابل قبولی دارد.

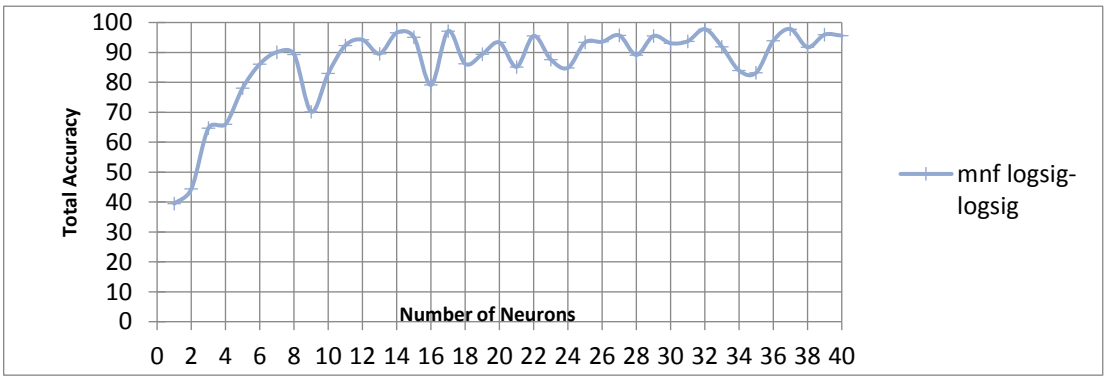

شکل (۱۷-۱): تابع MNF Logsig-Logsig.

انتخاب بهترین آرایش حاصل شده

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

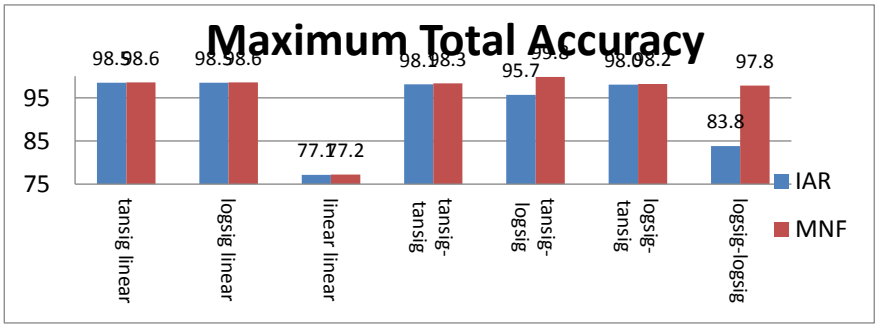

شکل (۱۸-۱): مقایسه حالات مختلف شبکه.

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 تنوّع پاسخ-های شبکه با توجّه به ساختارهای متنوّع 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 هوشمند حریق را بیشتر می‌کند. نتایج شبیه‌سازی نشان داد روش Tansig-Logsig(MNF) بر روی مجموعه داده ماهواره‌ای لندست۸ 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(۲-۴) مورد مقایسه قرار می‌گیرد.

جدول (۱-۲): 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-nural network*	*Predictive modeling of wildfires: A new dataset and machine learning approach*	۲۰۱۹	۹۸/۳۲٪
[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	۹۴/۶۰٪
[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٪

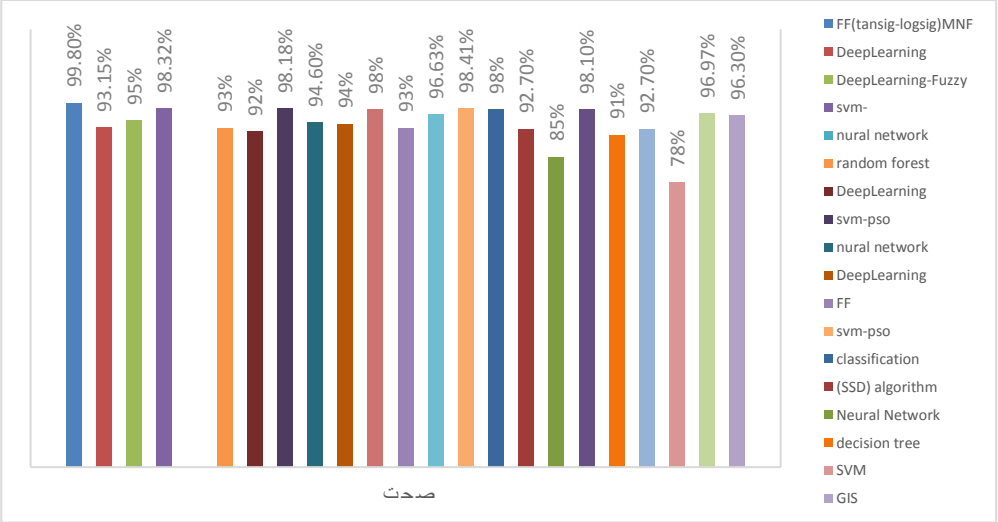

شکل شماره (۱۹-۱): مقایسه میزان صحت روش پیشنهادی در مقایسه با دیگر مطالعات

۴. نتیجه‌گیری

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، ارایه 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 شاخصه NDVI وRVI که هردو 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.

جهت پیاده‌سازی این محتوا از نرم‌افزار Matlab استفاده شده که پس از پیاده‌سازی و ارزیابی معیارهای مختلف از توابع انتقال تا تعداد نورون‌ها، نهایتاً نتایج به‌دست آمده از ۷ نوع ترکیب تابعی مطابق با شکل (۱-۵) 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 توجّه به اینکه با کمترین تعداد نورون به بهترین صحت دست یافت، به عنوان بهترین شبکه انتخاب گردید. از طرفی توابع Tansig-Linear وLogsig-Linear نیز می‌توانند به خوبی در خصوص تشخیص حریق اقدام نمایند. همچنین، به طور کلّی، 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

منابع

[۱]. 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. ۱۹۰, pp. ۸٤-۹٥, ۲۰۱۷.

[۲]. 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. ۷٦-۸۸, ۲۰۱۳

[۳]. M. A. Belenguer-Plomer, M. A. Tanase, A. Fernandez-Carrillo, & E. Chuvieco, "Burned area detection and mapping using Sentinel-۱ backscatter coefficient and thermal anomalies," *Remote Sensing of Environment*, vol. *233*, pp. ۱۱۱-۳٤٥, ۲۰۱۹.

[٤]. 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.* ۳, pp. ۳۱۹-۳٤٥, ۲۰۰٦.

[٥]. 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. ۱۰, ۲۰۱۸.

[٦]. 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. ٤, pp. ۳۰٥-۳۱۷, ۲۰۱۷.

[۷]. 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.* ۱۸, ۲۰۱۹.

[۸]. 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. ۱٤٤-۱٥۹, ۲۰۱۹.

[۹]. 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. ۹, ۲۰۱۸.

[۱۰]. ق. اردستانی، م. نافیان و بهمنی، "مدل‌سازی خطر سقوط درختان خطرآفرین با کاربرد شبکه عصبی مصنوعی و رگرسیون لجستیک در فضای سبز شهری" ، محیط شناسی، سال ۴، شماره ۴۵، ص. ۶۱۶-۶۳۰، ۲۰۲۰.

[۱۱]. صیادی و عساکره، "تحلیل و پیش‌بینی روزهای خشک با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: ایستگاه تهران) "، نشریه جغرافیا و برنامه ریزی، ۲۰۲۰.

[۱۲]. 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 ۲۰۱۸ International Conference on Information Technology (ICIT), pp. ۱٦۱-۱٦٥, IEEE, ۲۰۱۸.

[۱۳]. J. H. Park, S. Lee, S. Yun, H. Kim & W. T. Kim, "Dependable fire detection system with multifunctional artificial intelligence framework," Sensors, vol. ۱۹, No. ۹, ۲۰۱۹.

[۱٤]. Y. O. Sayad, H. Mousannif & H. Al Moatassime, "Predictive modeling of wildfires: A new dataset and machine learning approach," Fire safety journal, vol. ۱۰٤, pp. ۱۳۰-۱٤٦, ۲۰۱۹.

[۱٥]. E. Jang, Y. Kang, J. Im, D. W. Lee, J. Yoon &S. K. Kim, "Detection and monitoring of forest fires using Himawari-۸ geostationary satellite data in South Korea," Remote Sensing, vol. ۱۱, No. ۳, ۲۰۱۹.

[۱٦]. 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. ۱۹۳, ۲۰۲۱.

[۱۷]. Y. Bian, M. Yang, X. Fan, & Y. Liu, "A fire detection algorithm based on Tchebichef moment invariants and PSO-SVM. Algorithms," vol. ۱۱, No. ٦, ۲۰۱۸.

[۱۸]. P. Barmpoutis, T. Stathaki, K. Dimitropoulos, & N. Grammalidis, "Early fire detection based on aerial ۳٦۰-degree sensors, deep convolution neural networks and exploitation of fire dynamic textures," Remote Sensing, vol. ۱۲, No. ۱۹, pp. ۳۱-۷۷, ۲۰۲۰.

[۱۹]. 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 ۲۰۱۹ ۷th International Conference on Robot Intelligence Technology and Applications (RiTA), pp. ۳۸-٤٥, IEEE, ۲۰۱۹.

[۲۰]. Y. Zhao, J. Ma, X. Li, and J. Zhang, "Saliency detection and deep learning-based wildfire identification in UAV imagery," Sensors, vol. ۱۸, no. ۳, p. ۷۱۲, ۲۰۱۸.

[۲۱]. 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. ۲٤, No. ۲, pp. ٥٥-٦۰, ۲۰۱۸.

[۲۲]. M. A. Mahmoud and H. Ren, **"**Forest Fire Detection Using a Rule-Based Image Processing Algorithm and Temporal Variation**,"** Mathematical Problems in Engineering, vol. ۱, pp. ۷٦۱۲٤۸۷, ۲۰۱۸.

[۲۳]. P. Chanthiya, & V. Kalaivani, "Forest fire detection on LANDSAT images using support vector machine. Concurrency and Computation: Practice and Experience," PP. ٦۲-۸۰, ۲۰۲۱.

[۲٤]. Y. Y. Qin, J. T. Cao & X. F. Ji, "Fire Detection Method Based on Depthwise Separable Convolution and YOLOv۳," International Journal of Automation and Computing, vol. ۱۸, No. ۲, pp. ۳۰۰-۳۱۰, ۲۰۲۱.

[۲٥]. 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 ۲۰۲۰ IEEE Eighth International Conference on Communications and Electronics (ICCE), pp. ۳۳۸-۳٤۳, IEEE, ۲۰۲۱.

[۲٦]. 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. ۱۱, No. ۹, ۲۰۲۰.

[۲۷]. S. Dutta, & S. Ghosh, "Forest Fire Detection Using Combined Architecture of Separable Convolution and Image Processing," In ۲۰۲۱ ۱st International Conference on Artificial Intelligence and Data Analytics (CAIDA), pp. ۳٦-٤۱, IEEE, ۲۰۲۱.

[۲۸]. J. Zhang, W. Li, Z. Yin, S. Liu, and X. Guo, **"**Forest fire detection system based on wireless sensor network**,"** in

۲۰۰۹ ٤th IEEE conference on industrial electronics and applications, IEEE, pp. ٥٢٠-٥٢٣, ۲۰۰۹.

[۲۹]. 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.* ۷, ۲۰۲۰.

[۳۰]. 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.* ۳۷, pp. ۲۸۱٥٥-۲۸۱٦۸, ۲۰۲۰.

[۳۱]. J. B. Maheen and R. Aneesh, **"**Machine learning algorithm for fire detection using color correlogram**,"** in ۲۰۱۹ ۲nd international conference on intelligent computing, instrumentation and control technologies (ICICICT), ۲۰۱۹, vol. ۱, pp. ۱٤۱۱-۱٤۱۸،۲۰۱۹.

[۳۲]. 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. ۲۸۳-۳۰۰, ۲۰۲۱.

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

Hassan Zaaferani[۱], Ali Abdi[۲], Ehsan Ayoubi[۳]

۱- Department of Computer Engineering - Faculty of Engineering - Ferdowsi University of Mashhad – Mashhad- Iran.
۲- Department of Chemical, Petroleum and Polymer Engineering - Faculty of Engineering - Ferdowsi University of Mashhad - Mashhad – Iran.
۳- 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 ٥٦٠ methods) were discussed and examined, and finally the Tansig-Logsig arrangement with Mnf input was accepted as the best arrangement with an accuracy of ٩٩,٨٪.

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