دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

اصالت سنجی اسناد الکترونیکی با استفاده از روش‌های پنهان نگاری و واترمارکینگ

پریسا دانشجو [۱]، مصطفی مظفری [۲]

دانشگاه آزاد اسلامی- واحد تهران غرب[۱]، Daneshjoo.p@wtiau.acir

دانشگاه آزاد واحد تهران غرب[۲]، m.mozafari@protonmail.com

خلاصه

همه سازمان‌ها باید سوابق تصمیمات و معاملات تجاری خود را برای پاسخگویی به خواسته‌های مشتریان یا ذی‌نفعان شرکت، نگه دارند. با توجه به افزایش روزافزون اسناد الکترونیکی و همچنین تبدیل اسناد کاغذی به الکترونیکی، استفاده از فن‌آوری اطلاعات و ارتباطات، نحوه انجام کار در سازمان‌ها را تغییر می‌دهد و منجر به وابستگی بسیار بیشتر به سوابق الکترونیکی می‌شود. مدیریت اسناد الکترونیکی به سازمان‌ها کمک می‌کند تا از اطلاعات به طور موثرتری بهره برداری و از نیازهای عملیاتی فوری برای اطلاعات تجاری پشتیبانی کنند. یک سیستم مدیریت سوابق الکترونیکی باید بتواند این سوابق را در طول چرخه حیات خود، از نظر ضبط, یکپارچگی، اصالت, امحا و در دسترس بودن، مدیریت کند. با این حال، یکی از مشکلات، اصالت سنجی و حفظ آثار معنوی فایل‌های الکترونیکی است. برای رفع چنین مشکلاتی می‌توانیم از روش‌های نوین در این زمینه استفاده کنیم که یکی از این روش‌ها، استفاده از پنهان‌نگاری و واترمارکینگ است. پنهان‌نگاری در دهه گذشته بسیار مورد استفاده قرار گرفته‌است. روش‌های پنهان‌نگاری و واترمارکینگ طراحی شده‌اند تا توالی‌های اطلاعات پنهان را در اشیاء الکترونیکی برای اهداف مختلف تعبیه کنند. این روش‌ها در حوزه‌های امنیتی و حفاظتی برای پنهان نگه‌داشتن پیام اصلی یا حفظ معنوی آثار به کار می‌روند. مقاله حاضر ابتدا به مطالعه مفاهیم EDMS پرداخته و **در مرحله بعد، تحقیقات فعلی در زمینه روش‌های جاسازی اطلاعات در اسناد الکترونیکی را مورد بررسی قرار داده‌است.**

کلمات کلیدی: سیستم مدیریت اسناد الکترونیکی، اسناد الکترونیکی، اصالت سنجی، پنهان نگاری، واترمارکینگ

۱ مقدمه

با اینکه سوابق کاغذی هنوز هم وجود دارند و برای آینده قابل پیش‌بینی تولید می‌شوند - و ابزارها و سیستم‌های مدیریت آنها به خوبی تثبیت شده‌اند-، نگرانی کلی در مورد توانایی سازمان‌ها برای مدیریت و حفظ آن دسته از سوابق الکترونیکی که برای پشتیبانی کسب و کار لازم است، همچنان وجود دارد. سازمان‌ها برای پشتیبانی از پرونده‌ها، ارائه خدمات و پاسخگویی و تعهدات سازمان نیازمند بایگانی هستند. مدیریت سوابق الکترونیکی از نیازهای اطلاعاتی میان مدت و بلند مدت کسب و کار پشتیبانی و حافظه شرکت را ایجاد و نگهداری می‌کند. ساختار بایگانی شرکتی را مدیریت می‌کند که سوابق در آن طبقه بندی می‌شوند. پس از طبقه‌بندی سوابق باید مشخص شود که چه مدت باید نگهداری شوند یا برخی از این سوابق به صورت دائمی در آرشیو(بایگانی) حفظ و در نهایت چگونه باید امحا شوند؟

اسناد الکترونیکی سازمان‌ها که در EDMS ایجاد می‌شوند برای تایید مالکیت اسناد در حال گردش خود و ارسال اسناد سازمانی به سازمان‌های دیگر و همچنین با هدف ارایه به محاکم قضایی در صورت هر گونه سرقت مالکیت معنوی یا اصالت سنجی اسناد نیازمند یک روش برای اصالت سنجی هستند.

با توجه به قوانین موجود، از اسناد الکترونیکی در آمریکا با عنوان «سوابق الکترونیک»، در قانون آنسیترال و ایران با عنوان «داده پیام» و در فرانسه با عنوان «سند الکترونیک» یاد می‌شود. اما نظر مشترک این است که، همگی کاربرد و جایگاه سند را مستقیماً یا به صورت معادل یا در حکم آن برای این نوع اسناد پذیرفته‌اند. شاید بتوان گفت روش فرانسویان با توجه به پیوند آن با قوانین کشور و نیز فرهنگ حقوقی آن، مدبرانه‌تر و کامل‌تر است.

قانون جرایم رایانه‌ای ایران، بدون این‌که تعریف خاصی برای محتوای حافظه رایانه در نظر بگیرد، در ماده ۵۰، این اسناد را قابل استناد خوانده است.

«اگر داده‌های رایانه‌ای به وسیله طرف دعوا یا شخص ثالثی که از دعوا آگاهی نداشته، ایجاد یا پردازش یا ذخیره یا منتقل شده و سیستم رایانه‌ای یا مخابراتی مربوطه به گونه ای عمل کند که به صحت و تمامیت، اعتبار و انکارناپذیری داده‌ها خدشه وارد نشده باشد، می‌توان به آنها استناد نمود.»

براین اساس، برای شناسایی جعلی بودن سند باید داده یا علائمی در اسناد -در سامانه‌های رایانه‌ای یا مخابراتی- وجود داشته باشد. از پنهان‌نگاری و واترمارکینگ برای مخفی کردن یک قطعه و یا برای اضافه کردن جزئیاتی به اسناد می‌توان استفاده کرد.

۲ سیستم مدیریت اسناد الکترونیکی(Electronic Document Management System)

بسیاری از سازمان‌های جهانی استراتژی(راهبرد) و عملیات خود را از طریق چهارچوب سیستم مدیریت یکپارچه (IMS) مبتنی بر ISO هماهنگ کرده‌اند که امکان ادغام سیستم‌های مدیریت کیفیت، محیط زیست، سلامت و ایمنی را فراهم می‌کند. در چنین شرایطی، داشتن یک سیستم مدیریت اسناد الکترونیکی قوی (EDMS) ضروری است، به ویژه در شرکت‌های جهانی که در آن حجم زیادی از اسناد تولید شده توسط فرایندها، از طریق فرهنگ‌های کاری مختلف جریان می‌یابد. سیستم‌های مدیریت یکپارچه (IMS) به عنوان یک رویکرد فرایندگرا برای حمایت از سازمان‌ها در ترکیب سیستم‌های مدیریت کیفیت، محیط زیست، سلامت و ایمنی در انطباق با استانداردهای ISO 9001، ISO 14001 و OHSAS 18001 توجه فزاینده ای را به خود جلب کرده‌اند.(Eriksson & Hansson, 2003; Rasmussen, 2007; Tambo, 2012; Oliveira, 2013).

در حوزه مدیریت اسناد، سیستم مدیریت اسناد الکترونیکی(EDMS) به عنوان مفهومی برای کاهش استفاده از کاغذ ایجاد شده‌است.(Agarkar, Borle, Deshmukh & Bhagat, 2012؛ Ralph, 1995). EDMS دارای ابزارهای ضروری برای شرکت‌ها به‌منظور مستندسازی فرایندهای تجاری و مدیریت جریان داخلی اطلاعات است. EDMS نقش‌های متعددی در ذخیره‌سازی، بایگانی، مدیریت، تایید و کنترل جریان اسناد IMS برای تسهیل گردش کار سازمانی دارد(Bae & Kim, 2002). استانداردهای فردی و همچنین پیاده‌سازی‌های شرکتی بر نقش حیاتی کنترل اسناد در IMS تأکید دارند(موئهلن، ۲۰۰۴).

اسناد مورد استفاده یا تولید شده توسط فرایندها باید برای کاهش عدم انطباق مربوط به سند، ارائه اطلاعات به روز، مدیریت «منبع واحد حقیقت» [۱] و اطمینان از اینکه فقط اسناد تایید شده از طریق سازمان مورد استفاده واقع شود، کنترل شوند. بنابراین، به منظور رعایت استانداردهای IMS، کارایی یک سیستم مدیریت اسناد مستقر در سازمان‌های مربوطه، بسیار حیاتی است.

۲-۱ نحوه اجرا EDMS

مدیریت الکترونیکی اسناد نتیجه اجرای فرایند یا پروژه‌های آرشیو الکترونیک یا بایگانی الکترونیکی و داده آمایی (ورود اطلاعات) مربوط به اسناد در نرم افزارهای مربوطه بوده و چندین سال است که توسط سازمان‌ها و موسسات مختلف درحال اجرا و بهره‌برداری است. مدیریت اسناد الکترونیکی حوزه‌ای پیچیده و بی‌نهایت گسترده است. این حوزه مدیریتی باید ضرورت‌هایی را برای هماهنگی بین اجزای تشکیل دهنده سامانه و کارکرد بهتر آن در نظر گیرد.

در دیدگاه مدیریت الکترونیکی اسناد، ابتدا می بایست مدارک و اسناد موجود در سازمان آرشیوی خود را شناسایی و نحوه مدیریت اسناد را بر اساس استانداردها تعریف کنیم. سیاست‌های سازمانی و اهمیت تاریخی و پیشینه هویتی اسناد موجود جزء دیگر تشکیل دهنده این نظام است. فرایند مدیریت بر اطلاعات و میزان اهمیت ذاتی اسناد یک سازمان را می‌توان نقطه آغازین سامانه مدیریت اسناد الکترونیکی در نظر گرفت. همچنین به منظور بالا بردن بازدهی و کارائی اطلاعات و اسناد تولید شده در گذشته، حال و آینده سازمان، آرشیو اسناد با به کارگیری استانداردها و سیاستگذاری‌های مناسب بسیار ضروری به نظر می‌رسد. مدیریت اسناد الکترونیکی را می‌توان یافتن راهی برای خلق، شناسایی، کسب، اشتراک و توزیع اسناد الکترونیکی به افراد نیازمند آن دانست. این خود، عاملی برای شرکت‌های نرم‌افزاری به منظور ورود به بازار و ارایه سیستم‌های EDMS است که می‌تواند آن‌ها را به سودآوری برساند، اما این عمل باید با دقت و در نظر گرفتن تمام جوانب انجام شود.

سیستم مدیریت اسناد الکترونیکی، نرم‌افزاری قدرتمند برای متمرکز سازی و مدیریت اسناد الکترونیک است. هدف سیستم مدیریت اسناد و آرشیو الکترونیک، ارائهٔ یک منبع واحد و ثابت از داده‌ها و اطلاعات حقیقی و صحیح است که می‌تواند کنترل نسخه‌های اسناد و انطباق را تسهیل کند و در نهایت منجر به کارایی و بازگشت سرمایه شود. امروزه نرم افزارهای مختلفی با عنوان «مدیریت اسناد الکترونیکی» به بازار عرضه شده است که برای کار در بایگانی‌های اسناد طراحی شده‌اند.

این سیستم با رعایت ملاحظات امنیتی و مجوزهای دسترسی، امکان دستیابی از راه دور به اسناد را در اختیار کاربران خود قرار داده و با ثبت تمامی وقایع رخداده در سیستم امکان ممیزی عملکرد کاربران را به مدیر سیستم می‌دهد.

1. Single Source of truth

۲-۲ مزایای EDMS

مزایای قابل توجه EDMS شامل کاهش هزینه‌ها، بهبود امنیت، ذخیره سازی اسناد الکترونیکی به صورت متمرکز و کارایی کلی کسب و کار است. پیاده‌سازی این سیستم به معنای صرفه‌جویی زیاد در زمان رویه‌های روزمره مانند چاپ یا بایگانی اسناد و همچنین جست‌وجوی یک سند کاغذی است. برچسب‌ها، کلمات کلیدی و ابرداده‌ها به کاربران EDMS اجازه می‌دهند یک سند را در عرض ۱-۲ دقیقه پیدا کنند. به طور کلی، سیستم‌های مدیریت اسناد برای افزایش ذخیره‌سازی داده‌ها و بهبود تجربه کلی طراحی شده‌اند و دیگر مزایای آنها به شرح ذیل است :

- پشتیبان‌گیری یا بازیابی سریع و آسان
- کنترل نسخه
- بهبود در گردش کار
- کاهش زمان
- همکاری بهتر بین تیم
- فضای ذخیره‌سازی کمتر
- انعطاف‌پذیری
- ادغام با سیستم‌های اتوماسیون اداری

۲-۳ مشکلات EDMS

فرایند انتقال از اسناد کاغذی به DMS یا حتی مهاجرت از یک DMS به DMS دیگر، ممکن است چالشی به نظر برسد. آشکارترین مشکل، آموزش مجدد کارکنان و دادن زمان به آنها برای تطبیق با سیستم، عملکردها و رابط کاربری آن است. برای مدیران اجرایی غیرفنی و شرکت‌هایی که در بخش فن‌آوری اطلاعات درگیر نیستند، ممکن است کار با پشتیبانی ۲۴ ساعته و به‌روزرسانی‌های دائمی که همه سیستم‌های مدیریت اسناد نیاز دارند، سخت باشد. با این حال، اگر راه حلی را خریداری کنید، ارائه دهنده خدمات از آن مراقبت خواهد کرد، و اگر یک DMS سفارشی دارید، همیشه می‌توانید یک متخصص پشتیبانی فنی استخدام کنید (یا او را ساعتی به کار بگیرید).

این سیستم‌ها باید به مرور و با پیاده‌سازی امکانات آنها، از قبیل جریان گردش سندهای قابل طراحی، آرشیو الکترونیکی، به‌روز نگهداشتن اسناد و امکان گزارش‌گیری از محتویات آنها و منطبق بر ساز و کارهای اداری سازمان‌ها وارد بازار شوند تا به این ترتیب، بتوانند با گذشت زمان تحولی در فرهنگ اداری سازمان‌ها به‌وجود آورند و راه را برای تولید و راه‌اندازی سیستم‌های مدیریت اسناد و محتوا در آینده هموار کنند. در غیر این صورت، راه‌اندازی این سیستم‌ها در سازمان‌ها با صرف وقت و هزینه ای بسیار بالا همراه خواهد بود.

Doc Flow ۲

۳ واترمارکینگ

واترمارکینگ نوعی تکنیک علامت‌گذاری الکترونیکی است که به‌طورعمده برای شناسایی مالکیت و همچنین برای احراز هویت یا یکپارچگی استفاده می‌شود. در ابتدا به صورت الکترونیکی توسط اندرو تیرکل و همکاران در سال ۱۹۹۲ ابداع شد. عملکرد یک واترمارک الکترونیکی مشابه عملکرد امضای الکترونیکی است. واترمارک الکترونیکی برچسبی است که به عنوان مثال امکان شناسایی نویسنده یک شیء الکترونیکی یا تأیید صحت و یکپارچگی این شیء را فراهم می‌کند. واترمارک‌های الکترونیکی اغلب برای محافظت از نویسندگی فایل‌های چند رسانه‌ای[۳]، کنترل یکپارچگی داده‌ها و تأیید اعتبار منابع این داده‌ها استفاده می‌شود. در حال حاضر، استفاده از چنین روش‌هایی برای محافظت از داده‌ها، به نوع متفاوت مرتبط می‌شود.

واترمارکینگ می‌تواند برای مثال متن، لوگو، کد هش یا اطلاعات دیگر باشد. در بیشتر موارد از روش‌های واترمارک الکترونیکی برای محافظت از خود تصویر روی جلد[۴] استفاده می‌شود، نه از اطلاعات جاسازی شده، زیرا اطلاعات جاسازی شده یک پیام مخفی نیست، بلکه برای شناسایی صاحب تصویر یا کنترل یکپارچگی تصویر استفاده می‌شود. استخراج چنین اطلاعاتی در صورتی اتفاق می‌افتد که تأیید نویسندگی[۵] یک تصویر، تأیید صحت آن، ارزیابی وجود هرگونه تحریف تصادفی یا عمدی ضروری باشد. گسترده‌ترین واترمارک‌های الکترونیکی در زمینه حفاظت از حق چاپ برای محتوای الکترونیکی، به ویژه، تصاویر الکترونیکی استفاده می‌شود. اما روش‌های واترمارک الکترونیکی را می‌توان در زمینه‌های دیگر نیز مورد استفاده قرار داد، به عنوان مثال، برای جاسازی داده‌های بیمار در تصاویر پزشکی. بسیاری از الگوریتم‌های جاسازی نه فقط به تشخیص تغییرات در تصویر می‌پردازند، بلکه به محلی‌سازی و بازیابی ناحیه آسیب‌دیده نیز اجازه می‌دهند.

نامحسوس بودن و استحکام، دو شرط اساسی برای تکنیک‌های واترمارک هستند. واترمارکینگ می‌تواند شکننده، قوی یا نیمه شکننده باشد. واترمارک شکننده نمی‌تواند پس از کوچکترین تغییر در واترمارک، آن را استخراج کند. در نتیجه، آنها معمولاً فقط برای اهداف احراز هویت قابل استفاده هستند. از سوی دیگر، تکنیک واترمارک قوی قادر است واترمارک را حتی پس از ایجاد تغییراتی در آن، با دقت استخراج کند. بنابراین، این تکنیک‌ها معمولا برای حفاظت از حق چاپ استفاده می‌شود. در نهایت، تکنیک واترمارک نیمه شکننده از واترمارک‌های قوی و شکننده بهره می‌برد. این تکنیک‌ها در درجه نخست هم برای یکپارچگی و هم برای احراز هویت استفاده می‌شوند. علاوه بر این، تکنیک‌های واترمارک نیمه شکننده قادر به تشخیص و بازیابی مناطق دستکاری شده[۶] هستند.

Authorship of multimedia files۳

Cover ۴

Authorship۵

Tempered۶

شکل ۱ و ۲ روش درج و استخراج واترمارک را به صورت تصویری نشان می‌دهد.

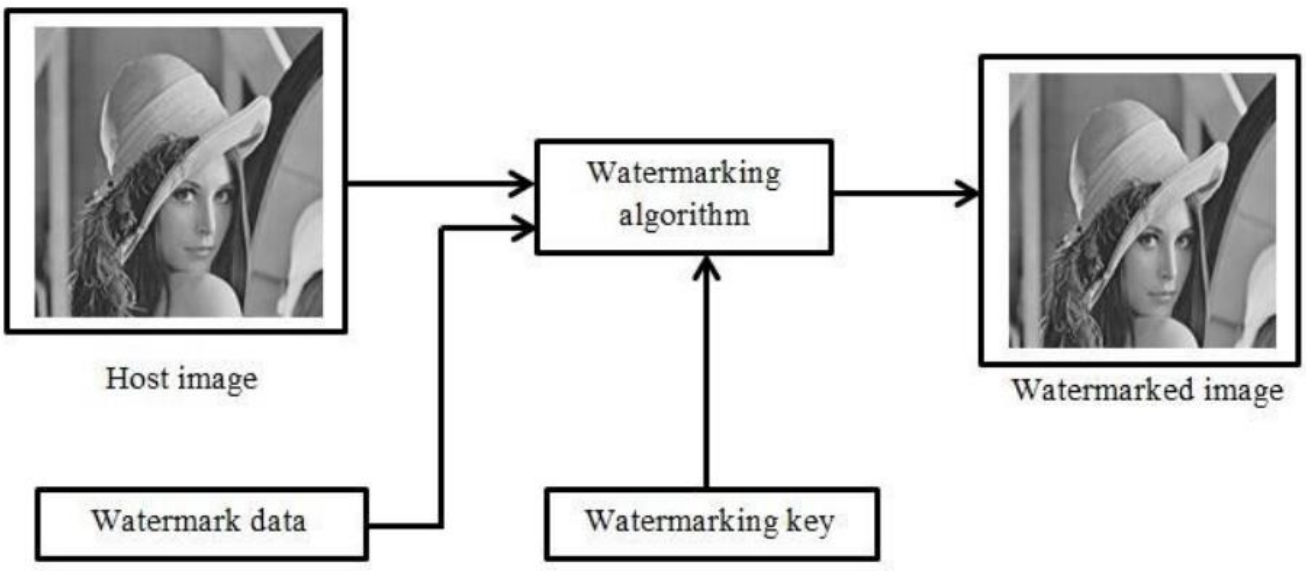

شکل ۱ نحوه درج کردن واترمارک

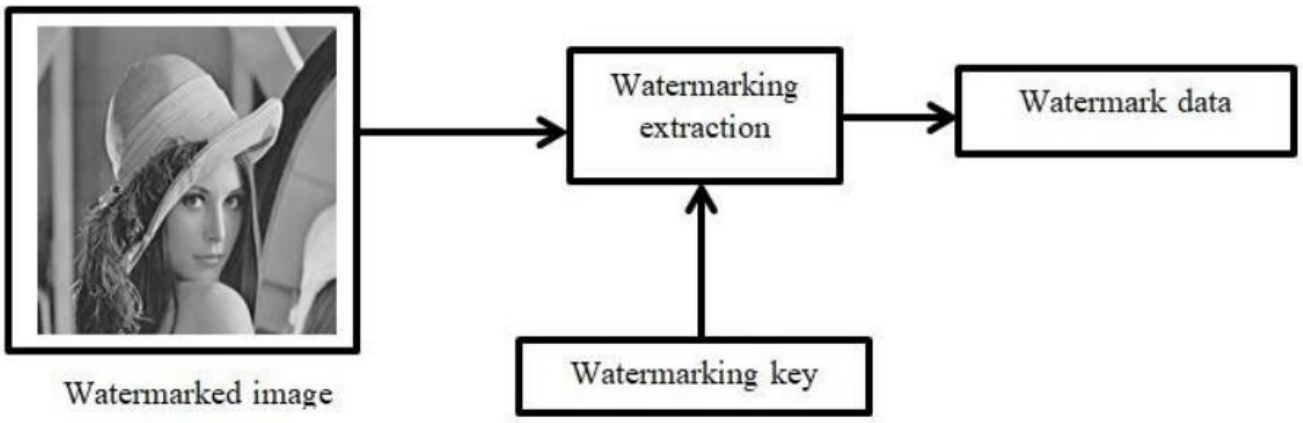

شکل ۲ نحوه استخراج واترمارک

مقالات [۱]، [۲] نمونه‌هایی از مقالات مروری در مورد تکنیک‌های واترمارک الکترونیکی هستند.

۴ پنهان‌نگاری

پنهان‌نگاری، هنر ارتباط با اطلاعات نامرئی است و نقشی مهم در امنیت اطلاعات ایفا می‌کند. اصطلاح پنهان‌نگاری یک کلمه یونانی و در لغت به معنای «نوشتن پنهان» است که از دو کلمه Stego به معنی «پنهان» و Graphein به معنای «نوشتن» تشکیل شده است.

پنهان‌نگاری، اطلاعات را به گونه‌ای مخفی می‌کند که هیچ شخص ثالثی به جز گیرنده نداند که یک پیام مخفی در داخل اطلاعاتی که منتقل می‌شود پنهان شده‌است. مزیت اصلی این تکنیک این است که شخصی دیگر -به جز گیرنده‌ای که قصد دریافت اطلاعات را دارد- نمی‌تواند به وجود اطلاعات مخفی در پیامی که از طریق یک کانال منتقل می‌شود مشکوک شود. بنابراین، پنهان‌نگاری، وجود اطلاعات یا پیام مخفی را برای شخص سوم جدا از فرستنده و گیرنده نامرئی می‌کند.

نامرئی بودن داده‌ها و ظرفیت جاسازی تصویر دو الزام اولیه هستند که به طور گسترده در تکنیک‌های مختلف پنهان‌نگاری مورد تحقیق قرار گرفته‌اند.

همانطور که در تصویر مشاهده می‌کنید، هر دو فایل جلد(x) و پیام مخفی(m) به عنوان ورودی به رمزگذار پنهان‌نگاری وارد می‌شوند. تابع رمزگذار Steganographic، f(x,m,k) پیام مخفی را در یک فایل جلد جاسازی می‌کند. شیء حاصل Stego که بسیار شبیه به فایل جلد شماست، این کدگذاری را کامل می‌کند. برای بازیابی پیام مخفی، شیء Stego به رمزگشای پنهان‌نگاری وارد می‌شود.

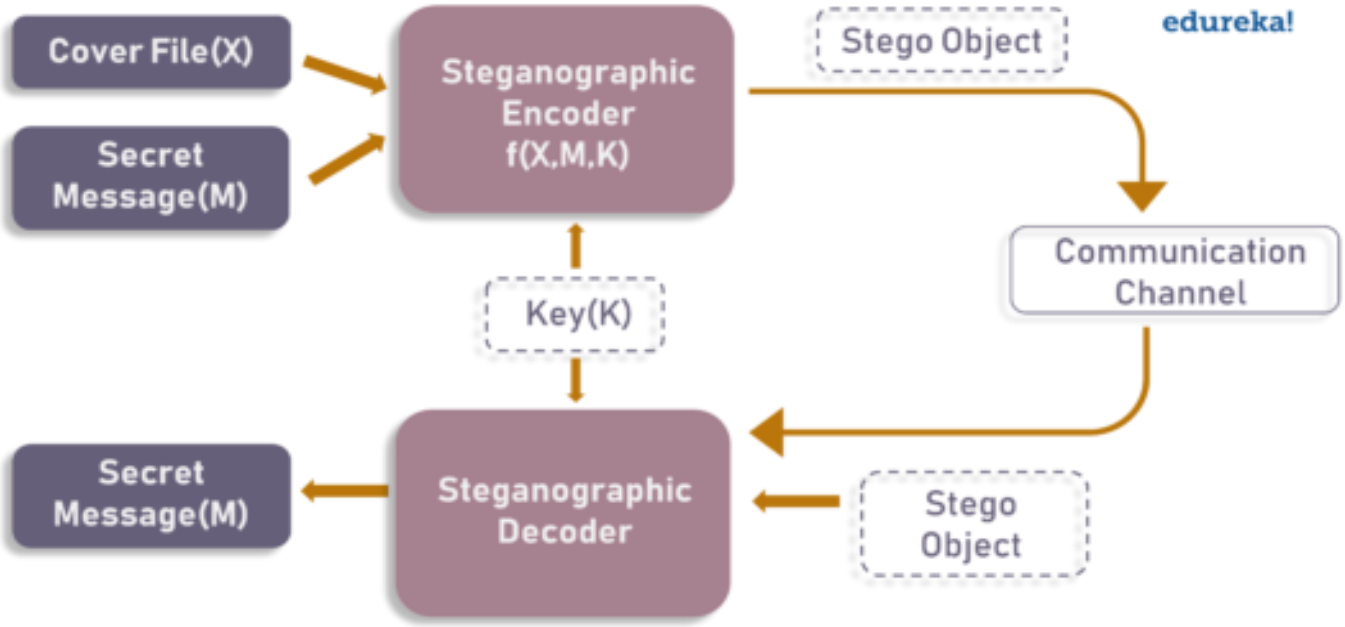

شکل ۳ ساختار کلی فرایند تعبیه و استخراج پنهان نگاری

۴-۱ انواع روش‌های پنهان نگاری

۴-۱-۱ پنهان‌نگاری در متن

پنهان‌نگاری متن، اطلاعاتی را در داخل فایل‌های متنی پنهان می‌کند که شامل مواردی مانند تغییر قالب متن موجود، تغییر کلمات در متن، ایجاد توالی کاراکترهای تصادفی یا استفاده از گرامرهای بدون زمینه برای تولید متون قابل خواندن است. تکنیک‌های مختلفی که برای پنهان کردن داده‌ها در متن استفاده می‌شود عبارتند از:

- Format Based Method
- Random and Statistical Generation
- Linguistic Method

۴-۱-۲ پنهان‌نگاری در تصویر

مخفی کردن داده‌ها با قرار دادن شیء پوششی در تصاویر را پنهان‌نگاری تصویر می‌گویند. در پنهان‌نگاری الکترونیکی، تصاویر به طور گسترده‌ای مورد استفاده قرار می‌گیرند، زیرا تعداد زیادی بیت در نمایش الکترونیکی یک تصویر وجود دارد. راه‌های زیادی برای پنهان کردن اطلاعات در داخل یک تصویر وجود دارد. رویکردهای رایج عبارتند از:

- Least Significant Bit Insertion
- Masking and Filtering
- Redundant Pattern Encoding
- Encrypt and Scatter

- Coding and Cosine Transformation

۴-۱-۳ پنهان‌نگاری در صدا

در پنهان‌نگاری صوتی، پیام مخفی در یک سیگنال صوتی جاسازی می‌شود که توالی باینری فایل صوتی مربوطه را تغییر می‌دهد. پنهان کردن پیام‌های مخفی در صدای الکترونیکی در مقایسه با سایرین، مانند پنهان‌نگاری تصویر، فرایندی بسیار دشوارتر است. روش‌های مختلف پنهان‌نگاری صوتی عبارتند از:

- Least Significant Bit Encoding
- Parity Encoding
- Phase Coding
- Spread Spectrum

این روش، داده‌ها را در فایل های صوتی wav، au و حتی mp3 مخفی می‌کند.

۴-۱-۴ پنهان نگاری در ویدیو

در پنهان‌نگاری ویدیویی می‌توانید نوع داده‌ها را در قالب ویدیوی الکترونیکی پنهان کنید. پنهان کردن مقدار زیادی داده در داخل ویدیو مزیت این نوع نهان‌نگاری به شمار می‌رود و در واقع یک جریان متحرک از تصاویر و صداها است. شما می‌توانید این پنهان‌نگاری را به عنوان ترکیبی از پنهان‌نگاری تصویر و پنهان نگاری صوتی در نظر بگیرید. دو دسته اصلی از پنهان نگاری ویدئویی عبارتند از:

- Embedding data in uncompressed raw video and compressing it later
- Embedding data directly into the compressed data stream

۴-۱-۵ پنهان نگاری در پروتکل

این تکنیک، جاسازی اطلاعات در پروتکل‌های کنترل شبکه است که در انتقال داده‌ها مانند TCP، UDP، ICMP و غیره استفاده می‌شود. به عنوان مثال، می‌توانید اطلاعات را در سربرگ[۷] یک بسته TCP/IP در برخی از فیلد(قسمت)ها که اختیاری هستند، پنهان کنید.

۵ تفاوت واترمارکینگ و پنهان نگاری

در برخی موارد تفاوت بین این دو برای پنهان کردن داده‌ها در اشیاء الکترونیکی صرفاً در هدف کاربرد نهفته است، زیرا بسیاری از الگوریتم‌ها برای آماده ساختن نهان‌نگاری و جاسازی واترمارک الکترونیکی مبتنی بر عملیات مشابه هستند. با این وجود، بسیاری از الگوریتم‌های خاص وجود دارند که به صراحت فقط برای پنهان‌نگاری یا واترمارکینگ الکترونیکی اعمال می‌شوند. در چنین مواقعی، تفاوت‌های اصلی در الزامات اثربخشی جاسازی داده‌ها است. به طور کلی، نیاز اصلی برای اثربخشی الگوریتم‌های پنهان‌نگاری، نامرئی بودن تعبیه است، زیرا ایده پنهان‌نگاری در نامرئی بودن تعبیه نهفته است. در این میان، الگوریتم‌های پنهان کردن واترمارک الکترونیکی اغلب به عنوان الگوریتم‌های جاسازی قوی توسعه داده می‌شوند که می‌توانند داده‌های جاسازی شده را حتی پس از اعوجاج[۸] یک شیء الکترونیکی شناسایی کنند. اگرچه، نویسندگان مختلف در حال توسعه الگوریتم‌هایی با شاخص‌های کیفیت اضافی هستند که امکان به‌کارگیری چنین الگوریتم‌هایی را در عمل گسترش می‌دهند.

تعداد زیادی الگوریتم خاص برای جاسازی واترمارک الکترونیکی وجود دارد که -همانطور که در برنامه‌های پنهان‌نگاری فرض می‌شود-، برای آماده‌سازی حجم زیادی از داده‌ها مناسب نیستند. گاهی اوقات نیازی به استخراج کامل واترمارک داخلی نیست. کافی است متقاعد شود که واترمارک خاصی در این تصویر وجود دارد. نامرئی بودن و ظرفیت جاسازی برای تکنیک‌های واترمارکینگ مانند پنهان‌نگاری، مهم به‌شمار می‌روند، اما در برخی موارد واترمارک‌ها قابل مشاهده هستند و همیشه به ظرفیت بالایی نیاز نیست.

۶ نتایج بررسی

در حال حاضر، روش‌های پنهان‌نگاری و واترمارکینگ الکترونیکی به طور فعال در حال توسعه هستند و بسیاری از محققان از کشورهای مختلف، الگوریتم‌های جدید را که در ویژگی‌های کیفی متفاوت هستند، ارائه می‌کنند.

با پیشرفت در سامانه‌های مدیریت اسناد الکترونیکی، امکانات بسیار زیادی در خصوص اصالت سنجی اسناد الکترونیکی فراهم خواهد شد. در این راستا، یکی از بحث‌ها و سوالات مطرح شده در زمینه «مناسب بودن پنهان‌نگاری به عنوان ابزاری برای پنهان کردن اطلاعات» این است: زمانی که روش‌هایی دیگر مانند رمزنگاری، قوی‌تر به نظر می‌رسند، آیا پنهان‌نگاری روشی مناسب برای نگهداری اطلاعات دریافت‌کننده مورد نظر به شمار می‌رود؟

استفاده از امضای الکترونیکی، یک تکنیک رمزنگاری رایج برای احراز هویت متن است. از آنجا که مفهوم اصلی ارتباطات پنهان‌نگاری در محرمانه بودن انتقال نهفته‌است، بنابراین، برنامه‌هایی که ارتباطات مبتنی بر رمزگذاری محدود است، مناسب‌تر است. در هنگام استفاده از پنهان‌نگاری می‌توان برای نمایش اطلاعات پنهان شده در فایل از کلید رمز استفاده کرد که باعث ارتقاء امنیت اطلاعات رمزگذاری شده می‌شود.

شرکت‌های دارای نرم افزار مدیریت اسناد می‌توانند در هنگام ثبت سند در سیستم یا بانک اطلاعاتی از روش‌های مورد اشاره برای اصالت سنجی اسناد سازمان‌ها استفاده کنند. سازمان‌ها در صورت استفاده نکردن از سامانه‌های مدیریت اسناد الکترونیکی می‌توانند در قالب یک نرم افزار با استفاده از تکنیک‌های پنهان‌نگاری یا واترمارکینگ، اسناد مورد نیاز خود را برچسب‌گذاری و اطلاعات مورد نیاز را به منظور اصالت سنجی در اسناد پنهان کنند تا در صورت نیاز آن را برای شناسایی اسناد جعلی مورد استفاده قرار دهند.

۷ نتیجه گیری و آینده نگری

تحقیقات بیشتر باید به سمت پتانسیل(ظرفیت)هایی برای پیاده‌سازی عمیق‌تر EDMS در معماری سیستم‌های اطلاعات شرکت‌ها هدایت شود تا از گنجاندن مستقیم IMS نه تنها در فرایندهای تجاری استراتژیک، بلکه در شیوه‌های کاری روزانه با ادغام واضح‌تر با سیستم‌های مهندسی و فروش محصول اطمینان حاصل شود.

اکثر قریب به اتفاق الگوریتم‌های تعبیه‌سازی مدرن، منجر به نامحسوس بودن تعبیه می‌شوند. بنابراین، محققانی که در این زمینه کار می‌کنند لازم است برای دستیابی به سایر شاخص‌های کارایی تعبیه که عبارتند از: برگشت‌پذیری، استحکام، و مقاومت در برابر آنالیز پنهان‌نگاری اهتمام ورزند. بررسی‌ها نشان داد که فعالیت در این زمینه در حال انجام است، اما هنوز مشکلات زیادی وجود دارد که به کشف راه حل‌های اصلی جدید نیاز دارد.

پنهان‌نگاری، در امنیت جایگاه خود را دارد. قرار نیست جایگزین رمزنگاری شود، اما مکمل آن است. پنهان کردن یک پیام با روش‌های پنهان‌نگاری احتمال شناسایی پیام را کاهش می‌دهد. با این حال، اگر آن پیام نیز رمزگذاری شده باشد، در صورت کشف، باید کرک شود (لایه دیگری از حفاظت).

---

7 Header

8 Distortions

پنهان‌نگاری بخشی از برنامه‌های مختلف صنعتی دارای IoT، شهرهای هوشمند، تصویربرداری پزشکی، برنامه‌های نظامی و غیره است. برای جلوگیری از حمله و ارائه محرمانه بودن داده‌ها، یک دیدگاه امنیتی چند سطحی انعطاف پذیر باتوجه به پنهان کردن اطلاعات و رمزنگاری پیشنهاد شده است. احراز هویت متن، نقش حیاتی در دفاع از هویت و محتوای الکترونیکی در برابر انواع مختلف جرایم سایبری دارد.

با استفاده از مکانیزم‌های امنیتی در حوزه امنیت اطلاعات و به کارگیری این مکانیزم‌ها در انواع سامانه‌های مدیریت فایل یا سند الکترونیکی می‌توانیم مشکلات پیش روی سامانه‌های مدیریت فایل‌ها و اسناد را شناسایی و رفع کنیم یا آنها را کاهش دهیم.

۸ منابع

[۱] A. F. Qasim, F. Meziane, and R. Aspin, ‘‘Digital watermarking: Applicability for developing trust in medical imaging workflows state of the art review,’’ Comput. Sci. Rev., vol. 27, pp. 45–60, Feb. 2018, doi: 10.1016/j.cosrev.2017.11.003.

[۲] S. Kumar, B. K. Singh, and M. Yadav, ‘‘A recent survey on multimedia and database watermarking,’’ Multimedia Tools Appl., vol. 79, nos. 27–28, pp. 20149–20197, Jul. 2020, doi: 10.1007/s11042-020- 08881-y.

[۳] Integrated management systems and workflow-based electronic document management: An empirical study (Hang Thu Pho; Tambo, Torben)

[۴] Digital Steganography and Watermarking for Digital Images: A Review of Current Research Directions(Oleg Evsutin.)

[۵] Steganography A Data Hiding Technique(Naga Ranijth Kumar Kesa)

[۶] Digital image steganography and steganalysis: A journey of the past three decades(Aditya Kumar Sahu* and Monalisa Sahu)

[۷] A Sesure Image Steganography Using LSB Technique and Pseudo Random Encoding Technique(Kshetrimayum Jenita Devi)

[۸] Steganography: Past, Present, Future : Published by SANS Institute (James C. Judge)

[۹] https://www.edureka.co/blog/steganography-tutorial

[۱۰] https://www.thecloudtutorial.com/edms-electronic-document-management/

[۱۱] https://procoders.tech/blog/advantages-of-electronic-document-management-system/

دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

آینده اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان

پریسا دانشجو [۱]، سعید احمدی [۲]

دانشگاه آزاد اسلامی- واحد تهران غرب[۱]، Daneshjoo.p@wtiau.acir
دانشگاه آزاد اسلامی- واحد تهران غرب[۲]، Saeed.ahmadi.edu@gmail.com[۲]

چکیده

اینترنت اشیاء مفهومی جدید در دنیای فناوری و ارتباطات است که در آن برای تمام اشیاء، قابلیت ارسال داده‌های فناوری را از طریق شبکه‌های ارتباطی فراهم می‌سازد. اینترنت اشیاء در حوزه سلامت به بسیاری از اشیاء و وسایل محیط پیرامون اشاره دارد که به شبکه اینترنت متصل هستند تا بتوان به وسیله اپلیکیشن‌های موجود در تلفن‌های هوشمند و تبلت آنها را مدیریت و کنترل کرد. بر این اساس، پژوهش حاضر با هدف بررسی آینده اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان انجام شد. این پژوهش از نوع پژوهش‌های کمّی است که از نظر هدف، کاربردی و از لحاظ نحوه گردآوری داده‌ها، توصیفی-همبستگی است. ابتدا با مطالعه ادبیات پژوهش، مولفه‌های آینده اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان مورد شناسایی قرار گرفتند، سپس توسط مدلسازی معادلات ساختاری(SEM) و نرم افزار AMOS، مولفه‌های شناسایی شده مدلسازی شدند. جامعه آماری تمامی مدیران و کارشناسان بخش سلامت کشور هستند که با توجه به نامحدود بودن جامعه آماری، توسط فرمول کوکران، تعداد ۳۸۴ نفر به عنوان نمونه آماری انتخاب شدند. نتایج نشان داد که از میان مولفه‌های شناسایی شده برای آینده اینترنت اشیاء به‌منظور ارائه خدمات هوشمند درمانی به بازنشستگان؛ کنترل از راه دور بیماران، ردیابی بیماران سرگردان و اسکن کامل بدن به ترتیب رتبه‌های اول تا سوم را از نظر اهمیت دارا هستند.

کلمات کلیدی: اینترنت اشیاء، بازنشستگان، خدمات هوشمند درمانی.

مقدمه

امروزه حدود دو میلیارد نفر، از اینترنت برای وب‌گردی، فرستادن و دریافت ایمیل، دسترسی به خدمات مالی مدیا، شبکه‌های اجتماعی و بسیاری از کارهای دیگر استفاده می‌کنند. درحالی که روز به روز به تعداد استفاده‌کنندگان از این زیربنای اطلاعاتی و ارتباطی افزوده می‌شود، یک جهش بزرگ در استفاده از اینترنت در قالب یک نرم افزار جهانی در راه است

که اجازه ارتباط بین اشیاء هوشمند و ماشین‌ها را می‌دهد. اصطلاح اینترنت اشیاء[1]IOT نخستین بار توسط کوین اشتون در سال۱۹۹۹ مطرح شد. او جهانی را توصیف کرد که در آن هر چیزی، برای خود هویت دیجیتال داشته باشد و به کامپیوترها اجازه دهند آن‌ها را سازماندهی و مدیریت کنند. از دید او اینترنت اشیاء، وسیله‌ای برای غلبه بر سلطه زمان و مکان است. این دیدگاه برای نخستین بار توسط مرکز شناسایی خودکـار و نشریات تحلیل بازار مرتبط با آن مشهور شد. فناوری زیست سنجی و تشخیص سریع برخط[2](RFID) به عنوان یک پیش-شرط در این فناوری در نظر گرفته می‌شود. گرچه RFID هنوز با توجه به قابلیت‌های منحصر به فردش، به طور گسترده در جاهای مختلفی، نظیر درهای کنترل ورود و خروج و سیستم ترانزیت استفاده می‌شود، ولی فناوری‌های دیگری هم برای تحقق اینترنت اشیاء وارد صحنه شده‌اند. برخی از آنها مانند بارکدها از تکنیک‌های ساده‌تری استفاده می‌کنند و برخی از این فناوری هم مانند کدهای کیو آر، وای-فای و بلوتوث از تکنیک‌های جدیدتری بهره می‌برند (فرازمند و احمدی، ۱۳۹۴).

مهمترین دلیل IOT تاثیر زیاد آن بر روی جنبه‌های مختلف زندگی روزمره و عملکرد کاربران بالقوه است. زندگی مرفه، سـلامت الکترونیکی و یادگیری بیشتر نمونه‌های کوچکی از کاربردهایی است که این طرح به همراه دارد. از نظر کاربران تجاری، پیامدهای جدی این طرح در زمینه‌هایی از قبیل اتوماسیون و تولید صنعتی، ساماندهی، تجارت(مدیریت فرایند)، انتقال هوشمند افراد و کالاها به‌طور یکسان مشهود است. NIC پیش‌بینی می‌کند که در سال ۲۰۲۵ نودهای اینترنت ممکن است در همه اشیاء وجود داشته باشند مثل پاکت‌های غذا، لوازم خانه، مستندات و غیره. مشخص است فرصت‌هایی که در آینده پیش می‌آید در کنار درخواست مردم و پیشرفت تکنولوژی(فناوری) می‌تواند نقشی موثر در گسترش IOT داشته باشد که ایـن گسترش، نیازمند وجـود اینترنت در پیشرفت‌های اقتصادی است. برای پذیرشIOT باید پیش‌زمینه آن مانند فرهنگسازی فراهم شود و از پیامدهای اصلی آن، ارتباط درونی دستگاه‌هاست‌که آنها را با سازگاری و امنیت، به هوشمندی بالایی مجهز می‌کند. بنابراین طرح IOT نیاز به شبکه ارتباطی دارد. مشخصه اصـلی اجـزایIOT، داشتن منابع کم برای محاسبات و انرژی زیاد است. بر این اساس، باید به راه حل‌های مطرح شده توجهی خاص شود تا بتوان بهره‌وری بهتری در کنار مشکلات داشت(کارلار،[3] ۲۰۲۱).

بنابراین، اینترنت اشیاء، مفهومی جدید در دنیای فناوری و ارتباطات است که در آن برای تمام اشیاء، قابلیت ارسال داده‌های فناوری از طریق شبکه‌های ارتباطی فراهم می‌شود. اینترنت اشیاء در حوزه سلامت به بسیاری از اشیاء و وسایل محیط اطراف اشاره دارد که به شبکه اینترنت متصل هستند تا بتوان به وسیله اپلیکیشن(برنامه کابردی)های موجود در تلفن‌های هوشمند و تبلت آنها را مدیریت و کنترل کرد(پرئی و حمیدی، ۱۳۹۶).

با توضیحات بالا، نشان داده شد که نوآوری، معطوف به یک فناوری خاص نبوده و این بار در اینترنت اشیاء ظهور کرده است. برای ایجاد ارزش و نوآوری در حوزه فناوری اطلاعات و ارتباطات، محل‌هایی برای ورود به این حوزه ضروری می نماید، زیرا در این گزارش با استفاده از روش مطالعه کتابخانه‌ای، حوزه‌ها، کاربردها، صنایع و سرویس‌های اینترنت اشیاء مورد بررسی قرار گرفته و متناسب با هر حوزه، کاربردهایی ارائه شده است. در اینترنت اشیاء نیز چنانچه کاربردها به خوبی تشریح شود، امکان تجاری سازی و ظهور نوآوری، محتمل خواهد شد.

پژوهشگاه ارتباطات و فناوری اطلاعات(مرکز تحقیقات مخابرات ایران)، همواره دغدغه مداقه و ارائه راهبردهای کاربردی را برای بخش و صنعت فناوری اطلاعات و ارتباطات ایران داشته و دارد. در این راستا، این مرکز بر اینترنت اشیاء متمرکز شده است، زیرا اینترنت اشیاء با دارا بودن قابلیتی بسیار بالا در بهره‌ور کردن کسب و کارها در صنایع مختلف، جزو انقلاب آتی حوزه فناوری اطلاعات و ارتباطات معرفی شده است. این بهره‌وری در بروز نوآوری و ارائه قابلیت‌های نو برای کسب و کارها است. صنایع مختلف در خصوص اینترنت اشیاء، واکنش‌های مختلفی را نشان داده‌اند، اما آنچه واضح به نظر می‌رسد، این است که اینترنت اشیاء در تمامی کسب و کارها و صنایع کاربرد دارد.

هر چه از طرف محصولات به سمت خدمات حرکت کنیم، پیچیدگی افزایش خواهد یافت. اینترنت اشیاء در برخی از صنایع باعث تسهیل در کارها شده و در بعضی صنایع نیز به افزایش دقت و تصمیم‌گیری کمک کرده است. در صنایع مالی به‌خصوص بانک‌ها، اینترنت اشیاء موجب شده است تا با دارا بودن اطلاعات دقیق و به‌روز، تصمیمات بهتری اتخاذ شود و گاهی ریسک(خطر)ها کاهش یابند(زارعی، ۱۳۹۴).

اینترنت اشیاء، مفهومی نو در دنیای فناوری و ارتباطات بوده و به طور خلاصه، فناوری جدیدی است که در آن برای هر موجودی (انسان، حیوان و اشیاء) قابلیت ارسال داده از طریق شبکه‌های ارتباطی، اعم از اینترنت یا اینترانت، فراهم می‌شود. بستر اینترنت اشیاء بر امواج رادیویی بی‌سیمی قرار داده شده‌است که به دستگاه‌های مختلف این امکان را می‌دهند تا از طریق اینترنت با یکدیگر به برقراری ارتباط بپردازند(رادور[4] و همکاران، ۲۰۱۶).

با استفاده از داده‌ها می‌توان مقداری زیاد از اطلاعات را در محدوده وسیعی ذخیره، مدیریت و پردازش کرد. علاوه بر این، داده‌ها سرعت اطلاعات مناسب را تضمین و با در نظر گرفتن خصوصیات حجم، مقدار، تنوع، صحت و سرعت، مزایا و تسهیلات برای شرکت‌ها، محققان و مصرف‌کنندگان ارائه می‌کنند. در نتیجه اینترنت اشیاء می‌تواند در حفاظت از دسترسی به داده‌های مهم نیز کارایی داشته باشد. علاوه بر این‌ها، امروزه شناسه و رمزکارت‌هایی که به‌کار برده می‌شوند، دسترسی را محدود می‌کنند اما این روش‌ها به‌راحتی می‌توانند شکسته شوند. بنابراین، غیرقابل اطمینان هستند. فناوری IOT کاربردهای فراوانی دارد که هدف اصلی آن تهیهٔ یک جانشین مناسب برای سیستم‌های کنترل دسترسی سنتی است و برای

[1] Internet of Things
[2] Fast Identity Online
[3] Karale
[4] Rathore

حفاظت شخصی یا دارایی‌های سازمانی استفاده می‌شود (کوی[5] و همکاران، ۲۰۲۱). همچنین اینترنت اشیاء در حوزه سلامت و درمان نیز خدماتی موثر و مفید را در اختیار افراد جامعه به‌ویژه بازنشستگان و سالمندان قرار می‌دهد که در این پژوهش به این موضوع مهم پرداخته شده است.

ادبیات پژوهش

اینترنت اشیاء، شبکه‌ای از وسائل الکترونیکی است که شامل قطعات الکترونیکی، نرم افزارها، حسگرها و عملگرهاست که قادرند از طریق یک شبکه ارتباطی با هم تبادل داده و اطلاعات داشته باشند. اینترنت اشیاء این امکان را فراهم می‌کند که وسایل الکترونیکی تحت یک شبکه ارتباطی بتوانند داده‌های کنترلی مورد نیاز را از محیط جمع‌آوری کنند و بر اساس این داده‌ها، عمل مناسب را انجام دهند. در واقع بلوک‌های یک سیستم کنترلی با قابلیت تبادل داده در یک محیط بین اشیاء مختلف، قسمت‌های مختلف اینترنت اشیاء را تشکیل می‌دهد.

اینترنت اشیاء، برای نخستین بار در سال ۱۹۹۹ توسط کوین اشتون مورد استفاده قرار گرفت و جهانی را توصیف کرد که در آن هر چیزی، از جمله اشیاء بی‌جان، برای خود هویت دیجیتال داشته باشند و به کامپیوترها اجازه دهند آنها را سازماندهی و مدیریت کنند. اینترنت در حال حاضر همه مردم را به هم متصل می‌کند ولی با اینترنت اشیاء تمام چیزها به هم متصل می‌شوند. البته پیش از آن کوین کلی در کتاب قوانین نوین اقتصادی در عصر شبکه‌ها (۱۹۹۸) موضوع نودهای کوچک هوشمند(مانند سنسور(حسگر) باز و بسته بودن در) را که به شبکه جهانی اینترنت وصل هستند، مطرح کرد. بر این اساس، تعدادی قابل توجه از مسئولان شرکت‌های فعال در این بخش معتقدند اینترنت اشیاء یا همان IOT برای همیشه سبک زندگی افراد را تغییر خواهد داد و ظرف چند سال آینده بحث‌هایی مانند هوش شبکه، اهمیتی بسیار خواهد یافت. بدین ترتیب به استناد گفته‌های فعالان این عرصه، سال ۲۰۱۶ میلادی را می‌توان سال ورود اینترنت اشیاء به فناوری اطلاعات دانست.

در ایران نیز طی سال‌های اخیر، اینترنت اشیاء مورد توجه قرار گرفته است. یکی از مراکزی که به صورت ویژه این موضوع را مورد بررسی قرار داده، پژوهشگاه ارتباطات و فناوری اطلاعات(مرکز تحقیقات مخابرات ایران) است. این پژوهشگاه، پروژه‌هایی را برای بررسی پیاده‌سازی فناوری اینترنت اشیاء در ایران انجام داده‌است. یکی از این پروژه‌ها با عنوان «تدوین کسب و کار اینترنت اشیاء در کشور» از ۱۰ دی ۱۳۹۳ تا ۱۰ خرداد ۱۳۹۴، انجام شده‌است. در این پروژه بر اساس تجربیات علمی و عملیاتی کشورهای مختلف در حوزه‌های حاکمیت، کسب و کار، کاربردها و فناوری‌ها مطالعات اولیه صورت گرفت و نقشه راه ایران با هدف استفاده ایران از فناوری‌های نوین نظیر اینترنت اشیاء با هدف افزایش رفاه اقتصادی، کیفیت زندگی و حفاظت از محیط زیست برای رسیدن به چشم‌انداز اقتصادی ۱۴۰۴ تعیین شد. بیشتر کشورهای دنیا در این زمینه و برای بهره‌برداری از فناوری اینترنت اشیاء، سرمایه‌گذاری‌هایی کلان به این پروژه اختصاص داده‌اند. در ایران نیز مسئولان به این مسئله واقف‌اند که برای جا نماندن از فناوری‌های وارداتی در بخشICT، باید همگام با سایر کشورها حرکت کرد. به همین دلیل موضوع اینترنت اشیاء در فهرست پروژه‌های کلان راهبردی کشور در حوزه ICT جای گرفت و از ابتدای امسال مقدمات ورود این فناوری به ایران در حال آماده سازی است. در صورتی که فناوری اینترنت اشیاء راه‌اندازی شود و ارتباطات به تمامی حوزه‌ها نفوذ پیدا کند، بنا بر پیش‌بینی‌ها، در ایران بالغ بر ۵۰ میلیارد حسگر به شبکه اینترنت متصل می‌شوند.

برای عملیاتی شدن اینترنت اشیاء در کشور، هوشمندسازی سیستم‌های برق، به عنوان نخستین گام در بهره‌گیری از این فناوری، مورد توجه قرار گرفت و طی آن، تفاهم‌نامه همکاری پژوهشی میان وزارت نیرو و مرکز تحقیقات مخابرات ایران منعقد شد. هم اکنون نیز با امضای قرارداد همکاری میان یکی از شرکت‌های بزرگ آی اس پی کشور و یک شرکت فرانسوی، طرح تجاری ارائه خدمات اینترنت اشیاء با پوشش سراسری شبکه ملی اطلاعات برای ایجاد زیرساخت ارتباطی فناوری «شبکه‌های دوربرد با توان پایین» (LPWAN) آغاز شده است.

از جمله ویژگی‌های این فناوری، توان مصرفی پایین برای اشیاء است که سبب افزایش طول عمر باتری آنها می‌شود. یکی از اپراتور(کاروَر)های بزرگ تلفن همراه هم فناوری-NB IOTرا به عنوان یکی از به‌روزترین بسترها در حوزهٔ اینترنت اشیاء برای مدیریت هوشمند منابع و انرژی رونمایی کرده‌است که این فناوری، ارتباطی مناسب برای ارتباط‌دهی کنتورهای هوشمند با قابلیت نظارت از راه دور محسوب می‌شود و اطلاعات تمامی اشیایی را که به اینترنت متصل هستند، از جمله کنتورهای آب و برق و گاز، به مرکز کنترل و سرویس‌های بالادستی منتقل می‌کند(طالب پور و همکاران، ۱۳۹۹).

اینترنت اشیاء شامل برنامه‌های کاربردی در زمینه‌های مختلف صنعتی و غیرصنعتی است. در چند سال گذشته، شرکت‌های بزرگی مانند گوگل و آمازون برای در دست گرفتن بازار اقتصادی حاصل از اینترنت اشیاء سرمایه‌گذاری زیادی کرده‌اند که خانه‌های هوشمند از جمله آنها است. با وجود این، به دلیل فقدان استانداردهای مشخص، مسائل پیرامون حریم شخصی و گاهی هزینه‌های استفاده از آن در محیط‌های شخصی و کوچک؛ ضریب نفوذ اینترنت اشیاء بسیار کند بوده‌است. همچنین وجود صنایعی که هنوز از استانداردهای M۲M استفاده می‌کنند و تمایلی برای تغییر استاندارد موجود به IOT ندارند، منجر به کند شدن ضریب نفوذ IOT شده‌است. با در نظر گرفتن تمامی این محدودیت‌ها، پیش‌بینی می‌شود تا سال ۲۰۲۵ بیش از ۴۰ میلیارد وسیله الکترونیکی تحت IOT به هم متصل باشند.

[5] Cui

مبحث اینترنت اشیاء، شامل بخش‌های مختلف و تخصصی در حوزه‌های مختلف است. موضوعی که در این میان، بسیار مورد توجه متخصصان این حوزه است و می‌تواند منجر به افزایش ضریب نفوذ IOT و فراگیرتر شدن آن شود، پروتکل(شیوه‌نامه)های ارتباطی بین اشیاء و ادوات تحت شبکه IOT است. انتخاب پروتکل مناسب، از ابعاد مختلف از جمله مصرف توان، نرخ ارسال داده، فضای تحت پوشش، فاصله حسگرها و کنترل کننده‌ها و سایر ادوات تحت شبکه و غیره حائز اهمیت است(اسچمیدت[6] ۲۰۱۶).

کاربرد به استفاده از اینترنت اشیاء در صنعت و به‌طور مشخص کسب و کار اشاره دارد. این کاربردها می‌تواند در لایه‌ها و زنجیره کسب و کارها تجلی یابد؛ مانند تامین، توزیع و فروش، انبارداری و غیره در هر یک از صنایع. با وجود این، کاربرد در حوزه اینترنت اشیاء بسیار وسیع است، فقط بر حوزهٔ پزشکی و یا حوزهٔ سلامت و حمل و نقل متمرکز نمی‌شود و محققان و نظرسنجی‌های مختلف، کاربردهایی متفاوت را برای صنایع مختلف مورد توجه قرار داده‌اند. یکی از این کاربردها در حوزهٔ هوشمندی است. هوشمندی و کاربرد اینترنت اشیاء در هوشمندی، بسیار متنوع است و می‌تواند در صنایع مختلفی ظهور یابد که در ادامه برخی از آن‌ها مورد توجه قرار گرفته‌است. برخی محققان این حوزه مانند ورمسان و فریس[7](۲۰۱۴) معتقد هستند که حوزه‌های کاربردی برای ورود اینترنت اشیاء با تمرکز بر هوشمندی به صورت زیر است.

شکل (۱) حوزه‌های کاربردی اینترنت اشیاء

این محققان به‌طور عمده اینترنت اشیاء را در هوشمندی دیده‌اند و بر معنی هوشمندی متمرکز هستند. مفهوم هوشمندی نیز بر ازدیاد ادراکات ما از محیط و بر اساس آن واگذاری برخی از اختیارات به برخی از اشیاء متمرکز است؛ مانند سیستم‌های تهویه در خانه‌های هوشمند و یا ابزارهای کنترل کننده فشار خون در سلامت هوشمند و غیره.

کاربردهای IoT بسیار متفاوت و متنوع است؛ در حقیقت گروه مخاطب و نیازهای آن‌ها است که کاربرد مناسب را تعیین می‌کند. با وجود این، کاربران اینترنت اشیاء را می‌توان به‌طور عموم در سه گروه زیر مورد شناسایی قرار داد: تک تک شهروندان، تجمع شهروندان(مردم یک شهر، یک ناحیه، یک کشور و یا منطقهٔ جغرافیایی خاص) و تشکلات اقتصادی، شرکت‌ها، کسب و کارها که در جدول(۱) مورد توجه قرار گرفته‌اند(مصلحی و ابراهیم پور کومله، ۱۳۹۶).

جدول (۱) کاربرد اینترنت اشیاء با در نظرگرفتن مخاطبان

شهروند	گروه‌های افراد	کسب و کارها
افزایش امنیت خود و خانواده	اطمینان از سلامت عمومی	افزایش کارایی و تولید
زندگی راحت‌تر	حفاظت محیط زیست	خلق مزیت رقابتی و تمایز
بهبود کیفیت زندگی	اشتغال‌زایی	کاهش هزینه‌ها
کاهش هزینه‌های زندگی		

[6] Schmidt
[7] Vermesan & Friess

گروه شهروندان می‌توانند از اینترنت اشیاء برای زندگی راحت‌تر، بهبود کیفیت زندگی و یا کاهش هزینه‌های زندگی استفاده کنند و گروه‌های افراد از آن برای مواردی مانند: اطمینان از سلامت عمومی، حفاظت محیط زیست یا اشتغال‌زایی سود می‌برند. کسب و کارها نیز در زمینه‌های کلی مانند: افزایش کارایی و تولید، خلق مزیت رقابتی و تمایز و کاهش هزینه‌ها می‌توانند از اینترنت اشیاء بهره‌مند شوند. البته مصرف‌کنندگان نهایی اینترنت اشیاء را می‌توان در دسته‌بندی‌های متنوع دیگری نیز مورد شناسایی قرار داد؛ زیرا مشتریان و تقاضاهای آن‌هاست که سرویس‌های مبتنی بر اینترنت اشیاء را تعیین می‌کند. در یکی از این طبقه‌بندی‌ها، چهار گروه مورد شناسایی قرار گرفته‌اند که عبارتند از: ۱) پوشیدنی‌ها، ۲) رسانه‌ها، ۳) اتوماسیون و خودکارسازی خانه، ۴) اپلیکیشن‌های هوشمند. در حوزه پوشیدنی‌ها نیز می‌توان به ساعت‌های هوشمند اشاره کرد.

سرویس‌ها در حالت کلی بر یک یا دو حوزه متمرکز نیستند بلکه دارای کاربرد در حوزه‌هایی متفاوت هستند(شکل ۲).

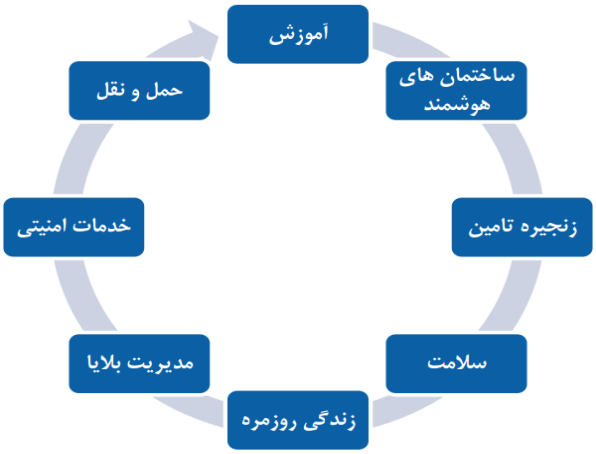

شکل (۲) سرویس‌های اینترنت اشیاء و حوزه‌های کاربردی

آمارهای اتحادیه‌های مختلف جهانی نشان دهنده افزایش تعداد اشیاء متصل به اینترنت در سال‌های آتی و به دنباله آن افزایش استفاده از اینترنت اشیاء هستند. بنابر پیش‌بینی اینتل در سال ۲۰۲۲، بالغ بر ۲۰۰ میلیارد شیء از طریق اینترنت اشیاء به یکدیگر متصل خواهند بود که در شکل(۳) نمایش داده شده است.

شکل (۳) پیش‌بینی تعداد دستگاه‌ها با قابلیت اتصال به اینترنت در سال ۲۰۲۲

اینترنت اشیاء در حوزهٔ درمانی

مفهوم اینترنت اشیاء مستلزم استفاده از ابزار الکترونیکی برای ثبت و ضبط اطلاعات است تا با اتصال به اینترنت، بلوتوث و یا سایر شبکه‌ها، قابلیت انجام امور خاص از قبیل ارسال به سرور، پردازش و غیره را به سیستم اضافه کنند.

بدیهی است کاربرد بسیاری از محصولات و تجهیزات صنعتی در صورت قابلیت استفاده از اینترنت می‌تواند تغییر کند. بیماران و ارائه‌کنندگان خدمات سلامت نیز می‌توانند در زمینه استفاده از اینترنت اشیاء در حوزه سلامت ذی‌نفع باشند. بخشی از کاربردهای اینترنت اشیاء را می‌توان در نرم افزارهای سلامت تلفن همراه و یا دستگاه‌هایی که اطلاعات سلامت فرد را ضبط می‌کنند دید. بسیاری از بیمارستان‌ها نیز در حوزه‌های تجهیزات پزشکی، کارمندان و بیماران خود از این حوزه فناوری بهره می‌برند.

علت اصلی استفاده از این فناوری، کاهش نقش انسان و البته اجتناب از خطاهای انسانی است که منجر به ارائه خدمات در حوزهٔ سلامت می‌شود.

اینترنت اشیاء روز به روز بیشتر مورد اقبال کارشناسان قرار می‌گیرد. به‌طبع، این فناوری نیز مانند سایر فناوری‌های روزآمد، چالش‌های خاص خود را دارد که در ادامه به آنها می‌پردازیم. این فناوری می‌تواند به عنوان ابزاری برای ارائه خدمات درمانی به بیماران به وسیله دسترسی و کنترل از راه دور و تسهیلاتی به‌منظور ثبت اطلاعات بیمار و انتقال آنها برای بررسی به کار آید.

۱- مصرف دارو

شرکت Proteus Digital Health با طراحی سیستمی مبتنی بر اینترنت اشیاء موفق شده است سیستمی برای تأیید بلع داروها طراحی کند. این سیستم با استفاده از حسگری که براساس اندازه قرص‌ها طراحی شده است، بلع قرص را تشخیص می‌دهد و با استفاده از یک واسط، اطلاعات را در بستر اینترنت ارسال می‌کند و پزشکان می‌توانند روند مصرف داروی بیماران خود را رصد کنند(بولحسنی[8] و همکاران، ۲۰۲۱).

۲- اسکن کامل بدن

اسکن بدن از دیرباز فرایندی زمان‌بر و پرهزینه بوده‌است و نیاز به چندین دوربین پیشرفته دارد، اما امروزه اسکن کامل بدن دستخوش تغییر شده است؛ استارت آپ به افراد کمک می‌کند در هر حالتی، فرایند ضبط حرکات بدن را انجام دهند(بولحسنی و همکاران، ۲۰۲۱).

۳- سلامت سالمندان

ردیابی بیماران سرگردان، نظارت بر تعامل و فعالیت‌های افراد سالخورده در خانه سالمندان و بیمارستان از جمله کاربردهای این فناوری در حوزه سلامت سالمندان است. در واقع مراقبت از سالمندان، یک بازار بزرگ برای دستگاه‌های پزشکی مبتنی بر اینترنت اشیاء است(بولحسنی و همکاران، ۲۰۲۱).

۴-جمع‌آوری اطلاعات سلامت

در بسیاری از پروژه‌های تحقیقاتی که نیاز به جمع‌آوری طیف وسیعی از اطلاعات افراد در نقاط مختلف است، استفاده از اینترنت اشیاء می‌تواند کمک بسزایی در کاهش زمان و خطای ورود داده کند. مواردی همچون فشارخون، قند خون، قد، وزن و غیره می‌توانند با استفاده از تجهیزات مبتنی بر اینترنت اشیاء محاسبه و در بستر اینترنت به سرور مطالعه ارسال شوند(بولحسنی و همکاران، ۲۰۲۱).

۵-سلامت مواد غذایی

گرفتن اطلاعات دقیق در مورد آلودگی مواد غذایی به طور معمول نیاز به یک آزمایشگاه کامل شیمی آلی برای آزمایش آن‌ها دارد. در عصر اینترنت اشیاء، بررسی ایمنی مواد غذایی با دستگاه‌های متصل به اینترنت در سطح مصرف کننده در حال راه اندازی است. به عنوان مثال، یک «مانیتور آلرژن» توسط Sensor Labs ساخته شده که می‌تواند محتوای «گلوتن» در مواد غذایی را طی یک آزمون ۲ دقیقه‌ای و با دقت ۹۹,۵ درصد شناسایی کند. این میزان به تلفن هوشمند فرد مصرف کننده ارسال و برای وی نمایش داده می‌شود.

البته موارد فوق تنها برخی از کاربردهای اینترنت اشیاء در حوزه سلامت است و با توجه به گسترش روز افزون این فناوری در زمینه سلامت، شاهد کاربردهای بیشتر آن در ارائه خدمات پزشکی و سلامت هستیم(بولحسنی و همکاران، ۲۰۲۱).

هیچ‌گاه فناوری نتوانسته است به تنهایی به عنوان یک راهکار شناخته شود و همواره موانعی در مسیر آن برای تطبیق با محیط‌های مختلف وجود داشته‌است. یکی از این موانع، امنیت است. برخی اوقات مردم از اینکه می‌دانند اطلاعات شخصی آن‌ها در جایی ذخیره شده و قابلیت دسترسی به آن وجود دارد احساس ناامنی می‌کنند.

نیاز امنیتی داده‌ها، باعث دسترسی نداشتن به برخی عملکردهای مفید ابزارهای حوزه سلامت و در واقع مانع از دسترسی به اطلاعات بیمار می‌شود. اینکه آیا مراکز خصوصی، بیمارستان‌های دولتی و یا سازمان‌های بهداشتی نیاز به تنظیم مجدد سیاست‌های امنیتی خود برای انطباق با فناوری‌های مبتنی بر اینترنت اشیاء (BYOD و M Health) دارند و یا خیر؟ سوالی است که در آیندهٔ این فناوری تأثیر بسزایی خواهد داشت و این اماکن در صورت تغییر مقررات امنیتی خود بایستی به شدت مراقب هکرها باشند، زیرا اطلاعات بیماران اغلب شامل اطلاعات بیمه‌ای و امور مالی بیماران نیز می‌شود. هکرها، بدون شک برای دسترسی به این گنجینه اطلاعات به‌شدت علاقه‌مند خواهند بود.

چالش دیگر از منظر عملیاتی استفاده از این فناوری است. مدیریت سیستم با این حجم بالای اطلاعات، خود چالشی است که در صورت پیش‌بینی نشدن راهکاری درست برای آن، ممکن است منجر به مشکلات عدیده‌ای شود. این موضوع ممکن است منجر به مواجهه پزشکان با اطلاعات بیش از حد و متعاقباً ایجاد وقفه در ارائه خدمات و روند درمان شود (ساسیندران و بلاگنش[9]، ۲۰۲۱).

جدول (۲)، استفاده‌کنندگان از اینترنت اشیاء را در حوزهٔ درمانی برخی از کشورهای جهان در سال‌های ۲۰۱۵، ۲۰۱۶ و ۲۰۱۷ بر حسب نفر از یک میلیون نفر نشان می‌دهد. کشورهای مورد مطالعه شامل کشورهای توسعه‌یافته(پیشرفته) و کشورهای در حال توسعه است.

[8] Bolhasani
[9] Suseendran & Balaganesh

جدول (۲) میزان استفاده از اینترنت اشیاء در حوزهٔ درمانی

سال / نام کشور	۲۰۱۵	۲۰۱۶	۲۰۱۷
بحرین	۱۸۰/۳۴	۱۸۸/۰۷	۱۹۵/۷۷
کانادا	۱۲۱۰/۱۸	۱۳۰۹/۴۸	۱۲۵۴/۲۳
چین	۷/۰۴	۱۰/۱۲	۲۰/۵
دانمارک	۱۶۷۱/۴۴	۱۹۷۳/۲۶	۲۰۷۹/۳۹
اسپانیا	۳۱۶/۲۴	۳۶۲/۲۶	۴۱۹/۲۶
فرانسه	۶۸۲/۱۶	۸۱۱/۵۵	۸۴۹/۴۴
غنا	۳/۶۷	۴/۹۷	۶/۲۷
یونان	۱۴۸/۲۷	۱۹۲/۰۴	۲۳۴/۵۳
هندوستان	۵/۵۴	۶/۸۳	۷/۸۲
ایران	۲/۱۳	۵/۵۱	۱۴/۱۹
عراق	۰/۷۱	۱/۳۳	۱/۵۳
ایتالیا	۲۵۱/۴۴	۲۸۸/۸۸	۳۳۳/۲۳
آلمان	۴۵۸/۵	۶۵۴/۲۵	۸۶۳/۳۳
ژاپن	۹۱۰/۶۵	۹۶۹/۶۲	۱۰۷۰/۶۸
کره جنوبی	۱۰۲۳/۳۶	۱۳۶۲/۳۳	۱۵۶۳/۲
لیبی	۳/۰۶	۳/۸۵	۳/۹۷
مالزی	۸۷/۵۷	۱۰۲/۴۶	۱۰۶/۴۵
هلند	۲۶۳۳/۳۸	۲۸۲۷/۵۸	۲۹۰۳/۶۴
پرتغال	۲۶۲/۷۶	۳۱۵/۶	۳۸۱
سوئد	۱۶۰۱/۱۶	۱۷۵۵/۳۵	۱۷۸۰/۴۹
ایالات متحده آمریکا	۱۵۴۹/۶۳	۱۶۵۲/۵۸	۱۶۲۳/۳۵
مالاوی	۵۵/۵۶	۵۶/۲۳	۸۹/۱۱
اتیوپی	۱/۲	۲/۲۳	۳/۳
تونس	۵/۳	۶/۳	۷/۲۱
نیجریه	۳/۲	۴/۳	۵/۲۲
آفریقای جنوبی	۵/۳	۶/۳۶	۸/۳۹
تانزانیا	۱/۰۲	۲/۰۳	۴/۳
کنیا	۰/۷۵	۱/۲	۲/۶

مأخذ: بانک جهانی

همانطور که مشاهده می‌شود، در کشورهای پیشرفته، میزان استفاده از اینترنت اشیاء به مراتب بیشتر از کشورهای در حال توسعه است. بیشترین میزان استفاده در میان کشورهای مورد بررسی در سال ۲۰۱۷، کشور هلند با ۲۹۰۳/۶۴ نفر از یک میلیون نفر است. همچنین کشورهای دانمارک، سوئد و ایالات متحده آمریکا دارای رتبه‌های دوم تا چهارم هستند.

در ایران، فقط ۱۴/۱۹ نفر از یک میلیون نفر، از اینترنت اشیاء در حوزهٔ درمانی استفاده می‌کنند. اما میزان رشد استفاده از اینترنت اشیاء در این کشور نسبت به سال ۲۰۱۶ افزایشی چشمگیر داشته‌است.

روش شناسی پژوهش

این پژوهش از نوع پژوهش‌های کمّی بوده که از نظر هدف، کاربردی و از لحاظ نحوه گردآوری داده‌ها، توصیفی-همبستگی است. ابتدا توسط مطالعه ادبیات پژوهش، مؤلفه‌های آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان مورد شناسایی قرار گرفت سپس توسط مدلسازی معادلات ساختاری (SEM) و نرم افزار AMOS، مؤلفه‌های شناسایی شده مدلسازی شد. جامعه آماری، تمامی مدیران و کارشناسان بخش سلامت کشور هستند که با توجه به نامحدود بودن جامعه آماری، توسط فرمول کوکران، تعداد ۳۸۴ نفر به عنوان نمونه آماری انتخاب شدند. از میان نمونه آماری انتخاب شده در بخش کمی، از نظر جنسیت ۴۲ درصد زن، ۵۸ درصد مرد؛ از نظر سن ۲۶ درصد ۳۰-۱۸ سال، ۳۸ درصد ۴۰-۳۱ سال، ۲۶ درصد ۵۰-۴۱ سال، ۱۰ درصد ۵۱ سال به بالا بوده‌اند. در ادامه، از مؤلفه‌های نهایی شناسایی شده، پرسشنامه‌ای مشتمل بر ۲۲ سؤال و در طیف لیکرت طراحی و در اختیار نمونه آماری قرار داده شد.

یافته‌ها

در این بخش، ابتدا مؤلفه‌های آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان به صورت جدول(۳) و به کمک ادبیات پژوهش شناسایی شد. همانطور که ملاحظه می‌شود، به کمک ادبیات پژوهش، ۹ مؤلفه برای آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان شناسایی شد که شامل: ۱)نرم افزارهای سلامت تلفن همراه، ۲)اجتناب از خطاهای انسانی به‌ویژه بازنشستگان، ۳)کنترل از راه دور بیماران، ۴)رصد روند مصرف دارو، ۵)اسکن کامل بدن، ۶)ردیابی بیماران سرگردان، ۷)جمع‌آوری اطلاعات سلامت بازنشستگان، ۸)سلامت مواد غذایی و ۹)ثبت اطلاعات بیماران می‌شود. همچنین مؤلفه‌های فرعی به تعداد ۲۲ مؤلفه(گویه) هستند که برای طراحی پرسشنامه مورد استفاده قرار گرفت.

جدول (۳) مؤلفه‌های شناسایی شده به کمک ادبیات پژوهش

ردیف	مولفه اصلی	مولفه فرعی (گویه)
۱	نرم افزارهای سلامت تلفن همراه (A)	نرم افزار کنترل قند خون نرم افزار کنترل فشار خون نرم افزار بررسی ضربان قلب نرم افزار کنترل تنفس
۲	اجتناب از خطاهای انسانی به ویژه بازنشستگان (B)	کاهش نقش انسان کاهش خطاهای مربوط به انسان
۳	کنترل از راه دور بیماران (C)	دسترسی به بیمار تسهیلات برای کنترل از راه دور
۴	رصد روند مصرف دارو (D)	سیستم تایید بلع دارو کمک به پزشکان
۵	اسکن کامل بدن (E)	کاهش هزینه اسکن ضبط حرکات بدن
۶	ردیابی بیماران سرگردان (F)	نظارت بر تعامل بازنشستگان نظارت بر فعالیت‌های بازنشستگان
۷	جمع‌آوری اطلاعات سلامت بازنشستگان (G)	کاهش زمان کاهش خطای ورود داده محاسبه وضعیت سلامت بیمار
۸	سلامت مواد غذایی (H)	بررسی محتوای گلوتن بررسی ایمنی مواد غذایی
۹	ثبت اطلاعات بیماران (I)	ثبت وضعیت بیمار ثبت مشخصات شامل قد و وزن بیمار ثبت سابقه بیمار

مأخذ: یافته‌های پژوهش

در مرحلهٔ بعد، ابتدا به‌منظور انتخاب روش مناسب برای مدلسازی، نرمال(طبیعی) بودن توزیع داده‌های پرسشنامه توسط آزمون کولموگروف اسمیرنوف (KS) بررسی شد. فرضیه صفر این آزمون، نرمال بودن توزیع داده‌ها در پرسشنامه است. بر اساس این آزمون، سطح احتمال آماره آزمون در تمامی سؤالات بالای ۵ درصد بوده و بنابراین فرضیه صفر نرمال بودن توزیع داده‌ها پذیرفته می‌شود. از آنجا که توزیع داده‌ها نرمال و حجم نمونه آماری نیز بالای ۲۰۰ نفر است، لذا برای مدلسازی فرهنگ سازمانی از معادلات ساختاری SEM و نرم افزار Amos استفاده می‌شود. در مرحله بعد، شاخص‌های نیکویی برازش برای ارزیابی اعتبار الگو، مورد بررسی قرار گرفته‌اند. این شاخص‌ها عبارتند از شاخص‌های GFI و AGFI، شاخص RMSEA، آماره خی‌دو، شاخص NFI و CFI. مطابق با نتایج به‌دست آمده از مدلسازی و نرم افزار، مقادیر شاخص‌های GFI و AGFI و NFI و CFI بالاتر از ۰/۹ به دست آمده

است. بنابراین این شاخص‌ها برازش قابل قبول مدل را نشان می‌دهند. مقادیر RMSEA نیز برابر ۰/۰۶ و حاکی از برازش قابل قبول مدل است. مقدار خی‌دو نیز برابر ۴۹/۹۷۳ بوده که در سطح احتمال ۵ درصد معنادار است. نسبت این آماره بر درجه آزادی (عدد ۲۰) کوچکتر از ۳ است و برازش خوب مدل را نشان می‌دهد. بنابراین با توجه به مناسب بودن معیارهای نیکویی برازش، مدل ساختاری دارای اعتبار لازم برای مدلسازی است.

پس از تایید برازش مناسب مدل، مدلسازی معادلات ساختاری SEM توسط نرم افزار Amos انجام شده است. فرم استاندارد مدل در شکل (۴) و نتایج ضرایب مسیر(بارهای عاملی) و معناداری ضرایب(آماره‌های t) در جدول(۴) ارائه شده است. مطابق با نتایج ارائه شده، تمامی بارهای عاملی مؤلفه‌های آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان به جز رصد روند مصرف دارو، در سطح احتمال ۵ درصد معنادار هستند. لذا این مؤلفه در این بخش از تحلیل حذف می‌شود. بار عاملی مؤلفه‌های نرم افزارهای سلامت تلفن همراه، اجتناب از خطاهای انسانی به‌ویژه بازنشستگان، کنترل از راه دور بیماران، اسکن کامل بدن، ردیابی بیماران سرگردان، جمع‌آوری اطلاعات سلامت بازنشستگان، سلامت مواد غذایی، ثبت اطلاعات بیماران و کل مدل به ترتیب برابر ۰/۲۳، ۰/۳۷، ۰/۷۰، ۰/۵۷، ۰/۵۸، ۰/۲۹، ۰/۴۴، ۰/۲۱ و ۰/۴۸ به‌دست آمده است. بنابراین از میان مؤلفه‌های آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان، کنترل از راه دور بیماران، ردیابی بیماران سرگردان و اسکن کامل بدن به ترتیب رتبه‌های اول تا سوم را از نظر اهمیت دارا هستند. همچنین بار عاملی مؤلفه‌های نرم افزارهای سلامت تلفن همراه، جمع‌آوری اطلاعات سلامت بازنشستگان و ثبت اطلاعات بیماران کمتر از ۰/۳ است که به این دلیل، این مؤلفه‌ها از تحلیل حذف می‌شوند.

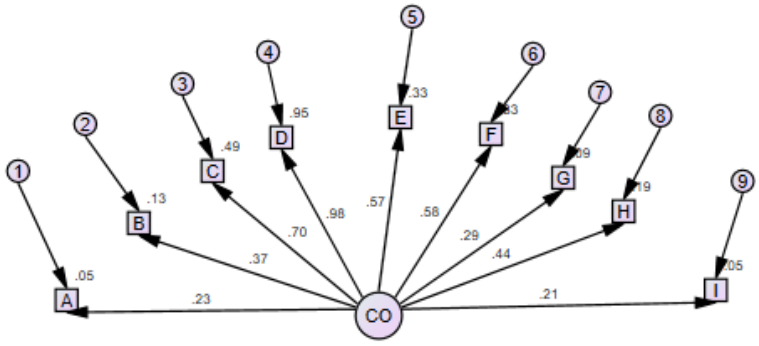

شکل (۴) فرم استاندارد معادلات ساختاری مأخذ: یافته‌های پژوهش

جدول (۴) بارهای عاملی و معناداری مؤلفه‌های آینده اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان

مولفه	بار عاملی استاندارد	آماره t	سطح معناداری	نتیجه
نرم افزارهای سلامت تلفن همراه (A)	۰/۲۳	۰/۳۰۸	۰/۰۰	بار عاملی کمتر از ۰/۳
اجتناب از خطاهای انسانی به ویژه بازنشستگان (B)	۰/۳۷	۳/۲۸۸	۰/۰۰	معنادار
کنترل از راه دور بیماران (C)	۰/۷۰	۲/۹۶۸	۰/۰۰	معنادار
رصد روند مصرف دارو (D)	۰/۹۸	۰/۳۱۹	۰/۷۵	بی معنی
اسکن کامل بدن (E)	۰/۵۷	۳/۱۸۶	۰/۰۰	معنادار
ردیابی بیماران سرگردان (F)	۰/۵۸	۳/۱۸۴	۰/۰۰	معنادار

جمع‌آوری اطلاعات سلامت بازنشستگان (G)	۰/۲۹	۳/۳۰۱	۰/۰۰	بار عاملی کمتر از ۰/۳
سلامت مواد غذایی (H)	۰/۴۴	۳/۲۶۹	۰/۰۰	معنادار
ثبت اطلاعات بیماران (I)	۰/۲۱	۳/۳۰۹	۰/۰۰	بار عاملی کمتر از ۰/۳
کل	۰/۴۸	۳/۲۸۸	۰/۰۰	معنادار

مأخذ: یافته‌های پژوهش

نتیجه‌گیری و پیشنهادها

اینترنت اشیاء مفهومی جدید در دنیای فناوری و ارتباطات است که در آن برای تمام اشیاء، قابلیت ارسال داده‌های فناوری را از طریق شبکه‌های ارتباطی فراهم می‌سازد. اینترنت اشیاء در حوزه سلامت به بسیاری از اشیاء و وسایل محیط پیرامون اشاره دارد که به شبکه اینترنت متصل هستند تا بتوان به وسیله اپلیکیشن‌های موجود در تلفن‌های هوشمند و تبلت، آنها را مدیریت و کنترل نمود. بر این اساس، پژوهش حاضر با هدف بررسی آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان و با ابزار پرسشنامه و به روش مدلسازی معادلات ساختاری انجام شد.

نتایج نشان داد که از میان مؤلفه‌های شناسایی شده برای آیندهٔ اینترنت اشیاء در ارائه خدمات هوشمند درمانی به بازنشستگان، کنترل از راه دور بیماران، ردیابی بیماران سرگردان و اسکن کامل بدن به ترتیب رتبه‌های نخست تا سوم را از نظر اهمیت دارا هستند. بنابراین در حوزه درمانی، اینترنت اشیاء می‌تواند خدمات مفیدی برای بازنشستگان ارائه دهد. از مهم‌ترین این خدمات، کنترل از راه دور و ردیابی بیماران است. به دلیل آنکه بیماران سالمند و بازنشستگان در دوران پیری با مشکلاتی از قبیل آلزایمر، فراموشی، گم کردن راه خانه و مسیر خود و عواملی از این قبیل مواجه هستند، اینترنت اشیاء می‌تواند کمک بزرگی به رفع این مشکل کند. لذا توسط فناوری اینترنت اشیاء می‌توان افراد گم شده را به‌راحتی ردیابی و پیدا کرد. همچنین توسط اینترنت اشیاء، خدمات مهم دیگری ازجمله اسکن کامل بدن نیز قابل انجام است که از این طریق می‌توان در زمان نیاز، از وضعیت سلامت بازنشستگان با خبر شد. توسط اینترنت اشیاء دسترسی به بیمار توسط تسهیلات برای کنترل از راه دور به‌سادگی انجام می‌شود. نظارت بر تعامل و فعالیت‌های بازنشستگان و ضبط حرکات بدن با هزینه کمتر انجام می‌شود و به طور کلی، مزایای زیادی برای بخش درمانی کشور به ارمغان خواهد آورد. با توجه به پیشرفت‌هایی که تاکنون در حوزهٔ درمانی و سلامت کشور داشته‌ایم، امید است بتوان با به‌کارگیری اینترنت اشیاء در حوزهٔ درمانی، خدمات هوشمند درمانی را در اختیار بازنشستگان کشور قرار داد. این خدمات همانطور که نتایج تحقیق نشان داد شامل کنترل و ردیابی و اسکن بدن برای بیمار است. بازنشستگان کشور به دلیل بالا بودن سن آنها، امکان استفاده از نرم‌افزارهای تلفن همراه را ندارند و به همین دلیل، اینترنت اشیاء باید به شکل دیگری مانند ردیابی و کنترل بیماران برای آنها مورد استفاده قرار گیرد. لذا آیندهٔ اینترنت اشیاء در حوزهٔ خدمات هوشمند درمانی در صورتی موفقیت آمیز است که بازنشستگان نیازی به آموزش زیاد برای یادگیری استفاده از این خدمات هوشمند را نداشته باشند و به‌راحتی برای آنان کاربرد داشته باشد.

با توجه به نتایج به‌دست آمده، پیشنهاد می‌شود اینترنت اشیاء در حوزهٔ درمانی و سلامت با سرعت و چابکی بیشتری پیاده‌سازی شود و این موضوع نیز برای سالمندان و بازنشستگان اولویت بیشتری داشته باشد. سالمندان و بازنشستگان کشور برای مسیریابی و درمان بیماری‌های جسمانی خود نیاز به فناوری‌های نوین دارند. اینترنت اشیاء یکی از بهترین فناوری‌هایی است که به کمک آن می‌توان زندگی سالم‌تر و راحت‌تری را برای آنان فراهم کرد. همچنین باید خدمات هوشمند درمانی به‌گونه‌ای باشد که بازنشستگان نیازی به آموزش و یادگیری این خدمات نداشته‌باشند. برای تحقیقات آتی پیشنهاد می‌شود مؤلفه‌های آیندهٔ اینترنت اشیاء به طور دقیق‌تر توسط روش تحقیق کیفی شناسایی شود.

منابع

پرئی، اعظم السادات، حمیدی، حجت الله، (۱۳۹۶)، ارائه رویکردی برای مدیریت تشخیص سریع بر خط با استفاده از فناوری بیومتریک در اینترنت اشیاء، فصلنامه علمی پژوهشی پژوهشگاه علوم و فناوری اطلاعات ایران، دوره ۳۴، شماره ۳.

زارعی، محمد، (۱۳۹۴)، کاربردهای اینترنت اشیاء، پژوهشگاه ارتباطات و فناوری اطلاعات (مرکز تحقیقات مخابرات ایران).

طالب پور، احمدرضا، طالبی، اشکان، نظری، مسعود، (۱۳۹۹)، اینترنت اشیاء، مفاهیم و پیاده سازی، موسسه فرهنگی هنری دیباگران تهران.

فرازمند، عاطفه، احمدی، سروش، (۱۳۹۴)، اینترنت اشیاء (IOT) و کاربردهای آن، اولین همایش ملی کامپیوتر، فناوری اطلاعات و ارتباطات اسلامی ایران.

مصلحی، محمدرضا، ابراهیم پور کومله، حسین، (۱۳۹۶)، اینترنت اشیاء و چالش‌های امنیتی آن، کنفرانس ملی فناوری‌های نوین در مهندسی برق و کامپیوتر.

Bolhasani, H., Mohseni, M. & Rahmani, A.M. (2021). Deep learning applications for IoT in health care: A systematic review, Informatics in Medicine Unlocked, 23.

Cui, Y., Liu, W., Rani, P. & Alrasheedi, M. (2021). Internet of Things (IoT) adoption barriers for the circular economy using Pythagorean fuzzy SWARA-CoCoSo decision-making approach in the manufacturing sector, technological forecasting and social change, 171.

Karale, A. (2021). The Challenges of IoT addressing Security, Ethics, Privacy and Laws, Internet of Things.

Smart Cities based on the), "Urban Planning and Building۲۰۱۶Rathore, M. Mazhar, Paul, Anand , Ahmad, Awais, Suengmin ,Rho, (.۸۰–۶۳, ۱۰۱Internet of Things using Big Data Analytics", Computer Networks

LoWPAN: An Open IoT Networking Protocol", OpenIoT Summit.۶Schmidt, S. (2016). "

Suseendran, G. & Balaganesh, D. (2021). Smart cattle health monitoring system using IoT sensors, Materials Today.

www.worldbank.org

دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

پیش بینی قیمت سهام با استفاده از روش داده کاوی

پریسا دانشجو[۱]، مجتبی حاجی غلامی [۲]

پریسا دانشجو، آزاد تهران غرب[۱] / دانشکده فنی ، daneshjoo.p@wtiau.ac.ir

مجتبی حاجی غلامی، آزاد تهران غرب[۲] ، m.hajigholami@yahoo.com

چکیده

زمینه و هدف:

مقاله حاضر به بررسی گونه‌های متنوعی از روش‌های داده‌کاوی می‌پردازد که در حوزه تجزیه و تحلیل بازارهای مالی کاربرد دارند و به طور ویژه تمرکز خود را بر پیش‌بینی تحرکات و روندهای بازار سهام معطوف می‌دارد. مطالعه ما نشان می‌دهد، از آنجایی که بازارهای مالی پویا و متغیر هستند و همواره تحت تأثیر عوامل اقتصادی، سیاسی و اجتماعی قرار دارند، استفاده از روش‌های یادگیری ماشینی و داده‌کاوی می‌تواند در پیش‌بینی دقیق‌تر حرکات قیمتی سهام مؤثر واقع شود.

با توجه به داده‌های گسترده و پیچیده موجود در بازارهای مالی، روش‌های داده‌کاوی می‌توانند ظرفیت فراوانی در کشف الگوهای پنهان و تعیین ارتباط میان متغیرهای مختلف داشته باشند. در این راستا، الگوریتم‌های مختلف یادگیری ماشینی مانند شبکه‌های عصبی م صنوعی، ما شین‌های بردار پ شتیبان و جنگل‌های ت صادفی به عنوان مثال مورد ا ستفاده قرار می‌گیرند و در کنار تجزیه و تحلیل‌های آماری، به بهبود قابلیت‌های تحلیل‌گران و سرمایه‌گذاران در تصمیم‌گیری‌های اقتصادی کمک می‌کنند.

ا ستفاده از داده‌های بزرگ و تحلیل‌های پیچیده همچنین در تو سعه راهبردهای معاملاتی هو شمندانه که می‌توانند به بهینه سازی بازگ شت سرمایه کمک کنند، تاثیری بسزا داشته‌است. برای نمونه، تحلیلگران می‌توانند با ادغام داده‌های احساسی حاصل از شبکه‌های اجتماعی در مدل‌های پیش‌بینی خود، دقت تخمین‌های خود را ارتقا دهند. این مطالعه تأکید دارد که توسعه پایدار در بازارهای مالی نیازمند درک عمیق‌تر و تحلیلی دقیق‌تر از داده‌ها است که در نهایت منجر به تصمیم‌گیری‌های مبتنی بر داده و فرآیندهای معاملاتی قوی و مستحکم‌تر می‌شود.

کلید واژه‌ها:

توسعه پایدار، داده‌کاوی، داده‌های بزرگ، شبکه عصبی مصنوعی، یادگیری ماشینی

۱-۱. مقدمه

پیش‌بینی بازار سهام با استفاده از تکنیک‌های داده‌کاوی، توجه دانشگاهیان، محققان و سرمایه‌گذاران را به خود جلب کرده است. بازار سهام حجمی عظیم از داده‌های ارزشمند را تولید می‌کند. به‌منظور ارائه اطلاعات مفید به سرمایه‌گذاران برای تصمیم‌گیری، پیگیری روش‌های مؤثر برای تجزیه و تحلیل و خلاصه کردن داده‌های بازار سهام به عنوان یک چالش اساسی در عصر حاضر مطرح شده است. بازار سهام آشفته است و داده‌های آن به دلیل آسیب پذیری چشم‌انداز سرمایه‌گذاران، عوامل سیاسی، ساختار اقتصادی و بلایای طبیعی، آشفته، غیرخطی و غیر ایستا است. برای مواجهه با چنین داده‌هایی، روش‌های داده‌کاوی موثرترین فناوری شناخته شده‌اند. این روش‌ها برای کمک به محققان در کشف الگوهای پنهان و ناشناخته طراحی شده‌اند. دسترسی و فراوانی داده‌های مالی مستلزم استفاده از ابزارهای داده‌کاوی در تحقیقات بازار سهام است. داده‌کاوی هنر و علم تحلیل پایگاه‌های داده برای یافتن روندها و ناهنجاری‌ها است و عنصری از کشف دانش گسترده‌تر در فرآیند پایگاه‌های داده (KDD)[1] است. یک فرآیند تکراری است که شامل جمع‌آوری داده‌ها، تبدیل آن، کاهش داده‌ها و سپس داده‌کاوی می‌شود. این روش را می‌توان به صورت رسمی به صورت «فرآیند سازمان‌یافته شناسایی الگوهای معتبر، بدیع، مفید و قابل درک از مجموعه داده‌های بزرگ و پیچیده» تعریف کرد. داده‌کاوی شامل استخراج اطلاعات از داده‌های موجود با بررسی الگوها و روابط بین ویژگی‌ها با استفاده از روش‌هایی مانند الگوریتم‌های یادگیری ماشین (ML)[2] است. نوع الگوریتم داده‌کاوی که باید استفاده شود، بر اساس وضعیت موجود و طبیعت داده‌های موجود تعیین می‌شود. از آنجا که روش کشف دانش در پایگاه داده‌ها(KDD) تکراری است، برخی از فرایندها ممکن است نیاز به اعمال مجدد و چندین بار تجدیدنظر داشته باشند تا نتایج خوبی به دست آیند. روش‌های سنتی محدودیت‌های مختلفی، از جمله عدم کارایی در مدیریت مجموعه داده‌های بزرگ و متغیرهای چند بعدی، مدل‌های پیش‌بینی و برآورد ضرایب عوامل دارند.

این تکنیک‌ها، به جزء اساسی تحقیقات پیش‌بینی سهام در سال‌های اخیر تبدیل شده‌اند. به طور سنتی، محققان از تکنیک‌های مرسوم پیش‌بینی مانند میانگین متحرک، هموار سازی نمایی، رگرسیون خطی و مدل‌های میانگین متحرک تلفیقی اتورگرسیو(arima) برای تصمیم‌گیری استفاده می‌کردند. با این حال، پیش‌بینی مبتنی بر تکنیک داده‌کاوی، جایگزین قدرتمندی برای روش‌های سنتی شده‌است. تکنیک‌های سنتی نتایج معناداری را در مورد مؤلفه‌های قابل شمارش و ابعاد پیش‌بینی عددی متناهی ارائه می‌دهند، اما داده‌های انبوه و چندبعدی فقط می‌توانند با استفاده از تکنیک‌های داده‌کاوی انجام شوند. تکنیک‌های داده‌کاوی نسبت به روش‌های سنتی در پیش‌بینی پیچیده بهتر هستند، زیرا این روش‌ها توانایی بهبود دقت پیش‌بینی‌ها را دارند و تابع زیان را به حداقل می‌رسانند که با مجموع مربعات خطا در پیش‌بینی محاسبه می‌شود.

---

1. Knowledge Discovery in Databases (KDD)
2. Machine Learning (ML)
3. Artificial Neural Network (ANN)

4. Support Vector Machine (SVM)
5. Principal Component Analysis (PCA)

یکی از مهم‌ترین وظایف مالی داده‌کاوی، پیش‌بینی قیمت سهام است. این امر مستلزم تحلیل روندهای بازار، تدوین راهبردهای سرمایه‌گذاری، تعیین زمان بهینه خرید سهام و تصمیم‌گیری نهایی برای خرید سهام است. تصمیم‌گیرندگان به شدت علاقه‌مند به پیش‌بینی روند شاخص بازار سهام و روندهای قیمت سهام برای ایجاد معاملات سودآور هستند. هدف از پیش‌بینی کاهش ریسک(خطر) تصمیم‌گیری مالی بد است. با این حال، پیش‌بینی بازارهای سهام یک روش چالش برانگیز است، زیرا دینامیک بازار، بحرانی و ا سا ساً غیر خطی ا ست. اگرچه تجزیه و تحلیل رفتار حرکت سهام یک کار چالش برانگیز ا ست، تکنیک‌های داده‌کاوی می‌توانند سرمایه‌گذار را راهنمایی کنند تا تصمیمات سرمایه‌گذاری بهتری بگیرد.

۱-۲. اهمیت و ضرورت انجام تحقیق

با توجه به دسترسی به طیف وسیعی از تکنیک‌های داده‌کاوی، ابزارهای پردازش و تکنیک‌های مختلف برای پیامدها، نیاز به شناخت تکنیک‌های مناسب و قابل‌اعتماد در حوزه پیش‌بینی سهام و درک نقاط قوت و ضعف داده‌کاوی وجود دارد. علاوه بر این، کشف انواع داده‌های ورودی، روش‌های پردازش و معیارهای خروجی برای کمک به سرمایه‌گذاران، محققان و دانشگاهیان نیز لازم است. مطالعات قبلی با هدف تعیین تکنیک‌های دقیق داده‌کاوی انجام شده‌است، اما اطلاعاتی بیشتر در مورد کاربرد این تکنیک‌ها مانند پیش‌بینی سودآوری، حرکت کوانتومی سهام و استفاده از مدل‌های ترکیبی می‌توان استخراج کرد. بنابراین، پژوهش حاضر با هدف بررسی پتانسیل(ظرفیت) تکنیک‌های داده‌کاوی انجام شده‌است و بدین وسیله دانشگاهیان، سرمایه‌گذاران و محققان را قادر می‌سازد تصمیمات بهتری اتخاذ کنند.

۱-۳. جنبه جدید بودن و نوآوری در تحقیق

آخرین تحقیقات و بررسی‌ها نشان می‌دهند که تکنیک‌های جدید و پیشرفته‌تری از داده‌کاوی، از جمله یادگیری عمیق و یادگیری ماشین برای تحلیل بازار سهام استفاده می‌شوند. این تکنیک‌ها قادر به کشف الگوهای پیچیده‌تر و غیرخطی در داده‌ها هستند که می‌تواند به پیش‌بینی دقیق‌تر و موثرتر بازار سهام منجر شود.

مثال‌هایی از نوآوری‌ها :

- استفاده از شبکه‌های عصبی کانولوشنی (CNN) و شبکه‌های عصبی بازگشتی (RNN) برای تحلیل توالی زمانی قیمت سهام.
- استفاده از تکنیک‌های تقویت یادگیری (Reinforcement Learning) برای تصمیم‌گیری در مورد خرید و فروش سهام.
- استفاده از داده‌های بزرگ و انواع مختلف داده‌ها مانند اخبار، شبکه‌های اجتماعی و داده‌های مالی برای تحلیل و پیش‌بینی بازار سهام.

به طور کلی، نوآوری در این حوزه به معنای استفاده از تکنیک‌های پیشرفته‌تر و داده‌های متنوع‌تر برای تحلیل و پیش‌بینی دقیق و صحیح‌تر بازار سهام است. با گسترش فناوری و دسترسی به داده‌های بیشتر، این حوزه همچنان در حال توسعه و پیشرفت است.

۴-۱. اهداف مشخص تحقیق

۱. بررسی و ارزیابی کارایی تکنیک‌های مختلف داده‌کاوی در پیش‌بینی بازار سهام.
۲. توسعه و ارائه مدل‌های پیشرفته‌تر براساس تکنیک‌های داده‌کاوی برای پیش‌بینی بازار سهام بر اساس داده‌های موجود.
۳. تأکید بر نقش داده‌های بزرگ و متنوع در افزایش دقت پیش‌بینی‌ها.
۴. مقایسه تکنیک‌های داده‌کاوی مبتنی بر یادگیری عمیق با روش‌های سنتی تر.
۵. کشف الگوها و روابط پنهان در داده‌های بازار سهام که ممکن است برای سایر تحلیل‌گران و سرمایه‌گذاران غیرقابل تشخیص باشد.

در عصر کنونی، با پیشرفت‌های چشمگیر در فناوری اطلاعات و تجمیع حجم انبوهی از داده‌ها، روش‌های نوینی برای تحلیل و درک بازارهای مالی به وجود آمده‌اند. یکی از این روش‌ها، داده‌کاوی است که به عنوان ابزاری قدرتمند در پیش‌بینی حرکت‌های بازار سهام شناخته می‌شود. توانایی تشخیص الگوهای پیچیده و پیش‌بینی روندهای آتی در داده‌های گسترده، داده‌کاوی را تبدیل به حوزه‌ای جذاب و مورد توجه در مطالعات مالی کرده‌است.

با توجه به اهمیت ویژه پیش‌بینی رفتار بازار سهام در توسعه سیاست‌های سرمایه‌گذاری و مدیریت ریسک، این تحقیق قصد دارد تا با مروری جامع بر ادبیات موجود، پژوهش‌هایی را که به ا ستفاده از تکنیک‌های داده‌کاوی برای پیش‌بینی قیمت‌های سهام پرداخته‌اند، برر سی نماید. این برر سی شامل تحلیل عملکرد الگوریتم‌های مختلف، از جمله شبکه‌های ع صبی، ما شین‌های بردار پ شتیبان و درخت ت صمیم‌گیری، در بازارهای مالی خواهد بود. همچنین، رونق ا ستفاده از داده‌های بزرگ و تکنیک‌های یادگیری ماشین در این حوزه بیانگر نیاز به تحلیل دقیق‌تر و عمیق‌تر این ابزارها و ارزیابی پتانسیل(ظرفیت) آن‌ها برای بهبود راهبردهای معاملاتی است.

علاوه بر این، این مطالعه به تجزیه و تحلیل اهمیت توسعه و کاربرد مدل‌های داده‌کاوی پایداری می‌پردازد که می‌توانند در برابر تغییرات بازار و شرایط غیرقابل پیش‌بینی مقاوم باشند. مرور ادبیات نظری در این زمینه، به ارزیابی پیشرفت‌های اخیر و دستاوردهای موجود در عرصه پیش‌بینی بازار سهام با استفاده از داده‌کاوی خواهد پرداخت و بحث در مورد دورنمای کاربرد آن‌ها در یک محیط دینامیک بازاری را تسهیل می‌کند.

در پایان، این ادبیات نظری قرار ا ست نق شه راهی برای تحقیقات آتی ارائه دهد، به چالش‌های کلیدی بر سر راه پیش برد تکنیک‌های داده‌کاوی در بازار سهام ا شاره کند و پیشنهادهایی برای رفع این موانع و پیشبرد دانشکدهٔ مالی پیش‌بینی‌کننده ارائه دهد.

5-1. جدول نظریه‌ها:

نام نظریه	دسته بندی	شرح
نظریه بازده مورد انتظار (Expected Return Theories)	نظریه‌های بازار و قیمت‌گذاری	این نظریه‌ها به تعیین میزان بازده‌ای که سرمایه‌گذاران انتظار دارند روی دارایی‌ها به دست آورند، می‌پردازند.
نظریه قیمت‌گذاری اوراق بهادار (Security Pricing Theories)		این نظریه‌ها که شامل مدل‌های قیمت‌گذاری دارایی‌های سرمایه‌ای (CAPM)و نظریه قیمت‌گذاری اوراق بهادار چند عاملی می‌شوند، به تحقیق در مورد رابطه بین ریسک و بازده و تأثیر عوامل متعدد روی قیمت‌گذاری دارایی‌ها می‌پردازند.
نظریه بازار کارا (Efficient Market Hypothesis - EMH)		بیان می‌کند که قیمت‌های سهام در هر زمان تمام اطلاعات موجود را منعکس می‌کنند و بنابراین «کارا» هستند.
نظریه‌های بازار کامل و ناکامل (Perfect and Imperfect Market Theories)		این نظریه‌ها به تفاوت بین بازارهای کامل-که در آنها هیچ مانعی برای ورود و خروج از بازار وجود ندارد- و بازارهای ناکامل که ممکن است شامل موانعی برای ورود یا اطلاعات نابرابر باشند، می‌پردازند.
نظریه تأثیر اطلاعاتی (Information Impact Theory)		این نظریه بررسی می‌کند که چگونه اطلاعات جدید تأثیراتی بلافاصله و گاهی اوقات پیچیده روی قیمت‌های بازار دارند.
نظریه موجودیت (Inventory Theory)	نظریه‌های رفتاری	این نظریه که بیشتر در مدیریت سرمایه‌گذاری به کار می‌رود، بر میزان دارایی‌های قابل معامله و چگونگی تأثیر آن بر قیمت‌ها در بازار سهام تمرکز دارد.
نظریه رفتار مالی (Behavioral Finance Theory)		این دیدگاه به مطالعهٔ تأثیر روان‌شناسی انسانی بر رفتار سرمایه‌گذاران و نتایج بازار می‌پردازد.

نظریه سیگنالینگ (Signaling Theory)		بررسی این موضوع می‌پردازد که چگونه شرکت‌ها از طریق سیگنال‌های خود مثل تقسیم سودها یا اعلانات مختلف، اطلاعات را به بازار منتقل می‌کنند.

۶. نظریه پرتفوی و انتخاب سرمایه (Portfolio and Capital Choice Theories)	نظریه‌های مدیریت ریسک و سرمایه‌گذاری	این نظریه‌ها به تحلیل روش‌هایی که سرمایه‌گذاران برای ترکیب دارایی‌ها و مدیریت ریسک اتخاذ می‌کنند، می‌پردازد.
نظریه پذیرش ریسک (Risk Appetite Theories)		این نظریه‌ها به بررسی رویکردها و تمایلات سرمایه‌گذاران نسبت به ریسک و چگونگی تأثیر آن بر انتخاب‌های معاملاتی و قیمت‌های بازار می‌پردازند.
نظریه های نوین پرتفولیو (Modern Portfolio Theories)		این نظریه‌ها به بررسی تکنیک‌های مختلف سرمایه‌گذاری و تعیین میزان بهینه ریسک و بازده در انتخاب دارایی‌ها می‌پردازند.
نظریه‌های مربوط به بازار مالی به عنوان سیستم پیچیده (Financial Markets as Complex Systems)	نظریه‌های اقتصادی	این دیدگاه به مطالعهٔ تعاملات متقابل و رفتارهای پیچیدهٔ بازارهای مالی به شکلی غیرخطی می‌پردازد که در آن اجزای مختلف بازار تأثیرات غیرمتوقعی بر یکدیگر می‌گذارند.
نظریه بازی‌ها (Game Theory)		در این نظریه به مطالعه رفتارهای رقابتی سرمایه‌گذاران در بازارهایی که تصمیمات یک شخص می‌تواند بر روی نتایج برای دیگران تأثیر بگذارد، پرداخته می‌شود.

نظریه پذیرش ریسک (Risk Appetite Theories)	نظریه‌های پردازش و تحلیل داده‌ها	این نظریه‌ها به بررسی رویکردها و تمایلات سرمایه‌گذاران نسبت به ریسک و چگونگی تأثیر آن بر انتخاب‌های معاملاتی و قیمت‌های بازارمی‌پردازند.
الگوریتم‌های ماشین برای یادگیری (Machine Learning Algorithm		در مدل‌های پیش‌بینی داده‌کاوی، از الگوریتم‌های یادگیری ماشین مانند شبکه‌های عصبی، ماشین‌های بردار پشتیبان(SVM) ، درخت تصمیم و یادگیری عمیق (Deep Learning) برای پیش‌بینی روندهای قیمت سهام استفاده می‌شود.
نظریه هزینه معاملات (Transaction Cost Theory)	نظریه‌های مبتنی بر هزینه‌ها	این نظریه به هزینه‌هایی که به هنگام خرید و فروش دارایی‌های مالی متحمل می‌شویم و چگونگی تأثیر این هزینه‌ها بر تصمیم‌های سرمایه‌گذاری می‌پردازد.

6-1. مرور ادبیات و سوابق مربوطه

در مرور ادبیات و سوابق مربوطه به «کاربرد و عملکرد تکنیک‌های داده‌کاوی در بازار سهام» باید به چند بخش مهم توجه شود. این مرور به معرفی مباحث اصلی، بررسی کاربردها و ارزیابی نتایج تحقیقات قبلی، به چالش کشیدن فرضیات موجود و طرح مسائل و جهات تحقیقی آینده می‌پردازد. در زیر، به تفصیل، این بخش‌ها را بررسی می‌کنیم. تحلیل و پیش‌بینی دقیق رفتار بازارهای مالی، همواره یکی از مهم‌ترین چالش‌های اقتصاددانان، محققان علوم داده و سرمایه‌گذاران بوده است. پیچیدگی‌های ذاتی در حرکات بازار سهام و تأثیر عوامل گوناگون بر آن، موجب شده‌است تا استفاده از رویکردهای مبتنی بر داده برای دستیابی به پیش‌بینی‌های موثر افزایش یابد. در اینجا نگاهی اجمالی بر تحقیقات گذشته و دستاوردهای کنونی در این زمینه خواهیم داشت.

۱. مقدمه و زمینه تحقیق:

در این بخش، به بیان اهمیت موضوع و دلایل انتخاب آن می‌پردازیم. باید بررسی کنیم که چرا مطالعه تکنیک‌های داده‌کاوی در بازار سهام مهم است و چگونه این تکنیک‌ها می‌توانند به درک بهتر بازارهای مالی و تصمیم‌گیری‌های سرمایه‌گذاری کمک کنند. همچنین، باید به تشریح دیدگاه‌ها و نظریات مربوط به کارایی بازار بپردازیم و تأثیر آن‌ها بر تکامل ابزارهای تحلیلی و تکنیک‌های معاملاتی را مورد بررسی قرار دهیم.

- Malkiel, B.G. (2003). *The Efficient Market Hypothesis and Its Critics*. Journal of Economic Perspectives, 17(1), 59-82.

۲. تاریخچه و تکامل تکنیک‌های داده‌کاوی در بازارمالی:

ا ستفاده از تکنیک‌های داده‌کاوی در حال افزایش پیش‌بینی بازار سهام ا ست. با د ستر سی به نرم افزارهای پیچیده و افزایش علاقه محققان و متخصصان، انتظار می رود دامنه به سرعت رشد کند. مطالعه حاضر برتری تکنیک‌های داده‌کاوی را در پیش‌بینی بازار سهام در مقایسه با تکنیک‌های سنتی مانند رگر سیون خطی و مدل‌های گردش ت صادفی ن شان داده ا ست. علاوه بر این، یک تغییر وا ضح از ا ستفاده از یک تکنیک به تکنیک‌های ترکیبی با هدف بهبود دقت مدل‌های پیش‌بینی وجود دارد. در حال حاضر، حوزه تحقیق به‌طورعمده بر بهبود دقت ریاضی مدل‌های پیش‌بینی سهام مبتنی بر داده‌کاوی تمرکز دارد. نیاز به حرکت بیش از دقت مدل برای سودآوری مدل وجود دارد.

Application and performance of data mining techniques in stock market: A review 2022

۳. رویکردهای مختلف داده‌کاوی و معرفی الگوریتم‌ها:

در این مقاله به برر سی جامع الگوریتم‌های مختلف داده‌کاوی از جمله شبکه‌های عصبی، ما شین‌های بردار پشتیبان، روش‌های درخت ت صمیم و یادگیری تقویتی که در تحلیل داده‌های مالی به کار رفته‌اند، می‌پردازیم. همچنین، به نحوه اعمال این روش‌ها بر داده‌های قیمتی و مقایسه عملکرد آن‌ها در پیش‌بینی بازار اشاره می‌کنیم.

- Han, J., Pei, J., & Kamber, M. (2011). *Data Mining: Concepts and Techniques, Third Edition*. Morgan Kaufmann Publishers.

۴. بررسی مطالعات موردی: کاربردهای واقعی و نتایج:

در این مقاله مفهوم یک بستر داده‌کاوی بازار مصنوعی ارائه شده است که ترکیبی از شبیه‌سازی بازار مصنوعی و داده‌کاوی است. مزیت این سکو این است که همه چیز در بازار مصنوعی می‌تواند کنترل و مشاهده شود. بنابراین با تغییر عوامل موجود در بازار مصنوعی و یا مؤلفه‌های حاکم بر آن بازار می‌توان شرایط بسیاری را آزمایش کرد. از این رو، در ترکیب با روش‌های داده‌کاوی، با توجه به داده‌های واقعی و بررسی اینکه چگونه عوامل مختلفی در پیش‌بینی بازارهای مالی نقش دارند، فرض بر این بود که این سکو به ما امکان ارزیابی نسبی روش‌های داده‌کاوی برای بازار مالی را می‌دهد، همچنین یک مدل عملی از مفهوم پیشنهادی خود را به عنوان مثال نشان دادیم سپس با استفاده از مدل عملی به بررسی نتایج پرداختیم. به عنوان یک مثال عملی، ما یک مدل شبیه‌سازی بازار مصنوعی سطح زمانی tick و داده‌کاوی برای پیش‌بینی تغییرات کوتاه مدت قیمت و بررسی تاثیر چهار عامل بازار مالی بر عملکرد مدل‌های داده‌کاوی ساختیم. از میان این عوامل، مشاهده شد که مقیاس نویز بازارهای مالی تاثیر معناداری بر عملکرد پیش‌بینی روش‌های داده‌کاوی دارد که اثر پیچیده‌ای خواهد داشت. در نهایت به بررسی پتانسیل‌ها و کاربردهای آینده مفهوم خود می‌پردازیم. در این مقاله، اعتبار و مزایای مدل مفهومی و عملی خود در آینده را مورد بررسی قرار می‌دهیم و امیدواریم که محققان دیگر از این مفهوم استفاده کنند و بتوانند پاسخگوی پرسش‌های مختلف در بازارهای مالی باشند. همچنین

قصد داریم تا موارد عملی‌تری از مفهوم خود بسازیم و سودمندی این مفهوم را حتی بیشتر هم نشان دهیم.

Concept and Practice of Artificial Market Data Mining Platform 2022.

۵. مسائل و چالش‌ها در داده‌کاوی بازار سهام:

بزرگترین چالش استفاده از پایگاه‌های داده برای تصمیم‌گیری، استخراج دقیق محتوای اطلاعات پنهان در داده‌های خام است. به طور معمول، غربالگری دستی برای چنین اهدافی به کار گرفته می‌شود که با بزرگ شدن حجم داده‌ها غیر عملی و ناکارآمد می شوند. همچنین پیش‌بینی بازار سهام شامل پردازش مقادیر زیادی از قیمت‌های سهام و داده‌های حجم است. به منظور رفع این مشکل، در این پژوهش سعی شده است از روش طبقه‌بندی داده‌کاوی استفاده شود. علاوه بر این، این مطالعه با استفاده از روش طبقه‌بندی داده‌های قیمت سهام به منظور هدایت بهتر سرمایه‌گذاران در تدوین راهبردهای تجاری سودآور انجام شده است. طبقه‌بندی داده‌ها را می‌توان به روش‌های مختلفی انجام داد: از جمله این روش‌ها طبقه‌بندی با درخت تصمیم است. این روش نمایش گرافیکی تمام نتایج ممکن و مسیرهای زیربنایی برای رسیدن به آنها را ارائه می‌دهد. (با توجه به این تحقیق، از مدل درخت تصمیم، فرآیند استاندارد صنعت متقاطع برای داده‌کاوی برای تحلیل و پیش‌بینی قیمت سهام نمونه شرکت از پنج بخش مختلف پذیرفته شده در بورس اوراق بهادار پاکستان استفاده شده است.)

(Ampomah, Qin, & Nyame, 2020; Basak, Kar, Saha, Khaidem, & Dey, 2019; Enke & Thawornwong, 2005; Guresen, Kayakutlu, & Daim, 2011; Niaki & Hoseinzade, 2013; Shah, Isah, & Zulkernine, 2019; Wang, Wang, Zhang, & Guo, 2011)

۶. کاربرد تکنیک‌های داده‌کاوی در مدیریت ریسک و بهینه‌سازی:

یافته های تحقیق نشان می‌دهد که سرمایه‌گذاران و مدیران پرتفوی(سود سهام) می‌توانند از روش‌های داده‌کاوی برای پیش‌بینی قیمت سهام با دقت قابل قبول در PSX ا ستفاده کنند. علاوه بر این، یافته‌های تحقیق می‌تواند به شرکت‌کنندگان بازار در تدوین راهبردهای تجاری سودآور در مقایسه با روش‌های مرسوم پیش‌بینی سهام کمک کند. به ویژه در بازارهای درحال ظهور، این رویکرد برای سرمایه گذاران به‌منظور بررسی تصمیمات سرمایه‌گذاری آنها مفید است، زیرا تحقیقات گذشته نشان داده‌است که بازارهای نو ظهور، در حال افزایش هستند. با این حال، میزان نسبتا پایین دقت نیز، با توجه به اینکه قیمت سهام در برابر افراد مختلف آسیب پذیر است، دشواری پیش‌بینی قیمت سهام را فقط با استفاده از ویژگی‌های مطالعاتی مربوط به تاریخچه قیمت و حجم سهام برجسته می‌کند.

- Forecasting on Stock Market Time Series Data Using Data Mining Techniques 2022.

۷. چشم‌انداز آینده و فناوری‌های نوظهور:

ارتباط بلاکچین با داده‌کاوی و پیش‌بینی در بازارهای مالی به این صورت است که بلاکچین به عنوان یک فناوری ثبت و انتقال داده‌ها، داده‌های مختلفی از جمله تراکنش‌های مالی، قراردادهای هوشمند و داده‌های مربوط به زنجیره تأمین را در

خود ذخیره می‌کند. این داده ها معمولاً حاوی اطلاعاتی مفید برای تحلیل الگو ها، رو ند ها و پیش‌بینی رو یداد های آینده هستند.

در این زمینه، داده‌کاوی به عنوان یک فرآیند اســـتخراج الگوهای مفید و اطلاعات قابل اســـتفاده از داده‌ها، می‌تواند به بررســـی داده های موجود در بلاکچین کمک کند. این فرآیند می‌توا ند الگو ها، رو ند ها و اطلا عات مفیدی را کشـــف کند که به تصمیم‌گیری‌های مالی، پیش‌بینی روندهای آینده و بهبود فرآیندهای مالی کمک کند.

به عنوان مثال، داده‌کاوی می‌تواند به تحلیل الگوهای تراکنش‌های مالی در بلاکچین کمک و الگوهای تقا ضا و عر ضه را شنا سایی کند. همچنین، با استفاده از داده‌کاوی می‌توان الگوهای تقلب و فعالیت‌های غیرقانونی را نیز شناسایی کرد.

بنابراین، این ارتباط می‌تواند به بهبود تصمیم‌گیری‌های مالی و پیش‌بینی روندهای بازار مالی کمک کند.

- The Sustainable Development of Financial Topic Detection and Trend Prediction by Data Mining 2021.

۸. نتیجه‌گیری و جهت‌گیری‌های آتی تحقیق:

به طور خلاصه، مدل‌های مختلفی از پیش‌بینی سهام وجود دارد که نتایج خوبی به دست آورده‌اند. با این حال، مشکلات زیادی وجود دارد که هنوز به طور کامل حل نشده‌اند. چالش‌ها و دیدگاه‌های احتمالی تحقیقات آینده عمدتا در چهار حوزه زیر هستند. اغلب مطالعات از یک الگوریتم واحد برای ساخت مدل‌های پیش‌بینی استفاده کرده‌اند، در حالی‌که مطالعات ترکیب‌کننده مدل‌های یادگیری ماشینی آماری با روش‌های سنتی تحلیل سهام(تحلیل بنیادی و تحلیل شاخص فنی) فاقد آن هستند. فرآیند پیش‌بینی، اغلب ارزش ذاتی سهام و تاثیر خارجی عوامل بازار را نادیده می‌گیرد. در آینده می‌توان از مزایای الگوریتم‌های بهینه، تنظیم ویژگی‌های مدل، بهینه‌سازی میانگین وزنی مدل برای ساخت یک مدل ترکیبی برای پیش‌بینی استفاده کرد. ما باید از تحلیل عاملی و روش‌های دیگر برای انتخاب ویژگی‌های شاخص مربوط به سهام استفاده کنیم. همچنین میتوان از تصاویر بازار سهام استفاده کرد که می‌تواند به طور کامل قوانین بازارهای سهام مختلف را ثبت و بازار سهام را عمیق‌تر کشف کند. اغلب روش‌های پیش‌بینی قیمت سهام فعلی، بدون در نظر گرفتن مطالعات متنی مانند اخبار مالی، گزارش‌های سود شرکت و نظرات نوار سهام که ممکن است بر سرمایه‌گذاران تاثیر داشته باشد، از داده‌های تجاری هیستوریکال(تاریخی) برای تحلیل و پیش‌بینی استفاده می کنند، بنابراین، تاثیر اطلاعات متنی بر بازار سهام باید به طور کامل در نظر گرفته‌شود. یادگیری عمیق باید برای پیش بیان قیمت سهام به کار رود. ما داده‌های متنی مانند تصمیمات گفتاری سرمایه‌گذاران و اخبار مالی را کمی و توجه سرمایه‌گذاران را با هم ترکیب می‌کنیم. همچنین مدل‌هایی برای ترکیب آنها با داده‌های تاریخی تجارت سهام و تجزیه و تحلیل و پیش‌بینی با استفاده از منابع مطالعاتی چندگانه می‌سازیم.

Progress and prospects of data-driven stock price forecasting research 2023

این توضیحات می‌توانند به تعیین گام‌های بعدی در تحقیق کمک کنند و برای فهمیدن زمینه‌هایی که نیاز به مطالعات بیشتری دارند، مهم هستند.

7-1. نتیجه‌گیری

استفاده از تکنیک‌های داده‌کاوی در حال افزایش پیش‌بینی بازار سهام است. با دسترسی به نرم‌افزارهای پیچیده و افزایش علاقه محققان و متخصصان, انتظار می‌رود دامنه به سرعت رشد کند. مطالعه حاضر برتری تکنیک‌های داده‌کاوی را در پیش‌بینی بازار سهام در مقایسه با تکنیک‌های سنتی مانند رگرسیون خطی و مدل‌های گردش تصادفی نشان داده‌است. علاوه بر این، یک تغییر واضح از استفاده از یک تکنیک به تکنیک‌های ترکیبی با هدف بهبود دقت مدل‌های پیش‌بینی وجود دارد. در حال حاضر، حوزه تحقیق عمدتاً بر بهبود دقت ریاضی مدل‌های پیش‌بینی سهام مبتنی بر داده‌کاوی تمرکز دارد. تکنیک‌ها و الگوریتم‌های متنوع مورد استفاده در این زمینه، از شبکه‌های عصبی و ماشین‌های بردار پشتیبان گرفته تا درختان تصمیم، به دانشمندان داده و تحلیلگران مالی این امکان را می‌دهند که با دقت و سرعت بیشتری به تحلیل بازار اقدام کنند.

با وجودپیشرفت‌های قابل توجه در این عرصه، همچنان چالش‌هایی نیز وجود دارد، مانند مدیریت داده‌های نامتعارف و اعتبارسنجی مدل‌ها. علاوه بر این، تاکید زیادی بر روی نیاز به توسعه مدل‌هایی است که بتوانند در برابر نوسانات بازار مقاومت نشان دهند و نتایج قابل اتکایی را فراهم آورند. با وجود پیشرفت‌های اخیر در تکنیک‌های داده‌کاوی و یادگیری ماشین، مطالعات نشان می‌دهند که هنوز پتانسیل(ظرفیت) زیادی برای بهبود و توسعه بیشتر وجود دارد. پیوستگی بین تحقیقات علمی و کاربردهای عملی نیازمند تلاش مضاعف در زمینه‌های دقت و پایداری مدل‌های پیش‌بینی است. برای نتیجه‌گیری، به نظر می‌رسد که مدل‌های ترکیبی که داده‌کاوی و یادگیری ماشینی را یکپارچه می‌کنند، پتانسیل داشته‌اند تا عملکرد قابل‌توجهی در بازارهای سهام مختلف از خود نشان دهند. منطق نهفته در این عمل، این است که با استفاده از نقاط قوت متعدد روش‌ها، می‌توان خطاهای مربوط به هر روش فردی را متعادل کرد.

در ادامه به یک نتیجه‌گیری فرضی اشاره می‌کنیم و جدولی ارائه می‌دهیم که روش‌های رایج پیش‌بینی بازار سهام را با یکدیگر مقایسه می‌کند. برای دقت بیشتر، باید این اطلاعات را با تحلیل داده‌های واقعی و مطالعات تجربی مورد بررسی قرار داد. بر اساس مرور ادبیات انجام شده، سه روش برجسته در پیش‌بینی بازار سهام شناسایی شده‌اند: شبکه‌های عصبی، ماشین‌های بردار پشتیبان(SVM) و تحلیل زمانی سری‌های زمانی. هر یک از این تکنیک‌ها نقاط قوت و ضعف خاص خود را دارند. شبکه‌های عصبی به دلیل قابلیت تقریب توابع غیرخطی و توانایی در یادگیری پیچیده‌ترین الگوهای بازار مورد توجه قرار گرفته‌اند. ماشین‌های بردار پشتیبان در دسته‌بندی و پیش‌بینی‌های دقیق، عملکرد خوبی دارند، به ویژه زمانی که مقدار داده محدود است.

تحلیل زمانی سری‌های زمانی که شامل روش‌های ARIMA می‌شود، برای داده‌های مالی که نمایش منظم ترند و فصلیت دارند مفید است.

جدول مقایسه روش‌های پیش‌بینی بازار سهام:

نام روش	نقاط قوت	نقاط ضعف
شبکه‌های عصبی (ANN)	۱. توانایی مدل‌سازی روابط غیرخطی پیچیده میان ورودی‌ها و خروجی‌ها. ۲. با دیتاست‌های بزرگ و پیچیده خوب عمل می‌کند. ۳. قابلیت خودیادگیری از داده‌ها و بهبود عملکرد با افزایش داده.	۱. حساس به تنظیمات پارامتر و ممکن است دچار بیش‌برازش شود. ۲. نیازمند منابع قدرتمند و محاسبات سنگین. ۳. تفسیرپذیری کمتر مدل‌ها
ماشین بردار پشتیبان (SVM)	1. عملکرد خوب به دلیل بهینه‌یابی مرز تصمیم.(Decision Boundary) ۲. کارآمد در فضاهای با ابعاد بالا. ۳. کمتر دچار بیش‌برازش می‌شود	۱. انتخاب پارامترها مانند C و هسته می‌تواند دشوار باشد. ۲. نیازمند تکنیک‌های مقیاس‌بندی موثر داده‌ها پیش از آموزش. ۳. کارآیی کم بر روی دیتاست‌های بسیار بزرگ به علت افزایش هزینه محاسباتی
تحلیل زمانی سری‌های زمانی (مانند ARIMA)	۱. مدل‌سازی پایدار و پیش‌بینی بلندمدت در صورت ثابت بودن سری زمانی. ۲. مناسب برای داده‌هایی با الگوهای فصلی و روند مشخص. ۳. تکنیک‌های ارزیابی و تشخیص استاندارد و قابل درک.	۱. فرض بر ثابت بودن سری زمانی و تنظیم نامناسب در مواجهه با داده‌های غیرثابت. ۲. عدم قابلیت در نظر گرفتن روابط پیچیده غیرخطی. ۳. محدودیت در مدل‌سازی فقط بر اساس داده‌های گذشته و استفاده نکردن از متغیرهای توضیحی خارجی.
الگوریتم‌های ژنتیکی (Genetic algorithm)	۱. توانایی در پیدا کردن راه‌حل‌های نزدیک به بهینه حتی در فضاهای جست‌وجوی بزرگ. ۲. قابلیت همزمان‌سازی و تطبیق‌پذیری با تغییرات محیطی	۱. نیاز به تنظیمات گسترده و دقیق مولفه‌های الگوریتم. ۲. ممکن است در بهینه‌یابی محلی گیر کند و به جواب‌های جهانی نرسد. ۳. زمان محاسباتی به‌نسبت بالا.
درخت تصمیم (Decision Trees)	۱. مدل‌های ساده و قابل فهم که می‌توانند تفسیرپذیر باشند. ۲. قادر به کار با انواع داده‌ها، چه عددی و چه دسته‌بندی شده.	۱. ممکن است دچار بیش‌برازش شوند و نیاز به هرس کردن دارند. ۲. کارایی کمتر در مقابل داده‌هایی که دارای روابط پیچیده و غیرخطی هستند.

یادگیری عمیق (Deep Learning)	توانایی عالی در کشف پیچیدگی‌های غیرخطی و الگوهای داده‌های بسیار بزرگ و پیچیده. پیشرفت‌های بزرگ در تشخیص الگو به واسطه معماری‌های پیشرفته مانند Convolutional Neural Networks (CNNs)و Recurrent Neural Networks (RNNs).	۱. نیاز به مقادیر زیادی از داده‌های برچسب‌دار برای آموزش دارد. ۲. تفسیر نتایج مشکل‌تر است.
مدل رگرسیون لجستیک (Logit Model)	۱. مدل ساده‌ای است که می‌توان به سرعت آموزش داد و برای تفسیر، قابلیت بالایی دارد. ۲. احتمالات خروجی و ارتباط مستقیم با حالت‌های ورودی را نشان می‌دهد.	۱. فرضیات محدودیت‌های خاصی را درباره توزیع داده‌ها دارد و در مواقعی که این فرضیات برقرار نباشد، ممکن است دقت پایینی داشته باشد. ۲. قادر به مدل‌سازی روابط پیچیده نیست.
k-NN (k-Nearest Neighbors)	۱. این مدل آموزشی نیاز به فرضیات خاصی ندارد و درک مفهومی ساده‌ای دارد. ۲. قادر به مدل‌سازی الگوهای پیچیده و غیرخطی است.	۱. برای پیش‌بینی، نیاز به محاسبات بالا و زمان‌بر است، به ویژه برای مجموعه داده‌های بزرگ. ۲. حساسیت به داده‌های نویزی و پرت است و نیاز به تعیین مناسب پارامتر k دارد.
LDA (Linear Discriminant Analysis)	۱. یک مدل ساده و مؤثر برای دسته‌بندی است. ۲. در مواردی که فرضیات LDA برقرار باشند، دقت بالایی دارد و نیازمند پارامترهای کمتری است.	۱. مدل تقریبی است و از فرضیات محدودیت‌های خاصی درباره توزیع داده‌ها استفاده می‌کند. ۲. نمی‌تواند الگوهای پیچیده‌تر داده‌ها را مدل کند.
QDA (Quadratic Discriminant Analysis)	۱. این مدل انعطاف‌پذیری دارد و می‌تواند توزیع‌های احتمالاتی مختلف برای هر کلاس را مدل کند. ۲. در صورتی که فرضیات QDA صدق کنند، دقت بالایی دارد.	۱. نیاز به تعداد نمونه داده‌ای بالا و انعطاف بیش‌اندازه ی می‌تواند منجر به بیش‌برازش شود. ۲. به دلیل پیچیدگی مدل، ممکن است در مقابل داده‌های کمتر مؤثر نباشد.

دقت پیش‌بینی برای هر یک از روش‌ها بستگی به مجموعه داده‌های خاص، تنظیمات مدل و حوزه کاربرد دارد. برخی تحقیقات نشان داده‌اند که مدل‌های ترکیبی که فنون مختلف را ادغام می‌کنند، ممکن است به دقت بالاتری در پیش‌بینی دست یابند. با توجه به بروز و تکامل تکنیک‌های یادگیری ماشین و داده‌کاوی، توصیه می‌شود که برای به دست آوردن دقت مطلوب، از الگوریتم‌های چندگانه برای سنجش و تطبیق عملکرد استفاده شود.

TABLE 16 Prediction performance of various techniques

Technique	ANN	SVM	Combined model	Logit model	QDA	LDA	k-NN
Kara et al. (2011)	75.74	71.52	-	-	-	-	-
Ou and Wang (2009)	-	86.00	86.40 (LS-SVM)	85.60	84.80	84.40	79.60
Yu et al. (2009)	67.56	72.61	82.66 (LS- SVM)	-	-	61.43	-
Choudhry and Garg (2008) (TCS)	-	58.09	61.73 (GA-SVM)	-	-	-	-
Kumar and Thenmozhi (2006)	62.93	68.44	-	59.60	-	56.34	-
Huang et al. (2005)	69.00	73.00	75.00	-	69.00	55.00	-
Kim (2003)	54.73	57.83	-	-	-	-	-

جدول فوق مقایسه عملکرد پیش‌بینی تکنیک‌های مختلف مورد استفاده محققان در مطالعات آنها را نشان می‌دهد. ترجیح NNs برای پیش‌بینی ممکن است ناشی از دقت و نتایج امیدوار کننده آنها باشد.
(Hammad et al., 2009; Majumder & Hussian, 2007; Mizuno et al., 1998; Tjung et al., 2010; Vojinovic et al., 2001).

برتری مدل‌های شبکه عصبی مصنوعی بر مدل‌های رگرسیونی در مطالعه Altay and Satman (2005) نشان داده شده است که درصد بالاتری از نشانه‌های پیش‌بینی شده برای ann نسبت به مدل‌های رگرسیونی را تبیین می‌کند. در مطالعه دیگر، میانگین عملکرد مدل ann (75.74 درصد) در مقایسه با مدل svm (71.52 درصد) از نظر آماری بهتر بود.(Kara et al., 2011)

با این حال، دیدگاه‌های متضادی نیز وجود دارند که محققان svm ها را بر شبکه‌های عصبی ترجیح می‌دهند.

1-8. بررسی تحقیقات پیشین:

بازارهای سهام به طور گسترده‌ای به عنوان مؤلفه‌های کلیدی اقتصاد جهانی شناخته می‌شوند. در سال‌های اخیر، با پیشرفت‌های عمیق در فناوری‌های داده‌کاوی، پژوهش‌های متعددی به بررسی کارایی و تاثیر این تکنولوژی‌ها بر قابلیت پیش‌بینی بازارهای سهام پرداخته‌اند. از بین این پژوهش‌ها می‌توان به مطالعات منتشر شده در سال‌های ۲۰۲۱ تا ۲۰۲۳ اشاره کرد که جنبه‌های مختلف فرآیند پیش‌بینی و تجارت را در بازار سهام مورد کنکاش قرار داده‌اند.

طیف گسترده‌ای از مدل‌ها و چهارچوب‌های داده‌کاوی، از جمله "A data mining framework for financial prediction" در سال ۲۰۲۱، بیانگر تلاش‌های مستمر برای بهبود دقت پیش‌بینی‌های مالی است. در راستای توسعه پایدار، مطالعه "The Sustainable Development of Financial Topic Detection and Trend Prediction by Data Mining" نه تنها به کشف موضوعات مالی می‌پردازد بلکه بر روند پیش‌بینی تأکید می‌کند.

در مقاله "Forecasting stock prices using a data mining method: Evidence from emerging market" منتشر شده در سال ۲۰۲۱، از تکنیک‌های استخراج داده بر اساس الگوهای سابقه‌دار در بازارهای نوظهور استفاده شده و نتایج نشان می‌دهند که روش‌های پیشرفته داده‌کاوی می‌توانند عملکرد خوبی در پیش‌بینی قیمت‌ها حتی در بازارهای نسبتاً ناپایدار داشته باشند.

"Stock Price Prediction Based on Data Mining Combination Model" منتشر شده در سال ۲۰۲۳، نوید بخش ترکیبی از مدل‌های داده‌کاوی است که با به‌کارگیری چندین روش مختلف و مکمل، دقت پیش‌بینی‌ها را بهبود می‌بخشد. این تحقیق نمایان‌گر پیشرفت‌های حاصل از ادغام تکنیک‌های یادگیری ماشین و سایر روش‌های تحلیلی داده‌هاست.

تحلیل فرضیه‌ها و مدل‌ها:

مطالعاتی نظیر "Progress and prospects of data-driven stock price forecasting research" پیشرفت‌ها و دورنمای روش‌های پیش‌بینی قیمت سهام را محور قرار داده‌اند. در این تحقیق، روش‌های نوین داده‌کاوی و تأثیر آن‌ها بر پیش‌بینی قیمت‌ها بررسی شده و این سوال مطرح می‌شود که چگونه فناوری‌های جدید می‌توانند بهینه‌سازی مدل‌های پیش‌بینی موجود و طراحی مدل‌های نوآورانه‌تر را تسهیل کنند.

ارزیابی روش‌ها و عملکرد:

تحقیق "Application and performance of data mining techniques in stock market: A review" به ارزیابی جامعی از تکنیک‌های داده‌کاوی در عمل پرداخته و شاخص‌های عملکرد مختلف را مورد تحلیل قرار داده‌است. این بررسی نشان‌دهنده قابلیت اتکای روش‌های داده‌کاوی و کاربرد آن‌ها در فرآیندهای تصمیم‌گیری مالی است.

شکاف‌های تحقیق:

در پایان، تحقیق "Netflix Stock Price Movements Insights from Data Mining" نمونه‌ای از چگونگی استخراج داده‌های مربوط به یک شرکت خاص و تحلیل روند قیمتی آن است. با استفاده از مطالعه موردی، این کار به ما نشان می‌دهد که چگونه داده‌کاوی در فهم بهتر رفتار بازار و کمک به سازمان‌ها برای تصمیم‌گیری‌های مالی استراتژیک به کار می‌رود.

در حالی که ادبیات تجربی تحقیق موجود پیشرفت‌های قابل توجهی را در زمینه پیش‌بینی قیمت سهام نشان می‌دهد، شکاف‌هایی نیز وجود دارند که فرصت‌هایی برای تحقیقات آینده ارائه می‌دهند. نیازمندی بیشتر به شفاف‌سازی مدل‌های نظری، دقت‌های بهبود یافته در انتخاب متغیرهای ورودی و بررسی آثار سیستماتیک عوامل ماکرواکونومیک بر بازارهای سهام از جمله این شکاف‌ها هستند.

در پایان، این بخش به طور خلاصه شکاف‌های موجود در تحقیقات و چگونگی ساخت یک زمینه محکم برای تحقیق کنونی را آشکار می‌کند و بستری را برای طرح پرسش‌های تحقیقاتی جدید فراهم می‌آورد.

روش‌شناسی تحقیق

روش‌شناسی یک پژوهش در برخورداری از تعریف چگونگی جمع‌آوری، تحلیل و تفسیر داده‌هاست. با توجه به موضوعات مقاله‌های فهرست شده، می‌توان یک روش شناسی عمومی برای تحقیقات مربوط به داده‌کاوی در پیش‌بینی قیمت‌های سهام مشخص کرد که عبارتند از:

۱. تعریف مشکل و فرضیات تحقیق:

- ابتدا به مشکل تحقیق از جمله پیش‌بینی قیمت سهام، ردیابی ترند(معروف)های مالی، یا توسعه راهبردهای تجاری اشاره شده و فرضیات مرتبط با تحقیق تعریف می‌شوند.

۲. جمع‌آوری داده‌ها:

- این فرآیند شامل جمع‌آوری داده‌های تاریخی سهام، داده‌های مالی، شاخص‌های اقتصادی، داده‌های خبری و سایر منابع مرتبط است.

- برای داده‌های زمانی و فرکانسی(پر تکرار و متوالی) مانند قیمت‌های سهام، ممکن است داده‌های روزانه، هفتگی یا ماهانه به‌کار رود.

۳. پیش‌پردازش و تهیه داده‌ها:

- پاک‌سازی داده‌ها برای حذف نویز و داده‌های پرت.

- کار با داده‌های گمشده و رسیدگی به داده‌های بی‌کیفیت.

- نرمال‌سازی و تبدیل داده‌ها برای آماده‌سازی برای تحلیل‌های داده‌کاوی.

۴. انتخاب ویژگی‌ها و کاهش بُعد:

- شناسایی ویژگی‌هایی که بیشترین تأثیر را در پیش‌بینی قیمت سهام دارند.

- استفاده از تکنیک‌هایی مانند PCA یا تحلیل مولفه‌های اصلی برای کاهش بعد داده‌ها و تمرکز بر داده‌های معنادار.

۵. استفاده از مدل‌های داده‌کاوی:

- توسعه و استفاده از مدل‌های داده‌کاوی مختلف مانند شبکه‌های عصبی، دسته‌بندی‌های درختی، روش‌های انسمبل و مدل‌های خطی.

- پیاده‌سازی چندین مدل برای مقایسه و انتخاب بهترین عملکرد با استفاده از معیارهای دقت.

۶. آزمایش و اعتبارسنجی مدل و تحلیل نتایج:

- استفاده از تکنیک‌های اعتبار سنجی مانند اعتبار سنجی متقاطع (cross-validation) برای آزمایش دقت پیش‌بینی‌های مدل بر روی داده‌های ناشناخته.

- تجزیه و تحلیل عملکرد مدل‌ها از طریق معیارهای ارزیابی سنجش خطای پیش‌بینی مانند MAE, RMSE, و ضریب تعیین (R^2).

- تفسیر نتایج و استخراج دانش قابل انتقال به تصمیم‌گیری‌های مالی و تجاری.

مرور گسترده‌ای که بر ادبیات تجربی تحقیقات مرتبط با پیش‌بینی قیمت سهام انجام گرفته، یک دید کلی از پیشرفت‌ها، چالش‌ها و فرصت های موجود در این حوزه تحقیقاتی پردینامیک را فراهم می‌آورد. در این بخش، جنبه های کلیدی بررسی های صورت‌گرفته، ابعاد مهم پیشرفت‌های اخیر و جهاتی که به شناسایی نیازهای تحقیقاتی بعدی منجر شده‌اند، مورد تأمل قرار گرفته‌اند.

یکی از جنبه‌های برجسته که از مرور ادبیات، مشخص می‌شود، توجه فزاینده به تکنیک‌های داده‌کاوی پیشرفته است. این رویکرد های داده‌بنیاد در مطالعاتی مانند "Stock Price Prediction Based on Data Mining Combination Model" نشان‌دهنده یک گرایش به سمت مدل‌های ترکیبی و بردارینیان است که قادر به ادغام پویایی‌های بازار و سیگنال‌های غیرخطی مربوطه هستند. این مدل‌های ترکیبی، با تثبیت دقت و کاهش وابستگی به فرضیات خاص مثل توزیع‌های آماری شناخته شده، قدمی رو به جلو در حوزه پیش‌بینی قیمت سهام را نشان می‌دهند.

با این حال، بازخوردهای عملی این تحقیقات نشان دهنده نیاز به توجه بیشتر به شفافیت مدل‌سازی و تفسیرپذیری نتایج است. علاوه بر این، بر لزوم توجه به نقش پیچیدگی مدل در قابلیت کاربردی تصمیم‌گیری مالی، به عنوان یک مانع بالقوه، تأکید می‌شود. ادبیات تجربی تحقیق نشان می‌دهد؛ با اینکه مدل‌های پیچیده به گرایش‌های جدیدی در داده‌کاوی کمک می‌کنند، اما ممکن است در مواقعی، کاربردی بودن مورد نیاز کارشناسان مالی را تحت تاثیر قرار دهند.

در نهایت، مطالعات حاضر به این نتیجه رسیده‌اند که درک بهتر از ارتباطات میان اطلاعات بازار- به عنوان ورودی‌های مدل و پیش‌بینی‌های حاصل از آن‌ها- اساسی است. تحقیقات مانند " Netflix Stock Price Movements Insights from Data Mining" نمونه‌ای از کاربرد داده‌کاوی در جهت فراهم آوردن بینش‌هایی کاربردی و عملی است که می‌تواند به معامله‌گران کمک کند تا استراتژی‌هایی متناسب با داده‌های واقعی بازار طراحی کنند.

شناسایی این شکاف‌ها و نیازمندی‌های تحقیقاتی نه تنها برای پژوهش‌های آتی بلکه برای توسعه عملی تکنیک‌های پیش‌بینی در دنیای استراتژیک تجارت سهام ضروری است. تقویت ادبیات تجربی تحقیق موجود با تحقیقات دقیق‌تر و جامع‌تر می‌تواند به روشن‌تر شدن مسیر پژوهش‌های آتی کمک شایانی نماید.

نتایج تحلیل داده‌ها و مطالعات مختلف نشان‌دهنده پتانسیل چشمگیر داده‌کاوی در ارتقاء دقت پیش‌بینی قیمت سهام است. تحقیقات نمایانگر آن است که اعمال روش‌های داده‌کاوی می‌تواند به اندازه‌گیری و استخراج ویژگی‌های پیچیده بازار کمک کند و در نتیجه، امکان تدوین راهبردهای معاملاتی دقیق‌تری را فراهم آورد.

ارزیابی دقیق یافته‌ها:

در مطالعه "Forecasting stock prices using a data mining method: Evidence from emerging market 2021"، مشاهده شد که رویکردهای داده‌کاوی قادر هستند تفاوت‌های قابل توجهی را در بازارهای نوظهور ایجاد کنند. از طرف دیگر، مطالعه "Stock Price Prediction Based on Data Mining Combination Model 2023" راهبردهای ترکیبی داده‌کاوی را شناسایی می‌کند که به افزایش قدرت پیش‌بینی می‌انجامد.

تحلیل انتقادی:

حال که پژوهش‌های صورت‌گرفته در مورد " The Sustainable Development of Financial Topic Detection and Trend Prediction by Data Mining 2021" و "Netflix Stock Price Movements Insights from Data Mining 2022" نشان‌دهنده پیشرفت‌های قابل توجهی در تشخیص و پیش‌بینی روند مالی هستند، باید توجه داشت که عدم شفافیت و تفسیرپذیری ممکن است کاربرد واقعی آن‌ها را محدود کند.

با وجود پیشرفت‌های حاصله، داده‌کاوی در پیش‌بینی قیمت سهام با محدودیت‌هایی نظیر تعصب در تجزیه و تحلیل داده‌ها، اشتباهات بالقوه در داده‌های پایه و تغییرات فوری بازار که به سادگی قابل پیش‌بینی نیستند، مواجه است.

1-9. پیشنهادها

پیشنهادهای پژوهشی و تصمیم‌گیری‌های مالی:

پیشنهاد می‌شود که تحقیقات آتی بر روی بهینه‌سازی الگوریتم‌های داده‌کاوی، ترکیب داده‌های بازار متنوع‌تر و به‌کارگیری شبکه‌های عصبی پیچیده‌تر با هدف بهبود دقت و کارایی متغیرهای پیش‌بینی‌کننده تمرکز کنند. این بهبود می تواند از طریق انتخاب ویژگی‌های بهتر، استفاده از الگوریتم‌های پیشرفته یادگیری ماشین، تعدیل پارامترهای مدل و یا ترکیب این روش‌ها با هم انجام شود. بهبود دقت و کارایی متغیرهای پیش بینی کننده می‌تواند باعث بهبود دقت و کارایی مدل در پیش بینی نتایج باشد.

یک پیشنهاد عملی این است که موسسات مالی و تاجران باید در استفاده از مدل‌های داده‌کاوی به‌عنوان یک ابزار تکمیلی و نه به‌عنوان جایگزین برای تجزیه و تحلیل‌های بنیادین سهام، به دقت عمل کنند.

تحقیقات مروری نشان دهنده پیشرفت‌های مهمی در زمینه داده‌کاوی و پیش‌بینی قیمت سهام است، با وجود این، اتکای بیش از حد به الگوریتم‌ها بدون درک کامل و شفافیت می‌تواند به اشتباهات تصمیم‌گیری منجر شود. تحقیقات آتی باید نه تنها به بهینه‌سازی مدل‌ها بلکه به بهبود فرآیندهای تفسیرپذیری و شفاف‌سازی بینجامد.

این ساختار پیشنهادی باید بر اساس داده‌ها و یافته‌های مشخص تحقیق، تعدیل و توسعه یابد.

در نوشتن پیشنهادها برای یک بخش کامل از تحقیق، باید به صورت جامع به بررسی چگونگی بهره‌گیری از یافته‌ها در عمل، توصیه‌هایی برای تحقیقات بعدی و رویکردهایی که می‌توانند به بهینه‌سازی اقدامات فعلی کمک کنند، پرداخت. پیشنهادها باید بر اساس یافته‌های کلیدی تحقیق و همچنین چالش‌ها و محدودیت‌های کشف شده شکل گیرند.

- پیشنهادها برای تحقیقات آینده:

بررسی و توسعه الگوریتم‌های پیشرفته داده‌کاوی:

** تحقیقات آینده باید به سمت توسعه الگوریتم‌هایی باشند که قادر به مدیریت حجم زیاد داده‌ها، پردازش سریع و کاهش پیچیدگی محاسباتی هستند. (توجه ویژه به یادگیری ماشینی و اعمال مدل‌های یادگیری عمیق برای شناسایی الگوهای پنهان در داده‌های بزرگ مالی)

پیشنهاد می‌شود که متغیرهای جدید و بیشتری از جمله متغیرهای اقتصادی کلان، رویدادهای جهانی و داده‌های رسانه‌های اجتماعی در مدل‌سازی‌ها ادغام شوند تا به افزایش دقت پیش‌بینی سهام کمک کنند.

- پیشنهادها برای سازگاری با تغییرات بازار:

۱- پایش و پاسخگویی به تغییرات فوری بازار: لزوم ایجاد سیستم‌هایی که به صورت داینامیک به تغییرات ناگهانی و فوری بازار پاسخ دهند، به ویژه در شرایط نااطمینانی و بحران.

۲- افزایش قابلیت تفسیر الگوریتم‌ها: اگرچه الگوریتم‌های داده‌کاوی می‌توانند پیچیدگی بالایی داشته باشند، اما توسعه رویکردهایی که قابلیت تفسیر نتایج آن‌ها را بهبود بخشند، امری ضروری است.

- پیشنهادها برای بهبود تصمیم‌گیری‌های مالی:

۱- ترکیب تحلیل مالی کلاسیک و داده‌کاوی: مهندسی مالی و تحلیل‌گران باید به مدل‌هایی که هم تکنیک‌های سنتی تحلیل مالی و هم الگوریتم‌های داده‌کاوی را تلفیق می‌کنند، بپردازند.

۲- تعیین راهبردهای‌های معاملاتی بر اساس الگوریتم‌ها: توسعه برنامه‌های تحلیلی که استراتژی‌های معاملاتی را بر اساس الگوریتم‌های داده‌کاوی بهینه می‌سازند.

- پیشنهادها برای رعایت مقررات و توسعه آموزش و برنامه‌ریزی:

۱- توجه به مسائل اخلاقی و حریم خصوصی: با افزایش استفاده از داده‌کاوی در بازارها، لزوم توجه به حریم خصوصی و اخلاق داده‌ها از اهمیت بالایی برخوردار است.

۲- رعایت مقررات و ایجاد ضوابط: تحلیلگران و موسسات مالی باید دائماً نسبت به مقررات جدید داده‌کاوی و تحلیل سهام به‌روز شوند و از تمامی ضوابط و مقررات مربوطه اطمینان حاصل کنند.

۳- توسعه برنامه‌های آموزشی: دوره‌ها و ورک‌شاپ‌هایی که تحلیلگران و مدیران مالی را با ابزارهای داده‌کاوی و تکنیک‌های مربوطه آشنا می‌کند.

۴- آموزش مداوم برای تحلیلگران: تأکید بر اهمیت آموزش مداوم برای تحلیلگران به منظور نگهداری و تقویت مهارت‌هایشان در استفاده از ابزارهای داده‌کاوی جدید.

این پیشنهادها که به صورت گسترده و جامع طراحی شده‌اند و نیازمند تلاش‌های بین‌رشته‌ای برای پیگیری و تحقق آن‌ها در آینده هستند. امید است که این پیشنهادها به عنوان نقطه عطفی برای محققان، تصمیم‌گیران و عملکردگران صنعت مالی عمل کنند تا به بهبود ادامه‌دار در فرایندها و نتایج مربوط به پیش‌بینی قیمت سهام منجر شوند.

به بدنه مقاله مراجعه کنید	لیست مرجع		
	"Application and performance of data mining techniques in stock market ...." https://onlinelibrary.wiley.com/doi/10.1002/isaf.1518	مقاله مروری	
	"Forecasting stock prices using a data mining method: Evidence from ...." 28 Jan. 2021, https://onlinelibrary.wiley.com/doi/10.1002/ijfe.2516.	شماره جلد موجود نیست	مقاله مجله با اطلاعات از دست رفته

	شماره نسخه موجود نیست	"Netflix Stock Price Movements Insights from Data Mining | IEEE ...." https://ieeexplore.ieee.org/document/9972547/.	
	شماره صفحه یا مقاله موجود نیست	"Concept and Practice of Artificial Market Data Mining Platform." https://ieeexplore.ieee.org/document/9776095.	
		"Stock Price Prediction Based on Data Mining Combination Model." https://www.igi-global.com/viewtitle.aspx?titleid=296707.	
		"A data mining framework for financial prediction | Expert Systems with ...." 01 Jul. 2021, https://dl.acm.org/doi/abs/10.1016/j.eswa.2021.114651.	
		"Progress and prospects of data-driven stock price forecasting research." 01 Jun. 2023, https://www.sciencedirect.com/science/article/pii/S2666307423000116.	
		"A Study on Developing Effective Option Trading Strategy On Nifty Index ...." https://ieeexplore.ieee.org/document/9377179.	
		"The Sustainable Development of Financial Topic Detection and Trend ...." 07 Jul. 2021, https://www.mdpi.com/2071-1050/13/14/7585.	
		"Forecasting on Stock Market Time Series Data Using Data Mining Techniques." http://www.ijesi.org/papers/NCIOT-2018/Volume-4/2.%2006-13.pdf.	

دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

برداشت و مدیریت انرژی مصرفی موردنیاز سیستم های اینترنت اشیاء

پریسا دانشجو [۱]، محمدمهدی یادگار [۲]

دانشگاه آزاد اسلامی- واحد تهران غرب[۱]، Daneshjoo.p@wtiau.acir

دانشگاه آزاد اسلامی واحد الکترونیکی[۲] , m.yadegar@iauec.ac.ir

چکیده – این مقاله مجموعه مقالات، جنبه‌های مختلف برداشت انرژی و مدیریت توان برای دستگاه‌های اینترنت اشیاء (IoT) را بررسی می‌کند. هدف کلی، افزایش کارایی و پایداری سیستم‌های اینترنت اشیاء از طریق تکنیک‌های نوآورانه برداشت انرژی و راهبردهای مدیریت توان موثر است.

روش‌های مورد استفاده در این مطالعات شامل طراحی معماری‌های کارآمد اینترنت اشیاء، کاوش در تکنیک‌های مختلف برداشت انرژی (مانند روش‌های خورشیدی و فتوولتائیک)، پیاده‌سازی سیستم‌های ردیابی نقطه حداکثر توان (MPPT) و ابداع الگوریتم‌های زمان‌بندی کار موثر برای دستگاه‌های اینترنت اشیاء برداشت‌شده انرژی است. این مطالعات همچنین به مکانیسم‌های مدیریت و کنترل انرژی، با تمرکز بر دستگاه‌های اینترنت اشیاء خودران که قادر به کار در محیط‌های راه دور یا سخت هستند، می‌پردازد.

یافته‌های مهم در سراسر مقالات، پیشرفت‌هایی را در برداشت انرژی خورشیدی برای دستگاه‌های IoT، بهبود ذخیره‌سازی انرژی با استفاده از ابرخازن‌ها و سلول‌های لیتیومی، و توسعه دستگاه‌های اینترنت اشیای بی‌سیم با توان بسیار کم نشان می‌دهد. یک مطالعه به طور خاص نمونه اولیه دستگاه IoT خودران را برجسته می کند و عملکرد آن را در برنامه‌های از راه دور با ظرفیت عملیاتی گسترده نشان می دهد.

نتیجه اصلی حاصل از این مطالعات امکان‌سنجی و اثربخشی سیستم‌های اینترنت اشیای خودپایدار از طریق تکنیک‌های پیشرفته برداشت انرژی و استراتژی‌های مدیریت انرژی است. این نوآوری‌ها کاهش قابل توجه وابستگی به منابع انرژی سنتی را وعده می‌دهند و در نتیجه راه را برای اکوسیستم‌های IoT قوی‌تر، کارآمدتر و پایدارتر در کاربردهای مختلف، از جمله محیط‌های راه دور و چالش‌برانگیز هموار می‌کنند.

کلید واژه ها – اینترنت اشیاء، انرژی خورشیدی، برداشت انرژی، فناوری پایدار، مدیریت قدرت

مقدمه - در عصر فناوری و پیشرفت‌های روزافزون، اهمیت بهره‌برداری بهینه و پایدار از فناوری‌های اینترنت اشیاء (IoT) به شکل چشمگیری افزایش یافته‌است. این تحقیق، با تمرکز بر روی راهبردهای مدیریت انرژی و فناوری‌های برداشت انرژی در دستگاه‌های IoT، به بررسی جامعی از پیشرفت‌ها و چالش‌های موجود در این حوزه می‌پردازد. با توجه به ضرورت فزاینده استفاده از منابع انرژی پایدار و کاهش وابستگی به منابع سنتی، این مطالعه، راهکارهای نوین در زمینه بهره‌برداری از انرژی خورشیدی و سایر منابع تجدیدپذیر را مورد بررسی قرار می‌دهد.

اهداف اصلی این تحقیق شامل توسعه سیستم‌های IoT خودکفا با استفاده از فناوری‌های نوآورانه در برداشت انرژی، ارتقاء کارایی مدیریت انرژی و ارائه راهکارهایی برای بهبود عملکرد و طول عمر دستگاه‌های IoT می‌باشد. این مطالعه، ضمن ارائه یک پیشینه تحقیق گسترده، به بیان اهمیت و نوآوری‌های موجود در این حوزه می‌پردازد و در نهایت، راهکارهایی را برای پیشبرد این فناوری‌ها در جهت دستیابی به یک محیط پایدارتر و کارآمدتر ارائه می‌دهد.

۱. بررسی فناوری‌های بهره‌برداری از انرژی:

۱.۱. بهره‌برداری از انرژی خورشیدی: انرژی خورشیدی، که فراوان‌ترین منبع است، از طریق اثرات فتوولتائیک بهره‌برداری می‌شود. انواع مختلف سلول‌های خورشیدی، مانند تک‌کریستال و پلی‌کریستال، کارایی‌ها و هزینه‌های متفاوتی را ارائه می‌دهند. بهره‌برداری از انرژی خورشیدی که از اثر فتوولتائیک (PV) استفاده می‌کند، یکی از امیدبخش‌ترین راه‌ها برای پایداری دستگاه‌های IoT است. مطالعه‌ای که با شماره ۱۰,۱۱۰۹ ۲۰۱۸,۸۷۱۰۱۷۱ANTS.@ منتشر شده، یک دستگاه IoT خودتأمین را با استفاده از یک پنل خورشیدی کوچک (۶۳ mm x ۶۳mm، W۰,۳۶) نشان می‌دهد که قادر است یک سال با یک باتری سکه‌ای ۱۲۰mAh کاملا شارژ شده کار کند. به طور مشابه، مایر و همکاران در سال ۲۰۲۰ استفاده از طراحی مبتنی بر میکروکنترلر برای تبدیل کارآمد انرژی خورشیدی را نشان دادند که قادر به کارکرد در محدوده زیر میکرو وات است. این پیشرفت‌ها، بر ظرفیت بهره‌برداری از انرژی خورشیدی در افزایش طول عمر و قابلیت اطمینان دستگاه‌های IoT، به ویژه در کاربردهای دوردست، تأکید می‌کنند.

۱.۲. بهره‌برداری از انرژی RF: بهره‌برداری از انرژی RF، همانطور که در مقاله سانیسلاو و همکاران در سال ۲۰۲۱ بیان شده، شامل تبدیل سیگنال‌های RF از منابعی مانند اینترنت بی‌سیم، رادیو، و ایستگاه‌های ماهواره‌ای به انرژی الکتریکی است. این روش به ویژه به دلیل در دسترس بودن دائمی آن، صرف نظر از زمان روز، مزیت دارد. با این حال، چالش‌هایی مانند تراکم انرژی پایین و کارایی، به ویژه در فواصل دور، باید مورد توجه قرار گیرند. راه‌حل‌های نوآورانه در بهره‌برداری از انرژی RF می‌تواند کارایی انرژی دستگاه‌های IoT مستقر در محیط‌هایی با منابع RF فراوان را به طور قابل توجهی افزایش دهد.

۱.۳. ارتعاشات مکانیکی: ارتعاشات مکانیکی به دلیل داشتن تراکم انرژی بالا، یک جایگزین معتبر برای انرژی خورشیدی در برخی از استقرارهای IoT است. طبق مطالعات مرور شده در سانیسلاو و همکاران (۲۰۲۱)، فناوری‌هایی مانند تبدیل‌کننده‌های انرژی پیزوالکتریک و الکترومغناطیسی برای تبدیل انرژی از ارتعاشات به قدرت الکتریکی مورد استفاده قرار می‌گیرند. این تبدیل‌کننده‌ها به دلیل تراکم قدرت بالا و قابلیت کاربرد در محدوده فرکانس وسیع، مفید هستند. به عنوان مثال، تبدیل‌کننده‌های الکترومغناطیسی ولتاژ پایین برای تأمین انرژی دستگاه‌های IoT به صورت مؤثر مورد استفاده قرار گرفته‌اند که نشان‌دهنده کاربرد عملی این روش بهره‌برداری در سناریوهای واقعی است.

۱.۴. بهره‌برداری از انرژی انسانی: بهره‌برداری از انرژی انسانی یک حوزه نوآورانه، به ویژه برای دستگاه‌های پوشیدنی و قابل کاشت IoT است. بدن انسان، از طریق حرکت و فیزیولوژی، منبع تأمین انرژی جایگزین را ارائه می‌دهد. با این حال، به دلیل طبیعت تصادفی حرکت انسانی و تغییرات دمای بدن، چالش‌هایی پیش می‌آید. ادغام بهره‌برداری از انرژی در دستگاه‌های پوشیدنی نیازمند توجه دقیق به اندازه، وزن، و حداقل تداخل با عملکردهای طبیعی بدن است.

۱.۵. بهره‌برداری از انرژی هیبریدی: سیستم‌های بهره‌برداری انرژی هیبریدی چندین منبع انرژی را ترکیب می‌کنند تا تأمین انرژی مداوم را تضمین کنند. سانیسلاو و همکاران در سال ۲۰۲۱ در مورد سیستم‌های هیبریدی که انرژی خورشیدی، بادی و حرارتی را ترکیب می‌کنند بحث کردند که به دستگاه‌های IoT خودمختاری انرژی را می‌بخشد. به عنوان مثال، یک گره شبکه حسگر بی‌سیم خودتأمین‌شده با استفاده از انرژی بادی، خورشیدی، و حرارتی توسعه یافته، انرژی بیشتری از مصرف خود تولید می‌کرد که نشان‌دهنده کارآمدی رویکرد هیبریدی است.

در جدول زیر مقایسه ای بین انواع تکنیک‌های برداشت انرژی آورده شده است:

Energy source	Technology	Power density	Advantages	Disadvantages	Application domains
Solar	PV cell	10 - 100 mW / cm^2 (outdoor) < 100 µW / cm^2 (indoor)	High-output voltage Low fabrication costs Predictable	Unavailable at night Non-controllable	Environment monitoring, healthcare, agriculture
RF	Antenna	0.01 - 0.1 µW / cm^2 1- 10 mW / cm^2	Available anywhere, anytime Predictable Controllable	Distance dependent Low-power density	Environment monitoring
Mechanical vibrations and pressure	Piezoelectric	4 - 250 µW / cm^3	High-power density No external voltage source Simplicity design and fabrication Controllable	Highly variable output Unpredictable	Infrastructure monitoring, automotive
	Electromagnetic	300 - 800 µW / cm^3	High-output currents Robustness Low-cost design Controllable	Relatively large size Unpredictable	
	Electrostatic	50 – 100 µW / cm^3	High-output voltage Relatively larger output power density Possibility to build low-cost devices Controllable	Requires bias voltage Unpredictable	
Human heat	Piezoelectric Pyroelectric	< 35 µW / cm^2	Sustainable and reliable Available Controllable	Low-power density Unpredictable	Healthcare
Biomechanical	Electromagnetic Piezoelectric Triboelectric Electrostatic	< 4 µW / cm^3 < 300 µW / cm^3	Available Controllable	Low-power density Unpredictable	Healthcare
Bio [102]	Metal electrodes	Extremely low wattage	Available Controllable	Extremely low wattage Suitable for nanoscale electrical devices	Environmental sensing in agricultural applications

جدول ۱: آنالیز تکنیک های برداشت انرژی

در نتیجه، این تکنیک‌های بهره‌برداری از انرژی، راه‌حل‌های متنوع و نوآورانه‌ای را برای تامین انرژی پایدار دستگاه‌های IoT ارائه می‌دهند. انتظار می‌رود که کارآمدی و کاربردپذیری این روش‌ها با پیشرفت فناوری بهبود یابد و زمینه‌ساز پایداری و خودمختاری بیشتر در حوزه IoT شود.

۲. مدل‌سازی بهره‌برداری از انرژی و طراحی سیستم:

۲.۱. مدل‌های بهره‌برداری از انرژی: هر دو مدل تعیینی و تصادفی برای مدیریت قدرت در دستگاه‌های EH استفاده می‌شوند. مدل‌های تعیینی به پیش‌بینی‌های دقیق انرژی نیازمندند، در حالی که مدل‌های تصادفی با عدم قطعیت‌های ذاتی در بهره‌برداری از انرژی سازگاری دارند. MPPT (Maximum Power Point Tracking) مدل‌هایی هستند که بیشتر به عنوان مدل‌های تعیینی در نظر گرفته می‌شوند. این بدان معناست که آن‌ها بر اساس مجموعه‌ای از الگوریتم‌ها و قواعد مشخص عمل می‌کنند تا نقطهٔحداکثر توان را در سیستم‌های فتوولتائیک پیدا کنند. هرچند، برخی از روش‌های پیشرفته MPPT مانند استفاده از منطق فازی یا الگوریتم‌های یادگیری ماشین، ممکن است عناصر تصادفی و پیش‌بینی‌ناپذیری را در بر گیرند تا به خوبی با تغییرات محیطی و شرایط متغیر کنار آیند. اما در اصل، MPPTها بر پایهٔ اصول تعیینی ساخته شده‌اند.

تکنیک‌های مختلفی برای Maximum Power Point Tracking (MPPT) در سیستم‌های خورشیدی وجود دارد که هرکدام ویژگی‌ها و تفاوت‌های خاص خود را دارند:

۱. **Perturb and Observe (P&O)**: این روش با تغییر دادن ولتاژ و نظارت بر تغییرات توان خروجی، نقطه حداکثر توان را پیدا می‌کند. اگرچه ساده و رایج است، اما در شرایط نور متغیر ممکن است به نقطه حداکثر توان واقعی نرسد.

۲. **Incremental Conductance (IncCond)**: این روش با محاسبه تغییرات شیب خط قدرت و ولتاژ، نقطه حداکثر توان را تشخیص می‌دهد. به‌ویژه در شرایط نور متغیر، دقت بیشتری نسبت به P&O دارد.

۳. **Constant Voltage (CV)**: این روش بر این فرض استوار است که نقطه حداکثر توان در نزدیکی یک ولتاژ ثابت خاصی قرار دارد. این تکنیک ساده است اما دقت کمتری دارد.

۴. **Fuzzy Logic یا Artificial Intelligence (AI) based Methods**: این روش‌ها با استفاده از منطق فازی یا الگوریتم‌های هوش مصنوعی، به تنظیم MPPT می‌پردازند. این روش‌ها انعطاف‌پذیری بیشتر و عملکرد بهتری در شرایط محیطی متغیر دارند.

هریک از این تکنیک‌ها مزایا و معایب خاص خود را دارند و انتخاب آن‌ها به شرایط کاربردی و نیازهای خاص سیستم بستگی دارد.

۲.۲. برخی از

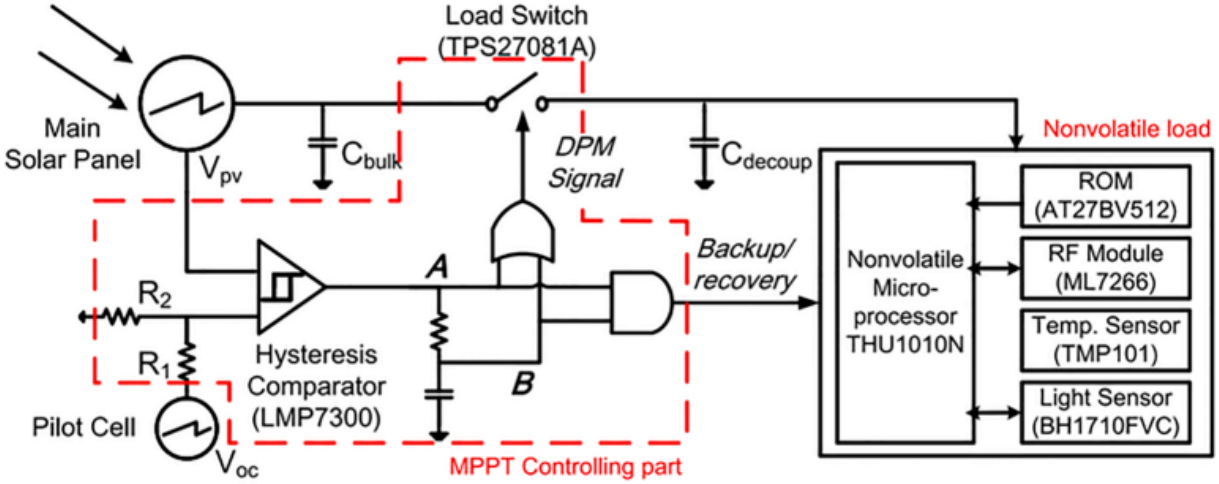

شکل ۱. سیستم برداشت انرژی بدون ذخیره سازی – بدون مبدل

دستگاه‌های PV-EH-IoT و مدارهای مجتمع که در این مقاله بررسی شده‌اند عبارتند از:

Heliomote: یک دستگاه IoT با تمرکز بر بهره‌برداری از انرژی خورشیدی.

Prometheus: یک سیستم بهره‌برداری انرژی خورشیدی با کاربردهای مختلف.

AmbiMax: دستگاهی که از فناوری پیشرفته برای بهره‌برداری از انرژی استفاده می‌کند.

Everlast و Fleck 1: سیستم‌های بهره‌برداری انرژی برای IoT با تمرکز بر طول عمر و کارایی بالا.

Solar Biscuit و Sunflower: دستگاه‌هایی با طراحی‌های نوآورانه برای بهره‌برداری از انرژی خورشیدی.

Hydrowatch: دستگاهی متمرکز بر رصد و بهره‌برداری از منابع انرژی آبی.

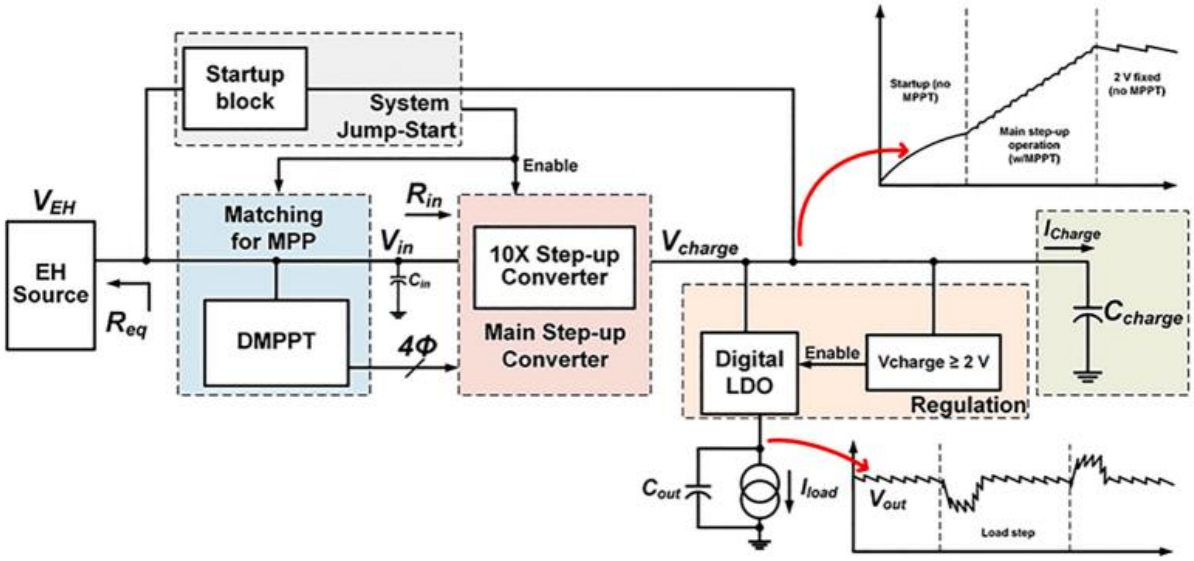

شکل ۲. برداشت کننده انرژی مستقل برای اینترنت اشیاء با بلوک شروع (start block)

۲.۳. ملاحظات طراحی سیستم: راهبردهای مدیریت انرژی مؤثر، مانند چرخه‌بندی وظیفه، برنامه‌ریزی خواب و مقیاس‌بندی ولتاژ پویا حیاتی هستند. طراحی باید توان تولید شده و ذخیره‌شده را با نیازهای مصرفی متعادل کند.

چند مورد از این موارد را در زیر بررسی کردیم:

۱. چرخه‌بندی وظیفه (Duty Cycling): این روش شامل تنظیم دوره‌های فعالیت و استراحت برای دستگاه‌های IoT است. به عنوان مثال، یک سنسور(حسگر) محیطی ممکن است برای ۱۰ ثانیه داده‌ها را جمع‌آوری کند و سپس برای ۵۰ ثانیه وارد حالت خواب شود تا مصرف انرژی را کاهش دهد.

۲. برنامه‌ریزی خواب (Sleep Scheduling): در این روش، دستگاه‌ها برنامه‌ریزی می‌شوند تا در زمان‌های غیر ضروری وارد حالت خواب شوند. مثلاً یک دستگاه IoT ممکن است در طول شب یا در زمان‌هایی که فعالیت کمتری لازم است، خاموش شود.

۳. مقیاس‌بندی ولتاژ پویا (Dynamic Voltage Scaling): این استراتژی(راهبرد) به تنظیم ولتاژ و فرکانس پردازنده بر اساس بار کاری دستگاه می‌پردازد. برای مثال، در زمان‌هایی که بار کاری کم است، ولتاژ و فرکانس پردازنده کاهش می‌یابد مصرف انرژی به حداقل برسد.

۳. نتایج و بحث ها:

در مقالاتی که مورد بررسی قرار گرفته اند، بحث‌های مفصلی در مورد نتایج و نوآوری‌های به دست آمده صورت گرفته است. به عنوان مثال، در یک مقاله، نوآوری در زمینه بهبود کارایی انرژی با استفاده از سیستم‌های برداشت انرژی پیشرفته مورد تاکید قرار گرفته است. همچنین، در مورد اعتبارسنجی نتایج، روش‌های مختلف تجزیه و تحلیل آماری و مقایسه با استانداردهای صنعتی به کار گرفته شده است تا اطمینان حاصل شود که نتایج موثق و قابل اتکاء هستند.

۴. روش‌ها، سؤالات و آمار:

در این تحقیقات، روش‌های گوناگونی برای بهبود کارایی و پایداری دستگاه‌های IoT از طریق فناوری‌های برداشت انرژی و مدیریت بهینه قدرت مورد استفاده قرار گرفته‌اند. سؤالات تحقیق به دنبال بررسی این موضوع هستند که چگونه می‌توان با استفاده از روش‌های نوآورانه در برداشت انرژی و مدیریت قدرت، کارایی دستگاه‌های

IoT را افزایش داد. این مقاله به دنبال پاسخ به این سؤال است که چگونه می‌توان کارایی انرژی در دستگاه‌های IoT را با استفاده از فناوری‌های برداشت انرژی خورشیدی افزایش داد. همچنین به بررسی تأثیر استراتژی‌های مدیریت قدرت بر عمر باتری دستگاه‌های IoT می‌پردازد. جامعه آماری در این تحقیقات شامل مجموعه‌ای از دستگاه‌های IoT و فناوری‌های مربوط به برداشت انرژی و مدیریت قدرت است. فرآیند تحقیق شامل طراحی، آزمایش و تحلیل داده‌های به دست آمده از این دستگاه‌ها و فناوری‌ها است. این مقاله از سیستم‌های پیشرفته MPPT برای بهینه‌سازی کارایی برداشت انرژی خورشیدی استفاده می‌کند و همچنین، رویکردهای مدیریت قدرت در دستگاه‌های IoT را با استفاده از الگوریتم‌های نرم‌افزاری و سخت‌افزاری خاص مورد بررسی قرار داده است. ابزار تحقیق شامل مجموعه‌ای از تجهیزات و نرم‌افزارهای تخصصی برای اندازه‌گیری و تحلیل کارایی انرژی در دستگاه‌های IoT است. در نهایت، مسائل و چالش‌های موجود به وسیله تحلیل‌های آماری و مهندسی دقیق حل شده‌اند که شامل بررسی و ارزیابی داده‌های جمع‌آوری شده است. در برخی از مقالات، تجزیه و تحلیل داده‌های به دست آمده از سیستم‌های PV برای ارزیابی کارایی MPPT انجام شده است و یا با استفاده از شبیه‌سازی‌های کامپیوتری، تاثیر الگوریتم‌های مدیریت قدرت بر کارایی کلی دستگاه‌های IoT را مورد بررسی قرار داده‌اند.

۵. جهت‌گیری‌ها و چالش‌های آینده:

تحقیقات آینده باید بر بهبود کارایی تبدیل انرژی، توسعه راهکارهای ذخیره‌سازی انرژی مستحکم‌تر و خلق الگوریتم‌های مدیریت انرژی انعطاف‌پذیر که قادر به مقابله با ماهیت غیرقابل پیش‌بینی منابع انرژی محیطی باشند، متمرکز شوند. رویارویی با این چالش‌ها راه را برای ایجاد اکوسیستم‌های IoT پایدارتر و دوام‌دارتر هموار می‌کند.

۶. نتیجه‌گیری:

این مطالعه، با بررسی جامعی از تکنیک‌ها و راهبردهای برداشت انرژی و مدیریت قدرت در دستگاه‌های IoT، به ارائه یک چشم‌انداز وسیع و عمیق در زمینه تکامل این فناوری‌ها پرداخته است. استفاده از روش‌های پیشرفته برداشت انرژی خورشیدی، بهینه‌سازی فرآیندهای مدیریت قدرت و توسعه سیستم‌های IoT خودکفا، نشان‌دهنده گام‌هایی بلند برای دستیابی به سیستم‌های پایدارتر و کارآمدتر است. از طرفی، پیاده‌سازی استراتژی‌های مدیریت انرژی مانند چرخه‌بندی وظیفه، برنامه‌ریزی خواب و مقیاس‌بندی ولتاژ پویا به کاهش چشمگیر مصرف انرژی و افزایش طول عمر دستگاه‌های IoT کمک کرده است.

این تحقیقات، ضمن نشان دادن امکانات و قابلیت‌های فناوری‌های موجود، به وضوح، چالش‌ها و محدودیت‌های پیش‌رو در توسعه این سیستم‌ها را نیز مورد توجه قرار داده‌اند. در نهایت، با تکیه بر دستاوردهای علمی و فناوری به دست آمده، می‌توان توقع داشت که آینده دستگاه‌های IoT در جهت بهره‌برداری مؤثرتر از منابع انرژی و ارائه راهکارهای نوآورانه در مدیریت انرژی گام‌های بزرگتری بردارد. این پیشرفت‌ها نه تنها به بهبود کارایی و پایداری دستگاه‌های IoT کمک می‌کنند، بلکه در راستای تحقق اهداف بزرگتر محیط زیستی و انرژی نیز قرار دارند.

۷. منابع و مراجع

[1] Kjellby, R. A., Cenkeramaddi, L. R., Johnsrud, T. E., Løtveit, S. E., Jevne, G., & Beferull-Lozano, B. (2018). Self-powered IoT Device based on Energy Harvesting for Remote Applications. Department of Information and Communication Technology, University of Agder, Grimstad, Norway. 2018 IEEE.

[2] Mayer, P., Magno, M., & Benini, L. (2020). Smart Power Unit – mW-to-nW Power Management and Control for Self-Sustainable IoT Devices. IEEE.

[3] Ahmad, F. F., Ghenai, C., Bettayeb, M. (2021). Maximum power point tracking and photovoltaic energy harvesting for Internet of Things: A comprehensive review. Received January 26, 2021; Accepted June 18, 2021.

[4] Sanislav, T., Mois, G. D., Zeadally, S., & Folea, S. C. (2021). Energy Harvesting Techniques for Internet of Things (IoT). IEEE. Received February 17, 2021; Published March 4, 2021.

[5] Zeadally, S., Shaikh, F. K., Talpur, A., & Sheng, Q. Z. (2020). Design architectures for energy harvesting in the Internet of Things. Renewable and Sustainable Energy Reviews, Volume 128, August 2020, 109901.

[6] Sandhu, M. M., Khalifa, S., Jurdak, R., & Portmann, M. (2021). Task Scheduling for Energy Harvesting-based IoT: A Survey and Critical Analysis. IEEE.

دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

بررسی ساز وکار هوشمند دفاعی در برابر حملات سرویس انکار توزیع‌شده اینترنت اشیاء

پریسا دانشجو [۱]، رضا غفاری دیزجی [۲]
دانشگاه آزاد اسلامی- واحد تهران غرب[۱]، Daneshjoo.p@wtiau.acir
تهران، ایران، دانشکده فنی آزاد اسلامی واحد غرب[۲]، rezaghaffarid@gmail.com

چکیده

اینترنت اشیاء یک فناوری پیشرو است که امکان اتصال گسترده‌ای از دستگاه‌های مختلف را برای ارائه خدمات و خودکارسازی در حوزه‌های مختلف از زندگی روزمره تا سامانه‌های زیرساختی حیاتی فراهم می‌کند. بااین‌حال، این دستگاه‌ها به حملات مختلف ازجمله، حملات سرویس انکار توزیع‌شده حساس هستند. هدف، از کار انداختن یک دستگاه معتبر و جلوگیری از دسترسی کاربران معتبر به سرویس‌ها یا منابع شبکه است. این حملات می‌توانند از طریق منابع حمله توزیع‌شده، منابع حمله متنوع و تغییرات ترافیک انجام شوند؛روش دفاع هوشمندانه که بانام محافظ جریان برای مقابله با این حملات ارائه‌شده است. این روش شامل تشخیص، شناسایی، طبقه‌بندی و کاهش حملات است که دو مؤلفه اصلی به نام فیلتر جریان و راه‌انداز جریان در بر دارد و برای شناسایی، تشخیص، طبقه‌بندی و کاهش حملات استفاده می‌شود. الگوریتم تشخیص حملات بر اساس تغییرات ترافیک ارائه‌شده و دو مدل یادگیری ماشین به نام حافظه بلندمدت- کوتاه‌مدت و شبکه عصبی پیچشی یا هم‌گشتی برای شناسایی و طبقه‌بندی حملات سرویس انکار توزیع‌شده ارائه‌شده است. این مدل‌ها با تأخیر مناسبی در سرورهای لبه که قدرت محاسباتی بالاتری نسبت به یک رایانه شخصی دارند، قابلیت استفاده دارند. راهکارهایی برای رفع محدودیت‌ها و نقاط ضعف در حفاظت از سامانه‌های اینترنت اشیاء در برابر حملات امنیتی می توان استفاده کرد که از جمله آنها؛ افزایش قدرت محاسباتی و فضای ذخیره‌سازی، استفاده از شیوه‌نامه‌های امن‌تر، استفاده از فن‌های دفاعی پیشرفته، توسعه روش‌های هوش مصنوعی و یادگیری عمیق است.

کلیدواژه: امنیت اینترنت اشیاء، حملات DDoS، محاسبات لبه، هوش مصنوعی

مقدمه

اینترنت اشیا یکی از فناوری‌های نوین در زمینهٔ ارتباطات هوشمند است که مزیت‌های آن باعث می‌شود تا هرروز سازمان‌ها و مؤسسات مختلفی به این فناوری بپیوندند . بر اساس مطالعات انجام‌شده، آینده دنیای ارتباطات را می‌توان در چهارچوب[۱] IOT تصور کرد[۱]. این ویژگی باعث شده است تا محققان، علاقه‌مند به پیاده‌سازی اینترنت اشیای مبتنی بر فناوری‌های جدید (مانند شبکه 5G) باشند[۲].

یکی از جنبه‌های کلیدی معرفی اینترنت اشیاء، توانایی پشتیبانی از بسیاری از دستگاه‌ها در مقایسه با تعداد فعلی است. مدیریت ارتباط بین میلیاردها حسگر متصل و دستگاه رادیویی یکی از برنامه‌های پیش‌بینی‌شده جدید برای اینترنت اشیاء است [۵-۳]. فراهم کردن بستر ارتباطی برای این تعداد تجهیزات باعث ایجاد مشکلات امنیتی جدید خواهد شد. برای مثال، در چنین شبکه‌ای، قربانیان حملات سایبری ممکن است دسترسی به تجهیزات خانه، اتومبیل یا تلفن‌های همراه خود را از دست بدهند.[۶] به همین دلیل در کارهای تحقیقاتی مختلف راهکارهایی برای تأمین امنیت ارتباطات در این شبکه‌ها ارائه شده‌است.[۷,۸] بااین‌حال، این یک مشکل حل‌نشده باقی‌مانده است و این شبکه به راه‌حل‌های امنیتی کارآمدتری نیاز دارد. با افزایش قابل‌توجه تعداد دستگاه‌ها و برنامه‌های کاربردی متصل در اینترنت اشیاء، این محیط فرصت‌های بیشتری را برای مهاجمان فراهم می‌کند تا تهدیداتی مانند حملات[۱] DoS را اجرا کنند. [۹]

از سوی دیگر، بر اساس مطالعات اخیر، بیش از استفاده از راه‌حل‌های رمزگذاری برای کدگذاری، ارتباطات و داده‌های اینترنت اشیاء نیاز است، زیرا علاوه بر اینکه نمی‌تواند مهاجم را شناسایی کند، باعث هدر رفتن منابع محاسباتی شبکه می‌شود. [۱۰]

[1] *Internt of thing*

[1] *Denial of Service*

روش دفاع هوشمندانه محافظ جریان (Flow Guard) یک مکانیسم دفاعی نوآورانه IOT در برابر حملات DDoS[2]است که از مدل‌های یادگیری ماشین برای تشخیص و طبقه‌بندی حملات استفاده می‌کند. این سیستم دفاعی شامل دو جزء اصلی است: فیلتر جریان و کنترل‌کننده جریان. فیلتر جریان مسئول شناسایی و فیلترکردن جریان‌های مخرب بر اساس قوانین فیلتراسیون از پیش تعیین‌شده است، درحالی‌که کنترل‌کننده جریان بر شناسایی و طبقه‌بندی جریان‌های مخرب با استفاده از مدل‌های یادگیری ماشین تمرکز دارد. مدل LSTM[3]پیشنهادی، دقت شناسایی بالا و مدل CNN[4] دقت طبقه‌بندی بالا را که از سایر مدل‌های یادگیری ماشین بهتر عمل کرده‌اند، به دست آورده است. نتایج این مقاله همچنین نشان داد که مدل‌ها هنگام آزمایش با مجموعه داده‌های شبیه‌سازی‌شده و مجموعه داده‌های CICDDoS2019[5]توانایی تعمیم دارند و قادر به شناسایی و طبقه‌بندی مؤثر انواع حملات DDoS هستند. علاوه بر این، ارزیابی کارایی نشان داد که زمان پردازش مدل‌های LSTM و CNN در محدوده‌های قابل‌قبول است و تضمین می‌کند که عملیات عادی دستگاه‌های IOT تحت تأثیر قابل‌توجهی از مکانیسم دفاعی قرار نمی‌گیرند. (شکل ۱)

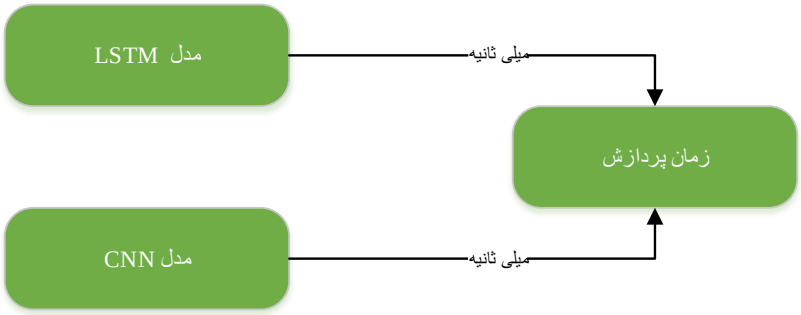

شکل ۱: فرآیند زمان پردازش

مکانیسم دفاعی FlowGuard به همراه مدل‌های LSTM و CNN، رویکردی امیدوارکننده برای مقابله با حملات سرویس انکار توزیع‌شده اینترنت اشیاء ارائه می‌دهد. (شکل۲) با شناسایی و طبقه‌بندی مؤثر جریان‌های مخرب، FlowGuard، یک استراتژی دفاعی پیشگیرانه در برابر حملات سرویس انکار توزیع‌شده (DDoS) به دستگاه‌های اینترنت اشیاء را فراهم می‌کند. ارزیابی جامع مدل‌ها، دقت و کارایی بالای آن‌ها را نشان می‌دهد، که ظرفیت آن‌ها برای کاربرد واقعی در دفاع در برابر حملات سرویس انکار توزیع‌شده اینترنت اشیاء را برجسته می‌کند. درمجموع، FlowGuard، یک مکانیسم دفاعی پیشرفته و مؤثر محوری را ارائه می‌دهد که می‌تواند امنیت شبکه‌های IoT را به‌طور قابل‌توجهی افزایش دهد.[۱۱]

شکل ۲: مدل دقت یادگیری ماشین

کارهای مرتبط

روش انتخاب ویژگی[6](FS)، روشی برای تشخیص حملات DDoS در شبکه‌های اینترنت اشیاء(IOT) است که به دنبال دستیابی به اهداف اصلی بیشینه‌کردن ارتباط، دقت طبقه‌بندی، بازخوانی، دقت نمونه‌های واقعی به نمونه‌های اندازه‌گیری و کمینه کردن تکرار و تعداد بوده و شامل انتخاب ویژگی‌هایی است که برای تشخیص حملات DDoS بسیار مرتبط هستند.

---

[1] *Distributed Denial of Service* [2]
[1] *Long Short-Term Memory* [3]
[1] *Convolutional Neural Network* [4]
[1] *Cybersecurity Intrusion Detection Dataset for Denial-of-Service Attacks in 2019* [5]
[1] *Feature Selection* [6]

این اهداف به‌طورکلی به بهبود عملکرد و کارایی سیستم تشخیص نفوذ[۷](IDS) در تشخیص حملات DDoS در شبکه‌های IOT از طریق انتخاب ویژگی‌های مرتبط و مؤثر می‌پردازند، اما این روش ممکن است محدودیت‌ها و نقاط ضعف زیر را داشته باشد:
پیچیدگی محاسباتی، به علت استفاده از الگوریتم‌های بهینه‌سازی چند هدف ممکن است نیازمند محاسبات زمان‌بر یا وابستگی به داده‌های ورودی باشد که نتایج آن برای دیگر مجموعه‌های داده ممکن است قابل‌اعمال نباشد. تنظیم پارامترها نیز نیازمند تخصیص زمان و توانایی تخصصی است.
اعتبارسنجی، ارزیابی دقیق و قابل‌اعتماد نتایج به دلیل وجود چندین هدف و همچنین انتخاب ویژگی‌های مناسب و حذف ویژگی‌های غیرضروری ممکن است به دلیل پیچیدگی مسئله، چالش‌برانگیز باشند. [۱۲]
لایه‌های اصلی در معماری SDN[۸]شامل لایه برنامه، لایه کنترل و لایه داده است. این لایه‌ها با هم کار می‌کنند تا انعطاف‌پذیری و قابلیت برنامه‌ریزی را که ویژگی‌های معماری SDN هستند، فراهم کنند، اما دارای محدودیت‌ها و نقاط ضعف مصرف منابع بالا، دشواری در تعریف آستانه تشخیص برای برنامه‌های مختلف، عدم شبیه‌سازی یا اجرای واقعی مرتبط با شبکه‌های تعریف‌شده، تولید تأخیر برای کاربران معتبر، دشواری محدودیت در تعریف پارامترهای کلیدی مانند زمان اوج و استفاده غیرعادی از لینک، محدودیت در تعریف معیارها و آستانه‌ها، نیاز به زمان طولانی برای اطلاع‌رسانی کنترل‌گرهای مجاور و مهار حملات و دیگر محدویت ها است. [۱۳]

استفاده از شبکه‌های تعریف‌شده توسط نرم‌افزار (SDN)، برای مدیریت تهدیدات DDoS در دستگاه‌های اینترنت اشیاء چندین مزیت شامل کنترل متمرکز، انعطاف‌پذیری و قابلیت تطبیق، قابلیت مقیاس‌پذیری، بهره‌وری منابع کارآمد، شناسایی و مهارت زودهنگام، تصمیم‌گیری تطبیقی را ارائه می‌دهد. به‌طورکلی، استفاده از SDN برای مدیریت تهدیدات DDoS در دستگاه‌های IOT، رویکردی قوی و کارآمد را برای افزایش امنیت و انعطاف‌پذیری شبکه‌های IOT فراهم می‌کند و چالش‌های منحصربه‌فردی را که توسط دستگاه‌های IOT با منابع محدود ایجاد می‌شود، مدیریت می‌کند. برخی محدودیت‌ها و نقاط ضعف مطرح‌شده در مورد روش‌های مختلف برای مقابله با حملات DDoS شامل محدودیت‌های مرتبط با تعداد گره‌های شبکه، نیاز به بهبود در مجموعه ویژگی‌ها و نرخ یادگیری در روش‌های تشخیص مبتنی بر هوش مصنوعی، ضعف در مقابله با حملات ناشناخته یا zero-day، مشکلات مربوط به حجم بزرگ ترافیک DDoS، نیاز به بهبود در مجموعه ویژگی‌ها و نرخ یادگیری در روش‌های تشخیص مبتنی بر هوش مصنوعی است.[۱۴]

نویسندگان از ResNet برای تشخیص حملات IOT استفاده کردند سپس با تبدیل داده‌های ترافیک شبکه به فرم تصویر و آموزش یک مدل CNN پیشرفته بر روی‌داده‌های تبدیل‌شده (ResNet)، مراحل جمع‌آوری داده، پیش‌پردازش داده، تشخیص حمله را بر روی تصاویر پیش‌پردازش شده آموزش دادند. این روش، علاوه بر دقت بالا، در مقایسه با روش‌های پیشین، در اصطلاحات دقت، بازخوانی برای تشخیص الگوهای حملات DoS و DDoS عملکرد بهتری داشت.
به‌طور خلاصه، نویسندگان از ResNet[۹]با تبدیل داده‌های ترافیک شبکه به فرم تصویر و سپس آموزش مدل ResNet بر روی‌داده‌های تبدیل‌شده برای تشخیص بهتر حملات DoS و DDoS در شبکه‌های IOT استفاده کردند. محدودیت‌ها و نقاط ضعف بر اساس این روش شامل نیاز به داده‌های ورودی واقعی، پیچیدگی در تبدیل داده، انتخاب ویژگی‌ها، انتقال دانش به دامنهٔ جدید و محدودیت‌های مدل می‌شود.[۱۵]

روش محافظ جریان (FlowGuard)

محافظ جریان برای رفع مشکلات و نقاط ضعف در زمینهٔ حملات DDoS اینترنت اشیاء، توسعه مکانیسم دفاعی هوشمند در لبه شبکه به نام FlowGuardاست. این روش طراحی‌شده است تا حملات DDoS IOT را تشخیص داده، بدون اینکه فشار محاسباتی قابل‌توجهی بر روی دستگاه‌های IOTوارد کند، آنها را شناسایی، طبقه‌بندی و مقابله کند. این سیستم از دو مدل یادگیری ماشینی، LSTM و CNN، برای شناسایی و طبقه‌بندی

[1] *Intrusion Detection Seystem*
[7]
[1] *Software-Define-Network*
[8]
[1] *Residual Network*
[9]

حملات DDoS استفاده می‌کند. اجزای کلیدیFlowGuard شامل Flow Filter که وظیفه فیلتر کردن جریان‌های مخرب و تشخیص جریان‌های مخرب ناشناخته را دارد وا Flow Handler است که جریان‌های مشکوک را برای شناسایی و طبقه‌بندی حملات DDoS تجزیه و تحلیل می‌کند.
FlowGuard در سرورهای لبه‌ای که به شبکه IOT نزدیک‌تر هستند عمل و تضمین می‌کند تمام بسته‌هایی که از طریق سرورهای لبه‌ای عبور می‌کنند مورد بازرسی قرار می‌گیرند. این سیستم، دقت بالایی در شناسایی حملات(بیش از ۹۸,۹٪) و طبقه‌بندی حملات(بیش از ۹۹,۹٪) دارد بدون اینکه بر عملیات شبکه معمولی تأثیر قابل‌توجهی بگذارد. علاوه بر این، این راه‌حل به‌منظور رفع محدودیت‌های فن‌های دفاعی سنتی DDoS، یک طرح دفاعی کارآمد و قدرتمند را ارائه می‌دهد که به‌طور خاص برای محیط‌های IOT طراحی‌شده است(شکل۳).

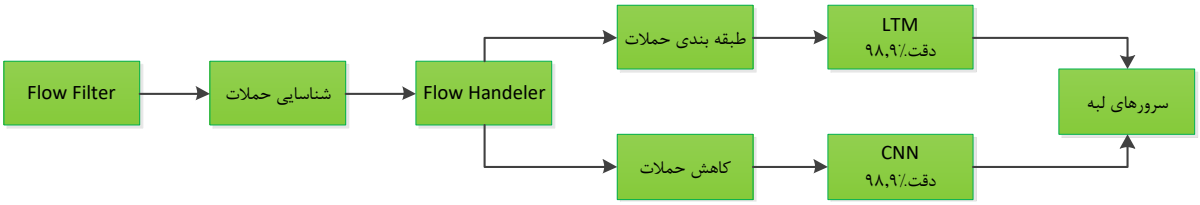

شکل۳:مولفه های Flow Guard وعملکرد آنها

علاوه بر این، این روش بر اهمیت فن‌های بازگشت به مبدأ IP، تغییرات آنتروپی و سامانه‌های تشخیص و پیشگیری از نفوذ که در لایه‌های مختلف شبکه پشته مستقر هستند، تأکید می‌کند تا دفاع کلی را در برابر حملات DDoS IoT تقویت کند.
نقاط قوت استفاده از LSTM و CNN را می‌توان توانایی در تشخیص الگوها و امکان استفاده از داده‌های ساختاریافته بیان کرد؛ LSTM و CNN قادرند الگوهای پیچیده و تغییرات زمانی را تشخیص دهند که می‌تواند برای تشخیص حملات DDoS مفید باشد. این شبکه‌ها می‌توانند الگوهای مشخصی را که به‌صورت متناوب و پیچیده در حملات DDoS ظاهر می‌شوند تشخیص دهند و اقدامات دفاعی مناسب را انجام دهند. همچنین LSTM و CNN قادر به کار با داده‌های ساختاریافته مانند ترافیک شبکه هستند. این امکان به آن‌ها کمک می‌کند تا الگوهای مختلف ترافیک شبکه را تشخیص داده و از حملات DDoS دفاع کنند.

نقاط ضعف استفاده از LSTM و CNN را نیز می‌توان نیاز به داده‌های بزرگ و پیچیدگی آموزش برشمرد. استفاده از LSTM و CNN نیازمند داده‌های بزرگ و متنوع است که ممکن است در برخی از موارد، دسترسی به چنین داده‌هایی دشوار باشد. برای آموزش مؤثر این شبکه‌ها نیازمند داده‌های بزرگ و گوناگون هستیم تا بتوانند الگوهای مختلف را تشخیص دهند. همچنین آموزش و تنظیم مدل‌های LSTM و CNN نیازمند تخصص و زمان زیادی است. این فرآیند، نیازمند دانش تخصصی و تجربه در زمینهٔ شبکه‌های عصبی است و ممکن است زمان‌بر باشد.[۱۱]
نقاط ضعف پیشنهادی راه‌حل FlowGuard به‌طور بالقوه می‌توانند شامل محدودیت‌های منابع دستگاه‌های اینترنت اشیاء که دارای قدرت محاسباتی و ذخیره‌سازی محدودی هستند، نگرانی‌های مربوط به کارایی، استقرار در دنیای واقعی، خطرات امنیتی مرتبط با پیاده‌سازی مکانیسم‌های دفاعی مبتنی بر یادگیری ماشینی، پیچیدگی و نگهداری باشند. به‌طور کلی می‌توان برای این روش نقشه مفهومی ذیل را ترسیم کرد. (شکل۴)

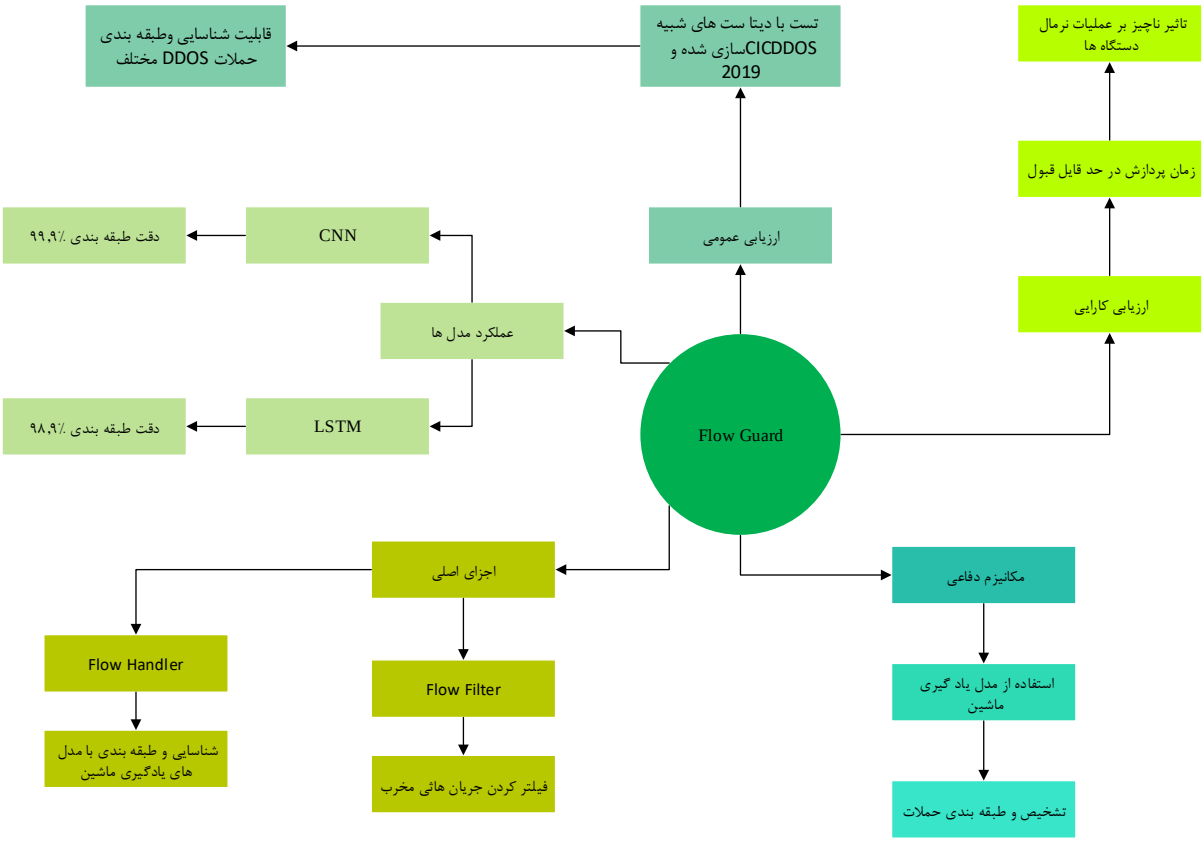

شکل ۴: نقشه مفهومی روش Flow Guard

نتایج

درحالی‌که روش FlowGuard قابلیت‌های امیدوارکننده‌ای را در تشخیص، شناسایی و طبقه‌بندی حملات DDoS در محیط‌های IOT نشان می‌دهد، مهم است که نقاط ضعف بالقوه مربوط به محدودیت‌های منابع، کارایی، چالش‌های استقرار در دنیای واقعی، خطرات امنیتی و پیچیدگی را در نظر بگیریم. رفع این نقاط ضعف برای تضمین کارایی و عملی بودن راه‌حل در سناریوهای امنیتی واقعی IOT حیاتی است(شکل۵).

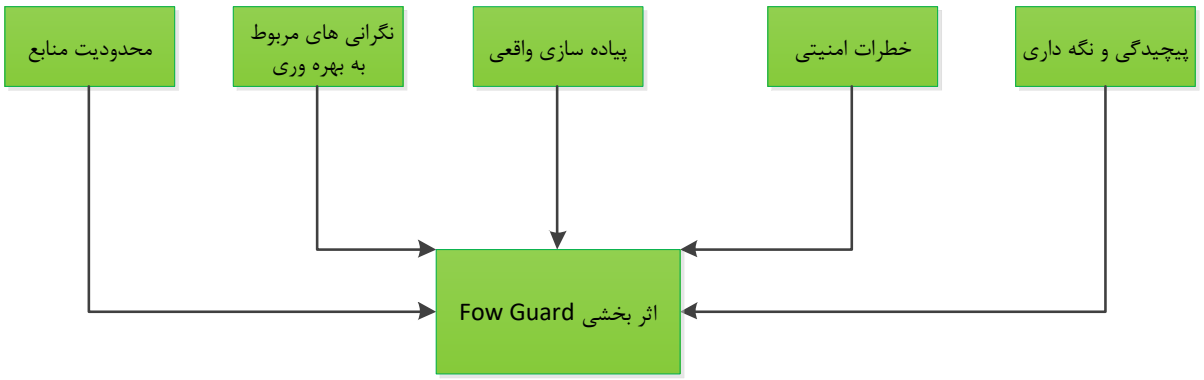

شکل۵:اثر بخشی روش Flow Guard

روش FlowGuard، یک رویکرد مؤثر و عملی برای رفع نقاط ضعف و چالش‌های مرتبط با حملات DDoS IOT ارائه می‌دهد و یک مکانیسم دفاعی قوی را فراهم می‌کند که از مدل‌های یادگیری ماشینی و معماری متمرکز بر لبه‌ای برای تأمین امنیت شبکه‌های IOT بهره می‌برد.
به‌طورکلی، استفاده از LSTM و CNN می‌تواند برای تشخیص حملات DDoS مفید باشد اما نیاز به‌دقت و توجه به محدودیت‌ها و مشکلات مربوطه دارد. این روش‌ها نیازمند منابع و دانش تخصصی برای پیاده‌سازی مؤثر هستند.

نتیجه‌گیری

مطابق با روش‌های بررسی‌شده در مقالات، می‌توان از راهکارهای زیر برای رفع محدودیت‌ها و نقاط ضعف در حفاظت از سامانه‌های IOT در برابر حملات امنیتی استفاده کرد:
افزایش قدرت محاسباتی و فضای ذخیره‌سازی: با افزایش قدرت محاسباتی و فضای ذخیره‌سازی دستگاه‌های IOT، می‌توان از روش‌های پیشرفته‌تری برای تشخیص و پیشگیری از حملات استفاده کرد. این امر می‌تواند باعث افزایش امکانات امنیتی دستگاه‌ها و کاهش آسیب‌پذیری‌ها شود.
استفاده از شیوه‌نامه‌های امن‌تر: انتخاب شیوه‌نامه‌های ارتباطی امن‌تر و پیچیده‌تر برای دستگاه‌های IoT می‌تواند به کاهش آسیب‌پذیری‌ها و افزایش امنیت این دستگاه‌ها کمک کند.
پیاده‌سازی سامانه‌های تشخیص حملات پیشرفته: استفاده از سامانه‌های تشخیص حملات هوشمند و پیشرفته برای تشخیص حملات Slow Request/Response و دیگر حملات DDoS می‌تواند به موفقیت‌آمیز بودن در پیشگیری از حملات کمک کند.
استفاده از فن‌های دفاعی پیشرفته: پیاده‌سازی فن‌های دفاعی پیشرفته مانند شبکه‌های تشخیص نفوذ و سامانه‌های پیشگیری از نفوذ می‌تواند به تشخیص و پیشگیری از حملات DDoS کمک کند.
توسعه روش‌های هوش مصنوعی و یادگیری عمیق: استفاده از روش‌های هوش مصنوعی و یادگیری عمیق برای تشخیص حملات ناشناخته و غیر قابل پیش‌بینی می‌تواند به افزایش دقت در تشخیص حملات و کاهش تأثیر آن‌ها کمک کند.
این راهکارها می‌توانند به بهبود امنیت سامانه‌های IOT و کاهش تأثیر حملات امنیتی بر روی آن‌ها کمک کنند.
استفاده از شبکه‌های عصبی مانند LSTM و CNN به‌عنوان روش هوش مصنوعی برای دفاع در برابر حملات DDoS مزایا و محدودیت‌های خود را دارد.

منابع

1. Ahmed Raoof, Ashraf Matrawy, Chung-Horng Lung,Secure Routing in IoT: Evaluation of RPL's Secure Mode under Attacks. Computer science cryptography and security Carleton (University Canada, 2019)

2. Cao, K., et al., Enhancing physical-layer security for IoT with nonorthogonal multiple access assisted semi-grant-free transmission. IEEE Internet of Things Journal, 2022. 9(24): p. 24669-24681.

3. Chen, P., et al., Effectively detecting operational anomalies in large-scale iot data infrastructures by using a gan-based predictive model. The Computer Journal, 2022. 65(11): p. 2909-2925.

4. El-Hajj, M., et al., A survey of internet of things (IoT) authentication schemes. Sensors, 2019. 19(5): p. 1141.

5. Glissa, G., A. Rachedi, and A. Meddeb. A secure routing protocol based on RPL for Internet of Things. in 2016 IEEE Global Communications Conference (GLOBECOM). 2016. IEEE.

6. Gupta, B., et al., Smart defense against distributed Denial of service attack in IoT networks using supervised learning classifiers. Computers & Electrical Engineering, 2022. 98: p. 107726.

7. Khanna, A. and S. Kaur, Internet of things (IoT), applications and challenges: a comprehensive review. Wireless Personal Communications, 2020. 114: p. 1687-1762.

8. Kore, A. and S. Patil, Cross layered cryptography based secure routing for IoT-enabled smart healthcare system. Wireless Networks, 2022: p. 1-15.

9. Li, B., et al., Dynamic event-triggered security control for networked control systems with cyber-attacks: A model predictive control approach. Information Sciences, 2022. 612: p. 384-398.

10. Stoyanova, M. Nikoloudakis, Y. Panagiotakis, S. Pallis, E. & Markakis, E. K. A survey on the internet of things (IoT) forensics: Challenges, approaches, and open issues. IEEE Commun. Surv. Tutor. 22(2), 1191–1221 (2020).

11. Hussain, F., Abbas, S. G., Husnain, M., Fayyaz, U. U., Shahzad, F., & Shah, G. A. (2020, November). IoT DoS and DDoS attack detection using ResNet. In 2020 IEEE 23rd International Multitopic Conference (INMIC) (pp. 1-6). IEEE.

12. Roopak, M., Tian, G. Y., & Chambers, J. (2020). Multi-objective-based feature selection for DDoS attack detection in IoT networks. IET Networks, 9(3), 120-127.

13. R., Russello, G., & Zanna, P. (2021). Mitigating ddos attacks in sdn-based iot networks leveraging secure control and data plane algorithm. Applied Sciences, 11(3), 929

14. .Bhayo, J., Jafaq, R., Ahmed, A., Hameed, S., & Shah, S. A. (2021). A time-efficient approach toward DDoS attack detection in IoT network using SDN. IEEE Internet of Things Journal, 9(5), 3612-3630.

15. Jia, Y., Zhong, F., Alrawais, A., Gong, B., & Cheng, X. (2020). Flowguard: An intelligent edge defense mechanism against IoT DDoS attacks. IEEE Internet of Things Journal, 7(10), 9552-9562.

دانشگاه آزاد اسلامی واحد الکترونیکی
مجله فناوری اطلاعات و امنیت شبکه

تشخیص و شناسایی علائم ترافیکی مبتنی بر یادگیری عمیق با سیستم‌های تعبیه شده

پیمان بابایی[1*]، فائزه عباسی[2]
[1،2] گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران.
Peyman.Babaei@IAU.ac.ir

چکیده – **تشخیص و شناسایی علائم ترافیکی، نیازمند به‌کارگیری الگوریتم‌های تشخیص و طبقه بندی است و اساساً از اطلاعات بصری مانند شکل و رنگ علائم ترافیکی استفاده می‌کنند. با این حال، این الگوریتم‌ها در آزمون‌های بلادرنگ با اشکالاتی مواجه هستند همچنین دستیابی به تشخیص چند هدف بسیار دشوار و نیازمند تسریع در عملکرد الگوریتم‌های مربوطه است. سیستم‌های تشخیص علائم ترافیکی مبتنی بر شبکه عصبی عمیق ممکن است به دلیل نیازهای محاسباتی و مصرف منابع، محدودیت‌هایی در کاربردهای عملی داشته باشند. اکثر سیستم‌های تعبیه شده به طور مستقیم با فرآیندها یا محیط تعامل دارند و بر اساس ورودی های خود تصمیم گیری می کنند. این امر باعث می‌شود که سیستم واکنش پذیر باشد و در زمان واقعی به ورودی های پردازش برای اطمینان از عملکرد صحیح پاسخ دهد. این مقاله یک شبکه عصبی سبک وزن را برای تشخیص علائم ترافیکی ارائه می‌کند که به صحت و دقتی بالا با پارامترهای قابل آموزش کمتر دست می‌یابد. برای ارزیابی کارایی و قابلیت اطمینان، مدل پیشنهادی مبتنی بر شبکه عصبی کانولوشنی به‌منظور شناسایی علائم ترافیکی، آزمایش‌های گسترده‌ای بر روی مجموعه داده *GTSRB* انجام شده است. همچنین نتایج به‌دست آمده با چند معماری پیشرفته از جمله *VGG16*، *MobileNetv2* و *ResNet50* مقایسه شده است. نتایج نشان می‌دهد که مدل پیشنهادی به عملکرد خوبی دست یافته است و بر پتانسیل آن برای استقرار مدل شناسایی علائم ترافیکی بلادرنگ و سیستم‌های کمک رانندگی تاکید می‌کند. راندمان محاسباتی و اندازه کوچک مدل پیشنهادی، آن را برای شناسایی علائم ترافیکی بلادرنگ کاربردی تر و مناسب تر می کند.**

کلید واژه– تشخیص و شناسایی علائم ترافیکی، سیستم‌های تعبیه شده، شبکه‌های عصبی کانولوشنی.

مقدمه

یک سیستم تعبیه شده را می توان به طور کلی به عنوان دستگاهی تعریف کرد که شامل اجزای سخت‌افزاری و نرم‌افزاری محکم به هم متصل شده برای انجام یک عملکرد واحد است، بخشی از یک سیستم بزرگ‌تر را تشکیل می‌دهد، به طور مستقل توسط کاربر قابل برنامه‌ریزی است و انتظار می رود که با حداقل منابع کار کند. صرف‌نظر از عملکردی که یک سیستم تعبیه شده انجام می‌دهد، ساختار آن دو مجموعه اصلی و محکم از اجزاء را نشان می‌دهد: مجموعه ای از قطعات سخت افزاری که شامل یک واحد پردازش مرکزی، معمولاً به شکل یک میکروکنترلر است و یک سری از برنامه‌های نرم افزاری که معمولاً به عنوان سیستم عاملی است که به سخت افزار کارایی می‌دهد. شکل ۱ نمای کلی آن و این دو جزء اصلی و ارتباط متقابل آنها را نشان می‌دهد. ورودی‌ها معمولا در یک سیستم تعبیه‌شده، متغیرهای فرآیند و پارامترهایی هستند که از طریق حسگرها و پورت(دروازه)های ورودی/خروجی وارد می‌شوند. خروجی ها به صورت اقدامات کنترلی بر روی محرک‌های سیستم یا اطلاعات پردازش شده برای کاربران یا سایر زیرسیستم‌هایی درون برنامه هستند. در برخی موارد، تبادل اطلاعات ورودی/خروجی با کاربران از طریق یک رابط کاربری که ممکن است شامل کلیدها، حسگرها، دیودهای نوری، نمایشگرها و سایر انواع دستگاه‌های نمایشگر باشد، انجام می‌شود.

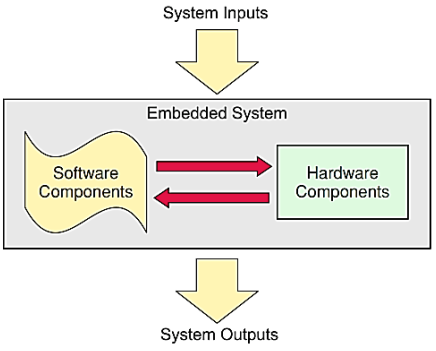

شکل ۱: نمای کلی یک سیستم تعبیه شده.

در ادامه نگاهی دقیق‌تر به اجزای سخت‌افزار و نرم‌افزاری خواهیم داشت که یک سیستم تعبیه‌شده را یکپارچه می‌کنند. اجزای سخت‌افزاری یک سیستم تعبیه‌شده شامل تمام لوازم الکترونیکی لازم برای انجام عملکردی است که برای آن طراحی شده است. بنابراین، ساختار خاص یک سیستم، بر اساس برنامه، می‌تواند به طور قابل ملاحظه‌ای با سیستم دیگر متفاوت باشد. با وجود این تفاوت ها، سه جزء سخت افزاری اصلی در یک سیستم تعبیه شده ضروری هستند(شکل۲): واحد پردازش مرکزی(CPU)، حافظه سیستم و مجموعه‌ای از پورت‌های ورودی/خروجی. CPU دستورالعمل‌های نرم افزاری را برای پردازش ورودی‌های سیستم و اتخاذ تصمیماتی اجرا می‌کند که عملکرد سیستم را هدایت می‌کند. حافظه برنامه‌ها و داده‌های لازم برای عملکرد سیستم را ذخیره می‌کند. اکثر سیستم‌ها بین حافظه‌های برنامه و داده‌ها تفاوت قائل می‌شوند. حافظه برنامه، برنامه های نرم افزاری اجرا شده توسط CPU را ذخیره می‌کند. حافظه داده، داده‌های پردازش‌شده توسط سیستم را ذخیره می‌کند. پورت‌های I/O امکان انتقال سیگنال‌ها را بین CPU و دنیای خارج از آن فراهم می‌کنند. فراتر از این نقطه، باتوجه به کاربرد، ممکن است تعدادی دیگر از دستگاه‌های پشتیبانی و ورودی/خروجی مورد نیاز برای عملکرد سیستم وجود داشته‌باشد.

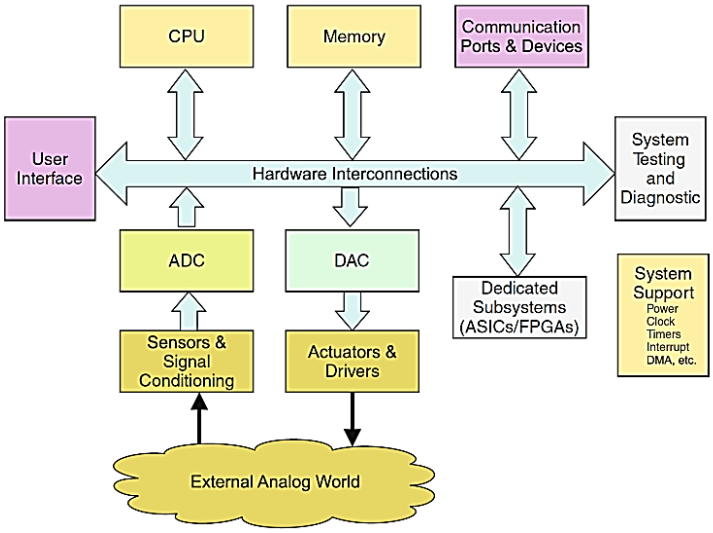

شکل ۲: عناصر سخت افزاری در یک سیستم تعبیه شده.

به‌طورکلی سیستم‌های تعبیه شده را می‌توان به دو دسته سیستم‌های تعبیه شده کوچک و سیستم‌های تعبیه شده با کارایی بالا طبقه‌بندی کرد. سیستم‌های تعبیه شده کوچک حول یک تراشه میکروکنترلر متمرکز است که کل برنامه را کنترل می‌کند. این سیستم‌ها به شدت یکپارچه هستند و در صورت نیاز فقط چند جزء آنالوگ، حسگرها، محرک‌ها و رابط کاربری را اضافه می‌کنند. این سیستم‌ها با حداقل‌ها کار می‌کنند، هزینه بسیار پایینی دارند و به صورت انبوه تولید می‌شوند. نرم افزار در این سیستم‌ها معمولا تک وظیفه‌ای است و به‌ندرت به RTOS نیاز دارند. نمونه‌هایی از این سیستم‌ها عبارتند از: سیستم‌های نظارت بر فشار باد تایر و کنترل‌کننده‌های اجاق مایکروویو. سیستم‌های تعبیه شده با کارایی بالا نشان‌دهنده کلاس سیستم‌های تعبیه شده بسیار تخصصی است که به محاسبات سریع، استحکام، تحمل خطا و قابلیت نگهداری بالا نیاز دارند. این سیستم‌ها معمولاً به پردازنده‌های گرافیکی اختصاصی NVIDIA یا ASICS نیاز دارند و ممکن است شامل DSPو FPGA به عنوان بخشی از سخت‌افزار اصلی باشند. در بسیاری از موارد، پیچیدگی نرم افزار آنها استفاده از RTOS را برای مدیریت وظایف متعدد الزامی می‌کند. آنها در مقادیر کم تولید می‌شوند و هزینه آنها بسیار بالا است. لذا سیستم‌های تعبیه‌شده‌ای هستند که در کاربردهای نظامی یا هوافضا استفاده می‌شوند، مانند کنترل‌کننده‌های پرواز، سیستم‌های هدایت موشک و سیستم‌های ناوبری فضاپیما. در این طبقه بندی می‌توانیم نواحی خاکستری را پیدا کنیم که در آن ویژگی‌های دو یا سه مورد از آنها همپوشانی دارند و ممکن است برنامه‌ها به یک کلاس خاص مرتبط شوند. با این حال، اگر به طیف وسیعی از برنامه‌های کاربردی تعبیه شده نگاه کنیم، در بیشتر موارد، تشخیص کلاسی که یک برنامه خاص به آن تعلق دارد، به طور کلی آسان می‌شود.

یادگیری عمیق و شبکه‌های عصبی کانولوشنی

عملیات کانولوشنی

عملیات ریاضی دو تابع f و g برای به‌دست آوردن تابع سوم را کانولوشنی می‌نامند. در واقع، انتگرالی که مقدار همپوشانی g را با جابجایی آن بر روی تابع f تعیین می‌کند، کانولوشن نامیده می‌شود. به‌طور کلی، عملگرستاره عملیات کانولوشنی را بیان می‌کند.

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t-\tau)\,d\tau$$

تابع کانولوشنی یک میانگین وزنی از $f(\tau)$ است. تابع وزنی g زمانی که تابع t تغییر می‌کند تاکید بیشتری بر ورودی تابع f دارد.

در اصطلاحات شبکه کانولوشنی، تابع f به عنوان ورودی، نقشه ویژگی به عنوان خروجی و تابع g به عنوان هسته شناخته می‌شود. در سیستم‌های دیجیتال، تابع کانولوشنی می‌تواند با فرض f زمانی که g روی مقادیر صحیح t تعریف می‌شود، گسسته شود:

$$(f * g)(t) = \sum_{r=-\infty}^{\infty} f(\tau)g(t-\tau)\,d\tau$$

در شبکه‌های عصبی کانولوشنی، آرایه‌های چند بعدی به عنوان ورودی و آرایه چند بعدی پارامترها که تنسور نامیده می‌شوند، به عنوان هسته در نظر گرفته می‌شوند. به عنوان مثال، در یک تصویر دو بعدی با ورودی I، از دو عدد هسته دوبعدی K استفاده شده است.

$$S(i,j) = (I * k)(i,j) = \sum_{m}\sum_{n} I(m,n)K(i-m, j-n)$$

و نقشه ویژگی (یا خروجی) مکان S است.

تعامل هر واحد ورودی با هر واحد خروجی توسط ماتریسی از پارامترها با پارامترهای جداگانه توصیف می‌شود. بنابراین، لایه‌های شبکه عصبی کاملاً متصل از ضرب ماتریسی استفاده می‌کنند. با پرداختن به ورودی‌های با ابعاد بیشتر مانند تصاویر، اتصال نورون‌ها به همه نورون‌ها غیرعملی خواهد بود، بنابراین شبکه‌های کاملاً متصل از تصاویر قابل مقیاس نیستند. به‌کارگیری یک هسته کوچکتر از ورودی باعث می‌شود عملیات کانولوشن، هر نورون را فقط به یک ناحیه محلی از ورودی متصل کند. مقایسه شبکه‌های کاملاً متصل سنتی با شبکه‌های کانولوشنی از نظرکارایی بسیار موثر است. الگوریتم‌های هر نمونه دارای $O(m\times n)$ زمان اجرا و ضرب ماتریس نیاز به $m\times n$ پارامتر دارند (m ورودی، n خروجی). برای اینکه الگوریتم ها را به پارامترهای $k\times n$ و زمان اجرا را به $O(k\times n)$ برسانیم، باید تعداد اتصالات هر خروجی را به K محدود کنیم. به عنوان مثال، برای پردازش یک تصویر، هزاران یا میلیون‌ها پیکسل ممکن است در ورودی باشد. از لبه‌های دارای هسته می‌توان برای کاهش تعداد پیکسل‌های مصرف شده به ده‌ها یا صدها پیکسل استفاده کرد. ذخیره پارامترهای کمتر با استفاده از کانولوشن امکان‌پذیر است و منجر به کاهش تقاضای محاسباتی شبکه می‌شود. به جای یادگیری مجموعه‌ای جداگانه از پارامترها برای هر مکان، استفاده از هر یک از اعضای هسته در هر موقعیت ورودی منجر به اشتراک‌گذاری پارامترها در شبکه‌های کانولوشنی می‌شود. در یک شبکه کاملا متصل معمولاً برای محاسبه خروجی یک لایه، هر عنصر ماتریس فقط یک بار استفاده می‌شود.

معماری شبکه‌های عصبی کانولوشنی

زیر مجموعه کاربردی از شبکه‌های عصبی به نام شبکه‌های عصبی کانولوشنی (CNN) معرفی شدند. دلیل ارائه شبکه‌های عصبی و شبکه‌های عصبی کانولوشنی این است که با پیشرفت دستگاه‌های هوشمند و رسانه‌های اجتماعی مختلف، حجم زیادی از داده‌ها در اینترنت در کسری از زمان تولید می‌شود. با این حال، این منابع داده گسترده، نمی‌تواند توسط انسان‌ها به‌طور دقیق پردازش شود. از این رو، انسان‌ها برای پردازش خودکار داده‌های گسترده به کمک رایانه نیاز دارند. علاوه بر این، مشکلات طبقه‌بندی، تشخیص شیء و الگو را می‌توان توسط معماری فوق‌العاده شبکه‌های عصبی کانولوشنی انجام داد که سریع‌تر و کارآمدتر است. شبکه‌های عصبی

کانولوشنی نه تنها می‌توانند شبکه‌های عمیق‌تری ایجاد کنند، بلکه روند آموزش را تسریع می‌کنند. با توجه به این روند آموزشی سریع، شبکه‌های عصبی کانولوشنی منجر به ایجاد شبکه‌های عمیق‌تر می‌شوند. اگرچه شبکه‌های عصبی مرسوم از نمایش‌برداری استفاده می‌کنند، عملکرد شبکه‌های عصبی کانولوشنی بر روی تصاویر بر اساس ارتفاع، عرض و تعداد کانال‌ها است. برای درک راحت‌تر مفاهیم، در لایه‌های شبکه‌های عصبی کانولوشنی، پیکسل‌ها توسط یک فیلتر یا هسته که مجموعه‌ای از بایاس‌ها و وزن‌ها است، روی لایه پنهان بعدی قرار می‌گیرند. گاهی اوقات فیلترها می‌توانند یک آشکارساز ویژگی مانند یک آشکارساز لبه عمودی یا افقی باشند. اعمال فیلتر بر روی یک تصویر معمولاً اندازه تصویر را کاهش می‌دهد. با این حال، تعداد کانال‌ها افزایش خواهد یافت. ساده‌سازی اطلاعات در خروجی لایه کانولوشن بسیار مهم است، زیرا این کار را می‌توان با کاهش لایه کانولوشن انجام داد. بنابراین، مفهوم ادغام معرفی شد. یکی از مهم‌ترین تفاوت‌های شبکه‌های عصبی معمولی با شبکه‌های عصبی کانولوشن، وجود لایه ادغام است. به‌طور کلی، شبکه‌های عصبی کانولوشنی از لایه کانولوشنی تشکیل شده‌اند که به عنوان لایه‌های کانولوشنی، لایه‌های ادغام و به دنبال آن یک لایه کاملاً متصل در انتها شناخته می‌شود که در شکل ۳ نشان داده شده است.

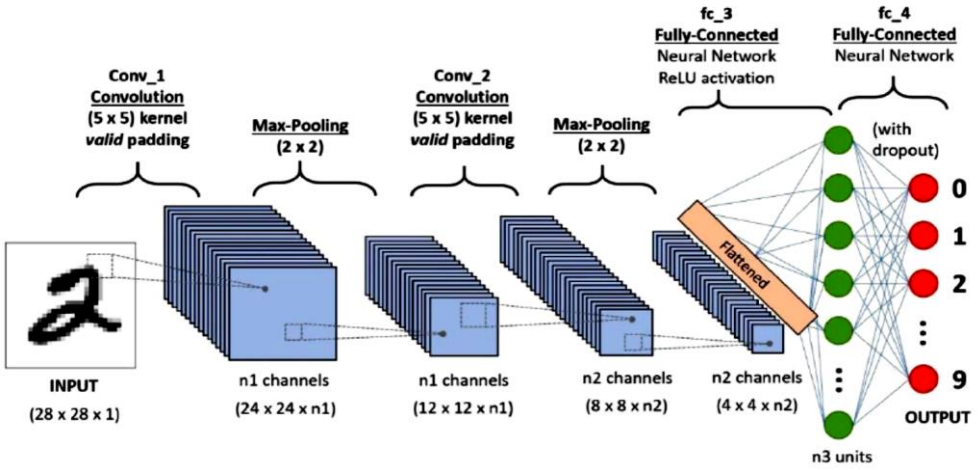

شکل ۳: معماری یک شبکه عصبی کانولوشنی

مانند شبکه‌های عصبی کلاسیک، شبکه‌های عصبی کانولوشنی از توابع فعال سازی مختلفی در لایه‌های خروجی خود استفاده می‌کنند که ورودی لایه‌های بعدی است. تابع خطیReLU، تابع سیگموئید و تابع تانژانت هیپربولیک انواع مختلفی از توابع فعال‌سازی هستند که می‌توانند برای شبکه‌های عصبی کانولوشنی اعمال شوند. درک صحنه، تشخیص و شناسایی اشیاء و استخراج ویژگی مسائل بینایی رایانه‌ای مواردی هستند که به عنوان معماری‌های پیشنهادی شبکه‌های عصبی کانولوشنی دسته‌بندی می‌شوند. در سال ۱۹۹۰، مدلی توسعه داده شد که می‌تواند به عنوان اولین کاربرد موفق شبکه‌های عصبی کانولوشنی به حساب آید. کاربردهای متعددی در مسائل بینایی رایانه‌ای مانند تشخیص ارقام دارد. معماری LeNet در شکل ۴ نشان داده شده است.

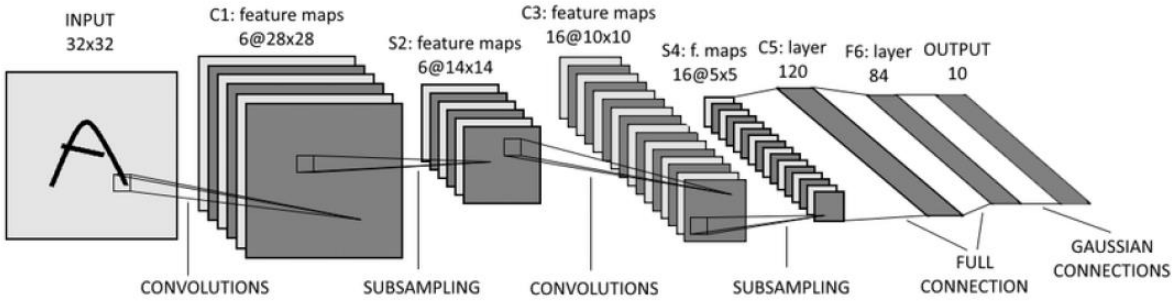

شکل ۴: معماری LeNet [۱]

معماری AlexNet ، یکی از نخستین آثاری است که شبکه‌های عصبی کانولوشنی را در بینایی رایانه‌ای رواج داد. اگرچه این شبکه، بسیار شبیه به LeNet بود، اما دارای لایه‌های کانولوشنی بزرگ‌تر و عمیق‌تر بود که روی هم چیده شده بودند. AlexNet در سال ۲۰۱۲ به چالش ILSVRC فرستاده شد. این معماری شامل ۶۳۰ میلیون اتصال، ۶۰ میلیون پارامتر و ۶۳۰ میلیون نورون است.(شکل ۵)

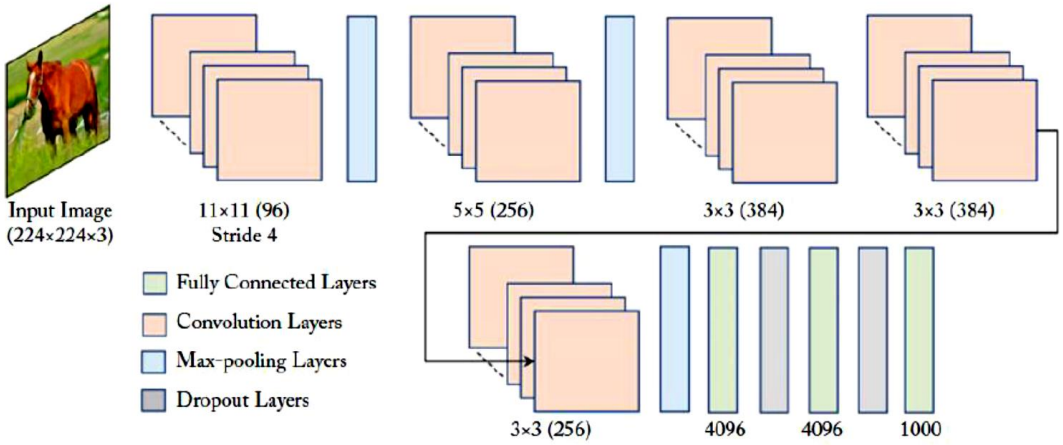

شکل ۵: معماری AlexNet [۱]

این شبکه GoogleNet در سال ۲۰۱۴ رتبه اول را در چالش تشخیص تصویر در مقیاس بزرگ ImageNet (ILSVRC) کسب کرد. تعداد پارامترها به طور چشمگیری، از ۶۰ میلیون به ۴ میلیون در مقایسه با AlexNet کاهش یافت. این معماری، ترکیبی از لایه‌های ادغام و کانولوشن به همراه ماژول‌های آغازین آنها بود. GoogleNet اولین شبکه‌ای است که از معماری مدرن شبکه‌های عصبی کانولوشنی استفاده می‌کند که فقط برای لایه‌های کانولوشن و ادغام استفاده نمی‌شود، بلکه در معماری inception نیز کاربرد دارد. همانطور که در شکل ۶ نشان داده شده‌است، به عنوان inception network نیز شناخته می‌شود. علاوه بر این، در مسیرهای موازی با اندازه مختلف نقشه ویژگی‌ها کار می‌کند. مزیت ماژول inception پرش از اتصالات در شبکه و ایجاد مینی ماژول است که از طریق شبکه تکرار می‌شود. هدف این ماژول کاهش تعداد پارامترها در شبکه است. هدف اصلی ماژول قرار دادن تمام بلوک‌های اساسی پردازش در سیستم موازی است. مزیت اصلی معماری GoogleNet ایجاد شبکه بزرگ با انباشتن چندین ماژول در کنار هم است.

VGGNet یکی دیگر از شبکه‌های عصبی کانولوشنی است که در چالش تشخیص تصویری در مقیاس بزرگ ImageNet (ILSVRC) در سال ۲۰۱۴ به عملکرد بالایی دست یافت. در آن زمان، VGGNet به عنوان یک شبکه عصبی پیچیده بسیار عمیق در نظر گرفته می‌شد. این به توضیح عمق شبکه برای افزایش دقت تشخیص یا طبقه‌بندی کمک می‌کند. اگرچه این شبکه بسیار عمیق است، اما سادگی آن قابل توجه است. این معماری شبکه از ابتدا تا انتها فقط از لایه‌های کانولوشن ۳*۳ و ادغام ۲*۲ استفاده می‌کند که در شکل ۷ نشان داده شده‌است. یکی از بزرگ‌ترین نقاط ضعف VGGNet این است که از حافظه و پارامترهای زیادی (۱۴۰ میلیون) استفاده می‌کند که به نوبه خود هزینه بیشتری دارد.

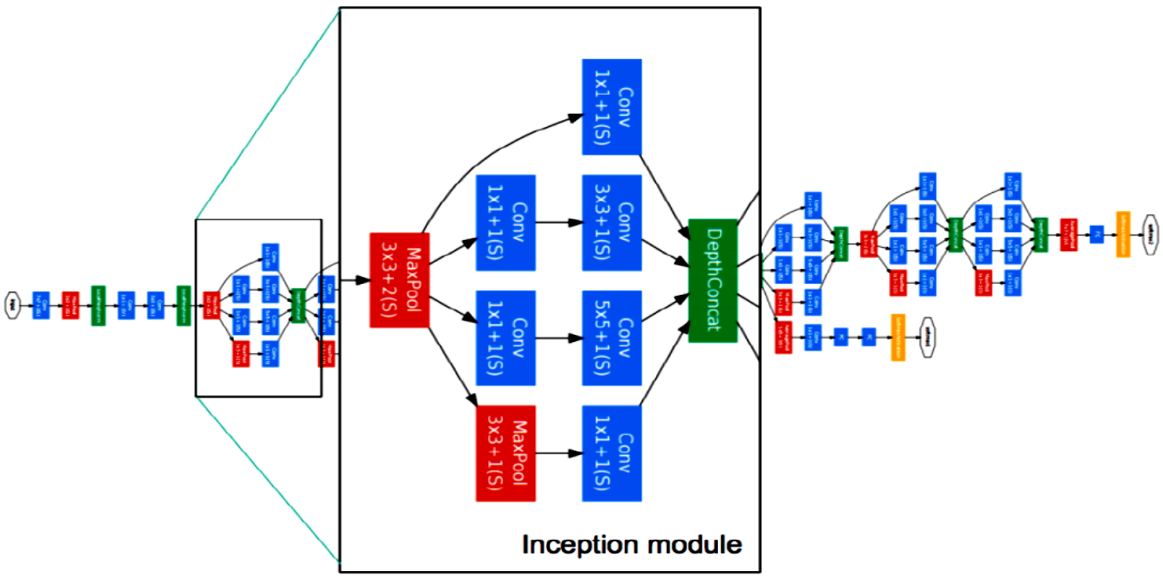

شکل ۶: معماری ماژول inception [۱]

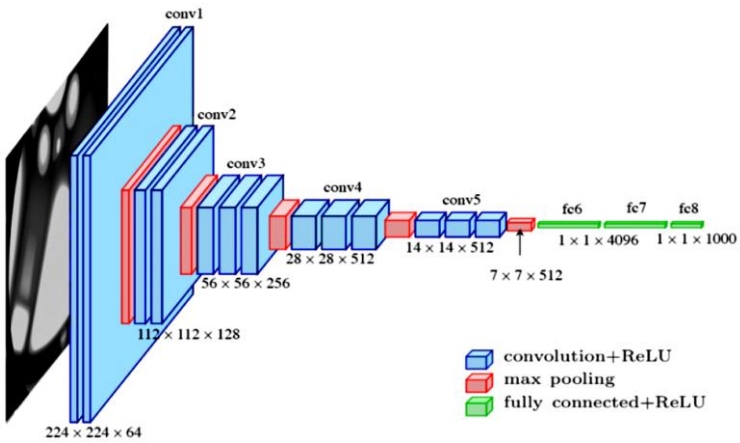

شکل ۷: معماری VGG-16 [۱]

ResNet یک شبکه عصبی کانولوشنی عمیق است. در چالش تشخیص تصویر در مقیاس بزرگ ImageNet (ILSVRC) در سال ۲۰۱۵ رتبه نخست را کسب کرد. در مجموع از ۱۵۲ لایه تشکیل شده بود. به دلیل توانایی آن در آموزش یک مدل عمیق ۱۰۰۱ لایه با استفاده از اتصالات باقیمانده تحت عنوان اتصالات باقیمانده شناخته شد. مزیت اصلی استفاده از اتصالات باقیمانده، کسب دانش در حین آموزش و افزایش سرعت زمان آموزش است. ResNet از نرمال‌سازی دسته‌ای بعد از هر لایه استفاده می‌کند و همانطور که در شکل ۸ نشان داده شده‌است، از اتصال پرش برای بهینه‌سازی ساده استفاده می‌کند.

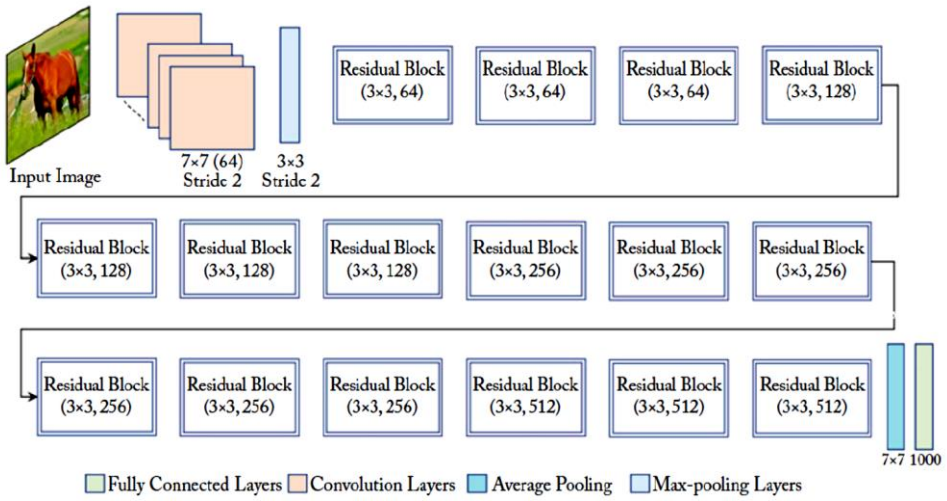

شکل ۸: معماری ResNet [۱]

یادگیری عمیق و تشخیص علائم ترافیکی

حوزه تشخیص علائم ترافیکی در سال‌های اخیر شاهد پیشرفت‌های متعددی بوده‌است و بسیاری از محققان برای توسعه الگوریتم‌های کارآمد و دقیق به تکنیک‌های یادگیری عمیق روی آورده‌اند. در[۲] از یک شبکه عصبی کانولوشنی (CNN) با یک مدل از پیش آموزش دیده MobileNet، برای تشخیص علائم ترافیکی استفاده کردند. معماری MobileNet به گونه‌ای طراحی شده‌است که سبک و کارآمد باشد و برای استفاده در برنامه‌های سیار و بینایی سیستم‌های تعبیه شده مناسب باشد. روش پیشنهادی از نرمال‌سازی دسته‌ای، فعال‌سازی ReLU و یک لایه softmax برای محاسبه احتمال اطمینان ورودی به عنوان علامت ترافیک استفاده می‌کند. این مدل بر روی مجموعه داده‌های تشخیص علائم ترافیکی آلمان (GTSRB) با استفاده از بهینه‌ساز Adam با نرخ یادگیری ۰,۰۰۱ آموزش داده شد و آموزش مدل برای ۳۰ دوره بدون افزایش داده و ۲۰۰ دوره دیگر با تکنیک‌های افزایش داده‌ها مانند چرخش، مقیاس‌گذاری، تغییر و تبدیل انجام شد. نتیجه نهایی دقت، ۹۹,۶۶ درصد بود که نشان دهنده اثربخشی روش پیشنهادی است. در[۳] دقت تشخیص علائم ترافیکی با استفاده از دو روش یادگیری عمیق YOLOv5و SSD مقایسه شدند. YOLOv5 یک الگوریتم تشخیص شی بلادرنگ است که کل تصویر را با یک شبکه عصبی پردازش می‌کند و آن را به بخش‌هایی تقسیم می‌کند تا جعبه‌های مرزی و احتمالات هر قسمت را تخمین بزند. از سوی دیگر، SSD با حذف نیاز به شبکه‌های پیشنهادی منطقه برای هر جزء، روند را تسریع می‌کند. نویسندگان مجموعه داده‌ای از ۲۱۸۲ تصویر علائم ترافیکی را از ۸ کلاس مختلف جمع‌آوری کردند که به صورت ۶۴٪ مجموعه آموزشی، ۱۶٪ مجموعه اعتبار سنجی و ۲۰٪ مجموعه آزمون تقسیم کردند. مدل‌ها با استفاده از تکنیک‌های افزایش داده‌ها، مانند چرخش و تغییر اندازه آموزش داده شدند. برای YOLOv5، اندازه تصویر روی ۶۴۰ × ۶۴۰ تنظیم شد، اندازه دسته‌ها ۱۶ بود، و مدل برای ۲۰۰ دوره آموزش داده شد. در[۴] یک راه حل مبتنی بر شبکه عصبی کانولوشنی (CNN) برای تشخیص علائم ترافیکی پیشنهاد کردند. معماری شبکه عصبی کانولوشنی پیشنهادی شامل لایه‌های کانولوشن، کاملاً متصل و softmax است. نویسندگان، آزمایش‌هایی را با پیکربندی‌های مختلف معماری شبکه عصبی کانولوشنی انجام دادند که بهترین آنها شامل ۳ لایه کانولوشن، ۱ لایه کاملاً متصل و یک لایه softmax بود. دقت روش پیشنهادی بر روی مجموعه داده GTSRB، به۹۹,۹۴ درصد دست یافت. در[۵] یک سیستم تشخیص علائم ترافیکی را با استفاده از شبکه عصبی کانولوشن LeNet پیشنهاد کردند که ترکیبی از دو مدل از پیش آموزش دیده، VGG16وLeNet است. این سیستم بر روی مجموعه داده GTSRB آموزش داده شد و به یک مجموعه آموزشی ۳۹۲۰۹ و یک مجموعه آزمایشی ۱۲۶۳۰ تقسیم شد. این سیستم با استفاده از بهینه‌ساز Adam با تابع softmax آموزش داده‌شد. این آزمایش نشان داد که مدل LeNetبهتر از مدل VGG16 با سطوح دقت ۹۸,۶ درصد و دقت ۹۶,۷ درصد عمل کرد. در[۶] یک مدل LeNet-5 پیشرفته برای طبقه بندی علائم ترافیکی پیشنهاد کردند. مدل پیشنهادی شامل دو لایه کانولوشن برای استخراج ویژگی‌ها از تصاویر، به دنبال آن دو لایه کانولوشنی و یک لایه کاملاً متصل بود. برای افزایش پایداری و سرعت آموزش مدل، نرمال‌سازی دسته ای و حذف با نرخ ۰,۵ بعد از لایه کاملا متصل اضافه شد. LeNet-5 بهبودیافته بر روی مجموعه داده‌های GTSRB و BTSD آموزش داده شد و تصاویر با استفاده از متعادل‌سازی هیستوگرام، تبدیل مقیاس خاکستری، تغییر اندازه و نرمال‌سازی، پیش پردازش شدند. این آزمایش، نشان داد که بهینه‌ساز Adam با فعال‌سازی ReLU بهتر از Adadelta با فعال‌سازی LeakyReLU عمل می‌کند و مدل LeNet-5 به دقت ۹۹,۸۴ درصد در مجموعه داده GTSRBو ۹۸,۳۷ درصد در مجموعه داده BTSD دست یافت. در[۷]، چندین مدل شبکه عصبی کانولوشنی (CNN) برای عملکرد آنها در طبقه‌بندی علائم ترافیکی

ارزیابی شدند. سه مدل ارزیابی شده VGG16، ResNet50 و CNN پیشنهادی نویسندگان بر اساس AlexNet بودند. مدل شبکه عصبی کانولوشنی پیشنهادی با اندازه فیلتر کاهش‌یافته و اندازه گام ۱ طراحی شد. همچنین از Maxpool با اندازه گام ۲ برای نمونه برداری از نقشه ویژگی، یک لایه مسطح و سه لایه کاملاً متصل استفاده می‌کند. در آخرین لایه کاملاً متصل، از ۴۳ نورون برای نشان دادن هر یک از ۴۳ کلاس مختلف علائم ترافیکی، همراه با یک تابع فعال‌سازی softmax برای طبقه‌بندی استفاده می‌شود. فعال سازی ReLU بعد از هر لایه کانولوشنی برای جلوگیری از میانگین به صفر شدن ویژگی‌های پیچیده استفاده می‌شود. مجموعه داده مورد استفاده، معیار تشخیص علائم ترافیک آلمان (GTSRB) بود. مجموعه آموزشی برای کاهش شدت و کاهش هزینه محاسباتی به مقیاس خاکستری تبدیل شد و به دنبال آن یکسان‌سازی هیستوگرام برای کشش کنتراست برای اطمینان از توزیع یکنواخت شدت پیکسل ها انجام شد. نتایج نشان داد که VGG16 به دقت ۹۵,۵ درصد، ResNet50 به دقت ۹۵,۴ درصد دست یافت و شبکه عصبی کانولوشنی پیشنهادی با AlexNet به بالاترین دقت ۹۶,۰ درصد دست یافت. در[۸]، یک روش طبقه‌بندی و تشخیص علائم ترافیکی را با شبکه عصبی کانولوشنی عمیق پیشنهاد کردند. در معماری مدل شبکه عصبی کانولوشنی پیشنهادی، لایه‌های کانولوشنی، یک لایه ادغام و یک لایه تجمیع حداکثری وجود دارد. برای آزمایش از سه مجموعه داده شامل GTSRB، BTSCو TSRD+GTSRB به ترتیب با ۴۳، ۶۲ و ۱۰۱ کلاس استفاده شد. به منظور جلوگیری از برازش بیش از حد و برای افزایش تعمیم پذیری آموزش، از تکنیک‌های تقویت داده‌ها مانند چرخش، بزرگ‌نمایی و مقیاس استفاده شد. با روش پیشنهادی شبکه عصبی کانولوشنی، GTSRBبه دقت ۹۹,۷۶ درصد، BTSCبه دقت ۹۹,۷۹ درصد و TSRD+GTSRB به دقت ۹۸,۳۷ درصد دست یافت. در [۹]، یک رویکرد با دو شبکه عصبی کانولوشنی برای طبقه‌بندی علائم ترافیکی استفاده شد. مدل MCNN با استفاده از مجموعه داده اصلی، آموزش داده شد، در حالی که مدل CCNN با نمونه‌های افزوده شده، آموزش داده شد. نتایج هر دو مدل با محاسبه احتمالات سوپرکلاس و زیر کلاس علائم ترافیکی و انتخاب برچسب تشخیص واقعی بر اساس وزن احتمال بالاتر مقایسه شد. مجموعه داده مورد استفاده مجموعه داده GTSRB بود و اندازه تصاویر به ۳۲ × ۳۲ تغییر داده شد و برای افزایش حجم نمونه مجموعه داده، از تکنیک‌های تقویت داده‌ها مانند مقیاس‌بندی، چرخش و چرخش استفاده شد. ۴۳ کلاس در مجموعه داده GTSRB به پنج ابر کلاس، از جمله علائم منع دایره‌ای قرمز، علائم خطر مثلثی قرمز، علائم اجباری دایره‌ای آبی، علائم ممنوعیت دایره‌ای سیاه و سایر علائم گروه‌بندی شدند. آزمایش‌ها برای ۱۰۰ دوره با اندازه دسته‌ای ۳۰ اجرا شد. نتایج نشان داد که CCNN با افزایش داده‌ها به سطح دقت بالاتری (۹۸,۲۶٪) در مقایسه با مدل MCNN (۹۷,۹۶٪) دست یافت. در[۱۰]، یک معماری سبک وزن شبکه عصبی کانولوشنی به نام DeepThin را معرفی کردند که چندین لایه کانولوشنی با اندازه هسته متوسط را روی هم قرار می‌دهد. مجموعه داده‌های مورد استفاده GTSRB و مجموعه داده‌های طبقه‌بندی علائم ترافیکی بلژیکی (BTSC) با اندازه تصاویر به ۴۵×۴۵ پیکسل و تبدیل به مقیاس خاکستری بودند. این روش دقت ۹۹,۷۲ درصد برای GTSRB و ۹۹,۲۹ درصد برای BTSC پس از ترکیب تکنیک‌هایی مانند یادگیری گروهی و تنظیم دقیق را به دست آورد. در[۱۱] روشی را برای طبقه‌بندی علائم ترافیکی با استفاده از MicronNet ارائه کردند. MicronNet یک شبکه عصبی عمیق کوچک است که برای استفاده در دستگاه‌های تعبیه شده طراحی شده است و MicronNet-BF دقت آن را با ادغام آن با نرمال‌سازی دسته ای بهبود بخشیده‌است. مجموعه داده GTSRB استفاده شد و MicronNet-BF با زمان پردازش فقط ۱,۴۱ ثانیه به دقت ۹۹,۳۸ درصد دست یافت. گنجاندن نرمال‌سازی دسته‌ای دقت را ۱,۰۵٪ در مقایسه با MicronNet اصلی بهبود بخشید. در[۱۲] با استفاده از چندین شبکه عصبی ResNets، از جمله ResNet18 ، ResNet50وResNet152 ، یک رویکرد جدید برای تشخیص علائم ترافیکی معرفی کردند. این مدل‌ها به ترتیب دارای ۱۸، ۵۰ و ۱۵۲ لایه پنهان وزن‌دار بودند. مجموعه‌ای با بیش از ۴۰۰۰۰ تصویر را با استفاده از یک ماشین خودران جمع‌آوری کردند، از ۲۲۴ تصویر با وضوح بالا برای آزمایش استفاده کردند. مجموعه داده شامل سه کلاس که هر کدام شامل ۳۰۰ تصویر است. اندازه تصاویر به ۲۲۴ × ۲۲۴ پیکسل تغییر یافت و به شرح زیر تقسیم شد: ۸۰٪ آموزش، ۲۰٪ اعتبار سنجی. از پانزده تصویر برای آزمایش استفاده شد. هیچ افزایش داده‌ای برای مجموعه داده اعمال نشد. این مدل برای ۱۰ دوره با اندازه دسته‌ای ۱۰ آموزش داده شد و آخرین لایه کاملاً متصل به خوبی تنظیم شد. بالاترین دقت تست ۹۳٪ برایResNet50 ، ۶۰٪ برای ResNet18 و ۳۳٪ برای ResNet152 بود. در[۱۳] یک معماری شبکه عصبی کانولوشنی بهبود یافته-LeNet 5را برای طبقه‌بندی علائم ترافیکی پیشنهاد کردند. معماری LeNet-5 شامل ۲ لایه کانولوشنی، ۲ لایه ادغام، ۲ لایه کاملا متصل و یک لایه طبقه‌بندی بود. برای بهبود عملکرد مدل، یک هسته گابور به عنوان اولین هسته کانولوشنی استفاده شد و نرمال‌سازی دسته‌ای پس از هر لایه ادغام انجام شد. تابع فعال‌سازی ReLU برای رسیدگی به مسائل ناپیدایی گرادیان استفاده شد و نرخ حذف ۰,۵ در لایه‌های کاملاً متصل اعمال شد. از مجموعه داده GTSRB استفاده کردند که ۷۵٪ برای آموزش و ۲۵٪ برای آزمایش بود و این مدل به دقت ۹۹,۷۵ درصد دست یافت. در[۱۴] یک شبکه کانولوشنی چند مقیاسی (MSCN) و یک شبکه عصبی عمیق با رویکرد چند ستونی (MCDNN) را برای تشخیص علائم ترافیکی پیشنهاد کردند. مجموعه داده TSRD برای آموزش استفاده شد، در حالی که مجموعه داده GTSRB برای آزمایش استفاده شد. برای بهبود عملکرد مدل، افزایش داده و تنظیم دقیق را انجام دادند. با این حال، نتایج نشان داد که دقت در ابتدا افزایش سپس با افزایش تعداد کلاس‌ها کاهش می یابد. روش پیشنهادی به دقت ۹۰,۱۳ درصد دست یافت. در[۱۵]، مطالعه‌ای برای بررسی تأثیر ابعاد مختلف فیلترهای لایه کانولوشنی بر عملکرد یک شبکه عصبی کانولوشنی برای طبقه‌بندی علائم ترافیکی انجام شد. ابعاد در نظر گرفته شده در آزمایش ۳، ۵، ۹، ۱۳، ۱۵، ۱۹، ۲۳، ۲۵ و ۳۱ بود. از مجموعه داده

GTSRBبرای آزمایش‌ها استفاده شد و تصاویر موجود در مجموعه داده با نرمال‌سازی و تغییر اندازه به ۳۲ × ۳۲ پیکسل پیش پردازش شدند. تابع خطا برای بهینه‌سازی شبکه به کار گرفته شد و ۱ گام برای لایه کانولوشنی و ۲ گام برای لایه ادغام، استفاده شد. نتایج نشان داد که فیلترهای لایه کانولوشنی با ابعاد ۹ × ۹ و ۱۹ × ۱۹ به ترتیب بالاترین سطوح دقت ۸۶,۴ درصد و ۸۶,۸ درصد را با سرعت طبقه‌بندی سریع ۰,۰۰۴۴۷۲ و ۰,۰۰۲۷۸۶ ثانیه داشتند. در[۱۶] یک روش مبتنی بر شبکه عصبی کانولوشنی برای طبقه‌بندی علائم ترافیکی پیشنهاد شد. معماری شبکه عصبی کانولوشنی پیشنهادی دارای ۱۲ لایه، شامل ۴ لایه کانولوشنی، ۲ لایه ادغام حداکثری، ۴ لایه حذفی، ۱ لایه مسطح و ۱ لایه کاملاً متصل است. تابع خطای متقاطع آنتروپی برای بهینه‌سازی شبکه استفاده شد و آزمایش‌ها بر روی مجموعه داده GTSRB انجام شد. اندازه تصاویر به ۳۰×۳۰ تغییر داده شد و از سایز دسته‌ای ۳۰ استفاده شد و روش پیشنهادی به دقت ۹۹,۶۶ درصد دست یافت. به طور مشابه، در[۱۷] از شبکه عصبی کانولوشنی برای طبقه‌بندی علائم ترافیکی استفاده شد. مدل متشکل از ۴ لایه کانولوشنی، ۲ لایه ادغام حداکثری، یک لایه حذفی، یک لایه مسطح و ۲ لایه متراکم بود. اندازه فیلتر کانولوشنی ۳×۳ در معماری اعمال شد و تابع فعال‌سازی ReLU در لایه‌های مخفی مختلف به کار گرفته شد. همچنین از تابع خطای متقاطع آنتروپی، بهینه‌ساز آدام و نرخ یادگیری ۰,۰۰۱ استفاده شد. مجموعه داده GTSRB و تکنیک‌های افزایش داده‌ها نیز استفاده شد. معماری شبکه عصبی کانولوشنی پیشنهادی به دقت ۹۹,۲۰ درصد با سرعت طبقه‌بندی ۶,۶۳ ثانیه برای داده‌های آزمایشی دست یافت. در[۱۸] سه مدل شبکه عصبی کانولوشنی را مقایسه کردند: AlexNet، DarkNet-53، و EfficientNet-b0 . معماری AlexNet از ۱۳ لایه شامل ۵ لایه کانولوشنی، ۳ لایه ادغام حداکثری، ۲ لایه حذفی و ۳ لایه کاملاً متصل تشکیل شده است. توابع فعال‌سازی مورد استفاده ReLU و Softmax بودند. معماری DarkNet-53 از ۵۳ لایه، عمدتاً ۱ × ۱ و ۳ × ۳ لایه کانولوشنی، یک لایه نرمال‌سازی دسته ای و یک لایه LeakyReLU بعد از هر لایه کانولوشنی تشکیل شده بود. EfficientNet-b0 شامل ۷ لایهMBConv ، یک لایه کانولوشنی و یک لایه ادغام و کاملاً متصل بود. مجموعه داده GTSRB برای آزمایش استفاده شد و ابعاد تصویر ورودی برای هر الگوریتم متفاوت و AlexNet 227×227، DarkNet-53 416×416و EfficientNet-b0 224×224بود. AlexNet با ٪۹۷,۴۵ و DarkNet-53 با ٪۹۴,۶۹ و EfficientNet-b0با ٪۹۸,۶۴ بالاترین دقت را ارائه دادند. در[۱۹] یک روش طبقه‌بندی علائم ترافیکی با استفاده از شبکه عصبی عمیق (DNN) و شبکه عصبی کوانتومی (QNN) پیشنهاد شد. از مجموعه‌ای از N فیلتر کوانتومی برای ساختن لایه‌های کانولوشنی کوانتومی استفاده کردند. هر دو شبکه DNN و QNN دارای لایه‌هایی با ویژگی‌های کانولوشنی، ادغام حداکثری، حذف و لایه متراکم بودند. نتایج نشان داد که DNN به دقت ۹۹,۸۶ درصد دست یافت، در حالی که QNN دقت ۹۴,۴۰ درصد را به دست آورد. در[۲۰] همچنین یک روش طبقه‌بندی علائم ترافیکی با استفاده از شبکه عصبی کانولوشنی پیشنهاد شد. شبکه از ۳ لایه کاملاً متصل، ۳ لایه ادغام حداکثری و ۳ لایه کانولوشنی تشکیل شده است. این شبکه برای تبدیل یک تصویر ۱۰۰ × ۱۰۰ در مقیاس خاکستری به اندازه کوچکتر و طبقه‌بندی آن به یکی از ۴۱ کلاس علائم ترافیکی طراحی شده است. ReLU به عنوان تابع فعال‌سازی استفاده شد و شبکه برای ۱۰ دوره آموزش داده شد. از مجموعه داده علائم ترافیکی اندونزیایی استفاده شد که شامل ۳۱۳۳ تصویر علائم ترافیکی و ۴۱ طبقه بندی بود. معماری پیشنهادی به دقت ۹۳ درصد دست یافت. در[۲۱] یک مدل طبقه بندی علائم ترافیکی با استفاده از شبکه عصبی کانولوشنی پیشنهاد شد. این مدل از ۱۱ لایه شامل چهار لایه کانولوشنی، دو لایه تجمیع، یک لایه مسطح و چهار لایه کاملاً متصل تشکیل شده است. این مدل با استفاده از مجموعه داده‌هایGTSRB و یک مجموعه داده محلی از علائم ترافیکی هندی آموزش داده شد. یک مجموعه داده ترکیبی از ترکیب دو مجموعه داده تشکیل شد که منجر به ۱۰۲ کلاس در کل و ۶۵۸۱۰ تصویر شد. مراحل پیش پردازش مانند مقیاس خاکستری، متعادل سازی هیستوگرام، و نرمال سازی، به مجموعه داده اعمال شد. مدل به سطوح دقت ۹۹,۸۵ درصد در مجموعه داده آلمانی، ۹۱,۰۸ درصد در مجموعه داده هندی و ۹۵,۴۵ درصد در مجموعه داده ترکیبی دست یافت.

معماری شبکه عصبی پیشنهادی

این بخش یک شبکه عصبی سبک وزن را برای تشخیص علائم ترافیکی ارائه می‌کند که به صحت و دقت بالایی با پارامترهای قابل آموزش کمتری دست می‌یابد. مدل پیشنهادی بر روی مجموعه داده‌های معیار تشخیص علائم ترافیکی آلمان (GTSRB) آموزش داده شده است. ابتدا تصاویر علائم ترافیکی جمع آوری و به عنوان مجموعه داده استفاده شد. در بلوک اول، تصاویر با استفاده از روش‌های مختلف برای بهبود شناسایی علائم ترافیکی پیش پردازش شدند. سپس، داده های از پیش پردازش شده به مرحله آموزش فرستاده شدند، جایی که مدل پیشنهادی بر روی مجموعه آموزشی با فراپارامترهای بهینه شده آموزش داده شد. در نهایت، عملکرد مدل در مجموعه آزمایشی برای تعیین عملکرد کلی آن مورد ارزیابی قرار گرفت. شکل ۹ یک نمایش بصری از گردش کار و مراحل مختلف درگیر در این فرآیند را ارائه می‌کند که درک بهتر روش مورد استفاده در این مطالعه را تسهیل می‌کند.

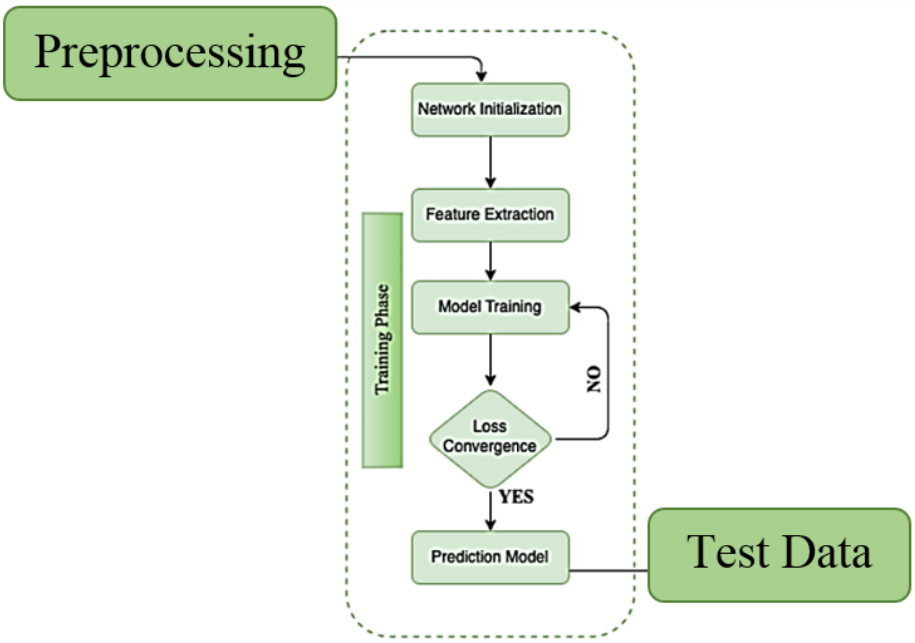

شکل ۹: فلوچارت مراحل اجرایی یک معماری کانولوشنی

پیش پردازش

مرحله پیش پردازش داده‌ها شامل سه مرحله است: تغییر مقیاس تصویر، نرمال‌سازی و تقویت داده‌ها. مجموعه داده‌های مورد استفاده در این مقاله GTSRB شامل تصاویر با نسبت ابعادی بین ۱۵ × ۱۵ تا ۲۵۰ × ۲۵۰ پیکسل است. برای سازگاری با شبکه‌های عصبی، داشتن اندازه‌های ثابت تصویر ضروری است. علاوه بر این، ذکر این نکته ضروری است که کاهش اندازه تصویر به نسبت پیکسل کمتر، مانند ۸۰ × ۸۰ یا ۵۰ × ۵۰، پیچیدگی مدل را کاهش می‌دهد. با این حال، ممکن است بر توانایی مدل برای نمایش دقیق اطلاعات بصری تأثیر منفی بگذارد و عملکرد طبقه‌بندی را کاهش دهد. در آزمایش‌های انجام شده، مدل خود را با اندازه‌های تصویر مختلف آزمایش کردیم و دریافتیم که ۱۰۰ × ۱۰۰ پیکسل، مبادله بهینه بین پیچیدگی محاسباتی و دقت طبقه‌بندی را فراهم می‌کند. نرمال‌سازی داده‌ها برای اطمینان از توزیع ثابت پارامترهای ورودی (مقادیر پیکسل)، که امکان همگرایی سریع‌تر در طول آموزش شبکه را فراهم می‌کند، حیاتی است. برای دستیابی به این هدف، مقدار میانگین کم می‌شود و نتیجه بر انحراف معیار آن تقسیم می‌شود و در نتیجه یک توزیع گاوسی با مقدار صفر ایجاد می‌شود. افزایش داده‌ها گام مهمی برای رفع نبود تعادل در مجموعه داده است، جایی که برخی از برچسب‌ها در مقایسه با سایر برچسب‌ها دارای تعداد زیادی تصویر هستند. این روش داده‌های اضافی را از نمونه‌های موجود با اعمال تبدیل‌هایی مانند چرخش، بزرگنمایی، تبدیل و تنظیمات روشنایی ایجاد می‌کند. تابعImageDataGenerator از کتابخانه Keras ، امکان می‌دهد پارامترهایی مانند ضریب مقیاس، دامنه تغییر ارتفاع و عرض، محدوده چرخش، چرخش‌های افقی و عمودی و موارد دیگر را تنظیم کنیم تا داده‌های جدید تولید کنیم که می‌تواند آموزش مدل را بهبود بخشد. افزایش به‌کارگیری یادگیری عمیق جامعه تحقیقاتی را بر آن داشته‌است تا برای دقت بهتر در کارهایی مانند طبقه‌بندی تصاویر تلاش کنند. در نتیجه، شاهد ابداع معماری‌های عمیق‌تری بوده‌ایم که دارای ۲۳٫۸ میلیون پارامتر و دارای ۱۴۳٫۶ میلیون پارامتر هستند. با این حال، افزایش عمق همیشه به سادگی منجر به بهبود دقت نمی‌شود. در واقع، استفاده از هسته‌های بیش از حد می‌تواند باعث کاهش عملکرد بدون کاهش مسئله بایاس بالا و واریانس بالا شود. روند تکراری یادگیری ویژگی‌های جدید بر اساس ویژگی‌هایی که قبلاً آموخته‌اند، همیشه بهینه نیست. در پاسخ به چالش تعادل عمق و دقت، یک معماری شبکه عصبی سبک وزن برای تشخیص علائم ترافیکی پیشنهاد می‌شود که ضمن استفاده از پارامترهای آموزش پذیر کمتر، به دقت و صحت بالاتری دست یابد.

لایه‌های شبکه عصبی کانولوشنی با تبدیل اطلاعات خام از تصاویر ورودی به یک تانسور، استخراج ویژگی‌ها را انجام می‌دهند. این فرآیند مدل را قادر می‌سازد تا الگوها و ویژگی‌های مهم را در تصویر شناسایی کند. سپس تانسور با استفاده از لایه ادغام میانگین جهانی به یک دسته علائم ترافیکی خاص طبقه بندی می‌شود. علاوه بر این، پارامترهای متغیر همه این لایه‌ها با به حداقل رساندن خطای طبقه‌بندی در مجموعه آموزشی بهینه می‌شوند. لایه‌های کانولوشنی اجزای اساسی شبکه‌های عصبی هستند که هر یک از نقشه‌های ورودی را با یک فیلتر دوبعدی کانوالو می‌کنند، به‌طوری که x و y ابعاد ورودی را نشان می‌دهند. هر لایه کانولوشنی شامل

نورون‌هایی با بایاس و وزن‌های قابل یادگیری است که به لایه اجازه می‌دهد در طول زمان یاد بگیرد و سازگار شود. نقشه خروجی لایه n با جمع کردن پاسخ‌های کانولوشنیی n-1 لایه ایجاد می‌شود. وزن‌های ω فیلتری را نشان می‌دهند که نقشه ورودی و نقشه‌های خروجی را به هم متصل می‌کند، در حالی که β نشان‌دهنده بایاس نقشه خروجی است. هدف اصلی لایه‌های کانولوشنی استخراج و شناسایی ویژگی‌های خاص از نقشه‌های ورودی و ایجاد انتزاعات سطح بالاتر از این ویژگی‌ها با ترکیب فعال‌سازی فیلتر با استفاده از معادله زیر است.

$$\mathbb{R}(z) = \sum_{i=1}^{n-1} \alpha_i^{n-1} * \omega_{ij}^n + \beta_j^n$$

در روش پیشنهادی، از تابع فعال‌سازی واحد خطی اصلاح‌شده (ReLU) به دلیل غیر خطی بودن، کارایی محاسباتی و توانایی مدیریت ورودی‌های غیرمنفی مانند مقادیر پیکسل استفاده می‌کنیم. معادلات زیر نمایش ریاضی تابع فعال‌سازی ReLU را با شرایط نشان می‌دهد. با صفر کردن مقادیر منفی، تابع فعال‌سازی ReLU به جلوگیری از ناپدید شدن گرادیان‌ها و بهبود عملکرد مدل کمک می‌کند.

$$\mathbb{R}(z) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases}$$

$$\mathbb{R}(z) = \max(0, z)$$

لایه‌های ادغام حداکثری با کاهش اندازه فضایی نقشه‌های ویژگی، نقش مهمی در شبکه عصبی کانولوشنی ایفا می‌کنند و در نتیجه تعداد پارامترها و هزینه‌های محاسباتی را کاهش می‌دهند. علاوه بر آن، می‌توانند با انتخاب ویژگی‌های ثابت برتر-که توانایی تعمیم مدل را بهبود می‌بخشد، به جلوگیری از برازش بیش از حد کمک کنند. حداکثر فعال‌سازی روی مناطق غیرهمپوشان، خروجی لایه ادغام حداکثری را تعیین می‌کند. در طول این فرآیند، نقشه ورودی نمونه‌برداری و بعد عمق حفظ می‌شود. برای شناسایی خودکار علائم و سیستم‌های کمک رانندگی در وسایل نقلیه خودران که در آن توانایی تشخیص و طبقه‌بندی دقیق علائم ترافیکی برای ایمنی جاده بسیار مهم است، نرمال‌سازی دسته‌ای می‌تواند بسیار سودمند باشد. فعال‌سازی هر لایه را در یک سری کوچک از نمونه‌های آموزشی نرمال‌سازی می‌کند، در نتیجه وابستگی به تغییرات داخلی را کاهش می‌دهد و به مدل پیشنهادی اجازه می‌دهد تا به طور مؤثرتری یاد بگیرد. علاوه بر این، با بهبود پایداری و کارایی آموزش، مدل پیشنهادی می‌تواند به همگرایی سریع‌تر و عملکرد تعمیم بهتر منجر شود. در چهارچوب پیشنهادی، ادغام میانگین سراسری را قبل از لایه‌های مسطح و متراکم قراردادیم تا ضمن بهبود عملکرد تعمیم، هزینه‌های اضافی و محاسباتی را کاهش دهیم. این تکنیک، مقدار میانگین هر نقشه ویژگی را محاسبه، یک بردار ویژگی واحد برای کل تصویر برای طبقه‌بندی ایجاد و از بیش از حد برازش جلوگیری می‌کند و در این حال معماری را ساده می‌کند و پارامترهای قابل آموزش را کاهش می‌دهد. استفاده از ادغام میانگین سراسری، بهبود عملکرد کلی مدل و کاهش هزینه‌های محاسباتی را در برنامه‌های مختلف بینایی ماشین نشان داده‌است.
چهارچوب پیشنهادی از طریق یک فرآیند تکراری که هدف آن متعادل کردن پیچیدگی محاسباتی و عملکرد مدل و به حداقل رساندن خطای طبقه‌بندی در مجموعه آموزشی است، بهینه می‌شود. برای انتخاب مقادیر بهینه برای هایپرپارامترها، مانند اندازه هسته و اندازه خروجی، یک جست‌وجو در طیفی از مقادیر انجام و مدل را برای هر ترکیبی از هایپرپارامترها آموزش دادیم و ارزیابی کردیم و مجموعه ای را انتخاب کردیم که بالاترین دقت را در مجموعه اعتبار سنجی از یک تکنیک جست‌وجو با اعتبارسنجی متقابل برای ارزیابی عملکرد هر ترکیبی از هایپرپارامترها و انتخاب پیکربندی بهینه دارد. با این حال، انتخاب تعداد و اندازه لایه‌های کانولوشنی مشکل است که می‌تواند به طور قابل‌توجهی بر عملکرد یک معماری شبکه عصبی کانولوشنی تأثیر بگذارد. پیکربندی معماری پیشنهادی از جمله توابع فعال‌سازی، اندازه‌های هسته، گام‌ها و شکل‌های خروجی هر لایه در شکل ۱۰ نشان داده شده‌است.

Layer Name	Output Size	Kernel Size
Input	100 × 100 × 3	–
Conv2d	98 × 98 × 16	3 × 3
Conv2d	98 × 98 × 32	3 × 3
MaxPooling2D	49 × 49 × 32	2 × 2
Conv2d	49 × 49 × 32	3 × 3
Conv2d	49 × 49 × 64	5 × 5
Conv2d	49 × 49 × 64	3 × 3
MaxPooling2D	24 × 24 × 64	2 × 2
Batch Normalization	24 × 24 × 64	–
Conv2d	24 × 24 × 64	3 × 3
Conv2d	24 × 24 × 128	5 × 5
Conv2d	24 × 24 × 256	3 × 3
Global Average Pooling 2D	24 × 24 × 128	–
Flatten	256	–
Dense1	1024	–
Dense2	Number of Classes	–

شکل ۱۰: پیکربندی معماری شبکه پیشنهادی

به طور خلاصه، روش پیشنهادی شامل مراحل مختلفی از جمله پیش پردازش داده‌ها، طراحی معماری مدل و آموزش و ارزیابی است. با استفاده از تابع فعال سازی ReLU، نرمال‌سازی دسته‌ای و فراپارامترهای مناسب، دقت بهبود یافته در تشخیص علائم ترافیکی به دست آمده‌است.

تابع خطا و الگوریتم بهینه‌سازی

از بهینه‌ساز آدام و تابع خطای متقاطع آنتروپی در طول آموزش استفاده می‌کنیم. بهینه‌ساز آدام یک الگوریتم بهینه‌سازی پرکاربرد است که از نرخ‌های یادگیری تطبیقی برای همگرایی مؤثرتر به حداقل سراسری نسبت به الگوریتم شیب نزولی تصادفی استفاده می‌کند. از سوی دیگر، آنتروپی متقاطع به عنوان تابع ضرر برای مقایسه توزیع‌های پیش‌بینی‌شده و واقعی مسئله طبقه‌بندی انتخاب می‌شود. این تابع، احتمال ۱ را به کلاس واقعی و احتمال ۰ را به کلاس‌های دیگر اختصاص می‌دهد. مدل پیشنهادی شامل یک طبقه‌بندی‌کننده softmax در آخرین لایه است که از تابع خطای آنتروپی متقاطع استفاده می‌کند، همانطور که در رابطه زیر نشان داده شده است. در این معادله، k نشان‌دهنده کلاس‌های مختلف، $\wp$ توزیع احتمال پیش‌بینی‌شده، و $\hat{\wp}$ توزیع واقعی است که به‌عنوان یک بردار One-hot نشان داده می‌شود.

$$\mathcal{L}(\wp, \hat{\wp}) = \sum_{k}[\wp_k log(\hat{\wp}_k) + (1 - \wp_k) log(1 - \wp_k)]$$

همانطور که در معادله زیر نشان داده شده است، تابع Softmax σ برای محاسبه y اعمال می‌شود که یک بردار K بعدی از امتیازهای با ارزش واقعی دلخواه z را می‌گیرد و آن را به یک بردار K بعدی σ(zk) از مقادیر نگاشت می‌کند. بین مقادیر ۰ و ۱، که جمع آنها ۱ می‌شود. در آزمایش‌های انجام شده، ترکیب بهینه‌ساز آدام و تابع خطای متقاطع آنتروپی، نتایج مطلوبی را در افزایش دقت مدل نشان می‌دهد.

$$\sigma(\vec{z_k}) = \frac{e^{z_k}}{\sum_{l=1}^{N}(e^{z_j})} \quad \therefore \; k = 1, 2, \ldots, N$$

مجموعه داده

مجموعه داده‌های معیار تشخیص علائم ترافیک آلمان (GTSRB) شامل ۵۱۹۲۲ تصویر است که در قالب PNGذخیره شده‌اند. ابعاد تصاویر در این مجموعه داده از ۱۵ × ۱۵ پیکسل تا ۲۵۰ × ۲۵۰ پیکسل است. مجموعه داده GTSRB برای آموزش، اعتبارسنجی و آزمایش مدل به سه گروه تقسیم شده‌است: ۳۱۴۳۳ تصویر برای آموزش، ۷۸۵۹ تصویر برای اعتبارسنجی و ۱۲۶۳۰ تصویر برای آزمایش. این مجموعه داده شامل ۴۳ دسته متمایز (شکل ۱۱) است. لذا معیار تشخیص علائم ترافیکی آلمان، یک مجموعه داده از علائم ترافیکی است که به طور گسترده در زمینه تشخیص و شناسایی علائم ترافیکی استفاده می‌شود. GTSRB یک منبع جامع و قابل اعتماد برای ارزیابی عملکرد الگوریتم‌های تشخیص علائم ترافیکی ارائه می‌دهد. با این حال، توجه به این نکته مهم است که مجموعه داده GTSRBدر درجه اول از علائم ترافیکی آلمانی تشکیل شده‌است که ممکن است به طور دقیق تنوع علائم ترافیکی مورد استفاده در مناطق دیگر را نشان ندهند. این امر تعمیم مدل‌های آموزش‌دیده شده بر روی مجموعه داده GTSRB را محدود می‌کند و ممکن است منجر به کاهش عملکرد هنگام اعمال در مناطق دیگر شود. با وجود این محدودیت، مجموعه داده GTSRB به دلیل اندازه، حاشیه‌نویسی با کیفیت بالا و نمایش سناریوهای واقعی، منبعی عالی را برای محققان در زمینه تشخیص علائم ترافیکی تبدیل می‌کند.

جزئیات پیاده‌سازی

هدف، دستیابی به دقت بالا، به حداقل رساندن زمان آموزش و استفاده از منابع است. علاوه بر این، مدل پیشنهادی برای استقرار در دنیای واقعی طراحی شده است، به‌طوری که دقت و قابلیت اطمینان در اولویت هستند. استفاده از تصاویر با وضوح بالاتر منجر به تشخیص و طبقه‌بندی دقیقتر علائم ترافیکی می‌شود که در تضمین ایمنی رانندگان و عابران پیاده بسیار مهم است. در طول فرآیند آموزش، از بهینه‌ساز آدام با نرخ یادگیری ۰,۰۰۰۲۵ و اندازه دسته‌ای ۱۲۸ استفاده کردیم. علاوه بر این، تکنیک‌های مختلف افزایش داده‌ها را برای گسترش اندازه مجموعه آموزشی و بهبود توانایی تعمیم مدل بر روی Jupyter که مجهز به GPU GeForce RTX 1080 Ti بود انجام و با استفاده از پایتون ۳,۸ پیاده‌سازی شده‌است. مدل را با اندازه‌های تصویر مختلف آزمایش کردیم تا بهترین تعادل بین پیچیدگی محاسباتی(زمان و منابع) و عملکرد طبقه‌بندی را پیدا کنیم. وضوح تصویر ۱۰۰×۱۰۰ تعادل خوبی بین دقت طبقه‌بندی و پیچیدگی مدل ایجاد می‌کند. یافته‌ها نشان می‌دهد که وضوح پایین‌تر تأثیر منفی بر دقت مدل در طبقه‌بندی علائم ترافیکی دارد، در حالی که وضوح بالاتر منجر به افزایش پیچیدگی مدل و زمان‌های آموزشی طولانی‌تر می‌شود.(همانطور که در جدول ۱ نشان داده شده است.)

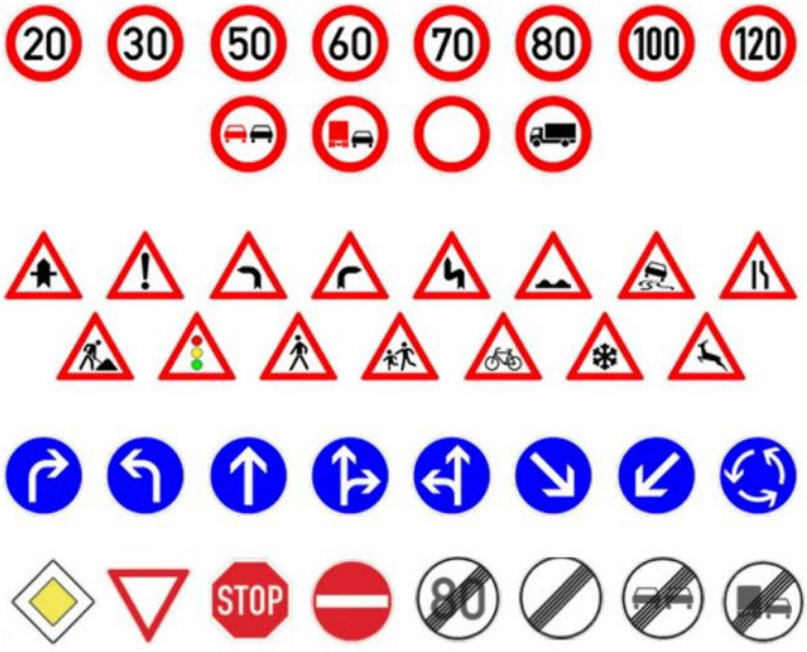

شکل ۱۱: مجموعه داده‌های معیار تشخیص علائم ترافیکی آلمان.(GTSRB)

جدول ۱: اندازه‌های تصویر ورودی و تعادل بین پیچیدگی محاسباتی(زمان و حافظه) و عملکرد طبقه‌بندی

وضوح تصویر	زمان محاسبه	میزان حافظه مصرفی	دقت	امتیاز F1
70X70	935s	18.3MB	96.9	97.1
100X100	1217s	21.6MB	98.31	98.43
150X150	2184s	28.7MB	98.63	98.64

معیارهای ارزیابی

معمولاً از شاخص‌های کلیدی عملکرد مدل برای ارزیابی اثربخشی مدل‌های طبقه‌بندی استفاده می‌شود. معیار صحت پیش‌بینی‌های انجام شده توسط مدل را اندازه‌گیری می‌کند و -همانطور که در روابط زیر نشان داده شده است- به عنوان نسبت تعداد نمونه‌های طبقه‌بندی شده صحیح به تعداد کل نمونه‌ها محاسبه می‌شود. از سوی دیگر، معیار دقت، نسبت مثبت‌های واقعی را در بین تمام پیش‌بینی‌های مثبت انجام‌شده توسط مدل، اندازه‌گیری می‌کند. معیار یادآوری نسبت مثبت های واقعی را در بین تمام نمونه‌های مثبت واقعی در مجموعه داده اندازه‌گیری می‌کند. معیار امتیاز F1 میانگین هارمونیک دقت و یادآوری است که تعادلی بین دو معیار ایجاد می‌کند. از شاخص‌های کلیدی عملکرد فوق‌الذکر برای اندازه‌گیری اثربخشی مدل پیشنهادی استفاده می‌کنیم. این معیارها توانایی مدل را در طبقه‌بندی دقیق علائم ترافیکی ارزیابی می‌کند.

$$\mathbb{A} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}$$

$$\mathbb{P} = \frac{T_P}{T_P + F_P}$$

$$R = \frac{T_P}{T_P + F_N}$$

$$\mathbb{F}1\text{-score} = 2 \times \frac{\mathbb{P} \times R}{\mathbb{P} + R}$$

نتایج ارزیابی

برای ارزیابی کارایی و قابلیت اطمینان مدل پیشنهادی مبتنی بر شبکه عصبی کانولوشنی برای شناسایی علائم ترافیکی، آزمایش‌های گسترده‌ای را بر روی مجموعه داده GTSRB انجام دادیم. برای ایجاد یک معیار، نتایج را با چند تکنیک پیشرفته از جمله VGG16، MobileNetv2و ResNet50 مقایسه کردیم. نتایج نشان داد که مدل پیشنهادی به عملکرد خوبی دست یافته است و بر پتانسیل آن برای استقرار مدل شناسایی علائم ترافیکی بلادرنگ و سیستم‌های کمک رانندگی تاکید می‌کند. مقایسه مدل پیشنهادی با سایر مدل‌های پیشرفته در مجموعه داده‌های GTSRB در جدول ۲ ارائه شده‌است. مدل پیشنهادی در مقایسه باVGG16، MobileNetv2و ResNet50 به دقت خوبی دست یافت. لازم به ذکر است که راندمان محاسباتی و اندازه کوچک مدل پیشنهادی، آن را برای شناسایی علائم ترافیکی بلادرنگ کاربردی‌تر و مناسب‌تر می‌کند.

جدول ۲: مقایسه مدل پیشنهادی با سایر مدل‌های پیشرفته بر روی مجموعه داده GTSRB

مدل معماری	صحت	دقت	فراخوانی	امتیاز F1	تعداد پارامتر	زمان آموزش	حافظه مصرفی

32.7MB	2543s	22.40M	97.44	97.28	97.61	97.32	VGG16
30.2MB	1419s	12.77M	97.22	97.11	97.33	97.17	MobileNetv2
33.2MB	2058s	40.37M	96.48	96.32	96.64	96.41	ResNet50
28.7MB	**2184s**	**2.78M**	**97.13**	**96.99**	**97.27**	**97.01**	**روش پیشنهادی**

با مقایسه عملکرد مدل پیشنهادی و مدل‌های فوق‌الذکر، قابل مشاهده‌است که مدل پیشنهادی از نظر زمان اجرا و مصرف حافظه به ترتیب با مقادیر زمان اجرای ۲۱۸۴ ثانیه و حافظه مصرفی ۲۸,۷ مگابایتی قابل مقایسه با معماری‌های پیشرفته است و تعادل خوبی بین زمان اجرا و حافظه مصرفی به‌دست آمده‌است و آن را به یک راه‌حل جذاب برای استقرار در دنیای واقعی بر روی دستگاه‌های تعبیه‌شده با توان محاسباتی و حافظه محدود تبدیل می‌کند. در شکل ۱۲ بررسی عملکرد مدل پیشنهادی با سایر مدل‌های پیشرفته بر روی مجموعه داده GTSRB نشان داده شده‌است. لذا عملکرد کلی آن از نظر زمان آموزش، تعداد پارامترها و مصرف حافظه، آن را به یک راهکار مناسب برای استقرار بلادرنگ در سیستم‌های تعبیه‌شده تبدیل می‌کند. روش پیشنهادی به گونه‌ای طراحی شد که سبک و کارآمد باشد و از مهندسی ویژگی‌های پیشرفته و شبکه عصبی کانولوشنی برای بهبود دقت و استحکام کلی و در عین حال کاهش تعداد پارامترهای مورد نیاز برای آموزش و استنتاج استفاده کند.

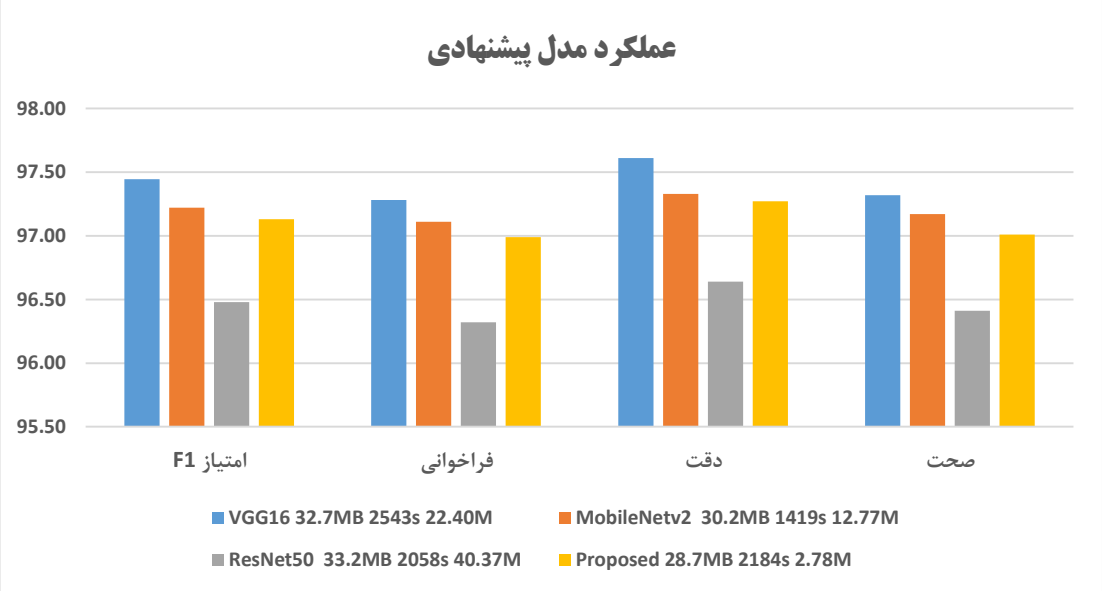

شکل ۱۲: بررسی عملکرد مدل پیشنهادی با سایر مدل‌های پیشرفته بر روی مجموعه داده GTSRB

نتیجه‌گیری

مدل پیشنهادی در این مقاله به طور موثر، طیف متنوعی از علائم ترافیکی را با اشکال، اندازه‌ها و رنگ‌های مختلف شناسایی و طبقه‌بندی می‌کند که نشان‌دهنده استحکام و سازگاری آن در سناریوهای دنیای واقعی است. موفقیت این مدل در تشخیص و طبقه‌بندی انواع علائم ترافیکی، پتانسیل آن را برای افزایش اقدامات ایمنی در مدیریت ترافیک و سیستم‌های رانندگی خودمختار برجسته می‌کند. علاوه بر این، عملکرد مطلوب این مدل پیشنهادی در تشخیص و طبقه‌بندی علائم ترافیکی، پتانسیل کاربرد آن را در مناطق حیاتی ایمنی، مانند وسایل نقلیه خودران، که در آن تشخیص و طبقه‌بندی دقیق و سریع علائم ترافیکی ضروری است، نشان می‌دهد. هنگام طراحی مدل‌های یادگیری ماشین برای کاربردهای عملی مانند تشخیص علائم ترافیکی، توجه به کارایی محاسباتی و اندازه مدل بسیار مهم است. علاوه بر آن،

در نظر گرفتن رابطه بین تعداد پارامترها/عملیات و زمان اجرا هنگام طراحی چنین مدل‌هایی نیز مهم است. به طور کلی، انتظار می رود مدلی با پارامترها و عملیات کمتر نسبت به مدل پیچیده‌تر، زمان پاسخگویی سریع‌تری داشته باشد؛ علت این است که یک مدل ساده‌تر به محاسبات کمتری نیاز دارد و پیش‌بینی‌های سریع‌تری را ممکن می‌سازد. در کاربردهای حیاتی ایمنی مانند سیستم‌های خودرو، طراحی چنین چهارچوب‌هایی که چهارچوب‌هایی دقیق و کارآمد با سربار محاسباتی کم و حداقل نیاز به حافظه هستند، ضروری است. این را می توان با کاهش تعداد پارامترها و عملیات قابل آموزش با حفظ دقت بالا به دست آورد و اطمینان حاصل کرد که مدل‌ها می‌توانند بر روی دستگاه‌های تعبیه شده با قدرت محاسباتی و حافظه محدود مستقر شوند که عملکردی قابل اعتماد و سریع را نیز ارائه می‌دهند. مدل پیشنهادی دارای اندازه مدل کوچک و راندمان محاسباتی بالایی است که آن را برای استقرار بلادرنگ کاربردی و مناسب می‌سازد. با افزایش تعداد پارامترها و عملیات در مدل‌های یادگیری ماشین، مدل، پیچیده‌تر می‌شود و به منابع محاسباتی بیشتری برای آموزش نیاز دارد. بنابراین، برای اطمینان از دقت بالا و زمان پاسخ کم، لازم است بین پیچیدگی و عملکرد، متعادل شود. هدف، توسعه یک سیستم سبک و کارآمد است که از تکنیک‌های یادگیری عمیق مانند شبکه عصبی کانولوشنی و مهندسی ویژگی‌های پیشرفته برای بهبود دقت و در عین حال کاهش تعداد پارامترهای مورد نیاز برای آموزش و استنتاج استفاده می‌کند. این سیستم در سناریوهای دنیای واقعی با منابع محاسباتی کم به طور موثر عمل خواهد کرد. آزمایش‌ها نشان می‌دهد که مدل پیشنهادی مبتنی بر شبکه عصبی کانولوشنی بسیار مؤثر و قابل اعتماد است و از نظر دقت با چندین تکنیک پیشرفته مانندVGG16 ، MobileNetv2 و ResNetv2 قابل مقایسه‌است. دقت، فراخوانی و امتیاز F1 در مجموعه داده GTSRBهمانطور که در جدول ۲ نشان داده شده‌است. مدل پیشنهادی به نتایج تشخیص و طبقه‌بندی مطلوبی برای علائم ترافیکی با اشکال، اندازه‌ها و رنگ‌های مختلف دست یافت که استحکام و سازگاری آن را در شرایط دنیای واقعی نشان می‌دهد. علاوه بر این، مدل پیشنهادی، سبک وزن و از نظر محاسباتی کارآمد است و آن را برای برنامه‌های بلادرنگ که استفاده از منابع، یک محدودیت است، مناسب می‌کند.

مراجع

[1] L. Jiao et al., “A Survey of Deep Learning-Based Object Detection,” IEEE Access, vol. 7, pp. 128837–128868, 2019.
[2] Li, J.; Wang, Z. Real-time traffic sign recognition based on efficient CNNs in the wild. IEEE Trans. Intell. Transp. Syst. 2018, 20, 975–984.
[3] Zhu, Y.; Yan, W.Q. Traffic sign recognition based on deep learning. Multimed. Tools Appl. 2022, 81, 17779–17791.
[4] Shustanov, A.; Yakimov, P. CNN design for real-time traffic sign recognition. Procedia Eng. 2017, 201, 718–725.
[5] Bangquan, X.; Xiong, W.X. Real-time embedded traffic sign recognition using efficient convolutional neural network. IEEE Access 2019, 7, 53330–53346.
[6] Zaibi, A.; Ladgham, A.; Sakly, A. A lightweight model for traffic sign classification based on enhanced LeNet-5 network. J. Sensors 2021, 2021, 8870529.
[7] Sokipriala, J.; Orike, S. Traffic sign classification comparison between various convolution neural network models. Int. J. Sci. Eng. Res. 2021, 12, 165–171.
[8] Mishra, J.; Goyal, S. An effective automatic traffic sign classification and recognition deep convolutional networks. Multimed. Tools Appl. 2022, 81, 18915–18934.
[9] Chen, L.; Zhao, G.; Zhou, J.; Kuang, L. Real-time traffic sign classification using combined convolutional neural networks. In Proceedings of the 2017 4th IAPR Asian Conference on Pattern Recognition (ACPR), Nanjing, China, 26–29 November 2017; pp. 399–404.
[10] Haque, W.A.; Arefin, S.; Shihavuddin, A.; Hasan, M.A. DeepThin: A novel lightweight CNN architecture for traffic sign recognition without GPU requirements. Expert Syst. Appl. 2021, 168, 114481.
[11] Fang, H.F.; Cao, J.; Li, Z.Y. A small network MicronNet-BF of traffic sign classification. Comput. Intell. Neurosci. 2022, 2022, 3995209.
[12] Sarku, E.; Steele, J.; Ruffin, T.; Gokaraju, B.; Karimodini, A. Reducing Data Costs-Transfer Learning Based Traffic Sign Classification Approach. In Proceedings of the SoutheastCon 2021, Atlanta, GA, USA, 10–13 March 2021; pp. 1–5.
[13] Cao, J.; Song, C.; Peng, S.; Xiao, F.; Song, S. Improved traffic sign detection and recognition algorithm for intelligent vehicles. Sensors 2019, 19, 4021.
[14] Fu, H.; Wang, H. Traffic Sign Classification Based on Prototypes. In Proceedings of the 2021 16th International Conference on Intelligent Systems and Knowledge Engineering (ISKE), Chengdu, China, 26–28 November 2021; pp. 7–10.
[15] Sichkar, V.; Kolyubin, S. Effect of various dimension convolutional layer filters on traffic sign classification accuracy. Sci. Tech. J. Inf. Technol. Mech. Opt. 2019, 19, 546–552.
[16] Agarwal, S.; X, C.; Kumar, R. Convolutional Neural Network for Traffic Sign Classification. Int. J. Inf. Technol. Proj. Manag. 2022, 9.
[17] Youssouf, N. Traffic sign classification using CNN and detection using faster-RCNN and YOLOV4. Heliyon 2022, 8, e11792.
[18] Gökberk, A.; Durdu, A.; Nesimio ˘glu, B.S. Accuracy Comparison of CNN Networks on GTSRB Dataset. J. Artif. Intell. Data Sci. 2022, 2, 63–68.
[19] Kuros, S.; Kryjak, T. Traffic Sign Classification Using Deep and Quantum Neural Networks. 2022.
[20] Pradana, A.I.; Rustad, S.; Shidik, G.F.; Santoso, H.A. Indonesian Traffic Signs Recognition Using Convolutional Neural Network. In Proceedings of the 2022 International Seminar on Application for Technology of Information and Communication (iSemantic), Semarang, Indonesia, 17–18 September 2022; pp. 426–430.
[21] Bhatt, N.; Laldas, P.; Lobo, V.B. A Real-Time Traffic Sign Detection and Recognition System on Hybrid Dataset using CNN. In Proceedings of the 2022 7th International Conference on Communication and Electronics Systems (ICCES), India, June 2022; pp. 1354–1358.