

پیاده سازی موثر الگوریتمهای یادگیری ماشین بر روی گرههای لبه در اینترنت اشیا

پیمان بابائی^۱، مجید فرشاد^۲

^۱گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران غرب، تهران Peyman.Babaei@iau.ac.ir

^۲گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد تهران غرب، تهران majidfarshad@gmail.com

چکیده

گرههای محاسباتی تعبیه شده^۱، به سرعت در حال گسترش در همه جنبه های زندگی بشر امروزی هستند و کاربردهای مفیدی در زمینه هایی مانند سیستم های پوشیدنی برای نظارت بر سلامت، سیستم های بی سیم برای کنترل نظامی، سیستم های شبکه در اینترنت اشیا، لوازم هوشمند برای اتوماسیون خانگی و سیستم های ترمز ضد قفل در خودروها دارند. روند تحقیقاتی اخیر در فناوریهای محاسباتی، نیاز به پیاده سازی روش های یادگیری ماشین در گره های محاسباتی تعبیه شده برای کاربردهای متنوع را نشان می دهد. همگرایی الگوریتم های یادگیری ماشین و سیستم های تعبیه شده که در آن مدل های یادگیری محاسباتی، سیستم های تعبیه شده با منابع محدود را هدف قرار داده است، فرصت های فراوانی را برای تحقیق در فناوری های محاسباتی بر روی گره های لبه در اینترنت اشیا فراهم کرده است. اگرچه تحقیقات در این زمینه در ابتدای راه است، با این حال تحقیقات زیادی شامل بهینه سازی مدل های مختلف یادگیری ماشین در محیط های با منابع محدود، توسعه معماری های سخت افزاری کارآمد شامل واحدهای شتاب دهنده برای تسریع در پیاده سازی الگوریتم های محاسباتی و معماری های سخت افزاری تخصصی جدید و نوآورانه برای برآورده نمودن الزامات کارایی در سطوح بالای این مدل ها، انجام شده است. لذا، نیاز به بررسی، تجزیه و تحلیل دیدگاه های مختلف برای ارائه مفاهیم بنیادی یادگیری ماشین بر روی گره های محاسباتی با منابع محدود با در نظر داشتن معماری کامپیوتر هدف، وجود دارد. در مجموع پیاده سازی الگوریتم های یادگیری ماشین در گره های محاسباتی لبه در اینترنت اشیا نیاز به ارائه راه حل هایی برای مشکلات پیچیده در این عصر کلان داده دارد. در این مقاله الگوریتم های یادگیری ماشین اعم مانند درخت تصمیم، k-نزدیک ترین همسایه، رگرسیون لجستیک و جنگل تصادفی مدل سازی شده اند. با تحلیل مقایسه ای الگوریتم ها، درخت تصمیم به عنوان مدلی با عملکرد مناسب با در نظر گرفتن دقت مدل (۹۲.۱۷٪)، میزان حافظه مصرفی و پیچیدگی محاسباتی الگوریتم معرفی می شود.

واژه های کلیدی

یادگیری ماشین، سیستم های تعبیه شده، گره های لبه، اینترنت اشیا.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

۱. متن مقاله

فناوریهای محاسباتی بر روی گره های لبه در اینترنت اشیاء به دلیل پیشرفت های جدید در معماری کامپیوتر و به کارگیری الگوریتمهای یادگیری ماشین، در حال تحول هستند. حوزه های کاربردی یادگیری ماشین بر روی سیستمهای تعبیه شده (بعنوان گره های لبه در اینترنت اشیاء)، شامل بینایی ماشین، تشخیص گفتار، مراقبت های بهداشتی نوآورانه، رباتیک و سایر موارد بسیار مورد توجه قرار گرفته اند. با این حال، لازم است ساختاری برای پیاده سازی موثر الگوریتم های یادگیری ماشین بر روی گره های لبه در اینترنت اشیاء بعنوان بستری مناسب در نظر گرفته شود. الگوریتم های یادگیری ماشین عموماً از نظر محاسباتی و حافظه برای محیط های دارای محدودیت منابع مانند سیستمهای تعبیه شده و سیار نامناسب هستند. برای پیاده سازی مؤثر این الگوریتم های محاسباتی در فضای محاسباتی تعبیه شده و سیار، نیاز به تکنیک های بهینه سازی نوآورانه در سطوح الگوریتم و سخت افزار است. گره های کم مصرف لبه در اینترنت اشیاء مانند میکروکنترلرها، به طور گسترده در کاربردهایی مانند نظارت، پایش سلامت، جستجو و نجات، ردیابی فعالیت، اشکال زدایی ماشین آلات صنعتی، ناوبری داخلی و رباتیک هوایی به کار گرفته شده اند. منابع حافظه و توان محاسباتی تجهیزات لبه در این کاربردها محدود است و نیاز به استقرار سخت افزار سبک وزن و خطوط لوله استنتاج دارند. به طور معمول، میکروکنترلرها با استفاده از روش های کلاسیک بر روی داده های ساختار یافته دریافتی از سنسورها با ابعاد پایین (مانند دما و رطوبت) کار می کنند و استنتاج های ساده ای را در لبه انجام می دهند. اخیراً، تلاش های قابل توجهی برای پیاده سازی الگوریتم های یادگیری ماشین در لبه در حال انجام است. با این حال، مدل های یادگیری ماشین که مستقیماً برای تجهیزات لبه طراحی شده اند، مانند تلفن های همراه و یا رایانه های تک برد، برای میکروکنترلرها مناسب نیستند. یک میکروکنترلر معمولی دارای ۱۲۸ کیلوبایت حافظه رم و ۱ مگابایت فلش است، در حالی که یک تلفن همراه می تواند ۴ گیگابایت حافظه رم و ۶۴ گیگابایت حافظه ذخیره سازی داشته باشد. محدودیت منابع گره های لبه اینترنت اشیاء، طراحی یک گردش کار سیستماتیک و ابزارهایی را برای استقرار خطوط لوله یادگیری ماشین نیاز دارد. در این مقاله الزامات، چالش ها و فرصتهایی را در توسعه مدل های یادگیری ماشین برای پردازش اطلاعات حسگرها بر روی میکروکنترلرها ارائه می کنیم. برای درک اینکه چگونه تجهیزات محاسباتی تعبیه شده کم مصرف ممکن است به پر کردن تقاضای فوق الذکر کمک کنند، الگوریتمهایی را که نیازمندی های اینترنت اشیاء را با اجرای الگوریتم های یادگیری ماشین با مصرف انرژی کارآمد برای تجهیزات کم مصرف برآورده می کنند، بررسی می کنیم.

۲. یادگیری ماشین و محاسبات لبه

الگوی محاسبات لبه در اینترنت اشیاء، با استفاده از تجهیزات هوشمند، فرآیند محاسباتی را به منابع داده مانند سنسورهای محیطی و دوربین ها نزدیک تر می کند. در چند سال اخیر، تحقیقاتی در زمینه تجزیه و تحلیل، تصمیم گیری و کنترل با گره های محاسباتی لبه که الگوریتم های کامل را اجرا می کنند، انجام شده است و تجهیزات لبه هوشمند کم مصرف با منابع حافظه و توان محاسباتی محدود که الگوریتم های یادگیری ماشین را برای شناسایی اشیاء و یا استخراج ویژگی ها اجرا می کنند محقق شده اند. پارادایم محاسبات لبه یک الگوی نوظهور برای سیستم های اینترنت اشیاء است که در آن محاسبات در انواع تجهیزات لبه توزیع می شوند تا قابلیت محاسباتی را به منابع داده، مانند حسگرهای محیطی و دوربین ها نزدیک تر کنند. می توان به مزایای محاسبات لبه نسبت به الگوی محاسبات متمرکز سنتی که در سیستم های ابری یافت می شود اشاره کرد:

- کاهش پهنای باند ارتباطی و هزینه های انرژی، در نتیجه کاهش انتقال داده ها به سرورهای ابری متمرکز.
 - نزدیکی فیزیکی داده ها و تجهیزات پردازشی، لذا پردازش داده ها در زمان واقعی تسهیل می شود.
 - پردازش در تجهیزات لبه، حریم خصوصی داده های حساس را تضمین می کند و از بارگذاری آنها به مکانهای دور جلوگیری می کند.
 - در سیستمهای توزیع شده، خرابی برخی از گره ها را می توان به راحتی با حداقل تاثیر بر کل سیستم برطرف نمود و تجهیزات جدید را به صورت مازولار برای افزایش توان محاسباتی اضافه کرد.
- برای گره های محاسباتی لبه، تجزیه و تحلیل داده ها، به ویژه پیاده سازی الگوریتم های یادگیری ماشین، یک چالش بزرگ است. امروزه کاربردهایی که می توانند از تکنیک های یادگیری ماشین در لبه استفاده کنند، بسیار هستند. ولی آنها با مشکل استنتاج سروکار دارند. بعنوان چند نمونه کاربرد می توان به تجزیه و تحلیل یک ویدیوی بلادرنگ در سیستم های نظارت تصویری کنترل ترافیک و یا وسایل

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

نقلیه خودران، استخراج ویژگی از تصاویر جهت شناسایی نواحی و اشیاء، شناسایی کاراکترهای دست نویس، نظارت بر مراقبت های بهداشتی و به حداقل رساندن مصرف انرژی با استفاده از منابع تجدیدپذیر در خانه و شهر هوشمند اشاره نمود.

گره های محاسباتی تعبیه شده، به سرعت در حال گسترش در همه جنبه های زندگی بشر امروزی هستند و کاربردهای مفیدی در زمینه هایی مانند سیستم های پوشیدنی برای نظارت بر سلامت، سیستم های بی سیم برای نظارت نظامی، سیستم های شبکه در اینترنت اشیا، لوازم هوشمند برای اتوماسیون خانگی و سیستم های ترمز ضد قفل در خودروها دارند [۱۰۲]. روند تحقیقاتی اخیر در فناوری های محاسباتی، نیاز به پیاده سازی روش های یادگیری ماشین در گره های محاسباتی تعبیه شده برای کاربردهای متنوع را نشان می دهد. پیشرفت های اخیر، کاربرد مدل های یادگیری ماشین را در زمینه های کاربردی مانند بینایی کامپیوتر [۳-۷]، تشخیص گفتار [۹۸]، ترجمه و پردازش زبان طبیعی [۱۱،۱۰]، رباتیک و مراقبت های بهداشتی [۱۲] نشان می دهد. روش های یادگیری ماشین مانند بردار ماشین پشتیبان (SVM) برای طبقه بندی ویژگی ها [۱۳]، شبکه های عصبی کانولوشنی (CNN) برای تشخیص نفوذ [۱۴]، و نیز تکنیک های یادگیری عمیق، به منابع محاسباتی و حافظه بالایی برای آموزش و استنتاج موثر نیاز دارند [۱۵-۱۸]. واحدهای پردازشی همه منظوره، حتی با اصلاح معماری آنها در طول سالها، از جمله خط لوله، سلسله مراتب حافظه پنهان عمیق، پیشرفت های چند هسته ای و غیره، نمی توانند نیاز محاسباتی بالای مدل های یادگیری را برآورده کنند. با این حال، واحدهای پردازش گرافیکی (GPU)، به دلیل عملیات ممیز شناور و پردازش موازی در سطح نخ، برای آموزش مدل های یادگیری عمیق مناسب تر هستند [۱۹]. تحقیقات گسترده ای برای توسعه واحدهای شتاب دهنده سخت افزاری مناسب با استفاده از ASICs، GPUs، FPGAs و TPUs [۲۰-۲۶] برای ایجاد سیستم های ناهمگن و گاه "توزیع شده برای پاسخگویی به تقاضای توان محاسباتی بالای مدل های یادگیری در حال انجام است. در هر دو سطح الگوریتم و سخت افزار، تکنیک های بهینه سازی برای پیاده سازی الگوریتم های یادگیری ماشین کلاسیک و الگوریتم های یادگیری عمیق در حال بررسی هستند تا امکان اجرای کارآمد مدل های یادگیری ماشین در تجهیزات سیار و سیستم های تعبیه شده فراهم شود [۲۷-۲۹].

سرجیو و همکاران [۲۴] یک بررسی جامع در خصوص پیاده سازی الگوریتم های یادگیری ماشین در سیستم های تعبیه شده و سیار انجام داده اند و مفاهیم و تکنیک های یادگیری ماشین را برای بهینه سازی و ارائه در حوزه های کاربردی مختلف بررسی کرده اند. قابل توجه است که چندین تحقیق برای دستیابی به این امر انجام شده است. برای مثال مراجع [۳۰،۳۱] مفاهیم، مدل ها و بهینه سازی های یادگیری عمیق را بررسی می کنند. در این تحقیق ها، توجه کمی به طراحی معماری سخت افزار شده است، که یک نگرانی کلیدی در توسعه سیستم های یادگیری ماشین کارآمد است. پوجا [۳۲] روند اخیر در طراحی معماری سخت افزار را برای برنامه های کاربردی یادگیری ماشین، با استفاده از واحد پردازش تنسور به عنوان مطالعه موردی بررسی می کند. با این حال، این تحقیق معماری های مختلف شبکه های عصبی عمیق را مورد بررسی قرار نداده است و فقط برخی از تکنیک های بهینه سازی یادگیری عمیق را بررسی کرده است. جیاسی و ژوکان [۳۳]، مفاهیم یادگیری عمیق را بررسی کردند، استنتاج در گره های محاسباتی را محدود کردند اما معماری های تعبیه شده مختلف را برای اطلاع از اینکه کدام معماری یا بهینه سازی برای مدل های مختلف شبکه های عصبی عمیق مناسب است، مقایسه نکرده اند و فقط یک مدل یادگیری عمیق را بررسی کرده و دیگر مدل های یادگیری عمیق (CNN، RNN) را که مورد توجه قرار گرفته اند، تحقیق نکرده اند.

۳. تکنیک های یادگیری ماشین تعبیه شده

یادگیری ماشین شاخه ای از هوش مصنوعی است که تکنیک هایی را توصیف می کند که از طریق آن سیستم ها از داده های موجود یاد می گیرند و هوشمندانه تصمیم می گیرند. تکنیک های یادگیری ماشین را می توان در سه گروه عمده طبقه بندی کرد که عبارتند از یادگیری نظارت شده، یادگیری بدون نظارت، و یادگیری تقویتی. در یادگیری نظارت شده، داده های برچسب گذاری شده را می توان آموخت در حالی که در یادگیری بدون نظارت، الگوهای پنهان را می توان از داده های بدون برچسب کشف کرد و در یادگیری تقویتی، یک سیستم ممکن است از محیط اطراف خود از طریق روش آزمون و خطا یاد بگیرد [۳۴-۳۶]. فرآیند یادگیری به عنوان مرحله آموزش مدل نامیده می شود و اغلب با استفاده از معماری های کامپیوتری با منابع محاسباتی بالا مانند پردازنده های گرافیکی متعدد انجام می شود. پس از یادگیری، مدل آموزش دیده برای تصمیم گیری هوشمندانه در مورد داده های جدید استفاده می شود. از این فرآیند به

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

عنوان مرحله استنتاج پیاده سازی یاد می شود. این استنتاج اغلب در دستگاه های کاربر با منابع محاسباتی محدود مانند تجهیزات اینترنت اشیا و دستگاه های تلفن همراه انجام می شود.

در یادگیری نظارت شده، مسئله طبقه بندی و رگرسیون اغلب با الگوریتم هایی مانند ماشین بردار پشتیبان (SVM)، شبکه های عصبی مصنوعی (ANN) و رگرسیون خطی به دست می آید. با استفاده از الگوریتم هایی مانند k-means می توان از یادگیری بدون نظارت برای مسائل خوشه بندی و پیش بینی استفاده کرد. اکثر الگوریتم های یادگیری ماشین که بر روی تجهیزات لبه پیاده سازی می شوند، در حال حاضر از استنتاج (فرآیند حل مستقیم مسائل یادگیری ماشین با شبکه های عصبی از قبل آموزش دیده شده) به جای آموزش (فرآیند به حداقل رساندن خطا به عنوان تابعی از پارامترهای شبکه عصبی، با توجه به مسئله یادگیری ماشین داده شده) استفاده می کنند. یکی از دلایل ذکر شده پهنای باند و هزینه های تأخیر بالا است که در تبادل داده ها و بروزرسانی های شبکه در تجهیزات متعدد لبه وجود دارد (آموزش مدل متمرکز ممکن است کارآمدتر باشد زیرا شبکه های بروز شده مستقیماً به تجهیزات لبه منتقل می شوند). تجهیزات لبه فاقد توان محاسباتی و ظرفیت ذخیره سازی داده مورد نیاز برای مسائل پیچیده هستند. چالش دیگر در طراحی گره های لبه، هزینه های مرتبط با انرژی و سخت افزار است.

اخیراً، تکنیک های یادگیری ماشین کاربردهای مفیدی در زمینه های تحقیقاتی مختلف و به ویژه در سیستم های محاسباتی تعبیه شده پیدا کرده اند. بررسی ها نشان می دهد [۳۷] که از بین تمامی تکنیک های یادگیری ماشین موجود، SVM، GMM، DNN، k-NN، HMM، درخت های تصمیم گیری، رگرسیون لجستیک، k-means و Bayes ساده تکنیک های رایجی هستند که برای برنامه های کاربردی تلفن همراه به کار می روند. Bayes ساده و درخت تصمیم از نظر هزینه های محاسباتی و حافظه پیچیدگی کمی دارند و بنابراین به بهینه سازی های نوآورانه نیاز ندارند. الگوریتم های رگرسیون لجستیک از نظر محاسباتی کم هزینه تر از Bayes و درخت های تصمیم ساده هستند، به این معنی که پیچیدگی کمتری دارند [۳۸]. HMM، k-NN، SVM، GMM، و DNN به هر حال از نظر محاسباتی و حافظه، فشرده هستند و از این رو، برای فشرده سازی کارآمد در محیط های با منابع محدود، به تکنیک های بهینه سازی جدید نیاز دارند لذا این الگوریتم ها ممکن است به طور موثر در محیط های محدود به منابع پیاده سازی شوند.

۴. یادگیری ماشین و محدودیت منابع در گره های لبه

سیستم های محاسباتی تعبیه شده معمولاً از نظر توان محاسباتی و حافظه مورد نیاز محدود هستند. علاوه بر این، توان بسیار کم مصرف کنند و محدودیت های زمان واقعی را برآورده کنند. بنابراین، برای اینکه این مدل های یادگیری ماشین فشرده محاسباتی به طور موثر در فضای سیستم های تعبیه شده اجرا شوند، بهینه سازی های مناسب هم در معماری سخت افزار و هم در سطوح الگوریتم مورد نیاز است. در ادامه، روش های بهینه سازی را برای مقابله با تنگناها از نظر توان مصرفی، حافظه مصرفی و میزان تأخیر بررسی می کنیم.

تکنیک های یادگیری ماشین در حال حاضر محیط های با منابع محدود مانند دستگاه های تلفن همراه، دستگاه های تعبیه شده و سایر دستگاه های اینترنت اشیا را هدف قرار داده اند. لذا مروری بر پیشینه محیط های مختلف با محدودیت منابع مانند واحدهای میکروکنترلر (MCU) و دستگاه های تلفن همراه ارائه می کنیم. همچنین گزینه واحدهای شتاب افزار مورد استفاده برای سرعت بخشیدن به اجرای این الگوریتم ها در محیط های با منابع محدود را مورد بحث قرار می دهیم. بطور کلی میکروکنترلرها در سخت افزار، برای پیاده سازی سیستم های تعبیه شده متنوع و سایر برنامه های کاربردی اینترنت اشیا قرار دارند [۳۹]. یک میکروکنترلر شامل یک ریزپردازنده، حافظه، پورت های ورودی/خروجی و سایر تجهیزات جانبی است که همگی در یک تراشه ادغام شده اند. در هسته پردازنده میکروکنترلرها، پردازنده های همه منظوره برای محاسبات قرار دارند. می توانیم محدودیت منابع اکثر میکروکنترلرها را از نظر توان پردازشی موجود و حافظه روی تراشه مشاهده کنیم. این محدودیت منابع یک اشکال اساسی در پیاده سازی مدل های یادگیری ماشین است لذا تکنیک های فشرده سازی را بررسی می کنیم تا در حافظه موجود میکروکنترلر قرار گرفته تا محاسبات به طور کارآمد انجام شود.

تکنیک های یادگیری ماشین به تدریج در دستگاه های تلفن همراه برای کاربردهایی مانند تشخیص گفتار، بینایی رایانه، و غیره نفوذ می کنند. دستگاه های تلفن همراه ممکن است به دلیل منابع محاسباتی و حافظه محدود، تحت سیستم های محدود به منابع طبقه بندی شوند. از این رو، برای اجرای موفقیت آمیز الگوریتم های یادگیری ماشین در این دستگاه ها، بهینه سازی های مناسب باید انجام شود. در [۴۰] یک شتاب دهنده نرم افزاری برای تسریع در اجرای مدل های یادگیری در دستگاه های تلفن همراه توسعه داده شده است.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

استنباط یادگیری ماشین در لبه به ویژه در میکروکنترلرهای بسیار کم توان در حال افزایش علاقه در بین جامعه الگوریتمهای یادگیری ماشین است. این علاقه به ایجاد یک پلتفرم مناسب می‌پردازد که در آن مدل‌های یادگیری ماشین ممکن است به طور موثر در دستگاه‌های IoT اجرا شوند. بنابراین، این یک حوزه تحقیقاتی رو به رشد در یادگیری ماشین تعبیه شده شده به نام TinyML باز کرده است. TinyML یک تکنیک یادگیری ماشین است که یادگیری ماشین فشرده و بهینه شده را برای سازگاری با میکروکنترلرهای بسیار کم مصرف یکپارچه می‌کند و اساساً با یادگیری ماشین ابری که در آن مدل‌های فشرده محاسباتی با استفاده از رایانه‌های پیشرفته در مراکز داده بزرگ پیاده‌سازی می‌شوند. TinyML پلتفرمی ایجاد می‌کند که به موجب آن مدل‌های یادگیری ماشین به دستگاه‌های کاربر منتقل می‌شوند تا تجربه کاربری خوب را برای برنامه‌های مختلف ارائه دهند و دارای مزایایی مانند بهره‌وری انرژی، کاهش هزینه‌ها، امنیت داده‌ها، تأخیر کم و غیره است که نگرانی‌های اصلی در ابر معاصر است. پلتفرم‌های مختلفی برای انتقال آسان الگوریتم‌های یادگیری ماشین به محیط‌های با محدودیت منابع توسعه یافته‌اند که معمولاً برای انتقال مدل‌های یادگیری ماشین به دستگاه‌های مختلف با منابع محدود سازگار استفاده می‌شوند.

۵. یادگیری ماشین و تشخیص ناهنجاری

به طور کلی، تشخیص ناهنجاری نقش مهمی در سیستم‌های نرم‌افزاری توزیع شده ایفا می‌کند. می‌تواند ارتباطات پیرامون رفتار سیستم را بهبود بخشد، تجزیه و تحلیل علت ریشه‌ای را بهبود بخشد و تهدیدات را برای اکوسیستم نرم‌افزار کاهش دهد. تشخیص ناهنجاری سنتی دستی است. با این حال، تکنیک‌های یادگیری ماشین موفقیت‌آمیز سازهای ناهنجاری را بهبود می‌بخشد. تشخیص ناهنجاری هر فرآیندی است که نقاط نامرتب یک مجموعه داده را پیدا کند. این بدان معنی است که مواردی را که به مجموعه داده مرجع تعلق ندارند شناسایی می‌کند. این ناهنجاری‌ها ممکن است به ترافیک غیرعادی شبکه اشاره کنند. در دنیای امروزی سیستم‌های توزیع شده، مدیریت و نظارت بر عملکرد سیستم یک وظیفه اساسی برای دستیابی است. با وجود هزاران مورد برای نظارت، تشخیص ناهنجاری می‌تواند به نشان دادن محل وقوع خطا کمک کند و به سرعت پشتیبانی فنی را در مورد این مشکل دریافت کند. بنابراین، یادگیری ماشین با هدف مهندسی برای ایجاد یک سیستم تشخیص ناهنجاری که بهتر کار می‌کند، مجموعه داده‌های بزرگ را مدیریت می‌کند، تطبیق می‌دهد و به سرعت عمل می‌کند، مناسب است. استفاده از یادگیری ماشین برای تشخیص ناهنجاری مستلزم درک خوب مسئله است. تشخیص ناهنجاری از مقادیر زیادی داده سود می‌برد زیرا فرض بر این است که ناهنجاری‌ها نادر هستند. در این مقاله داده‌های آموزشی با «عادی» و «غیرعادی» برچسب‌گذاری شده‌اند. در یادگیری ماشین نظارت شده یک مجموعه داده به طور منظم با نقاط داده مشروح با برچسب آماده شده است. در این حالت، تمام نقاط ناهنجار از قبل مشخص شده‌اند. در سیستم‌های اینترنت اشیا، تشخیص ناهنجاری به عنوان تشخیص نفوذ شناخته می‌شود. در بیشتر موارد، نفوذ منجر به از بین رفتن محرمانه بودن و یکپارچگی، از کارافتادگی و یا استفاده غیرمجاز از منابع می‌شود. برخی از نمونه‌های نفوذ رایج به شرح زیر است:

- تغییرات غیرمجاز در فایل‌های سیستم
- دسترسی غیرمجاز به داده‌ها و فایل‌های کاربر یا تغییر آنها
- تغییرات جداول یا سایر اطلاعات سیستم (شامل اطلاعات شبکه)
- استفاده غیرمجاز از منابع محاسباتی (ایجاد حساب‌های کاربری غیرمجاز)

به طور کلی، راه حل‌های پیشرفته بسیاری برای شناسایی حملات سایبری اینترنت اشیا با استفاده از رویکردهای هوش مصنوعی وجود دارد. اخیراً رویکردهای یادگیری ماشین مختلفی برای توسعه این رویکردها برای دستگاه‌های اینترنت اشیا استفاده شده است. رفتار ترافیک عادی و ترافیک غیرعادی را می‌توان با دقت تشخیص نسبتاً بالا و نرخ مثبت کاذب پایین شناسایی کرد، بنابراین، امنیت داده‌های محرمانه و دستگاه‌های اینترنت اشیا را به حداکثر می‌رساند. به عنوان مثال، یک رویکرد جدید مبتنی بر ناهنجاری برای شبکه‌های اینترنت اشیا با یک موتور انتخاب ویژگی ترکیبی اجرا می‌شود که فقط مرتبط‌ترین ویژگی‌ها را انتخاب می‌کند و الگوریتم جنگل تصادفی هر ترافیک را به عنوان عادی یا غیرعادی طبقه‌بندی می‌کند. در این مقاله با استفاده از تکنیک‌های یادگیری ماشین، کارایی و دقت یک سیستم تشخیص نفوذ را بررسی می‌کنیم. هدف استفاده از مدل‌های طبقه‌بندی مختلف است که رفتارهای عادی و غیرعادی را تشخیص می‌دهد. مجموعه داده‌ای را انتخاب کرده و پیش‌پردازش مورد نیاز برای سازماندهی مجموعه داده را با انتخاب مهم‌ترین ویژگی‌ها و

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

آماده سازی آن برای ساخت مدل اعمال می کنیم. به دنبال این فرآیندها، الگوریتمهای آموزشی مختلفی را اعمال می کنیم و بهترین طبقه بندی کننده یادگیری ماشین را ارزیابی می کنیم.

۱.۵. مجموعه داده

این بخش پیاده سازی مدل یادگیری ماشین را برای تشخیص ناهنجاری در حوزه اینترنت اشیا مورد بحث قرار می دهد. اسکریپت به زبان پایتون با استفاده از نوت بوک Google Collab نوشته شده است. کتابخانه یادگیری ماشین مورد استفاده Scikit-Learn است. این کتابخانه به طور گسترده در تمام مراحل اجرا برای طبقه بندی، تجزیه و تحلیل پیش بینی کننده و وظایف یادگیری ماشین استفاده می شود. تصمیم گرفتیم مدل طبقه بندی باینری را اعمال کنیم. طبقه بندی باینری به پیش بینی یکی از دو کلاس اشاره دارد. کلاس صفر نشان می دهد که رفتار عادی است در حالی که کلاس یک نشان می دهد که رفتار غیرعادی است. مجموعه داده KDD [۴۱] برای ارزیابی تشخیص نفوذ استفاده می شود که شامل طیف گسترده ای از نفوذهای شبیه سازی شده در یک محیط شبکه است. ابعاد مجموعه داده شامل ۴۹۴۰۲۱ ردیف \times ۴۲ ستون است که بر روی آن پیش پردازش به جهت پیاده سازی بر روی تجهیزات لبه اینترنت اشیا انجام می دهیم. پیش پردازش داده ها یک مرحله ضروری در یادگیری ماشین است زیرا کیفیت داده ها و اطلاعات مفیدی که می توان از آن به دست آورد مستقیماً بر توانایی مدل برای یادگیری تأثیر می گذارد. بنابراین، بسیار مهم است که داده ها را قبل از وارد کردن به مدل، پیش پردازش کنیم. ستون برجسب ها دارای ۲۳ نوع است، بنابراین اولین تغییری که انجام می دهیم این است که انواع آن را به '۰' (رفتار عادی) و '۱' (رفتار غیرعادی) تبدیل می کنیم. از آنجایی که هدف اعمال یک طبقه بندی باینری است، باید دو برجسب کلاس را به عنوان ۰ یا ۱ اختصاص دهیم. به جهت سادگی تصمیم گرفتیم یک طبقه بندی باینری اعمال کنیم و نه یک طبقه بندی چند کلاسه. با داشتن مقادیر باینری در ستون برجسب، مدل آموزش دیده ۰ یا ۱ را پیش بینی می کند. پس از بررسی کل مجموعه داده، ویژگیهای طبقه بندی را تجزیه و تحلیل می کنیم. بسیاری از الگوریتمهای یادگیری ماشین انتظار داده های ورودی عددی را دارند زیرا نمی توانند مستقیماً روی داده های برجسب کار کنند. لذا باید داده های دسته بندی خود را به شکل عددی تبدیل کنیم. این رمزگذاری یک متغیر باینری جدید برای هر عدد صحیح منحصر به فرد اضافه می کند. کارایی الگوریتم ها با متغیرهای ورودی بیش از حد، کاهش می یابد. بنابراین با افزایش ابعاد، تعداد نقاط داده مورد نیاز برای عملکرد خوب به طور تصاعدی افزایش می یابد. قدرت پیش بینی هر طبقه بندی کننده با افزایش تعداد ابعاد افزایش می یابد، اما پس از پیشی گرفتن از تعداد مشخصی از ابعاد، عملکرد بدتر می شود. بنابراین باید کاهش ابعاد را اعمال کنیم. این فرآیند به تکنیک هایی اشاره دارد که تعداد متغیرهای ورودی را در یک مجموعه داده کاهش می دهد. هنگامی که با داده های با ابعاد بالا سروکار داریم، اغلب مفید است که ابعاد را با نمایش داده ها به یک زیرفضای با ابعاد پایین تر که ماهیت داده ها را در بر می گیرد، کاهش دهیم. این تکنیک در یادگیری ماشین برای ساده سازی مجموعه داده های طبقه بندی برای تطبیق بهتر با یک مدل پیش بینی استفاده می شود. ویژگی ها را با استفاده از انتخاب ویژگی تک متغیره انتخاب می کنیم.

۲.۵. آموزش و ارزیابی مدل

در این مرحله الگوریتم یادگیری ماشین با تغذیه مجموعه داده ها آموزش داده می شود. مدل آموزشی شامل داده های خروجی نمونه و مجموعه های مربوطه از داده های ورودی است که بر خروجی تأثیر دارند. مدل آموزشی برای اجرای داده های ورودی از طریق الگوریتم به منظور همبستگی خروجی پردازش شده با خروجی نمونه استفاده می شود. آموزش مدل در زبان ماشین فرآیند تغذیه الگوریتم مورد نظر با داده ها برای کمک به شناسایی و یادگیری مقادیر خوب برای همه ویژگی های استفاده شده است. ۴ الگوریتم درخت تصمیم، k-نزدیکترین همسایه، رگرسیون لجستیک و جنگل تصادفی را انتخاب کرده ایم. درخت تصمیم از برخی توابع هزینه برای انتخاب بهترین طبقه بندی استفاده می کند. لذا سعی می کنیم بهترین ویژگی را پیدا کنیم که بهترین عملکرد را در طبقه بندی داده های آموزشی داشته باشد. این فرآیند تا رسیدن به یک گره برگ تکرار می شود و بنابراین به آن طبقه بندی باینری بازگشتی می گویند. مشهود است که در درخت تصمیم ریشه در بالا قرار دارد و این ریشه به چندین گره مختلف تقسیم می شود. هدف یادگیری ماشین کاهش عدم قطعیت در مجموعه داده است، بنابراین مفاهیمی مانند آنتروپی و شاخص جینی را استفاده می کنیم. ایده اصلی درخت تصمیم، شناسایی ویژگی هایی است که حاوی بیشترین اطلاعات برای ویژگی هدف هستند و سپس مجموعه داده را در امتداد مقادیر ویژگی ها به گونه ای

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

تفکیک می کند که خروجی ویژگی هدف تا حد امکان خالص باشد. حرکت به سمت پایین منجر به کاهش سطح عدم قطعیت می شود و طبقه بندی بهتری را در هر گره انجام می دهد. آنتروپی عدم قطعیت را در مجموعه داده تعریف می کند. معادله آنتروپی در طبقه بندی به صورت زیر است:

$$Entropy = - \sum_{i=1}^n p_i * \log_2(p_i) \quad (1)$$

آنتروپی اساساً ناخالصی یک گره را اندازه گیری می کند. ناخالصی درجه تصادفی است که نشان می دهد داده ها چقدر تصادفی هستند. برای مثال، آنتروپی در یک موقعیت خاص، بدون دانستن رفتار آنتروپی در گره والد محاسبه می شود. آنتروپی نقش مهمی در محاسبه بهره اطلاعات ایفا می کند. اطلاعات بدست آمده برای تعیین کمیت اینکه کدام ویژگی حداکثر اطلاعات را در مورد طبقه بندی بر اساس مفهوم آنتروپی ارائه می دهد، اعمال می شود. این کار با محاسبه عدم قطعیت، بی نظمی یا ناخالصی، با هدف کاهش مقدار آنتروپی از بالا (گره ریشه) به پایین (گره های برگ) انجام می شود:

$$Gain(T, X) = Entropy(T) - Entropy(T, X) \quad (2)$$

شاخص جینی یا اندازه گیری ناخالصی جینی یکی از روش هایی است که در الگوریتم های درخت تصمیم برای تصمیم گیری تقسیم بهینه از یک گره ریشه و از تقسیم های بعدی استفاده می شود. کاهش شاخص جینی احتمال طبقه بندی اشتباه را کاهش می دهد:

$$GiniIndex = 1 - \sum_{i=1}^n (p_i)^2 \quad (3)$$

برای تنظیم مدل پارامترهای مهمی در درخت تصمیم وجود دارد که بر مدل از نظر بیش برازش و کم برازش تأثیر می گذارند.

۳.۵. نتایج و ارزیابی مدل

ابعاد نهایی مجموعه داده ۴۹۴۰۲۱ سطر و ۱۱ ستون است. مجموعه داده را به یک مجموعه آموزشی (۷۵٪) و یک مجموعه آزمایشی (۲۵٪) تفکیک کردیم. مجموعه آموزشی مجموعه ای است که به مدل تغذیه می شود در حالی که مجموعه تست مجموعه ای است که امکان ارزیابی عملکرد مدل را فراهم می کند. برای بررسی عملکرد مدل، معیارهای مختلف عملکرد مانند صحت، دقت، فراخوانی و امتیاز F1 را محاسبه می کنیم.

- **صحت**، تعداد نقاط داده به درستی پیش بینی شده از تمام نقاط داده است:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (4)$$

- **دقت**، نسبت نقاط داده مثبت پیش بینی شده صحیح به کل نقاط داده مثبت پیش بینی شده است:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

- **فراخوانی (حساسیت)**، نسبت نقاط داده مثبت پیش بینی شده صحیح به تمام نقاط داده در کلاس واقعی است:

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

- **امتیاز F1**، میانگین وزنی دقت و فراخوانی است:

$$Recall = \frac{2 * (Recall * Precision)}{(Recall + Precision)} \quad (7)$$

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

ماتریس سردرگمی یک ماتریس $N \times N$ است که برای ارزیابی عملکرد یک مدل طبقه‌بندی استفاده می‌شود، که در آن N تعداد کلاس‌های هدف است و این ماتریس، مقادیر هدف واقعی را با مقادیر پیش‌بینی شده توسط مدل مقایسه می‌کند (شکل ۱).

Actual Values

		Positive (1)	Negative (0)
		Predicted Values	Positive (1)
Negative (0)	FN		TN

	رگرسیون لجستیک			درخت تصمیم	
	عادی	غیرعادی		عادی	غیرعادی
عادی	۱۹۰۷۲	۳۵۰	عادی	۱۹۲۹۰	۱۳۲
غیرعادی	۱۰۴۶	۷۸۳۵۷	غیرعادی	۵۵۶	۷۸۸۴۷

	جنگل تصادفی			k-نزدیکترین همسایه	
	عادی	غیرعادی		عادی	غیرعادی
عادی	۱۹۲۹۲	۱۳۰	عادی	۱۹۲۱۲	۲۱۰
غیرعادی	۵۴۰	۷۸۸۶۳	غیرعادی	۶۲۲	۷۸۷۸۱

شکل ۱. جداول ماتریس سردرگمی الگوریتمهای یادگیری ماشین

در جدول ۱ قابل مشاهده است که درخت تصمیم به بالاترین دقت ۹۲.۱۷٪ دست یافته است. برای پیاده سازی آن بر روی دستگاه لبه باید مدلی را انتخاب کنیم و لازمه انتخاب مدل داشتن دقت بالا، پیچیدگی زمان اجرا سریع و میزان حافظه مصرفی است. لذا، درخت تصمیم انتخاب می‌شود. نمودار مقایسه ای میزان حافظه مصرفی مدل های آموزش داده شده در شکل ۲ نشان داده شده است. همچنین نمودارهای ارزیابی معیارهای صحت، دقت، فراخوانی و امتیاز F1 برای هر یک از مدل های آموزش داده شده بر روی داده های آزمایش در شکل ۳ نشان داده شده است. با بررسی پارامترهای معیارهای ارزیابی، زمان اجرای مدل و میزان حافظه مصرفی، درخت تصمیم برای پیاده سازی بر روی گره لبه انتخاب می‌شود.

جدول ۱. معیارهای ارزیابی الگوریتمهای یادگیری ماشین


اندازه حافظه	امتیاز F1	فراخوانی	دقت	صحت	الگوریتم یادگیری ماشین
۳۲۰KB	%۸۹.۷۲	%۸۹.۴۲	%۹۲.۱۷	%۸۹.۳۵	درخت تصمیم
۲.۳MB	%۸۹.۴۱	%۸۹.۲۲	%۹۱.۷۵	%۸۹.۱۱	k-نزدیکترین همسایه
۲۷KB	%۸۶.۳۴	%۸۶.۱۲	%۸۸.۶۷	%۸۵.۴۲	رگرسیون لجستیک
۱.۷MB	%۸۹.۳۱	%۸۹.۲۷	%۹۱.۴۳	%۸۹.۲۲	جنگل تصادفی

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senacnf.ir

اندازه حافظه



شکل ۲. نمودار مقایسه ای میزان حافظه مصرفی مدل های آموزش داده شده


صحت



دقت




فراخوانی



دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir



شکل ۳. نمودار ارزیابی معیارهای صحت، دقت، فراخوانی و امتیاز F1 مدل های آموزش داده شده بر روی داده های آزمایش

۶. نتیجه گیری

در این مقاله، تشخیص ناهنجاری را برای پیش بینی حملات سایبری برای اینترنت اشیا با استفاده از یادگیری ماشین مدل سازی کردیم. با توجه به توسعه سریع سیستمهای اینترنت اشیا در حوزه های مختلف، مقادیر زیادی داده به طور مداوم در حال تولید است که نیاز به تمرکز بیشتر بر حریم خصوصی و امنیت دارد. حملات در اینترنت اشیا شامل انواع مختلفی است. اگر این نوع حملات موفقیت آمیز باشد، عملکرد اینترنت اشیا می تواند از طرق مختلفی مانند ارائه اطلاعات نادرست به خطر بیفتد. امروزه رویکرد هوش مصنوعی مزایای بسیاری دارد که می توان آن را یکی از امیدوارکننده ترین روش ها دانست. بنابراین طبقه بندی باینری را مدل سازی کردیم که پیش بینی یکی از دو کلاس (رفتار عادی و رفتار غیرعادی) در مجموعه داده KDD انجام شد. الگوریتم های مختلف یادگیری ماشین مانند درخت تصمیم، K-نزدیک ترین همسایه، رگرسیون لجستیک و جنگل تصادفی مدل سازی شدند. درخت تصمیم را به عنوان بهترین مدل با عملکرد مناسب با توجه به مبادله بهینه بین دقت (۹۲.۱۷٪) و میزان حافظه مصرفی و همچنین پیچیدگی محاسباتی انتخاب نمودیم. با ارزیابی رفتار در یک سناریوی واقعی، بسط بیشتر به استقرار مدل یادگیری ماشین انتخاب شده در دستگاه لبه خواهد بود.

منابع

- Wayne, W. Praise of High-Performance Embedded Computing: Architectures, Applications, and Methodologies; Morgan Kaufmann Publishers: CA, USA, 2007.
- Haigh, K.Z.; Mackay, A.M.; Cook, M.R.; Lin, L.G. Machine Learning for Embedded Systems: A Case Study; BBN Technologies: MA, USA, 2015; Volume 8571, pp. 1–12.
- Krizhevsky, A.; Sutskever, I.; Hinton, G. ImageNet classification with deep convolutional neural networks Alex. Adv. Neural Inf. Process. Syst. 2012, 25, 1097–1105.
- Szegedy, C.; Liu, W.; Jia, P.Y.; Reed, S.S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. Going deeper with convolutions. In Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 2015; pp. 1–9.
- He, K.; Zhang, X.; Ren, S.; Sun, J. Deep residual learning for image recognition. In Proceedings of the IEEE Computer Society Conference Computer Vision Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016; pp. 770–778.
- Real, E.; Moore, S.; Selle, A.; Saxena, S.; Suematsu, Y.L.; Tan, J.; Le, Q.V.; Kurakin, A. Large-scale evolution of image classifiers. In Proceedings of the 34th International Conference Machine Learning ICML, Australia, 6–11 August 2017; pp. 4429–4446.
- Tan, M.; Le, Q.V. Efficient Net: Rethinking model scaling for convolutional neural networks. In Proceedings of the 36th International Conference Machine Learning ICML 2019, Long Beach, CA, USA, 10–15 June 2019; pp. 10691–10700.

دوازدهمین کنگره ملی سراسری فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

8. Hinton, G.; Deng, L.; Yu, D.; Dahl, G.E.; Mohamed, A.R.; Jaitly, N.; Senior, A.; Vanhoucke, V.; Nguyen, P.; Sainath, T.N.; et al. Deep neural networks for acoustic modeling in speech recognition. *IEEE Signal. Process. Mag.* 2012, 29, 82–97.
9. Chan, W.; Jaitly, N.; Le, Q.V.; Vinyals, O. Listen, attend and spell. In *Proceedings of the 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Shanghai, China, 20–25 March 2016.
10. Wu, Y.; Schuster, M.; Chen, Z.; Le, Q.V.; Norouzi, M.; Macherey, W.; Krikun, M.; Cao, Y.; Gao, Q.; Macherey, K.; et al. Google's neural machine translation system: Bridging the Gap between human and machine translation. *arXiv* 2016.
11. Collobert, R.; Weston, J.; Bottou, L.; Karlen, M.; Kavukcuoglu, K.; Kuksa, P. Natural language processing (almost) from scratch. *J. Mach. Learn. Res.* 2011, 12, 2493–2537.
12. Haj, R.B.; Orfanidis, C. A discreet wearable long-range emergency system based on embedded machine learning. In *Proceedings of the 2021 IEEE International Conference on Pervasive Computing and Communications Workshops*, Kassel, Germany, 22–26 March 2021.
13. Dean, J. The deep learning revolution and its implications for computer architecture and chip design. In *Proceedings of the 2020 IEEE International Solid-State Circuits Conference-(ISSCC)*, San Francisco, CA, USA, 16–20 February 2020; pp. 8–14.
14. Khan, M.A.; Kim, J. toward developing efficient Conv-AE-based intrusion detection system using heterogeneous dataset. *Electronics* 2020, 9, 1771.
15. Li, P.; Luo, Y.; Zhang, N.; Cao, Y. Hetero Spark: A heterogeneous CPU/GPU spark platform for machine learning algorithms. In *Proceedings of the 2015 IEEE International Conference Networking, Architecture Storage, NAS*, Boston, MA, USA, 6–7 August 2015; pp. 347–348.
16. Raparti, V.Y.; Pasricha, S. RAPID: Memory-aware NoC for latency optimized GPGPU architectures. *IEEE Trans. Multi-Scale Computer. Syst.* 2018, 4, 874–887.
17. Cheng, X.; Zhao, Y.; Robaei, M.; Jiang, B.; Zhao, H.; Fang, J. A low-cost and energy-efficient noc architecture for GPGPUs. *J. Nat. Gas Geosci.* 2019, 4, 1–28.
18. Zhang, L.; Cheng, X.; Zhao, H.; Mohanty, S.P.; Fang, J. Exploration of system configuration in effective training of CNNs on GPGPUs. In *Proceedings of the 2019 IEEE International Conference Consumer Electronics ICCE*, Las Vegas, NJ, USA, 11 January 2019; pp. 1–4.
19. Cui, X.; Liu, H.; Fan, M.; Ai, B.; Ma, D.; Yang, F. Seafloor habitat mapping using multibeam bathymetric and backscatter intensity multi-features SVM classification framework. *Appl.* 2020, 174, 107728.
20. Yu, Q.; Wang, C.; Ma, X.; Li, X.; Zhou, X. A deep learning prediction process accelerator-based FPGA. In *Proceedings of the 2015 IEEE/ACM 15th International Symposium Cluster Cloud, Grid Computer CC Grid 2015*, China, 4–7 May 2015; pp. 1159–1162.
21. Noronha, D.H.; Zhao, R.; Goeders, J.; Luk, W.; Wilton, S.J.E. On-chip FPGA debug instrumentation for machine learning applications. In *Proceedings of the 2019 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays*, Seaside, CA, USA, 24–26 February 2019.
22. Wang, C.; Gong, L.; Yu, Q.; Li, X.; Xie, Y.; Zhou, X. DLAU: A scalable deep learning accelerator unit on FPGA. *IEEE Trans. Computer. Des. Integrated. Circuits Syst.* 2016, 513–517.
23. Chang, A.X.M.; Martini, B.; Culurciello, E. Recurrent Neural Networks Hardware Implementation on FPGA.
24. Branco, S.; Ferreira, A.G.; Cabral, J. Machine learning in resource-scarce embedded systems, FPGAs, and end-devices: A survey. *Electronics* 2019, 8, 1289.
25. Zhang, C.; Li, P.; Sun, G.; Guan, Y.; Xiao, B.; Cong, J. Optimizing FPGA-based accelerator design for deep convolutional neural networks. In *Proceedings of the 2015 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays*, USA, 2015; pp. 161–170.

دوازدهمین کنگره ملی سراسری
فناوریهای نوین در حوزه توسعه پایدار ایران

12th National Congress of
the New Technologies in Sustainable Development of Iran

senaconf.ir

26. Neshatpour, K.; Mokrani, H.M.; Sasan, A.; Ghasemzadeh, H.; Rafatirad, S.; Homayoun, H. Architectural considerations for FPGA acceleration of machine learning applications in MapReduce. In Proceedings of the 18th International Conference on Embedded Computer Systems: Architectures, Modeling, and Simulation, Greece, 15–19 July 2018.
27. Iandola, F.N.; Han, S.; Moskewicz, M.W.; Ashraf, K.; Dally, W.J.; Keutzer, K. Squeeze Net: Alex Net-level Accuracy With 50 Fewer Parameters and <0.5 mb Model Size.
28. Deng, Y. Deep learning on mobile devices: A review. In Proceedings of the SPIE 10993, Mobile Multimedia/Image Processing, Security, and Applications 2019, 109930A, Baltimore, ML, USA, 14–18 April 2019.
29. Kim, D.; Ahn, J.; Yoo, S. A novel zero weight/activation-aware hardware architecture of convolutional neural network. In Proceedings of the 2017 Design, Automation and Test in Europe DATE 2017, Switzerland, 27–31 March 2017; pp. 1462–1467.
30. Lecun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature* 2015, 521, 436–444.
31. Schmidhuber, J. Deep learning in neural networks: Neural network. 2015, 61, 85–117.
32. Jawandhiya, P. Hardware design for machine learning. *Int. J. Artif. Intell. Appl.* 2018, 9, 1–6.
33. Chen, J.; Ran, X. Deep learning with edge computing: *Proc. IEEE* 2019, 107, 1655–1674.
34. Frank, M.; Drikakis, D.; Charissis, V. Machine-learning methods for computational science and engineering. *Computation* 2020, 8, 15.
35. Xiong, Z.; Zhang, Y.; Niyato, D.; Deng, R.; Wang, P.; Wang, L.C. Deep reinforcement learning for mobile 5G and beyond: Fundamentals, applications, and challenges. *IEEE Veh. Technol. Mag.* 2019, 14, 44–52.
36. Carbonell, J.G. Machine learning research. *ACM SIGART Bull.* 1981, 18, 9.
37. Jadhav, S.D.; Channe, H.P. Comparative STUDY of K-NN, naive bayes and decision tree classification techniques. *Int. J. Sci. Res.* 2016, 5, 1842–1845.
38. Logistic Regression as a Classifier. December 2020.
39. Lane, N.D.; Bhattacharya, S.; Georgiev, P.; Forlivesi, C.; Jiao, L.; Qendro, L.; Kawsar, F. DeepX: A Software accelerator for low-power deep learning inference on mobile devices. In Proceedings of the 2016 15th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN), Vienna, Austria, 11–14 April 2016.
40. Han, S.; Mao, H.; Dally, W.J. Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding. In Proceedings of the 4th International Conference on Learning Representations, San Juan, Puerto Rico, 2–4 May 2016; pp. 1–14.
41. «KDD Cup 1999 Data». In: The UCI KDD Archive (1999).