

یادگیری عمیق برای داده های بزرگ IoT و تجزیه و تحلیل جریان:

یک بررسی کلی

ترجمه علی لطف‌اللهی

96223046

چکیده — در عصر اینترنت اشیا (IoT)، تعدادی غیرعادی از دستگاه‌های سنسور برای طیف گسترده‌ای از زمینه‌ها و برنامه‌ها، داده‌های حسی مختلفی را در طول زمان جمع‌آوری و یا تولید میکنند. بر اساس ماهیت برنامه، این دستگاه‌ها منجر به جریان یافتن سریع داده‌های بزرگ در زمان واقعی میشوند. استفاده از تجزیه و تحلیل از طریق جریان این داده‌ها برای کشف اطلاعات جدید، پیش‌بینی نگرش‌های آینده و تصمیم‌گیری‌های کنترلی، یک فرایند مهم است که IoT را تبدیل به یک الگوی شایسته برای مشاغل و یک فناوری بهبود کیفیت زندگی میکند. در این مقاله، ما یک مرور کلی راجع به استفاده از یک کلاس از تکنیک‌های پیشرفته یادگیری ماشین، یعنی Deep Learning (DL)، برای تسهیل در تجزیه و تحلیل و یادگیری در حوزه IoT ارائه میدهم. ما با بیان خصوصیات داده IoT و شناسایی دو روش اصلی برای اینگونه داده‌ها از دیدگاه یادگیری ماشین، یعنی تجزیه و تحلیل داده های بزرگ IoT و داده‌های جاری آن شروع میکنیم. ما همچنین درمورد اینکه چرا DL یک روش امیدوار کننده برای دستیابی به تجزیه و تحلیل مورد نظر در این نوع داده‌ها و برنامه‌های کاربردی است، بحث خواهیم کرد. سپس پتانسیل استفاده از تکنیک‌های DL در حال ظهور برای تجزیه و تحلیل داده‌های IoT مورد بحث قرار گرفته و قراردادها و چالش‌های آن معرفی می‌شود. ما یک پیش‌زمینه جامع درمورد معماری و الگوریتم‌های مختلف DL ارائه میدهم. ما همچنین تلاش‌های پژوهشی عمده‌ای را که از DL گزارش شده‌اند در حوزه IoT تجزیه و تحلیل میکنیم. دستگاه‌های هوشمند IoT که DL را در پس زمینه اطلاعاتی خود گنجانده‌اند نیز مورد بحث قرار گرفته است. رویکردهای اجرای DL در مراکز فضای ابری نیز در راستای حمایت از برنامه‌های IoT مورد بررسی قرار گرفته است. سرانجام، ما برخی از چالش‌ها و جهت‌های بالقوه را برای تحقیقات آینده روشن ساختیم. در پایان هر بخش، بر اساس آزمایشات خود و مرور ادبیات اخیر، درس‌های آموخته شده را مشخص میکنیم.

کلمات کلیدی: یادگیری عمیق، شبکه عصبی عمیق، اینترنت اشیا، هوش سرخود دستگاه، داده بزرگ IoT، تجزیه و تحلیل سریع داده‌ها، تجزیه و تحلیل مبتنی بر فضای ابری.

مقدمه

چشم‌انداز اینترنت اشیا (IoT)، برای تبدیل اشیا مرسوم به اشیا هوشمند با بهره‌گیری از طیف گسترده‌ای از فناوریهای پیشرفته، از دستگاه‌های تعبیه شده و فناوریهای ارتباطی گرفته تا پروتکل‌های اینترنتی، تجزیه و تحلیل داده‌ها و موارد دیگر است. انتظار می‌رود که تأثیر اقتصادی بالقوه IoT فرصتهای شغلی بسیاری را ایجاد کرده و رشد اقتصادی خدمات مبتنی بر IoT را تسریع کند. براساس گزارش مکنزی، تأثیر اقتصادی سالانه IoT در سال 2025 در بازه 2.7 تا 6.2 تریلیون دلار خواهد بود. بخش بهداشت و درمان با حدود 41 درصد و پس از آن صنعت و انرژی به ترتیب با 33 و 7 درصد در بازار IoT دخیل هستند. حوزه‌های دیگر مانند حمل و نقل، کشاورزی، زیرساختهای شهری، امنیت و خرده‌فروشی تقریباً 15 درصد از بازار IoT را به خود اختصاص داده‌اند. این انتظارات بر رشد شگرف و شیب دار خدمات IoT، داده‌های تولید شده آنها و به تبع آن، بازار فروش مرتبط با آنها در سالهای آینده دلالت دارد.

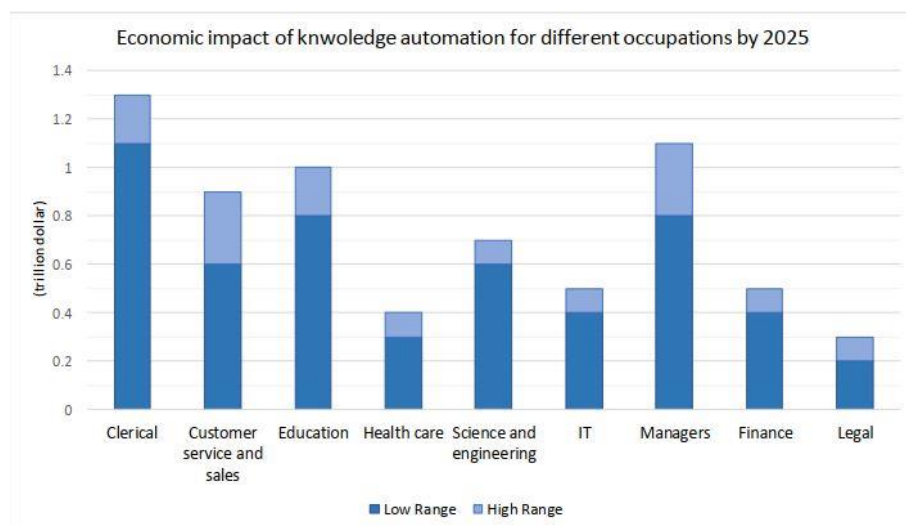


شکل 1. تولید داده IoT در سطوح مختلف و مدل‌های یادگیری عمیق برای پرداختن به انتزاع دانش آنها.

در حقیقت، یادگیری ماشینی (ML)¹ تأثیرات خود را در شغلها و نیروی کار خواهد داشت، زیرا بخشهایی از بسیاری از مشاغل ممکن است "برای برنامه‌های کاربردی ML" مناسب باشند. این امر منجر به افزایش تقاضا برای برخی محصولات ML و تقاضای حاصل از وظایف، سیستم‌عاملها و

¹ Machine Learning

متخصصان مورد نیاز برای تولید چنین محصولاتی خواهد شد. تأثیر اقتصادی یادگیری ماشینی در گزارش مکنزی تحت اتوماسیون کار دانش تعریف شده است؛ "استفاده از رایانه برای انجام کارهایی که به تجزیه و تحلیل‌های پیچیده، قضاوت‌های ظریف و حل مسئله خلاقانه متکی هستند". در این گزارش آمده است که پیشرفت در تکنیک‌های ML، مانند یادگیری عمیق و شبکه‌های عصبی، اصلی‌ترین عامل اتوماسیون کار دانش است. رابط کاربری طبیعی مانند گفتار و تشخیص حرکات، دیگر امکاناتی هستند که از فناوریهای ML بسیار بهره‌مند هستند. تأثیر احتمالی اقتصادی اتوماسیون کار دانش می‌تواند تا سال 2025 از 5.2 به 6.7 تریلیون دلار در سال برسد. شکل زیر نشان دهنده تجزیه این برآورد در مشاغل مختلف است. در مقایسه با تأثیر اقتصادی IoT، این برآورد بیشتر بر استخراج ارزش داده‌ها و تأثیرات احتمالی ML در وضعیت اقتصادی افراد و جوامع تأکید می‌کند. این تأثیرات اقتصادی عواقب جدی برای افراد و کشورها دارد، زیرا مردم برای حفظ سطح زندگی مطلوب خود باید با وسایل جدید کسب درآمد مناسب برای خودشان سازگار شوند.



شکل 2. سقوط تأثیر تخمینی اقتصادی 5.2 به 6.7 تریلیون دلار برای آموزش ماشین در سال 2025.

در سالهای اخیر، بسیاری از برنامه‌های IoT در حوزه‌های مختلف عمودی، یعنی بهداشت، حمل‌ونقل، خانه هوشمند، شهر هوشمند، کشاورزی، آموزش و... پدید آمدند. عنصر اصلی اکثر این برنامه‌ها یک مکانیسم یادگیری هوشمند برای پیش‌بینی (یعنی رگرسیون، طبقه بندی و خوشه بندی)، داده کاوی و شناخت الگو یا به طور کلی تجزیه و تحلیل داده‌ها است. در میان بسیاری از رویکردهای یادگیری

ماشین، Deep Learning (DL) در سالهای اخیر بطور جدی در بسیاری از برنامه‌های IoT مورد استفاده قرار گرفته است. این دو فناوری (یعنی DL و IoT) جزو سه روند برتر استراتژیک فناوری برای سال 2017 هستند که در Gartner Symposium / ITxpo 2016 اعلام شدند. علت این تبلیغات گسترده برای DL به این واقعیت اشاره دارد که رویکردهای سنتی یادگیری ماشین، نیازهای تحلیلی نوظهور سیستمهای IoT را برطرف نمیکند. در عوض، مطابق با سلسله مراتب تولید و مدیریت داده IoT، همانگونه که در شکل 1 نشان داده شده، نیاز به رویکردهای تحلیلی مدرن مختلف و روشهای هوش مصنوعی (AI) دارند.

علاقه فزاینده به اینترنت اشیا (IoT) و داده‌های بزرگ مشتق از آن نیاز به ذینفعان دارد تا تعریف، موانع سازندگی، پتانسیلها و چالشها را به وضوح درک کنند. IoT و داده‌های بزرگ رابطه دوطرفه دارند. از یک طرف، IoT تولیدکننده اصلی داده‌های بزرگ است و از سوی دیگر، هدف مهمی برای تجزیه و تحلیل داده‌های بزرگ در جهت بهبود فرایندها و خدمات میباشد. علاوه بر این، تجزیه و تحلیل داده‌های بزرگ IoT ثابت کرده است که میتواند ارزشهایی را برای جامعه به ارمغان بیاورد. بعنوان مثال، گزارش شده است که با شناسایی آسیب در لوله‌کشی‌ها و رفع آنها، اداره مدیریت پارکها در میامی حدود یک میلیون دلار از قبض‌های آب را پس انداز کرده است.

داده‌های IoT با داده‌های بزرگ عمومی متفاوت است. برای درک بهتر الزامات مربوط به تجزیه و تحلیل داده‌های IoT، باید ویژگیهای آنها و چگونگی تفاوتشان با داده‌های بزرگ عمومی را بررسی کنیم. داده‌های IoT ویژگی‌های زیر را نشان می‌دهد:

- **داده‌های استریم مقیاس بزرگ:** تعداد بیشماری از دستگاه‌های ضبط داده برای برنامه‌های IoT توزیع و مستقر میشوند و به طور مداوم جریان داده‌ها را تولید میکنند. این منجر به ایجاد حجم عظیمی از داده‌های مداوم می‌شود.
- **ناهمگونی:** دستگاه‌های مختلف کسب اطلاعات IoT، اطلاعات مختلفی را جمع‌آوری میکنند که منجر به ناهمگونی داده‌ها میشود.
- **همبستگی زمان و مکان:** در اکثر برنامه‌های IoT، دستگاههای حسگر به یک مکان خاص متصل شده‌اند و به این ترتیب برای هر فقره از داده‌ها دارای یک مکان و تمبر-زمان هستند.
- **داده‌های پرسر و صدا:** با توجه به تعداد کم داده‌ها در برنامه‌های IoT، بسیاری از این داده‌ها ممکن است هنگام دستیابی و انتقال در معرض خطا و نویز باشند.

اگرچه به دست آوردن دانش و اطلاعات پنهان از داده‌های بزرگ نویدبخش افزایش کیفیت زندگی ماست، اما با این حال کار آسان و ساده‌ای هم نیست. برای چنین کار پیچیده و چالش برانگیزی که فراتر از تواناییهای رویکرد استنتاجی و یادگیری سنتی باشد، به فناوریهای جدید، الگوریتمها و زیرساختها نیاز است. خوشبختانه پیشرفتهای اخیر در هر دو روش محاسبات سریع و تکنیکهای پیشرفته یادگیری ماشین، درها را برای تجزیه و تحلیل داده‌های بزرگ و استخراج علمی باز میکند که برای برنامه‌های IoT مناسب است.

فراتر از تجزیه و تحلیل داده‌های بزرگ، داده‌های IoT برای پشتیبانی از برنامه‌های دارای جریان پرسرعت و نیاز به اقدامات حساس به زمان (یعنی در زمان واقعی یا نزدیک به زمان واقعی)، کلاس جدید دیگری از تجزیه و تحلیلها، یعنی تجزیه و تحلیل سریع داده و جریان را فرا میخواند. در واقع برنامه‌هایی از قبیل رانندگی اتوماتیک، پیش‌بینی آتش‌سوزی، وضعیت راننده و سالخوردگان (و بنابراین هوشیاری و یا وضعیت سلامتی) شناخت و پردازش سریع داده‌های دریافتی و اقدامات سریع برای رسیدن به هدف خود را میطلبد. محققان متعددی رویکردها و چارچوبهایی را برای تجزیه و تحلیل سریع داده‌های استریم ارائه داده‌اند که از قابلیت‌های زیرساختها و خدمات فضای ابری استفاده میکند. با اینحال، برای برنامه‌های IoT فوق‌الذکر در میان دیگران، ما به تجزیه و تحلیل سریع در سیستم‌عامل‌های مقیاس کوچکتر (یعنی در لبه سیستم) یا حتی در خود دستگاه‌های IoT نیاز داریم. بعنوان مثال، اتومبیل‌های خودکار باید در مورد اقدامات رانندگی مانند خط یا تغییر سرعت تصمیم‌گیری سریعی انجام دهند. در واقع این نوع تصمیمات باید با تجزیه و تحلیل سریع داده‌های احتمالاً چندجهته و چندمنبعی، از جمله سنسورهای مختلف وسیله نقلیه (به عنوان مثال، دوربینها، رادارها، LIDAR، سرعت سنج، سیگنالهای چپ و راست و...)، ارتباطات از سایر وسایل نقلیه و عوامل راهنمایی و رانندگی (بعنوان مثال، چراغ راهنمایی، علائم راهنمایی و رانندگی) هماهنگ باشند و از آنها پشتیبانی کنند. در این حالت، انتقال داده به سرور فضای ابری برای تجزیه و تحلیل و برگشت پاسخ، منوط به تأخیر است که میتواند باعث نقض قوانین ترافیکی و یا تصادف شود. سناریوی مهمتر، شناسایی عابران پیاده توسط وسایل نقلیه از این دست میباشد. شناخت دقیق باید در زمان واقعی انجام شود تا از بروز حوادث مرگبار جلوگیری کند. این سناریوها حاکی از آن است که تجزیه و تحلیل سریع داده برای IoT در راستای حذف تأخیرهای غیرضروری و ممنوعیت ارتباط باید نزدیک یا درون منبع داده باشد.

الف) دامنه بررسی

مدلهای DL بطور کلی دو پیشرفت مهم را نسبت به رویکردهای سنتی یادگیری ماشین در دو مرحله آموزش و پیش بینی به ارمغان میآورند. در وهله اول، آنها نیاز به مجموعه ویژگیهای دستساز را برای استفاده در آموزش کاهش میدهند. در نتیجه، برخی از ویژگیهایی که ممکن است از نظر انسان آشکار نباشد، توسط مدلهای DL به راحتی قابل استخراج است. علاوه بر این، مدلهای DL دقت² را بهبود میبخشند.

در این مقاله، ما طیف گسترده‌ای از معماریهای شبکه عصبی عمیق (DNN) را مرور میکنیم و برنامه‌های IoT را که از الگوریتمهای DL بهره‌مند شده‌اند مورد بررسی قرار میدهیم. در این مقاله پنج سرویس اصلی و اساسی IoT که میتوانند در دامنه‌های مختلف عمودی فراتر از سرویسهای خاص در هر دامنه مورد استفاده قرار گیرند، شناسایی شده است. همچنین در مورد ویژگیهای برنامه‌های IoT و راهنمای تطبیق آنها با مناسب ترین مدل DL بحث خواهد شد. این نظرسنجی در مورد تلاقی دو فناوری نوظهور، یکی در شبکه‌های ارتباطی، یعنی IoT و دیگری در هوش مصنوعی، یعنی DL، و تفصیل برنامه‌های بالقوه آنها و موضوعات حل نشده است. این بررسی، الگوریتمهای یادگیری مرسوم ماشین را برای تجزیه و تحلیل داده‌های IoT پوشش نمیدهد، زیرا برخی از تلاشهای دیگر که در بخش I-B ذکر شده‌اند، وجود دارند که چنین رویکردهایی را پوشش داده باشند. علاوه بر این، این نظرسنجی از دیدگاه ارتباطات و شبکه، به بررسی جزئیات زیرساختی IoT نمیپردازد.

² دقت در این کار به طور کلی به میزان مطابقت نتیجه پیش بینی با ارزش های حقیقی زمین اشاره دارد. خوانندگان همچنین ممکن است با دقت درجه 2 یا درجه 3 در متن روبرو شوند. به طور کلی، دقت درجه N ام به در نظر گرفتن N پاسخ با بالاترین احتمال مدل پیش بینی و بررسی اینکه آیا این مجموعه شامل مقدار مورد انتظار است یا خیر، اشاره دارد. بنابراین، دقت درجه 1 به خروجی با بیشترین احتمال اشاره میکند. به همین ترتیب، دقت درجه 3 به سه پیش بینی احتمالی اشاره دارد. به عنوان مثال، اگر ما ی تصویر یک ببر را به مدلی که تصاویر حیوانات را تشخیص میدهد ارائه کنیم و لیست خروجی های اینگونه برگرداند: سگ: 0: 72 سگ ، ببر: 0: 69 و گربه: 0: 58 ، دقت درجه 1 جواب مجموعه ای را شامل میشود که فقط "سگ" باشد، که اشتباه است. از طرف دیگر، دقت های درجه 2 و 3 به نتیجه منجر میشود که مجموعه های خروجی حاوی "ببر" باشند، و به همین ترتیب صحیح شمرده میشوند.

ب) کار مرتبط

حتی در ادبیات بهترین دانشهای ما، مقاله‌ای وجود ندارد که به بررسی رابطه خاص بین داده‌های IoT و DL و همچنین کاربردهای روشهای DL در IoT اختصاص یابد. تعداد کمی از کارهای ارائه شده متداول در مورد استخراج داده‌ها و روشهای یادگیری ماشین وجود دارد که در محیطهای IoT مورد استفاده قرار گرفته باشد. اثری که توسط تسای و همکاران ارائه شده، بر رویکردهای داده‌کاوی IoT تمرکز کرده است. این الگوریتمهای مختلف طبقه‌بندی، خوشه‌بندی، و الگوهای مکرر داده‌کاوی برای زیرساختها و خدمات IoT مورد توجه قرار گرفته است؛ اما با اینحال، رویکردهای DL را که مرکز تحقیقات ماست، در نظر نگرفته است. علاوه بر این، تمرکز آنها به طور عمده روی داده‌کاوی آفلاین است، در حالیکه ما یادگیری و استخراج را هم برای زمان واقعی (سریع) و هم برای تجزیه و تحلیل داده‌های بزرگ در نظر می‌گیریم.

پروا و همکاران کلاسهای مختلف رویکردهای یادگیری ماشینی (نظارت شده و نظارت نشده، قوانین، منطق فازی و غیره) را در مرحله استدلال از یک سیستم محاسبات متناوب بررسی کرده و پتانسیلهای استفاده از این روشها را در سیستمهای IoT مورد بحث قرار داده‌اند. با این وجود، آنها باز هم نقش DL را در استدلال متن مطالعه نکردند.

الشیخ و همکاران، بررسی روشهای یادگیری ماشین برای شبکه‌های حسگر بی‌سیم (WSN) را ارائه میدهد. در اینجا، نویسندگان روشهای یادگیری ماشینی را در جنبه‌های عملکردی WSN، مانند مسیریابی، بومی‌سازی و خوشه‌بندی و همچنین الزامات غیرکاربردی مانند امنیت و کیفیت خدمات را مورد مطالعه قرار دادند. آنها چندین الگوریتم را در رویکردهای نظارت‌شده، بدون نظارت و تقویت یادگیری بررسی کردند. این کار به زیرساختهای WSN (که یکی از زیرساختهای بالقوه برای اجرای برنامه‌های IoT است) متمرکز است، در حالیکه کار ما به دیتابیس‌ها (یعنی زیرساختهای IoT) وابسته نیست و طیف گسترده‌ای از برنامه‌ها و خدمات IoT را دربر می‌گیرد. علاوه بر این، تمرکز ما بر روی روشهای مرسوم یادگیری ماشین بود، در حالیکه این مقاله بر تکنیکهای پیشرفته و DL متمرکز است. سرانجام، فضل‌الله و همکاران به رویکردهای DL در سیستمهای شبکه کنترل ترافیک پرداختند. در حالیکه این کار در درجه اول بر زیرساختهای شبکه متمرکز است، با کار ما که بر استفاده از DL در برنامه‌های IoT متمرکز است تفاوت دارد.

فراتر از آثار خاص در مورد IoT، کیو و همکاران چندین تکنیک یادگیری سنتی ماشین را به همراه چندین تکنیک پیشرفته از جمله DL برای پردازش داده‌های بزرگ عمومی بررسی کردند. به طور خاص، آنها ارتباط تکنیکهای مختلف یادگیری ماشین را با فن آوری پردازش سیگنال، برای پردازش و تحلیل به موقع برنامه های کاربردی داده‌های بزرگ برجسته کردند.

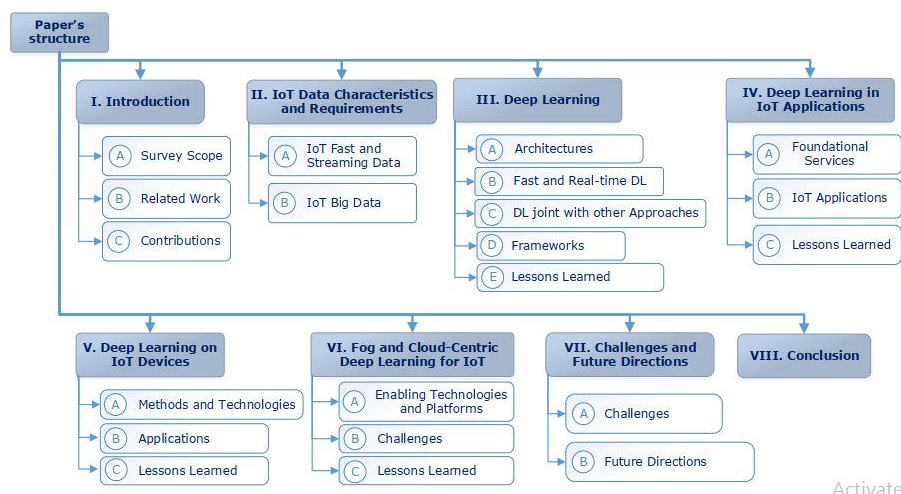
ج) مشارکتها

این مقاله برای محققان و توسعه دهندگان IoT در نظر گرفته شده است؛ کسانی که میخواهند با استفاده از رویکردهای نوین یادگیری ماشین DL، تجزیه و تحلیل و سیستمهای هوش مصنوعی، راه حل‌های یادگیری را روی زیرساختهای IoT خود بسازند. سهم این مقاله در این کار به شرح زیر خلاصه میشود:

- به منظور اتخاذ رویکردهای DL در اکوسیستمهای IoT، ویژگیها و مشکلات اصلی داده‌های IoT را شناسایی میکنیم.
- در مقایسه با برخی از کارهای مرتبط در ادبیاتی که به یادگیری ماشین در زمینه IoT پرداخته‌اند، ما روشهای DL و کاربرد آن در حوزه IoT را برای داده‌های بزرگ و تجزیه و تحلیل داده‌های استریم بررسی میکنیم.
- ما طیف گسترده‌ای از برنامه‌های IoT را که از DL در متن خود استفاده کرده‌اند، مرور میکنیم؛ همچنین یک مقایسه و یک راهنما برای استفاده از انواع مختلف DNN در حوزه‌ها و برنامه‌های مختلف IoT ارائه میدهم.
- ما رویکردها و فناوریهای اخیر را برای استقرار DL در کلیه سطوح سلسله مراتب IoT از دستگاههای محدود شده تا منابع فضای ابری بررسی میکنیم.
- ما برای ادغام موفقیت‌آمیز و بارور برنامه‌های DL و IoT، چالشها و مسیرهای تحقیق را در آینده برجسته میکنیم.

بقیه این مقاله بدین شرح برگزار می شود. در بخش 2، ویژگیهای داده IoT را برجسته میکنیم و توصیف میکنیم که چطور داده‌های بزرگ IoT و همچنین داده های سریع استریم با داده‌های بزرگ عمومی

تفاوت دارند. بخش 3 چندین معماری معمول و موفق DNN را ارائه میدهد. این برنامه همچنین شامل شرح مختصری از پیشرفته‌ها با رویکرد معماری DL در زمان واقعی و همچنین الگوریتمهای پیشرفته معماری است که با DL مشترک هستند. یک بررسی اجمالی نیز از چندین چارچوب و ابزار با قابلیت‌ها و الگوریتمهای مختلفی که از DNN ها پشتیبانی میکنند ارائه شده است. برنامه‌های IoT در حوزه‌های مختلف (به عنوان مثال مراقبتهای بهداشتی، کشاورزی، ITS، و غیره) که از DL استفاده کرده‌اند در بخش 4 بررسی خواهد شد. بخش 5 تلاش برای آوردن DNN به دستگاههای دارای محدودیت منابع را بررسی میکند. بخش 6 کارهایی را که بر روی بارگذاری DNN در مقیاس محاسباتی فضای ابری انجام شده‌اند بررسی میکند. ابعاد تحقیقات آینده و چالشهای حل نشده در بخش 7 ارائه شده است. این مقاله در بخش 8 با گرفتن خلاصه‌ای از پیامهای اصلی آن پایان یافته است. شکل 3 ساختار مقاله را نشان میدهد.



شکل 3. ساختار بررسی.

مشخصات و نیازهای داده‌های IOT برای تجزیه و تحلیل

داده‌های IOT میتوانند به صورت مستمر پخش شوند یا به عنوان دیتابیس‌های بزرگ انباشته شوند. داده‌های استریم به داده‌های تولید شده یا ضبط شده در فواصل زمانی ناچیز از زمان اشاره دارند و برای استخراج بینشهای فوری و یا تصمیم‌گیری سریع باید فوراً مورد تجزیه و تحلیل قرار گیرند. داده‌های بزرگ به مجموعه داده‌های عظیمی اطلاق میشود که رایانه‌های متداول سخت‌افزاری و نرم‌افزاری قادر به ذخیره، مدیریت، پردازش و تجزیه و تحلیل آنها نیستند. با این دو رویکرد باید به شکل متفاوتی برخورد شود زیرا الزامات آنها برای پاسخ تحلیلی یکسان نیست. نتایج حاصل از تجزیه و تحلیل داده‌های بزرگ میتواند پس از چند روز تولید داده تحویل داده شود، اما تجزیه و تحلیل داده‌های استریم باید در دامنه چند صدم میلی ثانیه تا چند ثانیه آماده تحویل باشند.

ادغام داده‌ها و به اشتراک گذاری آنها نقش مهمی را در توسعه محیطهای همه‌جانبه بر اساس داده‌های IOT ایفا میکند. این نقش برای برنامه‌های IOT حساس به زمان ضروری است زیرا در آن به همجوشی به موقع داده‌ها نیاز است تا همه قطعات داده‌ها را برای تجزیه و تحلیل و در نتیجه ارائه بینش عملی قابل اعتماد و دقیق بدست بدهند. علم و همکاران یک مقاله پیمایشی ارائه دادند که در آن تکنیکهای تلفیق داده‌ها برای محیطهای IOT مورد بررسی قرار میگیرد و بدنبال آن چندین فرصت و چالش هم وجود دارد.


الف) داده‌های سریع و استریم IOT

بسیاری از تلاشهای تحقیقاتی، تجزیه و تحلیل داده‌های استریم را ارائه میدهند که میتوانند بطور عمده در سیستمهای محاسباتی با کارایی بالا یا سیستم‌عامل‌های فضای ابری مستقر شوند. تجزیه و تحلیل داده‌های استریم در چنین چارچوبهایی بر اساس موازی‌سازی داده‌ها و پردازش افزایشی است. با موازی‌سازی داده‌ها، یک مجموعه داده بزرگ به چندین مجموعه داده کوچکتر تقسیم میشود، که در آنها تجزیه و تحلیل‌های موازی به طور همزمان انجام میگیرد. پردازش افزایشی به واکنشی‌های کوچک از داده‌ها گفته میشود که باید به سرعت در خط لوله‌ای از کارهای محاسباتی پردازش شوند. اگرچه این تکنیکها برای بازگشت پاسخی از چارچوب تحلیلی داده‌های استریم، تأخیر را در زمان کاهش میدهند، اما بهترین راه حل ممکن برای حفظ دقت زمانی برنامه‌های IOT نیستند. با نزدیک کردن

تجزیه و تحلیل داده‌های استریم به دیتابیس (یعنی دستگاه‌های IOT یا دستگاه‌های لبه)، نیاز به موازی-سازی حساس داده‌ها و پردازش افزایشی، بیشتر است زیرا اندازه داده‌های موجود در منبع امکان پردازش سریع آن را فراهم می‌کند. با اینحال، استفاده از آنالیز سریع در دستگاه‌های IOT چالش‌های خاص خود را از قبیل محدود کردن محاسبات، ذخیره سازی و منابع قدرت را در دیتابیس‌ها به همراه دارد.

(ب) داده‌های بزرگ IOT

IOT بعنوان یکی از منابع اصلی داده‌های بزرگ شناخته شده است، زیرا مبتنی بر اتصال تعداد زیادی از دستگاه‌های هوشمند به اینترنت است تا وضعیتی را که مرتباً از محیط اطراف خود ضبط کرده‌اند گزارش کنند. شناخت و استخراج الگوهای معنی دار از داده‌های ورودی خام عظیم، ابزار اصلی تجزیه و تحلیل داده‌های بزرگ است، زیرا نتیجه آن در سطوح بالاتر بینش برای تصمیم‌گیری و پیش‌بینی مشخص خواهد شد. بنابراین، استخراج این بینش‌ها و دانش از داده‌های بزرگ برای بسیاری از مشاغل از اهمیت بالایی برخوردار است، زیرا این امکان را به آنها می‌دهد تا مزیت‌های رقابتی کسب کنند. در علوم اجتماعی، هیلبرت به ترتیب تأثیر تحلیل داده‌های بزرگ را با اختراع تلسکوپ و میکروسکوپ روی نجوم و زیست‌شناسی مقایسه می‌کند.



شکل 4. گوگل ترند در سالهای اخیر توجه بیشتری را نسبت به یادگیری عمیق نشان داده است.

چندین اثر ویژگیهای کلی داده‌های بزرگ را از جنبه‌های مختلف از نظر حجم، سرعت و تنوع شرح داده‌اند. با اینحال، ما تعریفی عمومی از داده‌های بزرگ را برای توصیف داده‌های بزرگ IoT از طریق ویژگیهای "6V" زیر انجام میدهیم:

- **حجم:** حجم داده‌ها عاملی تعیین کننده برای در نظر گرفتن یک مجموعه داده به عنوان داده‌های بزرگ یا داده‌های عظیم و بسیار بزرگ سنتی است. مقدار داده‌های تولید شده با استفاده از دستگاه‌های IoT بسیار بیشتر از گذشته است و به وضوح با این ویژگی مطابقت دارد.
- **سرعت:** میزان تولید و پردازش داده‌های بزرگ IoT به اندازه کافی بالا هست تا بتواند از دسترسی به داده‌های بزرگ در زمان واقعی پشتیبانی کند. با توجه به نرخ بالای تولید داده، این موضوع نیاز ما به ابزارها و فناوریهای پیشرفته را برای تجزیه و تحلیل توجیه میکند.
- **تنوع:** بطورکلی، داده‌های بزرگ به اشکال و انواع مختلفی درمیآیند. این امر ممکن است از داده‌های ساختاری، نیمه ساختار یافته و بدون ساختار نشأت گرفته باشد. طیف گسترده‌ای از انواع داده‌ها مانند متن، صدا، فیلم، داده‌های حسی و غیره ممکن است توسط IoT تولید شود.

• **صحت:** این امر به کیفیت، قوام و میزان قابل اعتماد بودن داده‌ها اشاره دارد که به نوبه خود منجر به تجزیه و تحلیل دقیق می‌شود. این ویژگی برای نگه داشتن برنامه‌های IoT، به ویژه آنهایی که داده‌های مربوط به جمعیت را دارند، نیاز به توجه ویژه دارد.

• **تنوع پذیری:** این ویژگی به نرخهای مختلف جریان داده اشاره دارد. بسته به ماهیت برنامه‌های IoT، اجزای تولید کننده داده‌های مختلف ممکن است جریان داده‌های متناقض داشته باشند. علاوه بر این، یک منبع داده میتواند نرخهای مختلف بار داده را بر اساس زمانهای خاص داشته باشد. بعنوان مثال، یک برنامه سرویس پارکینگ که از سنسورهای IoT استفاده میکند ممکن است حداکثر بار داده را در ساعتهای شلوغ دارا باشد.

• **ارزش:** ارزش، تبدیل داده‌های بزرگ به اطلاعات مفید و بینشهایی است که مزیت رقابتی را برای سازمانها به ارمغان می‌آورد. ارزش داده به شدت به فرآیندهای و خدمات اساسی و نحوه برخورد با داده‌ها بستگی دارد. بعنوان مثال، یک برنامه خاص (مثلاً نظارت بر علائم حیاتی پزشکی) ممکن است نیاز به ضبط داده‌های حسگر داشته باشد، درحالیکه یک سرویس پیش‌بینی آب و هوا فقط به نمونه‌های تصادفی از داده‌های سنسورهای آن نیاز داشته باشد. یک نمونه دیگر، ممکن است یک ارائه دهنده کارت اعتباری نیاز داشته باشد که داده‌ها را برای مدت زمانی مشخص نگه داشته و پس از آن، آنها را دور بیندازد.

فراتر از خواص فوق، محققان خصوصیات دیگری مانند موارد زیر را شناخته اند:

• داده‌های بزرگ میتوانند یک محصول جانبی یا ردپای یک فعالیت دیجیتالی در تداخل با IoT باشند. استفاده از رایج ترین اصطلاحات جستجوی گوگل برای پیش‌بینی آنفولانزای فصلی نمونه خوبی از چنین محصول جانبی دیجیتالی است.

• سیستمهای داده بزرگ باید از نظر افقی قابل قیاس باشند، یعنی منابع داده‌های بزرگ باید بتوانند به چندین مجموعه داده گسترش یابند. این ویژگی همچنین منجر به پیچیدگی داده‌های بزرگ میشود که به نوبه خود چالشهای دیگری مانند انتقال و پاکسازی داده‌ها را نیز تحمیل میکند.

انجام تجزیه و تحلیل بیش از جریان مداوم داده، در ادبیات معمولاً بعنوان پردازش استریم یا گاهی پردازش رویداد پیچیده (CEP) گفته میشود. اشتروباخ و همکاران، یک چارچوب بزرگ تحلیلی داده IoT برای پشتیبانی از ویژگیهای حجم و سرعت تحلیلی آنها پیشنهاد داده‌اند. ادغام داده‌های بزرگ IoT

و تجزیه و تحلیل داده‌های استریم، یک موضوع حل نشده است که نیاز به تحقیقات بیشتری دارد، همچنین بعنوان بخشی از این کار مورد مطالعه قرار گرفته است. با این حال، چارچوب پیشنهادی آنها برای استقرار در زیرساختهای فضای ابری طراحی شده است. علاوه بر این، تمرکز آنها روی جنبه مدیریت داده‌های دارای چارچوب است و از مدل‌های پیشرفته یادگیری ماشین مانند DL استفاده نمیکنند. سایر محصولات از رده خارج مانند آپاچی استورم³ نیز برای تجزیه و تحلیل در زمان واقعی روی فضای ابری موجود است. شکاف بزرگ این مسئله، عدم وجود چارچوبها و الگوریتمهایی است که میتواند در مه (مثلاً لبه سیستم) یا حتی در دستگاه‌های IoT مستقر شود. وقتی DL در چنین مواردی نقش ایفا کند، باید بین عمق و عملکرد DNN مبادله‌ای در نظر گرفته شود.

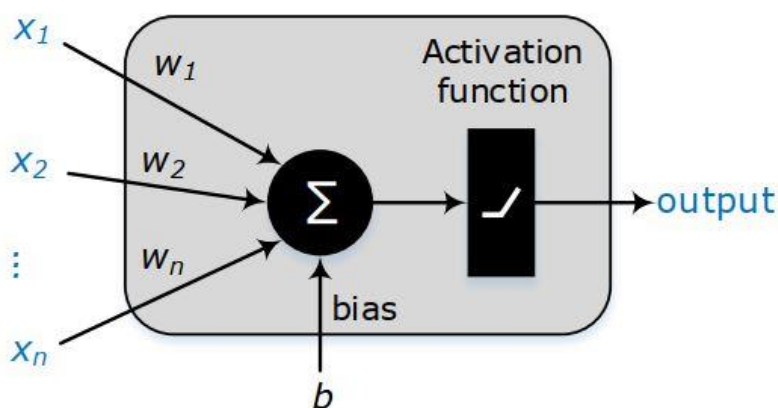
یادگیری عمیق

DL متشکل از تکنیکهای یادگیری نظارت شده یا بدون نظارت است که براساس بسیاری از لایه‌های شبکه عصبی مصنوعی (ANN) ساخته شده است که قادر به بازنمایی سلسله مراتبی در معماریهای عمیق هستند. معماری DL از چندین لایه پردازش تشکیل شده است که هر لایه قادر به تولید پاسخهای غیرخطی بر اساس داده‌های لایه ورودی خودش است. عملکرد DL از مکانیسم‌های مغز و نورونهای انسان برای پردازش سیگنال‌ها تقلید میکند.

معماری DL در سالهای اخیر در مقایسه با سایر رویکردهای یادگیری سنتی ماشین، مورد توجه بیشتری قرار گرفته است. چنین رویکردهایی به عنوان نسخه‌های ساختاری معماری کم‌عمق (به عنوان مثال، یک زیر مجموعه محدود) از DL در نظر گرفته میشوند. شکل 4 روند جستجوی پنج الگوریتم یادگیری محبوب ماشین را در روندهای گوگل نشان میدهد که در آن DL محبوبیت بیشتری پیدا میکند. اگرچه ANN ها در دهه‌های گذشته معرفی شده اند، اما روند روبه رشد DNN ها از سال 2006 شروع شد که جی. هینتون و همکاران مفهوم شبکه‌های عمیق-باور را ارائه دادند. پس از آن، عملکرد مدرن این فناوری در زمینه‌های مختلف هوش مصنوعی از جمله شناسایی تصویر، بازیابی تصویر، موتورهای جستجو و بازیابی اطلاعات و پردازش زبان طبیعی مشاهده شده است.

³ Apache Storm

تکنیکهای DL بر روی دامنه ANN های سنتی توسعه یافته اند. شبکه های عصبی بازخورد یا همان FNN⁴ ها (پیشتر، ادراک چندلایه ای⁵) در دهه های گذشته برای آموزش سیستمها استفاده شده اند، اما وقتی تعداد لایه ها بیشتر شود، آموزش آنها دشوار میشود.



شکل 5. نورون واحدی از شبکه های عصبی مصنوعی است، که دارای چندین ورودی، وزن و تعصب قابل آموزش میباشد.

اندازه کوچک از داده های تمرینی نیز عامل دیگری بود که منجر به ایجاد مدل های اضافی میشود. علاوه بر این، محدودیت در قابلیت های محاسباتی در آن روزها جلوی اجرای FNN های عمیق تر و کارآمدتر را گرفته بود. این محدودیت های محاسباتی اخیراً به دلیل پیشرفتهای سخت افزاری به طور کلی، توسعه واحدهای پردازش گرافیکی (GPU) و شتاب دهنده های سخت افزاری به طور خاص برطرف شده است. فراتر از جنبه های ساختاری و اهمیت عمق معماری DL و همچنین پیشرفتهای سخت افزاری، تکنیکهای DL از پیشرفتهای موجود در الگوریتم های آموزش موثر در شبکه های عمیق بهرمنند شده اند:

- استفاده از واحدهای خطی اصلاح شده (ReLU) بعنوان عملکرد فعال سازی،
- معرفی روشهای رهاسازی،
- اولیه سازی تصادفی برای اوزان شبکه،

⁴ Feed-forward Neural Networks

⁵ Multilayer Perceptrons (MLP)

- پرداختن به تنزل دقت آموزش توسط شبکه‌های یادگیری باقیمانده،

- حل مشکل شیب ناپدید شده درست مثل از بین بردن مشکل شیب با معرفی و تقویت شبکه‌های حافظه کوتاه مدت،

یکی از مزیت‌های معماری DL در مقایسه با ANN‌های سنتی، این است که تکنیک‌های DL میتوانند ویژگی‌های پنهان را از داده‌های خام بیاموزند. هر لایه بر اساس خروجی‌های لایه قبلی، مجموعه‌ای از ویژگی‌ها را آموزش میدهد. بیشترین لایه‌ها میتوانند ویژگی‌های پیچیده‌تری را تشخیص دهند، زیرا ویژگی‌های لایه‌های قبلی را جمع میکنند و در نهایت نوترکیب میشوند که به این امر، سلسله مراتب ویژگی‌ها گفته میشود. بعنوان مثال، در صورت وجود مدل تشخیص چهره، داده‌های خام تصویر از پرتورها بعنوان بردار پیکسل‌ها، به یک مدل در لایه ورودی آن تغذیه میشوند. سپس هر لایه پنهان میتواند ویژگی‌های انتزاعی‌تر از خروجی‌های لایه قبلی را بیاموزد؛ بعنوان مثال اولین لایه پنهان، خطوط و لبه‌ها را مشخص میکند، لایه دوم اجزای چهره مانند بینی، چشمها و غیره را شناسایی میکند و لایه سوم همه موارد قبلی را ترکیب میکند تا از آن در راستای استخراج ویژگی‌هایی برای تولید چهره استفاده کند.

با اینحال، پیشرفتهای گزارش شده از مدل‌های DL بر اساس ارزیابی‌های تجربی است، و هنوز هیچ پایه و اساس تحلیلی مشخصی برای پاسخ به این دلیل که چرا تکنیک‌های DL بهتر از هم‌تابان کم‌عمق خود هست، وجود ندارد. علاوه بر این، هیچ مرز مشخصی بین شبکه‌های عمیق و کم‌عمق بر اساس تعداد لایه‌های پنهان موجود نیست. به طور کلی، شبکه‌های عصبی با دو یا چند لایه پنهان که الگوریتم‌های آموزش پیشرفته اخیر را شامل میشوند، بعنوان مدل‌های عمیق در نظر گرفته میشوند. همچنین، شبکه‌های عصبی متداوم با یک لایه پنهان بعنوان شبکه عمیق شناخته میشوند، زیرا یک چرخه در واحدهای لایه پنهان دارند که میتوانند در یک شبکه عمیق معادل کنترل شوند.

الف) معماری

در این بخش، مختصراً به چند مدل رایج DL و همچنین برترین معماری‌هایی که در سال‌های اخیر معرفی شده‌اند می‌پردازیم. خوانندگان علاقمند میتوانند به ادبیات دیگری که مدل‌ها و معماری DL را با جزئیات بیشتری بررسی کرده است مراجعه کنند. جدول ۱ بطور خلاصه این مدل‌ها، ویژگی‌ها، خصوصیات و برخی از کاربردهای نمونه را نشان میدهد.

Model	Category	Learning model	Typical input data	Characteristics	Sample IoT Applications
AE	Generative	Unsupervised	Various	<ul style="list-style-type: none"> • Suitable for feature extraction, dimensionality reduction • Same number of input and output units • The output reconstructs input data • Works with unlabeled data 	<ul style="list-style-type: none"> • Machinery fault diagnosis • Emotion recognition
RNN	Discriminative	Supervised	Serial, time-series	<ul style="list-style-type: none"> • Processes sequences of data through internal memory • Useful in IoT applications with time-dependent data 	<ul style="list-style-type: none"> • Identify movement pattern • Behavior detection
RBM	Generative	Unsupervised, Supervised	Various	<ul style="list-style-type: none"> • Suitable for feature extraction, dimensionality reduction, and classification • Expensive training procedure 	<ul style="list-style-type: none"> • Indoor localization • Energy consumption prediction
DBN	Generative	Unsupervised, Supervised	Various	<ul style="list-style-type: none"> • Suitable for hierarchical features discovery • Greedy training of the network layer by layer 	<ul style="list-style-type: none"> • Fault detection classification • Security threat identification
LSTM	Discriminative	Supervised	Serial, time-series, long time dependent data	<ul style="list-style-type: none"> • Good performance with data of long time lag • Access to memory cell is protected by gates 	<ul style="list-style-type: none"> • Human activity recognition • Mobility prediction
CNN	Discriminative	Supervised	2-D (image, sound, etc.)	<ul style="list-style-type: none"> • Convolution layers take biggest part of computations • Less connection compared to DNNs. • Needs a large training dataset for visual tasks. 	<ul style="list-style-type: none"> • Plant disease detection • Traffic sign detection
VAE	Generative	Semi-supervised	Various	<ul style="list-style-type: none"> • A class of Auto-encoders • Suitable for scarcity of labeled data 	<ul style="list-style-type: none"> • Intrusion detection • Failure detection
GAN	Hybrid	Semi-supervised	Various	<ul style="list-style-type: none"> • Suitable for noisy data • Composed of two networks: a generator and a discriminator 	<ul style="list-style-type: none"> • Localization and wayfinding • Image to text
Ladder Net	Hybrid	Semi-supervised	Various	<ul style="list-style-type: none"> • Suitable for noisy data • Composed of three networks: two encoders and one decoder 	<ul style="list-style-type: none"> • Face recognition • Authentication

جدول 1 خلاصه مدل های یادگیری عمیق

DNN از یک لایه ورودی، چندین لایه پنهان و یک لایه خروجی تشکیل شده است. هر لایه شامل چندین واحد به نام نورون است. یک نورون اطلاعات را از چندین ورودی دریافت میکند، یک جمع‌بندی وزنی بیش از ورودی‌های خود را انجام میدهد، سپس حاصل را از یک عملکرد فعال سازی برای تولید خروجی عبور میدهد. هر نورون، برداری از وزنهاى مرتبط با اندازه ورودی آن و همچنین سوگیری دارد که باید طی فرایند آموزش بهینه شود. شکل 5 ساختار یک نورون را نشان میدهد.

در فرایند آموزش، لایه ورودی، وزنها را (معمولاً به طور تصادفی) به داده‌های آموزشی ورودی اختصاص میدهد و آن را به لایه بعدی منتقل میکند؛ لایه بعدی نیز وزن را به ورودی خود اختصاص میدهد و خروجی آنها را تولید میکند، که به عنوان ورودی برای لایه زیرین عمل میکند. در آخرین لایه، خروجی نهایی نمایانگر پیش بینی مدل است. یک تابع محاسبه ضرر، با محاسبه میزان خطا بین مقادیر پیش بینی شده و درست، صحت این پیش بینی را تعیین می کند و یک الگوریتم بهینه سازی

مانند نزول شیب تصادفی (SGD)⁶ برای تنظیم وزن نورون ها با محاسبه شیب عملکرد از دست دادن استفاده می شود. میزان خطا در سراسر شبکه در لایه ورودی پخش میشود (معروف به الگوریتم باز نشر). سپس شبکه بعد از تعادل وزن، بر روی هر نورون این چرخه تمرین را تکرار میکند تا اینکه میزان خطا در زیر آستانه مورد نظر قرار بگیرد. در این مرحله، DNN آموزش دیده و آماده استنتاج است. در شکل 6، مکانیسم سطح بالای آموزش برای مدل های DL نشان داده شده است.

در یک طبقه بندی گسترده، مدل های DL در سه دسته قرار میگیرند، یعنی مدل های تولیدی، تمیز دهنده و ترکیبی. اگرچه نمیتوان مرز محکمی را میان داده ها قائل شد، اما تمیز دهنده معمولاً رویکردهای یادگیری نظارت شده را ارائه میدهند، در حالی که از مدل های تولیدی برای یادگیری بدون نظارت استفاده میشود. مدل های ترکیبی مزایای هر دو مدل تمیز دهنده و تولیدی را شامل میشوند.

1) شبکه های عصبی مفهومی (CNN⁷):


برای کارهای مبتنی بر بینایی، آموزش DNN با اتصال متراکم بین لایه ها دشوار است و مقیاس خوبی ندارد؛ یکی از دلایل مهم آن، خاصیت ترجمه-متغیر بودن چنین مدل هایی است. بنابراین آنها ویژگی هایی را که ممکن است در تصویر دگرگون شوند، نمیآموزند (بعنوان مثال چرخش دست در تشخیص پوز). CNN ها با پشتیبانی از محاسبات ترجمه-معادله، این مشکل را حل کرده اند. CNN یک ورودی 2 بعدی (به عنوان مثال، یک تصویر یا سیگنال گفتاری) را دریافت میکند و ویژگی های سطح بالایی را از طریق یک سری لایه های پنهان استخراج میکند. لایه های پنهان از لایه های پیچشی و همچنین لایه های کاملاً متصل در انتها تشکیل شده است. لایه حلقوی در هسته CNN واقع شده که از مجموعه ای از پارامتر های قابل یادگیری به نام فیلترها تشکیل شده است که همان شکل ورودی اما دارای ابعاد کوچکتر است. در فرایند آموزش، فیلتر هر لایه مفهومی از کل حجم ورودی عبور میکند؛ بعنوان مثال، در صورت وجود یک تصویر، از عرض و طول تصویر عبور کرده و یک محصول داخلی از ورودی و فیلتر را محاسبه میکند. این محاسبه در کل ورودی به یک نقشه ویژگی های فیلترها منتهی میشود.

⁶ Stochastic Gradient Descent


⁷ Convolutional Neural Networks

یکی دیگر از ساختمانهای CNN، لایه‌های انباشته شده است که روی نقشه‌های نشانگر ویژگیها کار میکند. هدف از داشتن لایه‌های انباشته، کاهش فاصله مکانی پشتیبانی است، تا هم تعداد پارامترها و میزان زمان محاسبه کاهش یابد و هم احتمال پوشش بیش از حد پایین بیاید. **حداکثر انباشت**، یک رویکرد رایج است که فضای ورودی را به مناطق بدون همپوشانی تقسیم کرده و حداکثر مقدار را برای هر منطقه انتخاب میکند.

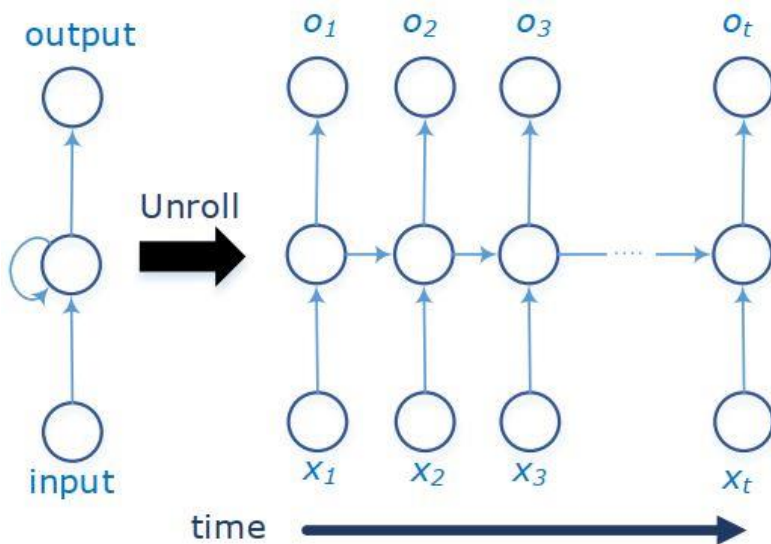
آخرین مؤلفه مهم در CNN، ReLU است که از سلولهای عصبی با عملکرد فعال سازی به شکل $f(x) = \max(0; x)$ تشکیل شده است. معرفی این عملکرد فعال سازی در CNN به شکلی معقول، منجر به افزایش زمان آموزش بدون تأثیرگذاری در شبکه به صورت منفی میشود. شکل 7 ساختار یک CNN را نشان میدهد.



شکل 6. مکانیسم کلی آموزش یک مدل DL.



شکل 7. معماری CNN.



شکل 8. ساختار یک شبکه عصبی نرونی

تفاوت اصلی بین CNN ها و شبکه‌های کاملاً متصل این است که هر نورون موجود در CNN ها تنها به یک زیر مجموعه کوچک از ورودی متصل است. این تعداد کل پارامترهای موجود در شبکه را کاهش داده و پیچیدگی زمانی فرایند آموزش را بهبود میبخشد. به این ویژگی، اتصال محلی گفته میشود. بسیاری از دستگاه‌های IoT مانند هواپیماهای بدون سرنشین، تلفنهای هوشمند و اتومبیل‌های متصل هوشمند، مجهز به دوربین هستند. معماری CNN و تغییرات آن برای انواع سناریوهای کاربردی که

شامل این دستگاه‌ها شده، مورد بررسی قرار گرفته است. برخی از برنامه‌های معمولی شامل پیش بینی سیل و رانش زمین از طریق تصاویر اتوماتیک، تشخیص مسمومیت‌های گیاهی با استفاده از تصاویر گیاهان بر روی تلفن‌های هوشمند و تشخیص علائم راهنمایی و رانندگی با استفاده از دوربین‌های وسایل نقلیه می‌باشد.

2) شبکه‌های عصبی مکرر (RNN⁸):

در بسیاری از کارها، پیش‌بینی به چندین نمونه قبلی بستگی دارد؛ به گونه‌ای که علاوه بر طبقه‌بندی نمونه‌های فردی، ما هم نیاز به تجزیه و تحلیل توالی ورودیها داریم. در چنین برنامه‌های کاربردی، یک شبکه عصبی تغذیه پیشرو قابل استفاده نیست زیرا هیچ وابستگی را بین لایه‌های ورودی و خروجی به عهده نمی‌گیرد. RNN برای حل مسئله مشکلات پی‌درپی (مثلاً گفتار یا متن) با مشکلات سری زمانی (داده‌های حسگر) با طولهای مختلف ایجاد شده است. تشخیص رفتارهای رانندگان در وسایل نقلیه هوشمند، شناسایی الگوهای حرکتی افراد و برآورد مصرف انرژی یک خانواده، نمونه‌هایی از کاربرد RNN است. ورودی RNN شامل نمونه فعلی و نمونه مشاهده شده قبلی است. به عبارت دیگر، خروجی RNN در مرحله $t-1$ بر خروجی در مرحله t تأثیر می‌گذارد. هر نورون به یک حلقه بازخورد مجهز است که خروجی فعلی را بعنوان ورودی برای مرحله بعدی باز می‌گرداند. این ساختار میتواند به گونه‌ای بیان شود که هر نورون در RNN دارای یک حافظه داخلی باشد که اطلاعات محاسبات را از ورودی قبلی حفظ میکند.

برای آموزش شبکه، از الگوریتم انتشار بازگشتی، با نام بازگشت انتشار در طول زمان (BPTT⁹) استفاده می‌شود. با توجه به وجود چرخه در سلولهای عصبی، ما نمیتوانیم از انتشار بازگشتی اصلی در اینجا استفاده کنیم، زیرا اینکار بر اساس مشتق خطا، با توجه به وزن در لایه بالایی آنها عمل میکند، درحالیکه در RNNها مدل لایه‌ای پشته‌ای نداریم. هسته اصلی الگوریتم BPTT روشی است به نام عدم کنترل RNN، به گونه‌ای که ما در طول زمان با یک شبکه تغذیه کننده رو به رو میشویم. شکل 8 ساختار یک RNN و مفهوم کنترل نشده را نشان میدهد.

⁸ Recurrent Neural Networks

⁹ Back Propagation Through Time

RNNهای سنتی میتوانند به عنوان مدل‌های عمیق در نظر گرفته شوند زیرا میتوان آنها را بعنوان چندین لایه غیرخطی نورون بین لایه ورودی و لایه خروجی در زمان کشف آنها مشاهده کرد. با اینحال، باتوجه به معماری و عملکرد RNNها، لایه‌های پنهان در RNNها قرار است به جای بازنمایی سلسله‌مراتبی از ویژگیها، حافظه‌هایی را فراهم کنند. چندین روش برای عمیق تر ساختن RNN وجود دارد، از جمله اضافه کردن لایه‌های بیشتر بین لایه‌های ورودی و پنهان، جمع کردن لایه‌های پنهان‌تر و اضافه کردن لایه‌های بیشتر بین لایه‌های پنهان و لایه خروجی.


3 حافظه کوتاه مدت بلند (LSTM¹⁰):

LSTM یک شاخه از RNN است. گونه‌های مختلفی از LSTM ارائه شده است، اگرچه بیشتر آنها از همان طراحی شبکه اصلی پیروی کرده اند. LSTM برای واحدهای خود از مفهوم دروازه استفاده میکند که هر یک مقدار بین 0 تا 1 را بر اساس ورودی خود محاسبه میکند. علاوه بر یک حلقه بازخورد برای ذخیره اطلاعات، هر نورون در LSTM (همچنین به آن سلول حافظه نیز گفته می شود) دارای یک دروازه فراموشی ضربدری، یک دروازه برای خواندن و یکی برای نوشتن است. این دروازه‌ها برای کنترل دسترسی به سلولهای حافظه و جلوگیری از آشفتنی آنها توسط ورودیهای بی‌ربط معرفی میشوند. هنگامی که دروازه فراموشی فعال است، نورون داده‌های خود را درون خودش مینویسد. هنگامیکه دروازه فراموشی با ارسال یک 0 خاموش میشود، نورون آخرین محتوای خود را فراموش میکند. هنگامیکه دروازه نوشتن روی 1 تنظیم شده است، سایر سلولهای عصبی متصل به آن میتوانند داده را روی آن نورون بنویسند. اگر دروازه خواندن روی 1 تنظیم شود، سلولهای عصبی متصل میتوانند محتوای نورون را بخوانند. شکل 9 این ساختار را نشان میدهد.


تفاوت مهم LSTMها در مقایسه با RNNها این است که واحدهای LSTM از دروازه‌های فراموشی استفاده میکنند تا بطور فعال حالت سلول را کنترل کنند و از عدم تخریب آنها اطمینان داشته باشند. دروازه‌ها میتوانند از سیگمویید یا برنزه به عنوان عملکرد فعال سازی خود استفاده کنند. در حقیقت، این کارکردهای فعال سازی دلیل اصلی مشکل ناپدید شدن شیب در حین بازپرداخت در مرحله تمرینی سایر مدلها هستند. با آموختن داده‌هایی که باید در LSTM بخاطر بیابورید، محاسبات ذخیره شده در

¹⁰ Long Short Term Memory


سلولهای حافظه با گذشت زمان تحریف نمیشوند. BPTT یک روش متداول برای آموزش شبکه در راستای به حداقل رساندن خطا است.



شکل 9. ساختار یک سلول حافظه LSTM. فلشهای ممتد، جریان داده‌ها را نشان میدهد و فلشهای نقطه‌چین، سیگنال‌هایی را از دروازه‌ها نشان میدهند.



شکل 10. ساختار یک شبکه خودکار.



شکل 11. ساختار یک شبکه خودکار تغییر دهنده تفاوتها.

هنگامی که داده‌ها با وابستگی طولانی به زمان مشخص میشوند، مدل‌های LSTM عملکرد بهتری نسبت به مدل‌های RNN دارند. این تاخیر طولانی وابستگی را میتوان در برنامه‌های IoT از قبیل شناخت فعالیت‌های انسانی، پیش‌بینی عملکردهای آموزشی در برنامه‌های آنلاین و پیش‌بینی بحرانه‌ها بر اساس نظارت زیست محیطی مشاهده کرد که تعدادی از آنها را شاهد هستیم.

4) رمزنگارهای خودکار (AE¹¹):

AE ها شامل یک لایه ورودی و یک لایه خروجی هستند که از طریق یک یا چند لایه پنهان به هم متصل میشوند. AE ها به تعداد واحدهای ورودی و خروجی یکسان هستند. این شبکه‌ها با هدف تبدیل مجدد ورودی به خروجی با ساده‌ترین روش ممکن هستند، به گونه‌ای که ورودی را خیلی هم تحریف نکنند. این نوع شبکه‌های عصبی عمدتاً برای حل مشکلات یادگیری بدون نظارت، درست مثل یادگیری انتقال مورد استفاده قرار میگیرند. با توجه به رفتار آنها در مورد ساخت ورودی در لایه خروجی، از AE ها عمدتاً برای کارهای تشخیص خطا استفاده میشود. این مورد برای IoT صنعتی مورد توجه

¹¹ Autoencoders

بسیاری از برنامه‌ها مانند تشخیص اشتباه در دستگاه‌ها و ماشینهای سخت‌افزاری و تشخیص ناهنجاری در عملکرد خطوط مونتاژ است.

AE ها دو مؤلفه اصلی دارند: یک رمزگذار و یک رمزشکن. رمزگذار ورودی را دریافت میکند و آن را به یک بازنمایی جدید تبدیل میکند، که معمولاً به آن یک کد یا متغیر پنهان گفته میشود. رمزشکن کد تولید شده را از رمزگذار دریافت میکند و آن را به یک بازسازی ورودی اصلی تبدیل میکند. روش آموزش در AE شامل به حداقل رساندن خطای بازسازی، یعنی خروجی و ورودی است که حداقل اختلاف را نشان میدهد. شکل 10 ساختار AE معمولی را نشان میدهد. چندین تغییر و الحاقی در مورد AEها مانند AE نویشکن، AE قراردادی، AE انباشته شده، AE پراکنده و AE متغیر وجود دارد.

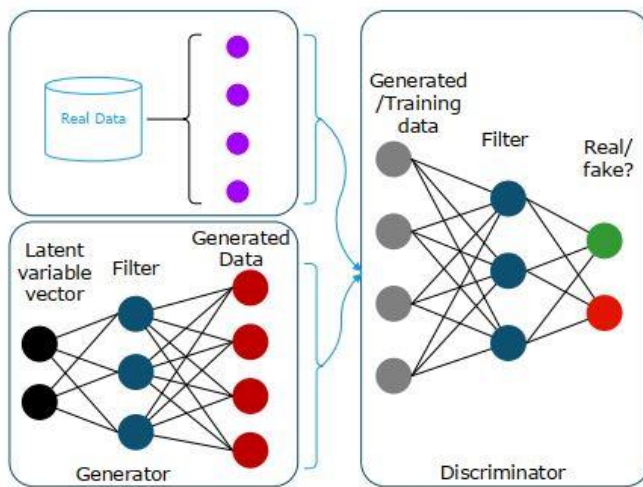
5) رمزگذارهای خودکار مختلف (VAE^{12s}):

VAEs، معرفی شده در سال 2013، یک چارچوب مدل تولیدی محبوب است که فرضیات ما در مورد ساختار داده‌های آن قوی نیست، در حالی که داشتن یک روند آموزش سریع از طریق انتشار بازگشتی میباشد. علاوه بر این، این مدل برای یادگیری نیمه نظارت شده استفاده شده است. بنابراین، این برای راه حل‌های IoT یک مزیت است که با داده‌های متنوع و کمبود داده‌های دارای برچسب سروکار دارند. چنین کاربردهایی شامل تشخیص عدم موفقیت در سنجش یا تحریک سطوح و تشخیص نفوذ در سیستم‌های امنیتی است. برای هر نقطه داده x ، یک بردار از متغیرهای پنهان مربوطه وجود دارد که توسط z نشان داده شده است. معماری آموزش یک VAE به ترتیب از یک رمزگذار و یک رمزشکن با پارامترهای ϕ و θ تشکیل شده است. توزیع شکل $q\phi(z|x)$ ثابت، به رمزگذار در تخمین توزیع خلفی $p\theta(z|x)$ کمک میکند. این مدل از دو شبکه تشکیل شده است: یکی نمونه‌های مولد و دیگری اجراگر استنتاج تقریبی. شماتیکی از VAE در شکل 11 نشان داده شده است.

¹² Variational Autoencoders


6) شبکه‌های مخالف مولد (GAN¹³):

GAN ها که توسط گودفلو و همکاران معرفی شده اند، متشکل از دو شبکه عصبی هستند، یعنی شبکه‌های تولیدی و تمیز دهنده که برای تولید داده‌های مصنوعی و با کیفیت همکاری میکنند. شبکه پیشین (پیش‌تر تولید کننده) پس از یادگیری توزیع داده از یک مجموعه داده آموزشی، مسئولیت ایجاد داده‌های جدید را برعهده دارد.



شکل 12. مفهوم یک شبکه تولیدی خلفی.

¹³ Generative Adversarial Networks



شکل 13. ساختار دستگاه بولتزمن محدود. لایه‌های قابل مشاهده و پنهان دارای جانبداری جداگانه‌ای هستند.

شبکه دوم (پیش‌تر تشخیص دهنده) کار تمایز میان داده‌های واقعی (حاصل از داده‌های آموزشی) و داده‌های ورودی جعلی (از تولید کننده) را انجام می‌دهد. شبکه مولد برای تولید داده‌های ورودی که تشخیص دهنده را فریب می‌دهند بهینه شده است (یعنی داده‌هایی که تشخیص دهنده نمی‌تواند به راحتی متوجه جعلی یا واقعی بودن آنها شود). به عبارت دیگر، شبکه مولد با یک شبکه تمیز دهنده مخالف رقابت می‌کند. شکل 12 مفهوم GANها را نشان می‌دهد.

عملکرد هدف در GANها بر اساس بازیهای مینیماکس است، بگونه‌ای که یک شبکه سعی دارد عملکرد ارزش را به حداکثر برساند و شبکه دیگر در تلاش برای به حداقل رساندن آن باشد. در هر مرحله از این بازی تخیلی، مولد مایل به گول زدن تشخیص دهنده یا تولید یک سری از داده‌ها با استفاده از نویزهای موجود در بازی است. از طرف دیگر، تشخیص‌دهنده چندین نمونه داده واقعی را از مجموعه آموزشی به همراه نمونه از مولد دریافت می‌کند. سپس وظیفه آن، تشخیص تمایز میان داده‌های واقعی و جعلی است. در نظر گرفته شده است که در صورت صحیح بودن طبقه بندی، اینگونه تمایزها عملکرد رضایت بخشی داشته باشد؛ مولد هم در صورتی که مثلهایی بزند که قادر به گول زدن تشخیص‌دهنده باشد، عملکرد خوبی دارد. سپس پارامترهای تشخیص دهنده و مولد به‌روز میشوند تا برای دور بعدی بازی آماده گردند. خروجی تشخیص‌دهنده به مولد کمک می‌کند تا داده‌های تولید شده خود را برای دور بعدی بهینه کند.

در برنامه‌های IoT میتوان از GANها برای سناریوهایی استفاده کرد که نیاز به ایجاد چیز جدیدی از داده‌های موجود دارند. این میتواند شامل برنامه‌های بومی‌سازی و مسیریابی باشد، جایی که یک شبکه

مولد در GAN مسیرهای بالقوه بین دو نقطه را تولید میکند، در حالی که تشخیص‌دهنده مشخص میکند که کدام مسیرها مناسب به نظر میرسند. GANها همچنین برای توسعه خدمات برای افراد کم بینا، مانند مبدلهای تصاویر به صدا با استفاده از هر دو GAN، برای تولید متون توصیفی از یک تصویر داده شده و یک مدل DL دیگر برای انجام تبدیل متن به گفتار، بسیار مفید هستند. در یک تحقیق پردازش تصویر با استفاده از GANها، تعداد زیادی از عکسهای مشهور واقعی برای ایجاد تصاویر جعلی جدید مورد تجزیه و تحلیل قرار گرفته است به طوری که یک انسان نمیتواند تشخیص دهد که آیا آنها تصاویر واقعی هستند یا خیر.

7 ماشین محصور بولتزمن (RBM^{14}):

RBM یک ANN تصادفیست که از دو لایه تشکیل شده است: یک لایه قابل مشاهده که حاوی ورودی است که ما میدانیم و یک لایه پنهان که حاوی متغیرهای نهفته است. محدودیت در RBMها در اتصال نورونها نسبت به ماشین بولتزمن اعمال میشود. RBMها باید یک نمودار دو بخشی ایجاد کنند، بگونه‌ای که هر نورون قابل مشاهده باید به همه نورونهای پنهان متصل شود و برعکس، اما هیچ ارتباطی بین هر دو واحد در یک لایه وجود ندارد. علاوه بر این، واحد تمایز به همه نورون های مرئی و پنهان متصل است. RBMها را میتوان انباشته کرد تا DNNها را تشکیل دهند. آنها همچنین ساختمان شبکه‌های عمیق باور هستند.

داده‌های آموزشی به واحدهای قابل مشاهده اختصاص داده میشود. روش آموزش میتواند از الگوریتمهای انتشار بازگشتی و شیب برای بهینه سازی وزن شبکه استفاده کند. هدف از آموزش RBM به حداکثر رساندن محصول تمام احتمالات واحدهای قابل مشاهده است. عملکرد RBM شبیه AE است زیرا برای محاسبه متغیرهای نهفته از تغذیه پیشرو استفاده میکند، که به نوبه خود برای بازسازی ورودی با استفاده از تغذیه پسرو مناسب است. ساختار یک RBM در شکل 13 نشان داده شده است.

RBMها میتوانند ویژگیها را از داده‌های ورودی استخراج کنند. این امر از طریق مدل سازی توزیع احتمال روی مجموعه‌ای از ورودیها که در مجموعه واحدهای پنهان نشانده شده است اتفاق میافتد. بعنوان مثال، با داشتن مجموعه‌ای از فیلمهای مورد علاقه افراد، یک مدل RBM میتواند دارای یک لایه قابل مشاهده باشد که از تعداد نورونها به اندازه تعداد فیلمهای موجود تشکیل شده و یک لایه پنهان

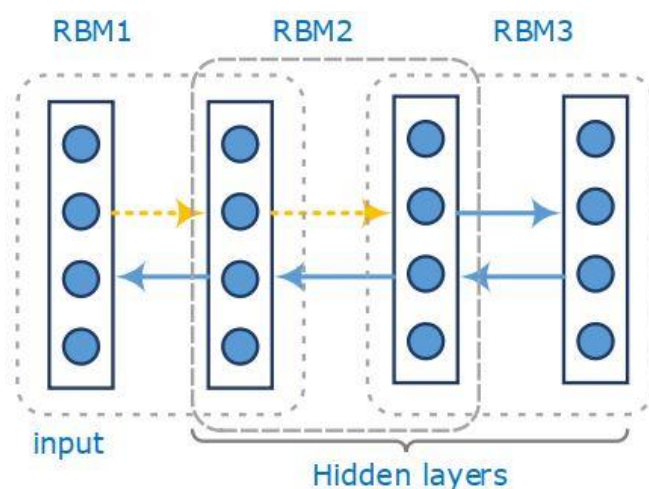
¹⁴ Restricted Boltzmann Machine

متشکل از سه نرون برای نشان دادن سه ژانر مختلف مانند درام، اکشن و کمدی بکار گرفته شود. بنابراین، بر اساس برنامه میتوان لایه پنهان را لایه خروجی در نظر گرفت؛ یا میتوان آن را با یک لایه طبقه بندی اضافی برای انجام طبقه بندی بر اساس ویژگیهای استخراج شده تکمیل کرد.

از انواع برنامه‌های کاربردی بالقوه که در آن میتوان از RBM استفاده کرد، میشود به بومی‌سازی داخلی، پیش‌بینی مصرف انرژی، پیش‌بینی تراکم ترافیک، آنالیز وضع حمل و معمولاً هر برنامه‌ای را که از استخراج مهمترین ویژگیهای موجود در دسترس باشد، نام برد.

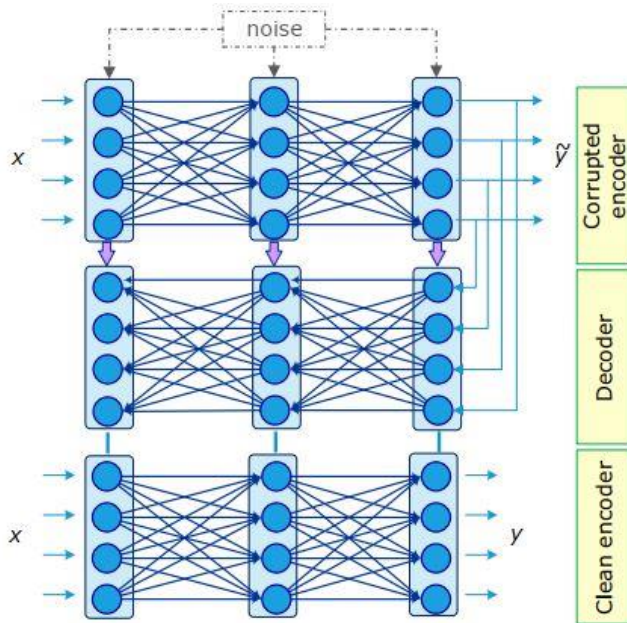
8) شبکه عمیق باور (DBN¹⁵):

DBNها نوعی از ANNهای مولد هستند که از یک لایه قابل مشاهده (مربوط به ورودیها) و چندین لایه پنهان (مربوط به متغیرهای نهفته) تشکیل شده است. آنها میتوانند بازنمایی سلسله مراتبی از داده‌های آموزشی را استخراج کرده و داده‌های ورودی آنها را بازسازی کنند. برای کارهای مربوط به پیش‌بینی میتوان از اضافه کردن یک لایه طبقه بندی کننده مانند softmax استفاده کرد.



شکل 14. ساختار یک شبکه عمیق باور. فلشهای نقطه‌چین مسیر استخراج ویژگیها و فلشهای ممتد مسیر تولید را نشان میدهند.

¹⁵ Deep Belief Network



شکل 15. ساختار شبکه نردبانی دولایه‌ای.

آموزش یک DBN بصورت لایه‌ای انجام میشود، بگونه‌ای که هر لایه بعنوان RBM که در بالای لایه آموزش دیده قبلی آموزش دیده است، درمان میگردد. این مکانیسم یک DBN را به یک الگوریتم کارآمد و سریع در DL تبدیل میکند. برای یک لایه مخفی در DBN، لایه پنهان RBM قبلی به عنوان لایه ورودی عمل میکند. شکل 14 ساختار یک DBN معمولی را نشان میدهد.

برنامه‌های کاربردی متعددی میتوانند از ساختار DBN استفاده کنند، مانند طبقه بندی تشخیص اشتباه در محیط‌های صنعتی، شناسایی تهدید در سیستم‌های هشدار امنیتی و استخراج ویژگی‌های احساسی از تصاویر.

(9) شبکه‌های نردبانی:

شبکه‌های نردبان در سال 2015 توسط والپولا و همکاران برای پشتیبانی از یادگیری بدون نظارت پیشنهاد شد. بعداً، آنها به کار در تنظیمات نیمه نظارت شده گسترش یافته و عملکرد فوق‌العاده‌ای را برای چندین کار، مانند شناخت ارقام دستنویس و طبقه بندی تصویر نشان داده شده، گمارده شده‌اند.

معماری شبکه نردبانی از دو رمزگذار و یک رمزشکن تشکیل شده است. رمزگذارها به عنوان بخش نظارت شده در شبکه عمل میکنند و رمزشکن، یادگیری بدون نظارت را انجام میدهد. یکی از رمزگذارها بنام رمزگذار پاک، محاسبات عادی را تولید میکند در حالی که رمزگذار دیگر بنام رمزگذار خراب، صدای گاوس را به همه لایه‌ها اضافه میکند.

رمزشکن با استفاده از یک تابع **denoising** میتواند بازنماییها را در هر لایه با توجه به داده‌های خراب مربوطه بازسازی کند. تفاوت بین داده‌های بازسازی شده و تمیز در هر لایه برای محاسبه هزینه دفع **denoising** آن لایه استفاده میشود. در سمت رمزگذار، تابع هزینه از تفاوت بین خروجی خراب لایه‌های رمزگذار و خروجیهای تمیز مربوطه استفاده میکند. هدف آموزش به حداقل رساندن مبلغ هزینه در بخش نظارت شده و شبکه بدون نظارت است.

ارزیابی تجربی اولیه شبکه‌های نردبانی محدود به برخی از کارهای استاندارد است، مانند طبقه بندی رقمهای دستنویس بر روی مجموعه داده‌های تغییر یافته موسسه ملی استاندارد و فناوری (MNIST¹⁶) یا وظایف تشخیص تصویر در مجموعه داده‌های موسسه تحقیقات پیشرفته کانادا 10- (CIFAR¹⁷). اگرچه این امر در سناریوهای IoT به طور گسترده ای مورد استفاده قرار نگرفته است، اما شبکه‌های نردبانی این پتانسیل را دارند که در بسیاری از تجزیه و تحلیل‌های IoT مبتنی بر بینایی استفاده کنند، جایی که نظارت نیمه نهایی یک امتیاز عالی است. شکل 15 ساختار شبکه نردبانی را نشان میدهد.

ب) معماری سریع و واقعی در زمان واقعی DL

این تحقیق برای تجزیه و تحلیل سریع و در زمان واقعی با استفاده از مدل‌های DL بر روی جریان داده‌ها کار میکند، اما هنوز در مراحل ابتدایی خود قرار دارد. کار اولیه در این زمینه که از ANN استفاده میکند توسط لیانگ و همکاران انجام شده است. این شبکه، شبکه‌های یادگیری افراطی (ELM) را گسترش داده است تا الگوریتم یادگیری پی‌درپی آنلاین را در شبکه‌های بازخورد لایه‌ای پنهان قرار دهند. چارچوب آنها، موسوم به OS-ELM، داده‌های آموزش را یک به یک و تکه به تکه میاموزد و فقط داده‌های تازه وارد شده روند آموزش را طی خواهند کرد. این معماری پایه‌ای برای سیستم اجرای ساخت زمان واقعی است که در آن پیشنهاد شده است. در این کار، OS-ELM برای بومی سازی اشیا

¹⁶ Modified National Institute of Standards and Technology

¹⁷ Canadian Institute for Advanced Research

کف فروشگاه با استفاده از فناوری RFID مورد استفاده قرار گرفته است. زو و همکارانش همچنین از استفاده از این معماری برای یک الگوریتم بومی‌سازی داخلی بر اساس اثر انگشت WiFi استفاده کرده‌اند، که در آن مدل OS-ELM میتواند تغییرات محیطی پویا را تحمل کند در حالی که هنوز دقت خوبی را نشان میدهد.

برای شبکه‌های پیچیده، معماری ارائه شده توسط رن و همکاران، با نام R-CNN سریعتر (مبتنی بر Fast RCNN)، با هدف کشف اشیا موجود در تصاویر در زمان واقعی شکل میگیرد. تشخیص شیء در تصاویر به محاسبات بیشتری احتیاج دارد و از این رو در مقایسه با کارهای طبقه بندی تصویر، انرژی بیشتری مصرف میکند، زیرا این سیستم تعداد زیادی از پیشنهادات بالقوه شیء را دارد که باید ارزیابی شوند. معماری پیشنهادی مبتنی بر استفاده از الگوریتمهای پیشنهادی منطقه در CNNهای کامل است که پیش بینی مرزهای اشیا و محاسبه نمره عینیت را در هر موقعیت همزمان انجام میدهند. ارزیابی آنها از معماری تشخیص اشیا پیشنهادی نشان میدهد که زمان اجرای سیستم بین 5-17 فریم در ثانیه (fps) است. با توجه به اینکه فریمهای ورودی اصلی مجدداً اندازه‌گیری میشوند به طوری که کوتاهترین ضلع تصویر 600 پیکسل خواهد بود. مانو و همکاران همچنین از Fast R-CNN برای سیستم‌عامل‌های تعبیه شده استفاده کرده‌اند که گزارش از زمان اجرا 1:85 فریم در ثانیه با فریمهای کوچک شده به 600 پیکسل در کوتاهترین سمت در پلتفرم CPU + GPU تعبیه شده‌اند، همچنین نشان داده شده است که با تاثیر نزدیک به زمان واقعی اجرا، انرژی کافی دارند. با اینحال، برای کارهای پردازش تصویر، وقتی میتوان با سرعت 30 فریم در ثانیه یا بهتر پردازش و تجزیه و تحلیل کرد، میتوان رویکردی را واقعی دانست. ردمون و همکاران، سیستم You Only Look Once (YOLO) را که برای عملکرد 45 فریم در ثانیه برای تصاویر ورودی به $448 * 448$ ized رسیده است، توسعه داده‌اند و حتی نسخه کوچک تر آن، که Fast YOLO نام دارد، با دستیابی به 155 فریم در ثانیه، برای دوربینهای هوشمند مناسب بنظر میرسد.

ج) DL مشترک با سایر رویکردها

معماری DL همچنین در سایر روشهای یادگیری ماشینی به طور مشترک مورد استفاده قرار گرفته است تا کارایی آنها را بیشتر کند. تقریب عملکرد غیرخطی مدل‌های DL که میتواند هزاران یا حتی میلیاردها پارامتر را پشتیبانی کند، انگیزه‌ای قوی برای استفاده از این روش در سایر روشهای یادگیری

ماشینی است که به چنین توابعی نیاز دارند. علاوه بر این، استخراج ویژگیهای خودکار در مدل‌های عمیق یکی دیگر از دلایل ایجاد انگیزه برای بهره‌برداری از این مدلها به طور مشترک با روشهای دیگر است. همچنین در زیرشاخه‌های آن، خلاصه‌ای از چنین رویکردهایی که برای سناریوهای IoT مناسب است ارائه شده است.

1 آموزش تقویت عمیق:

آموزش تقویتی عمیق (DRL¹⁸) ترکیبی از یادگیری تقویتی (RL) با DNN است. این هدف برای ایجاد عوامل نرم‌افزاری است که می‌توانند به تنهایی یاد بگیرند که سیاستهای موفقی را برای به دست آوردن حداکثر پاداشهای بلند مدت ایجاد کنند. در این روش، RL بهترین مدل اقدامات را نسبت به مجموعه‌ای از عبارات در یک محیط از یک مدل DNN می‌یابد. نیاز به DNN در یک مدل RL زمانی آشکار میشود که محیط زیرین توسط تعداد زیادی از عبارات فراهم باشد. در چنین شرایطی، RL سنتی به اندازه کافی کارآمد نیست. در عوض، یک مدل DL میتواند برای ارزش عمل برنامه ریزی شده تا به منظور برآورد کیفیت یک عمل در یک حالت معین استفاده شود. سیستمهایی که از DRL در بطن خود استفاده میکنند در مراحل ابتدایی خود هستند، اما قبلاً نتایج بسیار امیدوارکننده‌ای را نشان داده اند. در زمینه IoT، کارهای ارائه شده در استفاده از DRL در یک محیط نیمه نظارت شده برای بومی سازی محیط های دانشگاهی هوشمند استفاده میگردند. هدف از این کار، بومی سازی کاربران بر اساس سیگنالهای دریافت شده از چندین iBeacons بلوتوث کم انرژی (BLE¹⁹) است. عامل یادگیری از DRL استفاده میکند تا بهترین عملکرد را برای انجام دادن پیدا کند (به عنوان مثال، حرکت از جهتی مانند شمال، شمال غربی و... از نقطه شروع). عملکرد پاداش معکوس، خطای فاصله نسبت به یک هدف از پیش تعریف شده است، به گونه‌ای که عامل یادگیری با نزدیک شدن به هدف مورد نظر خود و برعکس، پاداش بیشتری دریافت میکند. شکل 16 نتیجه نمونه‌ای از چنین روشهایی را نشان میدهد؛ وقتی که یک مدل DNN به کسب جوایز بیشتر در یک محیط نیمه نظارت شده (شکل زیرین سمت چپ در شکل 16) و تعبیر پاداش آن به دقت (شکل زیرین راست) کمک میکند.

¹⁸ Deep Reinforcement Learning

¹⁹ Bluetooth Low Energy

2) انتقال یادگیری با مدل‌های عمیق:

یادگیری انتقال که در حوزه سازگاری دامنه و یادگیری چند کاره قرار دارد، شامل انتقال و بهبود یادگیری در یک دامنه جدید همراه با انتقال بازنمایی دانش است که از داده‌های یک دامنه مرتبط آموخته شده است. یادگیری انتقال برای بسیاری از برنامه‌های IoT یک راه حل بالقوه جالب است که جمع آوری داده‌های آموزشی در این زمینه کار ساده‌ای نیست. بعنوان مثال، با توجه به آموزش یک سیستم بومی‌سازی از طریق اثر انگشت BLE یا WiFi با استفاده از تلفن‌های هوشمند، مقادیر RSSI در همان زمان و مکان برای سیستم عامل‌های مختلف (به عنوان مثال، iOS و Android) متفاوت است. اگر یک مدل آموزش‌دیده برای یک پلتفرم خاص داشته باشیم، این مدل میتواند بدون جمع‌آوری مجدد مجموعه‌ای دیگر از داده‌های آموزشی برای پلتفرم جدید به سکوی دیگر منتقل شود.

مدل‌های DL به دلیل توانایی یادگیری بازنمایی‌های سطح پایین و انتزاعی از داده‌های ورودی، بخوبی در انتقال یادگیری همسان هستند. به طور خاص، نشان داده شده است که رفع اختلالات انباشته شده و سایر تغییرات AE در این زمینه عملکرد بسیار خوبی دارند. انتقال یادگیری با DNN هنوز یک زمینه تحقیقاتی در حال انجام و فعال در جامعه هوش مصنوعی است و ما برنامه‌های گزارش شده در دنیای واقعی را در IoT ندیده ایم.


3) الگوریتم‌های یادگیری آنلاین با DL مشترک:

از آنجا که جریان داده‌های حاصل از برنامه‌های IoT برای تجزیه و تحلیل از سیستم عامل‌های ابری عبور میکند، نقش الگوریتم‌های یادگیری ماشین آنلاین برجسته تر میشود، زیرا نیاز است تا مدل آموزش توسط حجم افزایشی داده‌ها به‌روز شود. این امر برخلاف آنچه که فناوریهای فعلی پشتیبانی میکند، مبتنی بر تکنیک‌های یادگیری دسته‌ای است، جایی که کل مجموعه داده‌های آموزشی باید برای آموزش در دسترس باشد و پس از آن، مدل آموزش‌دیده نمیتواند با داده‌های جدید تکامل یابد. چندین اثر تحقیق از تکنیک‌های یادگیری آنلاین در مدل‌های مختلف DL گزارش میدهند؛ از جمله AE‌های رفع اختلال انباشته شده، شبکه‌های جمع محصول و RBM.

د) چارچوب

رشد سریع علاقه به استفاده از معماریهای DL در حوزه‌های مختلف با معرفی چندین چارچوب DL در سالهای اخیر پشتیبانی شده است. هر چارچوب براساس معماریهای پشتیبانی شده DL، الگوریتمهای بهینه‌سازی و سهولت توسعه و استقرار قدرت خود را دارد. چندین مورد از این چارچوبها برای آموزش کارآمد DNNها در تحقیقات گسترده استفاده شده است. در این بخش برخی از این چارچوبها را مرور میکنیم.

H2O: یک چارچوب یادگیری ماشینی است که رابطی را برای R، Python، Scala، Java، JSON و CoffeeScript / JavaScript فراهم میکند. H2O را میتوان در حالتی مختلف از جمله حالت مستقل، در Hadoop یا در Spark Cluster اجرا کرد. علاوه بر الگوریتمهای یادگیری رایج ماشین، H2O شامل اجرای یک الگوریتم DL است که براساس شبکه‌های عصبی تغذیه پیشرو برنامه ریزی شده است و آنرا میتوان توسط SGD با استفاده از روش انتشار بازگشتی آموزش داد. DL H2O بر پایه معماری عصبی عمیق (چند لایه) است، که در آن بجای اینکه تجمع لایه به لایه اطلاعات را داشته باشیم، کل شبکه داده‌ها را همزمان میگیرند.



شکل 16. یادگیری تقویت عمیق (تحت نظارت و نیمه نظارت شده): بدست آوردن پاداش (سمت چپ) و اندازه گیری دقت مربوط به آنها (سمت راست).

Tensorflow: در ابتدا برای پروژه Google Brain ایجاد شد، Tensorflow یک کتابخانه منابع باز برای سیستمهای یادگیری ماشینی با استفاده از انواع مختلف DNN است. این محصول توسط بسیاری از محصولات Google از جمله Google Search، Google Maps، Street View و Google Translate، YouTube و برخی محصولات دیگر استفاده میشود. Tensorflow از ساخت نمودارها

برای ایجاد مدل‌های شبکه عصبی استفاده میکند. توسعه دهندگان همچنین میتوانند از TensorBoard که بسته‌ای برای تجسم مدل‌های شبکه عصبی و مشاهده روند یادگیری از جمله به روز کردن پارامترها است، استفاده کنند. Keras2 همچنین سطح بالایی از انتزاع برنامه‌نویسی را برای Tensorflow فراهم میکند.

Torch: Torch یک چارچوب منابع باز برای یادگیری ماشینی است که شامل طیف گسترده‌ای از الگوریتم‌های DL برای توسعه آسان مدل‌های DNN میشود. این زبان با برنامه‌نویسی Lua ساخته شده است تا برای آموزش الگوریتم‌های DL سبک و سریع باشد. این توسط چندین شرکت و آزمایشگاه تحقیقاتی مانند گوگل، فیسبوک و توئیتر استفاده میشود؛ همچنین از توسعه مدل‌های یادگیری ماشینی برای هر دو CPU و GPU پشتیبانی کرده و بسته‌های موازی سازی قدرتمندی را برای آموزش DNNها فراهم میکند.

Theano: یک چارچوب مبتنی بر پایتون منبع باز برای الگوریتم‌های یادگیری کارآمد ماشینی است که از کامپایل برای CPU و GPU پشتیبانی میکند. از کتابخانه CUDA در بهینه‌سازی کدهای پیچیده مورد نیاز برای اجرای GPU ها استفاده میشود؛ همچنین این امکان را به شما میدهد تا در پردازنده‌ها موازی سازی کنید. Theano از نمایش نمودار برای عبارات ریاضی نمادین استفاده میکند. از طریق این بازنمایی، از تمایز نیز در عبارات ریاضی Theano پشتیبانی میشود. چندین بسته بندی از جمله Pylearn2، Keras و Lasagne تجربه برنامه‌نویسی آسان تری را روی Theano ارائه داده‌اند.

Caffe: یک چارچوب منبع باز برای الگوریتم‌های DL و مجموعه‌ای از مدل‌های مرجع بوده و مبتنی بر C++ است، از CUDA برای محاسبات GPU پشتیبانی کرده و رابط‌هایی را برای Python و Matlab فراهم میکند. Caffe نمایندگی مدل را از بخش‌های اجرایی آن جدا میکند. این امر با تعیین مدلها توسط پیکربندی‌ها بدون کدگذاری آنها در کد منبع امکان پذیر است. جابجایی بین پلتفرمها (بعنوان مثال، CPU به GPU یا دستگاه‌های تلفن همراه) بسیار ساده و فقط با تغییر یک پرچم امکان‌پذیر است. سرعت آن در GPU اینگونه گزارش شده است: 1 ms / در تصاویر برای پیش بینی و 4 ms / در تصاویر برای آموزش.

Neon: چهارچوب DL منبع باز دیگریست که مبتنی بر پایتون بوده و از عملکرد بالایی برای DNNهای مدرن مانند AlexNet، گروه ویژوال هندسی (VGG²⁰) و GoogleNet برخوردار است. این برنامه از توسعه چندین مدل متداول مانند CNN، RNN، LSTM و AE در هر دو CPU و GPU پشتیبانی میکند. این لیست در حال گسترش است زیرا آنها GANها را برای یادگیری نیمه نظارت شده با استفاده از مدل‌های DL پیاده سازی میکنند. همچنین از تغییر آسان سکوی سخت افزاری نیز پشتیبانی میکند.

بهرامپور و همکارانش مطالعه‌ای مقایسه‌ای را برای چهار ابزار فوق الذکر یعنی Neon، Caffe، Theano و Torch ارائه داده‌اند. اگرچه عملکرد هر ابزار در سناریوهای مختلف متفاوت است، اما Theano و Torch بهترین عملکرد را در اکثر سناریوها نشان دادند. یکی دیگر از معیارهای دیگر در مقایسه عملکردها، عملکرد Caffe، TensorFlow، Torch، CNTK و MXNet است. جدول II چارچوب‌های مختلف DL را خلاصه و مقایسه میکند.

Frameworks	Core Language	Interface	Pros	Cons	Used in IoT Application
H2O	Java	R, Python, Scala, REST API	<ul style="list-style-type: none"> Wide range of interfaces 	<ul style="list-style-type: none"> Limited number of models are supported Is not flexible 	[77]
Tensorflow	C++	Python, Java, C, C++, Go	<ul style="list-style-type: none"> Fast on LSTM training Support to visualize networks 	<ul style="list-style-type: none"> Slower training compared to other Python-based frameworks 	[78]
Theano	Python	Python	<ul style="list-style-type: none"> Supports various models Fast on LSTM training on GPU 	<ul style="list-style-type: none"> Many low level APIs 	[79]
Torch	Lua	C, C++	<ul style="list-style-type: none"> Supports various models Good documentation Helpful error debugging messages 	<ul style="list-style-type: none"> Learning a new language 	[78] [80]
Caffe	C++	Python, Matlab	<ul style="list-style-type: none"> Provides a collection of reference models Easy platform switching Very good at convolutional networks 	<ul style="list-style-type: none"> Not very good for recurrent networks 	[81]–[83]
Neon	Python	Python	<ul style="list-style-type: none"> Fast training time Easy platform switching Supports modern architectures like GAN 	<ul style="list-style-type: none"> Not supporting CPU multi-threading 	[84]
Chainer [85]	Python	Python	<ul style="list-style-type: none"> Supports modern architectures Easier to implement complex architectures Dynamic change of model 	<ul style="list-style-type: none"> Slower forward computation in some scenarios 	[86]
Deeplearning4j	Java	Python, Scala, Clojure	<ul style="list-style-type: none"> Distributed training Imports models from major frameworks (e.g., TensorFlow, Caffe, Torch and Theano) Visualization tools 	<ul style="list-style-type: none"> Longer training time compared to other tools 	[87], [88]

جدول II. ویژگی‌های چارچوب‌های توسعه یادگیری عمیق (از سپتامبر 2017)

²⁰ Visual Geometry Group

ه) درسهای آموخته شده

در این بخش، ما چندین معماری معمول DL را مرور کردیم که میتوانند در مؤلفه تحلیلی برنامه‌های مختلف IoT خدمت کنند. بیشتر این معماریها با انواع مختلف داده‌های ورودی تولید شده توسط برنامه‌های IoT کار میکنند. با این حال، برای بدست آوردن عملکرد بهتر از داده‌های سریالی زمانی، RNNها و تغییرات آنها توصیه میشوند. بطور خاص، برای وابستگیهای طولانی‌مدت بین نقاط داده، LSTM دلیل داشتن مفهوم دروازه برای سلولهای حافظه مطلوبتر است. برای مواردی که داده‌های ورودی دارای بیش از یک بعد باشند، تغییرات CNN بهتر عمل میکنند. DBN، RBM، و تنوع AE در مقابله با کاهش ابعاد بالا و استخراج ویژگی سلسله مراتبی عملکرد خوبی دارند. در ترکیب با یک لایه طبقه‌بندی، میتوان از آنها برای انواع سناریوهای تشخیص و پیش‌بینی استفاده کرد. انتظار میرود معماریهای جدیدتری از جمله VAE، GAN و Ladder Networks تأثیر زیادی روی برنامه‌های IoT داشته باشند زیرا یادگیری نیمه نظارت شده را تحت پوشش قرار میدهند. این موارد برای برنامه‌های IoT در جایی که حجم عظیمی از داده‌ها تولید میشوند، در حالی که بخش کوچکی از آن برای یادگیری ماشین قابل یادداشت است، مطلوب تر هستند. جدول ۱ معماری DL را خلاصه میکند.

چند تلاش برای سریعتر کردن و سریع پاسخ دادن به معماری DL نیز مورد بحث قرار گرفت. این عرصه به اکتشافات و تحقیقات بیشتری نیاز دارد تا در بسیاری از برنامه‌های IoT حساس به زمان قابل اجرا باشد. معماریها و تکنیکهای یادگیری ماشینهای در حال ظهور که هر دو از DL بهره‌مند میشوند و الزامات خاص برنامه IoT را برطرف میکنند نیز برجسته شده‌اند. در واقع، DRL میتواند از استقلال برنامه‌های IoT پشتیبانی کند، یادگیری انتقال میتواند شکاف عدم وجود مجموعه داده‌های آموزشی را پر کند، و یادگیری آنلاین با نیاز به تجزیه و تحلیل داده‌های استریم IoT مطابقت دارد.

ما همچنین چندین چارچوب معمول و قدرتمند را برای توسعه مدل‌های DL بررسی کردیم. برای برنامه‌های IoT، زمان آموزش، زمان اجرا و بروزرسانی پویای مدل‌های آموزش دیده عوامل تعیین‌کننده یک ماژول تحلیلی مطمئن و کارآمد را تشکیل میدهند. بیشتر چارچوبهای فعلی بجای "تعریف اجرا" از الگوی "تعریف و اجرا" پیروی میکنند. اولی اجازه بروزرسانی پویا از مدل را نمیدهد در حالی که دومی از چنین اصلاحاتی پشتیبانی میکند. زنجیر، چارچوبی است که از الگوی دوم پیروی میکند و می‌تواند تغییرات پویای مدل را کنترل کند.

چهارم؛ برنامه DL در IOT

روشهای DL باوجود نتایج آزمایشی در چندین زمینه مانند پردازش سیگنال، پردازش زبان طبیعی و تشخیص تصویر امیدوارکننده است. این روند در IOT های عمودی روبه افزایش است. برخی از مدل‌های شبکه عصبی در حوزه‌های خاص بهتر عمل میکنند. بعنوان مثال، شبکه‌های کانوشنال عملکرد بهتری را در برنامه‌های مربوط به بینایی ارائه میدهند، در حالی که AE ها با تشخیص ناهنجاری، دفع داده‌ها و کاهش ابعادی برای تجسم داده‌ها عملکرد بهتری دارند. این ارتباط بین نوع و مدل شبکه‌های عصبی که به بهترین وجه متناسب با هر یک از حوزه‌های مختلف برنامه هستند، بسیار مهم است.

در این بخش، برنامه‌های موفق DL را در حوزه‌های IOT مرور میکنیم. براساس مشاهدات ما، بسیاری از برنامه‌های مرتبط با IOT بعنوان سرویس هوشمند پایه خود از طبقه بندی بینایی و تصویر استفاده میکنند (مانند تشخیص علائم راهنمایی و رانندگی یا تشخیص بیماری‌های گیاهی که در بخش IV-B در مورد آنها صحبت خواهیم کرد). خدمات دیگری نیز وجود دارد، مانند تشخیص انسان که برای برنامه‌های خانه هوشمند یا دستیار ماشین هوشمند استفاده میشوند. ما انواع مختلفی از این سرویسها را بعنوان خدمات اساسی که بر روی آنها دیگر برنامه‌های IOT ساخته شده است، شناسایی میکنیم. ویژگی مشترک این سرویسها این است که بجای اینکه داده‌های خود را برای تجزیه و تحلیل‌های بعدی جمع کرده باشند، باید مانند یک حالت تحلیلی سریع رفتار کنند. در واقع، هر دامنه ممکن است سرویسهای خاص و فراتر از این خدمات اساسی داشته باشد. شکل 17 خدمات اساسی و برنامه‌های IOT را روی آنها نشان میدهد. در بخشهای زیر، ما ابتدا خدمات بنیادی IOT را بررسی میکنیم که از DL بعنوان موتور اطلاعاتی خود استفاده میکنند، سپس برنامه‌ها و دامنه‌های IOT را برجسته میکنیم که در آنها ترکیبی از خدمات بنیادی و همچنین خدمات خاص ممکن است مورد استفاده قرار گیرند.

الف) خدمات بنیادی

1) تشخیص تصویر:

بخش بزرگی از برنامه‌های IOT، سناریوهایی را نشان میدهند که داده‌های ورودی برای DL به صورت فیلم یا تصاویر است. دستگاه‌های تلفن همراه همکاره و مجهز به دوربینهای با وضوح بالا، تولید تصاویر و فیلمها را توسط هم، در همه جا تسهیل میکنند. علاوه بر این، دوربینهای فیلمبرداری هوشمند

در بسیاری از مکانها مانند خانه‌های هوشمند، دانشگاه‌ها و تولیدی‌ها برای برنامه‌های مختلف استفاده میشوند. تشخیص یا طبقه‌بندی تصاویر و اشیا، از جمله کاربردهای اساسی چنین دستگاه‌هاییست.

مسئله‌ای که در مورد سیستمهای مرتبط با IoT که به شناخت تصاویر پرداخته، استفاده از مجموعه داده‌های منابع خاص برای ارزیابی عملکرد آنهاست. بیشتر این سیستمها از مجموعه داده‌های موجود در تصاویر مشترک مانند مجموعه داده‌های MNIST همچون دست نوشته‌ها، مجموعه داده‌های چهره VGG، CIFAR-10 و CIFAR-100، مجموعه داده‌های کوچک تصاویر و... استفاده میکنند. اگرچه برای مقایسه با رویکردهای دیگر خوب است، اما این مجموعه داده‌ها ویژگیهای خاصی از سیستمهای IoT را نشان نمیدهند. بعنوان مثال، ورودی برای کار تشخیص خودرو در اتومبیلهای متصل هوشمند همیشه یک تصویر واضح خواهد بود، زیرا مواردی وجود دارد که تصویر ورودی در شب یا در هوای بارانی یا مه آلود باشد. این موارد از طریق مجموعه داده‌های موجود رسیدگی نمیشود و از اینرو مدلهایی که بر اساس این مجموعه داده‌ها آموزش دیده‌اند به اندازه کافی جامع نیستند.

(2) تشخیص گفتار / صدا:

با گسترش دستگاه‌های تلفن همراه هوشمند و پوشیدنی، تشخیص خودکار گفتار به روشی طبیعی و راحت‌تر برای تعامل مردم با دستگاه‌های خود تبدیل میشود. همچنین اندازه کوچک دستگاه‌های تلفن همراه و پوشیدنی‌ها، امروزه احتمال داشتن صفحه نمایش لمسی و صفحه کلید را بعنوان وسیله ورودی و تعامل با این دستگاه‌ها کاهش میدهد. با اینحال، نگرانی اصلی برای ارائه قابلیت تشخیص گفتار/ صدا در دستگاه‌های دارای محدودیت منابع، شدت انرژی آن است، به ویژه هنگامی که داده‌ها از طریق شبکه‌های عصبی پردازش میشوند. در یک مدل شبکه عصبی به رسمیت شناختن گفتار، داده‌های صوتی بعنوان ورودی خام به شبکه نمایش داده میشوند. داده‌ها از طریق لایه‌های پنهان پردازش می‌شوند و احتمال تبدیل داده‌های صوتی به صدای گفتار خاص در لایه خروجی ارائه میشود.

پرایس و همکاران گزارش داده‌اند که برای تشخیص خودکار گفتار، یک تراشه DL کم مصرف ویژه برای هدف قرار داده‌اند. تراشه تخصصی جدید انرژی کمی بین 0.2 تا 10 میلی وات، یعنی 100 برابر کمتر از مصرف انرژی برای اجرای ابزار تشخیص گفتار در تلفنهای همراه فعلی را مصرف میکند. در تراشه جدید، DNN برای تشخیص گفتار اجرا شده است. بمنظور صرفه جویی در مصرف انرژی، سه سطح تشخیص فعالیت صوتی با سه شبکه عصبی جداگانه طراحی شده است که هر کدام دارای سطح پیچیدگی متفاوتی هستند. کمترین پیچیدگی شبکه، در نتیجه کمترین میزان انرژی با کنترل نویز در

محیط، فعالیت صوتی را تشخیص میدهد. اگر این شبکه صدا را شناسایی کند، تراشه شبکه تشخیص سطح پیچیدگی بعدی را اجرا میکند که وظیفه آن مدل سازی صوتیست تا تشخیص دهد که صدا مانند گفتار است. اگر خروجی این شبکه از میزان رضایتبخشی بالایی برخوردار باشد، پس از شناسایی شبکه‌های سوم، با داشتن بیشترین میزان مصرف انرژی برای شناسایی کلمات مجزا راه اندازی میشود.

3) بومی سازی داخلی:

ارائه خدمات آگاهی از موقعیت مکانی، از جمله ناوبری داخلی و بازاریابی آگاهی از مکان نمایندگیها، در محیطهای داخلی رواج دارد. بومی سازی داخلی ممکن است برنامه‌هایی در سایر بخش های IoT، مانند خانه‌های هوشمند، خوابگاه‌های هوشمند یا بیمارستانها داشته باشد. داده‌های ورودی حاصل، از چنین برنامه‌هایی مانند دید، ارتباط قابل مشاهده با نور (VLC)، مادون قرمز، سونوگرافی، WiFi، RFID، باند ultrawide و بلوتوث حاصل میشوند. برای رویکردهای مبتنی بر WiFi یا بلوتوث، بیشتر ادبیات از تلفنهای همراه برای دریافت سیگنال از فرستنده ثابت (یعنی نقاط دسترسی یا iBeacons) استفاده کرده‌اند که به آنها اثر انگشت میگویند. در میان این رویکردهای اثر انگشت، چندین تلاش از استفاده از مدل‌های DL برای پیش‌بینی مکان خبر داد.

از DL باموفقیت برای یافتن موقعیتهای داخلی با دقت بالا استفاده شده است. در سیستمی بنام DeepFi از یک روش DL برای انگشتنگاری از داده‌های اطلاعات کانال WiFi در راستای شناسایی موقعیتهای کاربر استفاده شده است. این سیستم شامل آموزش آفلاین و مراحل بومی‌سازی آنلاین است اما در مرحله آموزش آفلاین، DL برای آموزش کلیه وزنها بر اساس اثر اطلاعات اثر انگشت کانال قبلاً ذخیره شده، مورد سوء استفاده قرار میگیرد. این آزمایشات ادعا می کنند که تعداد لایه‌ها و واحدهای پنهان در مدل‌های DL تأثیر مستقیمی بر صحت بومی‌سازی دارد. در CNN برای بومی‌سازی داخلی از تلفیق داده‌های سنجش مغناطیسی و بینایی استفاده میشود. علاوه بر این، یک CNN برای تعیین موقعیتهای داخلی کاربران با تجزیه و تحلیل تصویری از صحنه اطراف آنها آموزش دیده است.

لو و همکاران همچنین از شبکه‌های LSTM برای بومی‌سازی رباتهای فوتبال استفاده کرده‌اند. در این نرم افزار، داده‌های جمع‌آوری شده از چندین حسگر یعنی سیستم ناوبری اینرسی (INS²¹) و برداشت بینایی، برای پیش‌بینی موقعیت ربات تجزیه و تحلیل میشوند. نویسندگان گزارش داده‌اند که دقت و

²¹ Inertia Navigation System

کارایی در مقایسه با دو روش پایه، یعنی استاندارد فیلتر کالمن تمديد شده استاندارد (EKF²²) و فیلتر ذرات استاتیک بهبود یافته است.

4) تشخیص وضعیت فیزیولوژیکی و روانی²³:

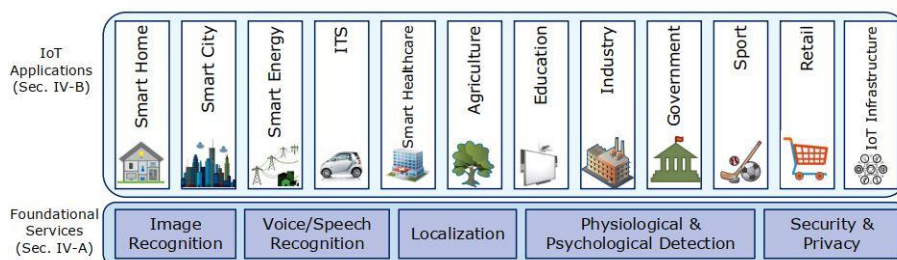
IoT همراه با تکنیکهای DL نیز برای تشخیص حالات مختلف فیزیولوژیکی و روانشناختی انسان، از جمله ناهنجاری، فعالیت و احساسات بکار گرفته شده است. بسیاری از برنامه‌های IoT برای ارائه خدمات خود، بعنوان مثال خانه‌های هوشمند، اتومبیل‌های هوشمند، سرگرمی (مثلا Xbox)، آموزش، توانبخشی و پشتیبانی بهداشتی، ورزشی و صنعتی، مازولی را برای تخمین موقعیتهای های بشری یا شناخت فعالیتهای داده‌اند. بعنوان مثال، برنامه‌های مناسب در خانه‌های هوشمند بر اساس تجزیه و تحلیل موقعیتهای سرنشینان ساخته شده است. دوربینها، فیلمهای سرنشین را به یک DNN منتقل میکنند تا وضعیت شخص را پیدا کرده و بر این اساس مناسب ترین اقدام را انجام دهند. توشف و همکارانش برای دستیابی به این هدف از سیستمی بهره میگیرند که از یک مدل CNN استفاده میکند. این نوع خدمات همچنین میتواند در آموزش و پرورش برای نظارت بر توجه دانشجویان و در فروشگاه‌های خرده فروشی برای پیش بینی رفتار خرید مشتریان استفاده شود.

اوردنوز و همکارانش چارچوب DL را ارائه داده‌اند که ترکیبی از قدرت شبکه‌های عصبی CNN و LSTM برای تشخیص فعالیت انسانی از داده‌های حسگر پوشیدنی (شتاب سنج، ژيروسکوپ و...) است. مدل آنها از چهار لایه حلقوی با ReLUها تشکیل شده است و به دنبال آن دو لایه LSTM و یک لایه نرم افزاری وجود دارد. آنها نشان دادند که این ترکیب از یک مدل مبنا که فقط بر اساس لایه‌های کانوشن به طور متوسط 4 درصد است، بهتر عمل میکند. تائو و همکارانش همچنین از معماری LSTM برای شناسایی فعالیتهای انسانی بر اساس داده‌های حسگر تلفن همراه استفاده کرده‌اند. لی و همکارانش همچنین استفاده از داده‌های خام برجسب‌های منفعل FRID را برای تشخیص فعالیتهای پزشکی در اتاق تروما (بعنوان مثال، اندازه گیری فشار خون، معاینه دهان، قرار دادن سرب قلبی و...) بر اساس CNN عمیق گزارش میدهند.

²² Extended Kalman Filtering

²³ Physiological and Psychological State Detection

یک مدل ترکیبی از CNN و RNN برای تشخیص ژست در قابهای ویدیویی پیشنهاد شد. این مدل در مقایسه با مدل‌های بدون چنین ترکیبی نتایج بهتری را نشان داد و اهمیت مؤثر خود را در چنین کارهایی تأیید کرد. فراجیاداکای و همکاران یک مدل DNN به نام رمزگذار-عودکننده-رمزشکن (ERD²⁴) را برای تشخیص بدن و پیش‌بینی حرکت در فیلمها و مجموعه داده‌های ضبط حرکت ارائه دادند. مدل پیشنهادی شامل RNN با رمزگذار قبل از لایه‌های مکرر و یک رمزشکن پس از آنها بود. این معماری نشان داده است که از ماشین‌آلات بولتزمن محدود شده شرطی (CRBMs) برای این برنامه بهتر است. فراتر از حرکات بدنی، برآورد احساسات انسان از قابهای ویدیویی نیز در استفاده از مدلی که شامل CNN، DBN و AE است، مورد بررسی قرار گرفته است. علاوه بر این، کار در داده‌های حسگر بی‌حرکت تلفن همراه برای تشخیص حرکت است. این تأیید کرد که الگوهای حرکت انسان میتواند بعنوان منبع شناسایی و احراز هویت کاربر استفاده شود. مدل به کار رفته در این سیستم ترکیبی از لایه‌های حلقوی و ساعت RNN است.



شکل 17. برنامه های IoT و خدمات بنیادی.

5) امنیت و حریم خصوصی:

امنیت و حفظ حریم خصوصی یک نگرانی عمده در همه حوزه‌ها و برنامه‌های IoT است. خانه‌های هوشمند، ITS، صنعت، شبکه هوشمند و بسیاری از بخشهای دیگر امنیت را یک نیاز اساسی میدانند. در واقع، اعتبار عملکرد سیستمها بستگی به محافظت از ابزارها و فرآیندهای یادگیری ماشین آنها از مهاجمان دارد.

²⁴ Encoder-Recurrent-Decoder

تزریق داده نادرست (FDI²⁵) نوعی حمله به سیستم‌های داده محور است. هی و همکاران DBN شرطی را برای استخراج ویژگی‌های حمله FDI از داده‌های پیشین شبکه‌های هوشمند پیشنهاد کرده و از این ویژگی‌ها برای شناسایی حمله در زمان واقعی استفاده کردند. اینکار همچنین مربوط به تشخیص ناهنجاری است که ممکن است در شبکه‌های خودرو رخ دهد.

تلفن‌های هوشمند بعنوان کمک بزرگی به داده‌ها و برنامه‌های IoT نیز در معرض تهدیدات جدی حملات هکرها قرار دارند. فراتر از دغدغه‌های کاربران، محافظت از این دستگاه‌ها در برابر انواع مختلف امنیت برای چشم‌انداز IoT ضروری است. یوان و همکاران چارچوب DL را برای شناسایی بدافزارها در برنامه‌های Android پیشنهاد دادند. معماری آنها مبتنی بر DBN است که با استفاده از آن، دقت 96.5 درصد را برای شناسایی برنامه‌های مخرب گزارش داده‌اند.

حفظ امنیت و حریم خصوصی رویکردهای یادگیری عمیق ماشین، مهمترین عوامل برای پذیرش استفاده از این روشها در بخش IoT است. وقتی آنها مشمول یادگیری توزیع شده بودند، شگری و همکاران روشهایی را برای حل مسائل مربوط به حفظ حریم خصوصی در مدل‌های DL پیشنهاد میکنند. رویکرد آنها قادر به حفظ حریم خصوصی داده‌های آموزشی شرکت کنندگان و همچنین صحت مدلها در یک زمان بود. هسته اصلی رویکرد آنها مبتنی بر این واقعیت است که الگوریتمهای بهینه سازی شیب نزولی تصادفی که در بسیاری از معماریهای DL مورد استفاده قرار میگیرند، میتواند بصورت موازی اما ناهمزمان انجام شود. بنابراین شرکت کنندگان میتوانند بطور مستقل مدل را بر روی داده‌های خود آموزش دهند و بخشی از پارامترهای مدل خود را با سایر شرکت کنندگان به اشتراک بگذارند. آبادی و همکاران نیز با استفاده از الگوریتم نزول شیب تصادفی خصوصی، روشی را برای تضمین حریم خصوصی پیشنهاد کردند.

²⁵ False Data Injection

ب) برنامه‌ها

1) خانه‌های هوشمند

مفهوم خانه‌های هوشمند طیف گسترده‌ای از برنامه‌های مبتنی بر IoT را شامل می‌شود که می‌تواند در کاهش مصرف انرژی و بهره‌وری خانه‌ها و همچنین راحتی و کیفیت زندگی ساکنین آنها نقش زیادی داشته باشد. امروزه لوازم خانگی می‌توانند به اینترنت وصل شوند و خدمات هوشمندی ارائه دهند. بعنوان مثال، مایکروسافت و لیبره‌ردو در یک پروژه مشترک، از Cortana DL برای اطلاعات جمع‌آوری شده از داخل یخچال استفاده می‌کنند. این تجزیه و تحلیل‌ها و پیش‌بینی‌ها می‌تواند به خانواده کمک کند تا کنترل بهتری در مورد منابع و هزینه‌های خانه خود داشته باشند و در کنار سایر داده‌های خارجی می‌توانند برای نظارت و پیش‌بینی روندهای بهداشتی مورد استفاده قرار گیرند.

بیش از یک سوم برق تولید شده در ایالات متحده توسط بخش مسکونی مصرف می‌شود و تجهیزات HVAC و دستگاه‌های روشنایی بزرگترین منبع مصرف انرژی در میان این نوع ساختمان‌ها هستند. انتظار می‌رود با مدیریت هوشمندانه انرژی و همچنین بهبود بازده در وسایل، این تقاضا با سرعت کمتری رشد کند. از اینرو، توانایی کنترل و بهبود بهره‌وری انرژی و پیش‌بینی نیاز آینده در سیستم‌های خانگی هوشمند ضروری است. در برنامه‌های کاربردی خانه هوشمند، پیش‌بینی بار الکتریکی جزو رایجترین برنامه‌هایی است که از شبکه‌های مختلف DL برای مشخص کردن وظایف استفاده می‌کند. مانیک و همکاران با استفاده از سه معماری DL از جمله LSTM، توالی‌مند (S2S²⁶) و CNN، یک تجزیه و تحلیل مقایسه‌ای از پیش‌بینی بار برای مصرف انرژی در خانه انجام دادند. نتایج آنها نشان می‌دهد که LSTM S2S استفاده از آینده را بهتر از سایر معماری‌ها، به دنبال آن CNN و سپس LSTM پیش‌بینی می‌کند. آنها همچنین مجموعه داده مشابه را با یک ANN معمولی مقایسه کردند و همه مدل‌های فوق از مدل ANN بهتر عمل کرد.

2) شهر هوشمند:

خدمات شهری هوشمند در چندین حوزه IoT مانند حمل و نقل، انرژی، کشاورزی و... گسترش یافته است. با اینحال، این بخش از دیدگاه یادگیری ماشین جالب تر است زیرا داده‌های ناهمگن حاصل از حوزه‌های مختلف منجر به تولید داده‌های بزرگ می‌شوند که می‌تواند به خروجی با کیفیت بالا هنگام تجزیه و تحلیل با استفاده از مدل‌های DL ختم شود. شهر هوشمند از پیشرفت در حوزه‌های دیگر برای

²⁶ Sequence to Sequence

دستیابی به مدیریت منابع کارآمد برای کل شهر بهره میبرد. بعنوان مثال، برای بهبود زیرساختهای حمل و نقل عمومی و ارائه خدمات پیشرفته جدید، اخذ تحلیل و الگوها از رفتارهای حمل و نقل عمومی مورد توجه مقامات محلیست.

توشیا اخیراً یک باند تست DL را به طور مشترک با Dell Technologies ایجاد کرده است و از این مجموعه تست در یک مجتمع هوشمند در کاوازاکی، ژاپن، برای ارزیابی داده‌های جمع آوری شده در این مرکز استفاده کرده است. هدف از اجرای این آزمایش، اندازه گیری اثربخشی استفاده از معماریهای DL در اکوسیستمهای IoT و شناسایی بهترین روشها برای بهبود خدمات از جمله افزایش در دسترس بودن دستگاهها، بهینه‌سازی سنسورهای مانیتورینگ و کاهش هزینه‌های نگهداری است. داده‌های بزرگی که آزمایشگاه را تغذیه میکند، از مدیریت ساختمان، تهویه هوا و امنیت ساختمانها جمع آوری شده است.

یک مسئله مهم برای شهر هوشمند، پیش‌بینی الگوهای حرکت جمعیت و استفاده از آنها در حمل و نقل عمومی است. سانگ و همکاران برای دستیابی به این هدف در سطح شهر، سیستمی مبتنی بر مدل‌های DNN تهیه کردند. سیستم آنها بر روی یک شبکه عصبی LSTM چهار لایه ساخته شده است تا از داده‌های تحرک انسان (داده GPS) با حالت‌های انتقال حمل و نقل آنها (به عنوان مثال، ماندن، پیاده‌روی، دوچرخه، ماشین، قطار) یاد بگیرند.

Service	Reference	Input data	DL model
Crowd density/ transportation prediction	[116]	GPS/ transition mode	LSTM
	[117]	Telecommunication data/CDR	RNN
Waste management	[81]	Garbage images	CNN
Parking lot management	[119], [120]	Images of parking spaces	CNN

جدول 3. خدمات مبتنی بر IOT TYPical در شهر هوشمند

آنها بجای پرداختن به همه این ویژگیها، با پیش‌بینی وضعیت تحرک و حمل و نقل افراد بعنوان دو کار جداگانه رفتار کردند. در نتیجه، سیستم یادگیری آنها براساس معماری LSTM عمیق چند کاره ساخته شده است که بطور مشترک میتوانند از دو مجموعه، ویژگیها را یاد بگیرند. انتخاب LSTM توسط ماهیت مکانی و الگوهای تحرک انسانی انجام و هدایت میشود. نویسندگان ادعا میکنند که رویکرد آنها

بر اساس LSTM عمیق چند کاره در مقایسه با هر دو LSTM کم عمق که تنها یک لایه واحد دارند و همچنین LSTM های عمیق و بدون سیستم چندکاره، عملکرد بهتری دارند.

لیانگ و همکاران یک سیستم پیش بینی تراکم جمعیت را در زمان واقعی و در ایستگاه های حمل و نقل ارائه داده اند که از داده های ارتباطی کاربران تلفن همراه به عنوان سابقه جزئیات تماس گیرنده (CDR) استفاده میکند. داده های CDR هنگامی جمع میشوند که کاربر اقدام به ارتباط از راه دور (یعنی تماس، پیام کوتاه، MMS و دسترسی به اینترنت) از طریق تلفن خود انجام دهد، که معمولاً شامل اطلاعات مربوط به شناسه کاربر، زمان، مکان و عملکرد ارتباطات کاربر است. آنها سیستم خود را بر اساس یک مدل RNN برای ایستگاه های مترو ساخته و پیش بینی های دقیقتری را در مقایسه با مدل های شبکه عصبی اتورگرسیوی غیرخطی گزارش دادند.

مدیریت پسماند و طبقه بندی زباله ها یکی دیگر از کارهای مرتبط با شهرهای هوشمند است. یک روش ساده برای انجام این اتوماسیون از طریق طبقه بندی مبتنی بر بینایی با استفاده از CNN های عمیق انجام میگردد. نظارت بر کیفیت هوا و پیش بینی آلودگی، جنبه دیگری از مدیریت شهر است. لی و همکاران یک مدل پیش بینی کیفیت هوا مبتنی بر DL با استفاده از یک AE انباشته شده برای استخراج ویژگی های بدون نظارت، و یک مدل رگرسیون لجستیکی برای رگرسیون پیش بینی های نهایی ایجاد کردند.

آماتو و همکاران، یک سیستم غیر متمرکز برای شناسایی نقاط اشغالی و خالی در پارکینگها با استفاده از دوربینهای هوشمند و CNN های عمیق طراحی کرده و توسعه دادند. نویسندگان، یک معماری کوچک از یک CNN را روی دوربینهای هوشمند مستقر کرده اند که مجهز به مدل Raspberry Pi 2 است. این دستگاه های تعبیه شده در دوربینهای هوشمند میتوانند CNN را بر روی هر دستگاهی اجرا کنند تا تصاویر فضاهای پارکینگ شخصی را بصورت اشغال یا خالی طبقه بندی کنند. سپس دوربینها فقط خروجی طبقه بندی را به سرور مرکزی ارسال میکنند. ولی پور و همکاران همچنین سیستمی را برای شناسایی نقاط مختلف پارکینگ با استفاده از CNN ایجاد کردند که در مقایسه با SVM نتایج بهتری را نشان داده است. جدول 3 تلاشهای فوق را خلاصه میکند.

3) انرژی:

ارتباط دوطرفه بین مصرف‌کنندگان انرژی و شبکه هوشمند، منبعی برای داده‌های بزرگ IoT است. در این زمینه، کنتورهای هوشمند در نقش تولید داده و دستیابی به سطح دانه ریز، مصرف انرژی را اندازه‌گیری میکنند. ارائه‌دهندگان انرژی علاقمندند که الگوهای مصرف انرژی محلی را یاد گرفته، نیازها را پیش‌بینی کنند و تصمیمات مناسبی را براساس تجزیه و تحلیل در زمان واقعی بگیرند. موکائو و همکارانش نوعی RBM برای شناسایی و پیش‌بینی انعطاف‌پذیری انرژی ساختمانها در زمان واقعی ایجاد کرده‌اند. انعطاف‌پذیری انرژی در مورد تغییر در مصرف برق یک خانواده و درعین حال به حداقل رساندن تاثیر بر ساکنین و کارهاست. در کار ذکر شده، زمان استفاده و مصرف لوازم شخصی برای دستیابی به کنترل انرژی منعطف پیش‌بینی شده است. مزیت این مدل علاوه بر نشان دادن عملکرد و دقت خوب، اینست که شناسایی انعطاف‌پذیری را میتوان با پیش‌بینی انعطاف‌پذیری همزمان انجام داد. دو متغیر از RBM برای پیش‌بینی مصرف انرژی در فواصل کوتاه مدت در خانه‌های مسکونی استفاده میشود. این مدل شامل RBM شرطی (CRBM) و یک RBM شرطی فاکتور شده (FCRBM) است. نتایج آنها حاکی از آن است که FCRBM عملکرد بهتری نسبت به CRBM، RNN و ANN دارد. علاوه بر این، با گسترش افق پیش‌بینی، FCRBM و CRBM پیش‌بینی‌های دقیق تری نسبت به RBM و ANN نشان میدهند.

پیرو شبکه هوشمند، پیش‌بینی میزان مصرف انرژی از انرژی خورشیدی، باد یا سایر منابع طبیعی انرژی پایدار یک زمینه تحقیقاتی فعال است. DL به طور فزاینده‌ای در بسیاری از برنامه‌های این دامنه استفاده میشود. بعنوان مثال، جنسلر و همکاران عملکرد چند مدل DL مانند DBN، AE و LSTM و همچنین MLP را برای پیش‌بینی انرژی خورشیدی 21 نیروگاه فتوولتائیک بررسی میکنند. برای پیش‌بینی انرژی خورشیدی، یک عنصر اصلی ورودی یک مقدار عددی برای پیش‌بینی هوا در یک افق زمانی معین است. از ارزیابی آنها، ترکیب AEها و LSTM (Auto-LSTM) نشان داده شده است که بهترین نتایج را در مقایسه با سایر مدلها و پس از آن DBN ایجاد میکنند. دلیل بدست آوردن نمره پیش‌بینی خوب توسط Auto-LSTM این است که آنها میتوانند ویژگیهای را از داده‌های خام استخراج کنند که این مورد برای ANN و MLP امکان‌پذیر نیست. یک سیستم پیش‌بینی آنلاین بر اساس LSTM برای پیش‌بینی توان انرژی خورشیدی 24 ساعته پیشنهاد شده است.

4) سیستمهای حمل و نقل هوشمند:

داده‌های سیستمهای حمل و نقل هوشمند (ITS) منبع دیگری از داده‌های بزرگ است که همه روزه و در همه جا رواج دارد. ما و همکارانش سیستم تحلیل شبکه حمل و نقل را بر اساس DL ارائه دادند. آنها معماریهای RBM و RNN را بعنوان مدل‌های خود در یک محیط محاسبات موازی و داده‌های GPS از مالیاتهای شرکت کنندگان بعنوان ورودی مدلها استفاده کردند. صحت سیستم آنها برای پیش‌بینی تکامل ازدحام ترافیک در طی یک ساعت از داده‌های جمع شده تا 88٪ است که در کمتر از 6 دقیقه محاسبه شده است؛ همچنین تحقیقات مربوط به پیش‌بینی، جریان ترافیک کوتاه مدت را گزارش داد. آنها از LSTM بعنوان الگوی یادگیری خود استفاده کرده و در مقایسه با سایر روشها از جمله SVM، شبکه‌های عصبی ساده رو به جلو و AE‌های انباشته شده، دقت بهتری را برای LSTM نشان دادند. برای فواصل مختلف (15، 30، 45، و 60 دقیقه) LSTM کمترین میانگین درصد خطای مطلق (MAPE) را نشان داد. با اینحال، برای فواصل کوتاه 15 دقیقه، میزان خطای SVM کمی بیشتر از مدل LSTM است. این نتیجه را میتوان با این واقعیت تفسیر کرد که تعداد کمی از نقاط داده در فواصل کوتاه، مرزهای تفکیک کننده را برای کار طبقه بندی در مدل LSTM در مقایسه با مدل SVM ایجاد نمیکند. در یک مطالعه دیگر، داده‌های ITS برای بهبود امنیت ارتباطات شبکه درون خودرو در معرض یک سیستم تشخیص نفوذ مبتنی بر DNN قرار گرفته اند.

ITS همچنین به ایجاد روشهای تشخیص و شناسایی علائم راهنمایی و رانندگی انگیزه میدهد. برنامه‌های کاربردی مانند رانندگی خودمختار، سیستمهای کمک به راننده و نقشه برداری تلفن همراه برای ارائه خدمات قابل اعتماد به چنین مکانیزم‌هایی نیاز دارند. کرسن و همکارانش یک سیستم شناسایی علائم راهنمایی و رانندگی را بر اساس DNN‌های لایه‌های جمع کننده و حداکثر مخلوط ارائه کردند. آنها یک معماری چند ستونی DNN را معرفی کردند که شامل چندین ستون از DNN‌های جداگانه است و با افزایش این دقت، گزارشها از صحت بالایی خبر دادند. ورودی، توسط چندین پردازنده مختلف پردازش شده است و تعداد ستونهای تصادفی ورودی قبلی را برای پردازش دریافت میکند. پیش‌بینی نهایی، میانگین تمام خروجیهای DNN است. نتایج آنها نشان میدهد که این روش پیشنهادی با دستیابی به میزان شناخت 99.46 درصد، با دقت 0.62 درصد توانسته است علائم راهنمایی و رانندگی را بهتر از افراد حاضر در این کار تشخیص دهد.

این تجزیه و تحلیل ها برای اینکه در سناریوهای واقعی قابل اجرا باشد، باید در زمان واقعی انجام شوند. لیم و همکاران در تحقیقاتشان یک علامت راهنمایی و رانندگی را در زمان واقعی بر اساس

CNN پیشنهاد کرده اند که با یک پردازنده گرافیکی عمومی هدف یکپارچه شده است. آنها اندازه F1 را با حداقل میزان 0.89 در نتایج خود با داده‌هایی که تغییری در روشنایی دارند گزارش کردند. برای داشتن موتور استنتاج سریعتر، آنها از CNN با دو لایه حلقوی استفاده می‌کردند.

Commented [S51]:

علاوه بر این، اتومبیل‌های خودران از DNNها در انجام بسیاری از کارها مانند شناسایی عابر پیاده، علائم راهنمایی و رانندگی، موانع و... استفاده میکنند. چندین استارت‌آپ وجود دارند که از DL در اتومبیل‌های خودران برای انجام کارهای مختلف هنگام رانندگی در خیابانها بهره می‌گیرند.

5) بهداشت و سلامتی:

IoT همراه با DL همچنین در ارائه راه حل‌های بهداشتی و درمانی برای افراد و جوامع به کار رفته است. بعنوان مثال، تهیه راه حل‌های مبتنی بر برنامه‌های تلفن همراه برای اندازه گیری دقیق رژیم غذایی، پیگیری تحقیق است که میتواند به کنترل سلامت و رفاه افراد کمک کند. لیبو و همکاران سیستمی را برای شناخت تصاویر غذایی و اطلاعات مربوط به آنها، از جمله انواع و اندازه‌های آنها ایجاد کردند. الگوریتم تشخیص تصویر آنها مبتنی بر CNN است که در مقایسه با سیستمهای پایه به نتایج رقابتی رسیده است.

DL برای طبقه‌بندی و تجزیه و تحلیل تصاویر پزشکی یک موضوع داغ در حوزه مراقبتهای بهداشتیست. بعنوان مثال، پریرا و همکاران برای شناسایی بیماری پارکینسون در مراحل اولیه خود از ایده تشخیص تصاویر دستنویس توسط CNN استفاده کردند. مدل آنها ویژگیهایی را از سیگنالهای یک قلم هوشمند که از حسگرها برای اندازه گیری دینامیک دست نوشته در امتحان فرد استفاده میکند، می‌آموزد. محمد و همکاران سیستم تشخیص آسیب شناسی صوتی را با استفاده از چارچوبهای IoT و ابری پیشنهاد میکنند که در آن سیگنالهای صوتی بیماران از طریق دستگاه‌های حسگر ضبط میشوند و برای تجزیه و تحلیل به یک سرور ابری ارسال می‌گردند. آنها برای تشخیص آسیب‌شناسی از یک دستگاه فوق آموزش دیده توسط سیگنالهای صوتی استفاده کردند. DL برای تشخیص بیماریهای قلبی و عروقی از طریق ماموگرافیها استفاده شد. آنها یک CNN با دوازده لایه ایجاد کردند تا وجود BAC را در بیمار تشخیص دهند. نتایج آنها نشان میدهد که دقت مدل DL آنها به اندازه متخصصان انسانی خوب است. اگرچه این کار بصورت آفلاین انجام شده است، اما پتانسیل توسعه یا گسترش دستگاه‌های ماموگرام در زمینه‌های IoT برای تشخیص آنلاین و زود هنگام چنین بیماریهایی را نشان میدهد.

فنگ و همکاران استفاده از RBMها و DBNها را برای تشخیص سقوط در محیط مراقبت از منزل گزارش میکنند درحالیکه حالت‌های معمولی در چنین محیطی ایستاده، نشسته، خم و بعضاً دروغگو هستند. دراز کشیدن روی زمین بیش از یک آستانه مشخص، بعنوان یک وضعیت افتاده در نظر گرفته میشود؛ عدم وجود مجموعه داده‌های بزرگ و انجام تشخیص آفلاین، از جمله محدودیتهای آنهاست.

محققان همچنین از داده‌های پزشکی سری زمانی در رابطه با مدل‌های مبتنی بر RNN برای تشخیص زودهنگام و پیش‌بینی بیماریها استفاده کردند. لپیتون و همکاران عملکرد شبکه‌های LSTM را بمنظور تجزیه و تحلیل و تشخیص الگوهای سری‌های زمانی چند متغیره پزشکی در بخش مراقبتهای ویژه (ICU) بررسی کردند. داده‌های ورودی در سیستم آنها از ورودیهای حسگر علائم حیاتی و همچنین نتایج آزمایشگاهی تشکیل شده است. نتایج عملکرد آنها نشان میدهد که یک مدل LSTM که براساس داده‌های سری زمانی خام شکل گرفته، از شبکه MLP بهتر است.

6 کشاورزی:

تولید محصولات زراعی سالم و ایجاد راه‌های کارآمد برای رشد گیاهان، یکی از نیازهای جامعه سالم و محیط پایدار است. تشخیص بیماری در گیاهان با استفاده از DNN، مسئله ایست که ثابت کرده که یک راه حل مناسب است. در مطالعه‌ای که توسط لاجویچ و همکاران گزارش شده است، نویسندگان سیستم تشخیص بیماریهای گیاهی را بر اساس طبقه بندی تصاویر برگها ساخته اند. آنها از یک مدل شبکه عمیق برانگیزاننده که با استفاده از چارچوبهای Caffe اجرا شده است، استفاده کرده اند. در این مدل میتوان برگهای بیمار را در 13 گروه از برگهای سالم با دقت حدود 96 درصد تشخیص داد. چنین مدل شناختی میتواند بعنوان یک برنامه کاربردی تلفن همراه هوشمند برای کشاورزان مورد استفاده قرار گیرد تا بیماری میوه، سبزیجات یا گیاهان را براساس تصاویر برگهای گرفته شده توسط دستگاههای تلفن همراه خود شناسایی کند. همچنین این امکان را به آنها میدهد تا در کنار داده‌های مکمل، داروهای آفت‌کش یا سموم دفع آفات را انتخاب کنند.

از DL همچنین در سنجش از دور برای تشخیص و طبقه بندی زمین و گیاهان استفاده شده است. راستای تعیین شده در این آثار امکان نظارت و مدیریت خودکار اراضی کشاورزی در مقیاسهای بزرگ را فراهم کرده است. در اکثر چنین کارهایی، از شبکه‌های پیچیده عمیق برای یادگیری تصاویر از زمین یا محصولات استفاده میشود. گزارش شده است که استفاده از CNN در تشخیص 85 درصد از

محصولات مهم از جمله گندم، آفتابگردان، سویا و ذرت دقت 85 درصد داشته است، در حالی که نسبت به سایر رویکردها مانند MLP و جنگل تصادفی (RF) بهتر عمل کرده است.

علاوه بر این، گزارش شده است که DL برای کارهای پیش‌بینی و تشخیص در کشاورزی اتوماتیک مورد استفاده قرار می‌گیرد. بعنوان مثال، از مدل DL مبتنی بر CNNهای عمیق برای شناسایی مانع در مزارع کشاورزی استفاده کرده است که ماشینهای مستقل را قادر می‌سازد تا با خیال راحت در آنها کار کنند. سیستم پیشنهادی با استفاده از زمینه (مثلاً محصولات ردیفی یا چمن زنی)، قادر به شناسایی یک شی استاندارد شده با دقت بین 90.8 درصد تا 90.9 درصد بود.

علاوه بر این، تشخیص میوه و یافتن مرحله رسیدن (خام یا رسیده) برای برداشت خودکار بسیار مهم است. سا و همکاران برای تجزیه و تحلیل تصویر میوه‌ها از نوعی CNN بنام CNN مبتنی بر منطقه²⁷ استفاده کرد. تصویر ورودی سیستم در دو حالت ارائه میشود: یکی حاوی رنگهای RGB و دیگری نزدیک مادون قرمز. اطلاعات این تصاویر در مدل ترکیب شده و در مقایسه با مدل‌های آموزشی مبتنی بر پیکسل، به بهبود تشخیص رسیده است.

7) تحصیلات:

IoT و DL در بهرهوری سیستم‌های آموزش از مهد کودک تا آموزش عالی نقش دارند. دستگاه‌های تلفن همراه میتوانند داده‌های زبان آموزان را جمع‌آوری کرده و از روشهای تحلیلی عمیق برای پیش‌بینی و تفسیر پیشرفت و دستاوردهای زبان آموزان استفاده کنند. فناوری واقعیت افزوده همراه با پوشیدنیها و دستگاه‌های تلفن همراه نیز کاربردهای بالقوه‌ای برای روشهای DL در این زمینه است تا دانش آموزان را با انگیزه کرده و دروس و مطالعات را جالبتر و روشهای یادگیری آموزشی را کارآمد جلوه دهد. علاوه بر این، DL میتواند بعنوان یک ماژول شخصی برای توصیه مطالب مرتبط تر به مربی مورد استفاده قرار گیرد. برنامه‌های DL در حوزه‌های دیگر، مانند ترجمه زبان طبیعی و خلاصه کردن متن، هنگام یادگیری آنلاین از طریق دستگاه‌های تلفن همراه، برای آموزش هوشمندانه یاری خواهد کرد.

علاوه بر این، ظهور دوره‌های گسترده آنلاین (MOOCs²⁸) و محبوبیت آنها در بین دانشجویان باعث شده است که داده‌های زیادی از رفتار فراگیران در چنین دوره‌هایی تولید شود. تجزیه و تحلیل MOOC

²⁷ Region-based CNN

²⁸ Massive Open Online Courses

میتواند به شناسایی دانش آموزان تلاشگر در جلسات ابتدایی یک دوره کمک کند و پشتیبانی و توجه کافی را از مربیان به آن دانش آموزان برای دستیابی به عملکرد بهتر ارائه دهد. یانگ و همکاران روشی را برای پیش بینی نمرات دانش آموزان در MOOC پیشنهاد دادند. آنها هنگامی که دانش آموزان در حال تماشای این فیلم و تعامل با آن هستند، از داده‌های clickstream جمع‌آوری شده از فیلمهای سخنرانی استفاده میکنند. داده‌های Clickstream به یک سری RNN سری زمانی تغذیه میشوند که از عملکرد قبلی و داده‌های clickstream یاد میگیرند. علاوه بر این، پیچ و همکاران از شبکه‌های RNN و LSTM استفاده کردند تا بتوانند بر اساس فعالیتهای گذشته و تعامل آنها در MOOC، پیش‌بینی پاسخهای مربی به تمرینها و آزمونها را مدل کنند. نتایج نشان داد که روشهای پیگیری دانش بیزی (BKT²⁹)، که از یک مدل مارکوف پنهان (HMM³⁰) برای به روزرسانی احتمالات مفاهیم مجزا استفاده میکند، بهبود یافته است. محمود و همکاران همچنین از DNNها برای یک چارچوب شخصی آموزش الکترونیکی و یادگیری الکترونیکی مبتنی بر فناوریهای IoT، با هدف توسعه و تحویل محتوای آموزشی در شهرهای هوشمند استفاده کردند. چارچوب پیشنهادی آنها روی زیرساخت IoT (بعنوان مثال، سنسورهای تلفن هوشمند، سنسورهای ساعت هوشمند، فناوریهای واقعیت مجازی) ایجاد شده است که کاربران را به منظور بهینه سازی فرایندهای آموزش و یادگیری به یکدیگر متصل میکند. آنها از DNN برای شناسایی فعالیتهای انسانی برای ارائه محتوای آموزشی تطبیقی به دانشجویان استفاده میکردند.

نظارت بر اشغال کلاس درس، برنامه دیگری است که توسط کانتی و همکاران بررسی شده است. در این کار، نویسندگان دو روش برای سرشماری و تخمین تراکم را پیشنهاد کرده اند، هر دو بر اساس معماری CNN برای شمارش دانش آموزان در یک کلاس. این الگوریتمها بر روی سیستم عامل موبایل ARM بدون طبقه بندی مستقر شده اند. الگوریتمهای آنها از تصاویر گرفته شده با دوربینهایی از سه کلاس درسی که در هر 10 دقیقه 3 عدد عکس میگیرند، دریافت شده است. آنها گزارش میدهند که خطای میانگین-مربع (RMS³¹) الگوریتمهای آنها حداکثر 8.55 است.

²⁹Bayesian Knowledge Tracing

³⁰Hidden Markov Model

³¹root-mean-square

8 صنعت:

برای بخش صنعت، IoT و سیستمهای فیزیکی-سایبری (CPS) عناصر اصلی برای پیشبرد فناوریهای تولید به سمت تولید هوشمند هستند (پیشتر، صنعت 0.4). تهیه سیستمهای هوشمند با دقت بالا در چنین کاربردهایی بسیار مهم است، زیرا مستقیماً منجر به افزایش کارایی و بهره‌وری در خطوط مونتاژ/محصول و همچنین کاهش هزینه‌های نگهداری و هزینه‌های بهره‌برداری میشود. بنابراین، DL میتواند در این زمینه نقش اساسی داشته باشد. در واقع، طیف گسترده‌ای از برنامه‌های کاربردی در صنعت (مانند بررسی بصری خطوط محصول، تشخیص و ردیابی اشیاء، کنترل رباتها، تشخیص اشتباه و...) میتوانند از معرفی مدل‌های DL بهره‌مند شوند. با بررسی بصری با استفاده از معماریهای CNN از جمله AlexNet و GoogLeNet بر روی سیستم عامل‌های مختلف (Caffe, Tensorflow, and Torch) بررسی میشود. در این کار چندین تصویر از وسایل نقلیه تولید شده در خط مونتاژ به همراه حاشیه نویسی آنها به سیستم DL ارسال میشود. علاوه بر این، Tensorflow از نظر زمان آموزش سریعترین چارچوب بود، جایی که این مدل در مدت زمان کوتاه‌تر به اوج دقت خود رسید و پس از آن Torch و سپس Caffe قرار گرفت.

شائو و همکاران از DNNها برای استخراج ویژگیها در تشخیص اشتباه (همچنین بعنوان سیستم تشخیص و تقسیم اشتباهات (FDC)) برای دستگاه‌های چرخان استفاده میکنند. مدل‌هایی با استفاده از رمزگذار خودکار بیصدا (DAE) و رمزگذار خودکار قراردادی (CAE) توسعه داده شدند. ویژگیهای آموخته شده از این مدلها هر دو با استفاده از روشی به نام پیش‌بینی حفظ محل (LPP) تصفیه شده و برای تشخیص اشتباه به یک طبقه‌بند نرم‌کننده (softmax) تغذیه شدند. ورودی سیستم، داده‌های لرزشی دستگاه گردان است. در سیستم آنها هفت شرط عملیاتی در نظر گرفته شده است که شامل کارکرد نرمال، اشتباه لغزشی، چهار رده اشتباه دیگر و اشتباهات دارای عدم تعادل است. باتوجه به داده‌های لرزشی، سیستم تشخیص دهنده میفهمد که دستگاه در حالت عادی است یا در یکی از شرایط اشتباه. با توجه به آزمایشات آنها برای تشخیص اشتباه دستگاه‌های تحمل رتور و لوکوموتیو، رویکرد پیشنهادی گزارش شده است تا از روشهای یادگیری کم عمق CNN بهتر باشد.

در مطالعه دیگری که توسط لی گزارش شده است، یک مدل DBN در رابطه با استقرار IoT و بستر ابری برای پشتیبانی از تشخیص اشتباهات انواع نقوص در ماژول چراغهای جلوی اتومبیل در یک تولید کننده وسیله نقلیه پیشنهاد گردیده است. نتایج آنها عملکرد برتر مدل DBN را بیش از دو روش پایه با استفاده از SVM و عملکرد پایه شعاعی (RBF)، از نظر میزان خطا در مجموعه داده‌های

آزمایشی، تأیید کرد. با اینحال، میزان خطای گزارش شده برای مجموعه داده‌های آموزشی آنها در مدل DBN قابل مقایسه با مدل SVM است. سیستم آنها برای تشخیص اشتباه در نمونه‌های ویفری یک فرآیند فوتولیتوگرافی استفاده شده است. نتایج نشان می‌دهد که SdA منجر به 14 درصد دقت بیشتر در شرایط پر سر و صدا در مقایسه با چندین روش پایه از جمله K-نزدیکترین-همسایگان³² و SVM میشود. یان و همکاران نیز از دستگاه SdA همراه با دستگاه‌های یادگیری فوری برای تشخیص ناهنجاری در رفتار سیستم احتراق توربین گازی بهره جستند. براساس نتایج آنها، استفاده از ویژگیهای آموخته شده توسط SdA منجر به طبقه‌بندی دقیقتر در مقایسه با استفاده از ویژگیهای دستکاری شده در سیستم آنها میشود.

(9) دولت:

دولتها میتوانند از راه اتصال پیشرفته و هوشمندانه ناشی از همگرایی IoT و DL، مزایای بالقوه بزرگی را بدست آورند. در واقع طیف گسترده‌ای از وظایف مربوط به دولتها یا مقامات شهری نیاز به تحلیل و پیش‌بینی دقیق دارند. بعنوان مثال، شناخت و پیش‌بینی سوانح طبیعی (زمین لغزش، طوفان، آتش سوزی جنگلها و...) و نظارت بر محیط زیست از اهمیت بالایی نزد دولتها برخوردار است تا آنها بتوانند اقدامات مناسب را انجام دهند. تصاویر سنجنش از راه دور نوری که به یک شبکه عمیق از AEها منتقل میشوند و طبقه بندی کننده‌های softmax توسط لیو و همکاران برای پیش‌بینی زمین لغزش در علم زمین شناسی ارائه شده اند. دقت 97.4 درصدی برای روش پیشنهادی گزارش شده است، بنابراین بهتر از مدل‌های SVM و ANN است. در یک پژوهش دیگر، از شبکه LSTM برای پیش‌بینی زلزله استفاده میشود. آنها از سابقه داده‌های وبسایت سازمان زمین شناسی ایالات متحده³³ برای آموزش استفاده کردند. سیستم آنها با داده‌های ورودی D-1 و D-2، به ترتیب میزان 63 و 74 درصد را کسب کرد. در مطالعه دیگری توسط لیو و همکاران، برای تشخیص حوادث شدید آب و هوایی مانند سیکلونها، گرمسیری، رودخانه‌های جوی و جبهه‌های هواشناسی، از یک معماری CNN استفاده میشود. داده‌های آموزشی در سیستم خود شامل الگوهای تصویری از وقایع آب و هوایی بودند. نویسندگان سیستم خود را در چارچوب نئونی توسعه داده و با دقت 89٪-99٪ بدست آوردند.

علاوه بر این، تشخیص خسارت در زیرساختهای شهرها از جمله جاده‌ها، خطوط لوله‌کشی انتقال آب و... مبحث دیگری است که DL و IoT میتوانند در آنها منافی را برای دولتها به ارمغان بیاورند.

³² K-Nearest Neighbors

³³ US Geological Survey

مشکل تشخیص خسارت در جاده‌ها با استفاده از DNN‌هایی که داده‌های آن را از راه سنجش تراکم جمعیت بدست می‌آورند (که توسط دستگاه های IoT امکان پذیر است)، مورد بررسی قرار گرفت. شهروندان میتوانند آسیب را بوسیله یک برنامه تلفن همراه به یک پلتفرم خاص گزارش دهند. با اینحال، این شهروندان دانش خاصی برای ارزیابی دقیق وضعیت خسارت جاده‌ای ندارند و این میتواند منجر به ارزیابی‌های نامشخص و یا اشتباه شود. برای از بین بردن این موارد، برنامه میتواند با تحلیل تصویر صحنه وضعیت آسیب جاده را تعیین کند. این تجزیه و تحلیل بوسیله یک CNN عمیق انجام میشود که توسط گزارشهای شهروندان و همچنین نتایج بازرسی مدیر راه آموزش دیده است. از آنجا که مرحله آموزش از دایره قابلیت‌های تلفن‌های همراه خارج نیست، مدل DL روی سرور ایجاد شده و همه روزه آموزش مییابد. سپس یک برنامه Android بعد از هر بار آموزش میتواند آخرین مدل را از سرور بارگیری کرده و وضعیت خسارت‌های جاده ای را که توسط تصاویر گزارش شده است، شناسایی کند. ارزیابی‌ها در 1 ثانیه تحلیل در دستگاه‌های تلفن همراه، دقت طبقه بندی آسیب را 81.4 درصد نشان داد.