

ادامه ترجمه مقاله زبان تخصصی از ابتدای صفحه 31 تا انتهای صفحه 40

امین وفا

جدول 9. مجموعه داده‌های متداول برای یادگیری عمیق در IoT.

نام مجموعه داده	حیطه	ارائه‌دهنده	توضیحات	آدرس/لینک
مجموعه داده CGIAR	کشاورزی، آب و هوا	CCAFS	مجموعه داده‌های اقلیمی با تفکیک بالا برای حوزه‌های مختلف از جمله کشاورزی	http://www.ccafs-climate.org/
فرآیندکاوی آموزشی	آموزش	دانشگاه ژنو	ثبت فعالیت‌های 115 سوژه از طریق یک برنامه وقایع‌نگار حین یادگیری با یک شبیه‌ساز آموزشی	http://archive.ics.uci.edu/ml/datasets/Educational+Process+Mining+%28EPM%29%3A+A+L+earning+Analytics+Data+Set
مجموعه داده انرژی ساختمان تجاری	انرژی، خانه هوشمند	IIITD	مجموعه داده مربوط به انرژی از یک ساختمان تجاری که داده‌ها بیش از یک بار در دقیقه نمونه‌برداری شده است.	http://combed.github.io/
مصرف برق خانوارها به‌طور مجزا	انرژی، خانه هوشمند	EDF R&D، کلامارت، فرانسه	نرخ نمونه‌برداری یک دقیقه طی یک دوره تقریباً 4 ساله	http://archive.ics.uci.edu/ml/datasets/Individual+household+electric+power+consumption
مجموعه داده AMPds	انرژی، خانه هوشمند	اس. ماکونین	AMPds شامل اندازه‌گیری برق، آب و گاز طبیعی در فواصل یک دقیقه برای مدت پایش 2 ساله	http://ampds.org/

http://www.doc.ic.ac.uk/~dk3810/data/	تقاضای برق پنج خانه. در هر خانه تقاضای برق کل خانه و همچنین تقاضای برق لوازم خانگی جداگانه ثبت می‌شود.	کلی و ناتنبلت	انرژی، خانه هوشمند	برق خانگی در سطح لوازم خانگی انگلیس
https://physionet.org/physiobank/database/	آرشیو بیش از 80 مجموعه داده فیزیولوژیکی.	PhysioNet	مراقبت‌های بهداشتی	پایگاه داده PhysioBank
http://www.stimmdatenbank.coli.uni-saarland.de/help_en.php4	مجموعه ای از صدای ضبط شده بیش از 2000 نفر برای تشخیص پاتولوژیکی صدا.	دانشگاه سارلند	مراقبت‌های بهداشتی	مجموعه داده صوتی ساربروکن
http://cmp.felk.cvut.cz/t-less/	مجموعه داده RGB-D و متدلوژی ارزیابی برای تشخیص و تخمین موقعیت شش‌بعدی اشیاء بدون بافت	CMP در دانشگاه فنی چک	صنعت	T-LESS
http://iot.ee.surrey.ac.uk:8080/datasets.html	اطلاعات ترافیک جاده‌ای، داده‌های مربوط به آلودگی، آب و هوا، پارکینگ	پروژه CityPulse EU FP7	شهر هوشمند	کلکسیون مجموعه داده CityPulse
http://theodi.fbk.eu/openbigdata/	آب و هوا، کیفیت هوا، برق، ارتباطات	تلکام ایتالیا	شهر هوشمند	موسسه Open Data - گروه Trento
http://datosabiertos.malaga.eu/dataset	طیف وسیعی از شاخه‌ها مانند انرژی، ITS، آب و هوا، صنعت، ورزش و غیره.	شهر مالاگا	شهر هوشمند	مجموعه داده‌های مالاگا
http://archive.ics.uci.edu/ml/datasets/Gas+sensors+for+home+activity+monitoring	داده‌های ثبت شده 8 حسگر گاز تحت سه وضعیت شامل نمایش‌های پس‌زمینه، شراب و موز.	دانشگاه کالیفرنیا سن‌دیگو	خانه هوشمند	حسگرهای گاز برای پایش فعالیت در خانه
http://ailab.wsu.edu/casas/datasets.html	چند مجموعه داده عمومی مربوط به عملکرد فعالیت‌های زندگی روزمره (ADL) در یک خانه دو طبقه، یک آپارتمان و یک محیط اداری.	دانشگاه ایالتی واشنگتن	خانه هوشمند	مجموعه داده‌های CASAS برای فعالیت‌های زندگی روزمره
https://www.cmpe.boun.edu.tr/aras/	مجموعه داده‌های بازشناسی فعالیت‌های انسان جمع‌آوری شده از دو خانه واقعی با ساکنان متعدد در طی دو ماه.	دانشگاه بوغازیچی	خانه هوشمند	مجموعه داده فعالیت انسان ARAS
http://www.merl.com/wmd	داده‌های حسگر حرکت رد باقیمانده از یک شبکه شامل بیش از 200 حسگر به مدت دو سال، حاوی بیش از 50 میلیون رکورد.	آزمایشگاه‌های تحقیقاتی میتسوبیشی الک‌تریک	خانه و ساختمان هوشمند	داده‌های MERLSense
http://go.stats.com/sportvu	فیلم بازی‌های بسکتبال و فوتبال ضبط شده با 6 دوربین.	Stats LLC	ورزش	SportVU

http://orestibanos.com/datasets.htm	شامل طیف وسیعی از فعالیت‌های بدنی (تمرینات گرم کردن، سرد کردن و آمادگی جسمانی).	ا. و. بانوس	ورزش	RealDisp
http://www.geolink.pt/ecmlpkdd2015-challenge/dataset.html	مسیرهای طی شده توسط تمام 442 تاکسی مشغول کار در شهر پورتو، پرتغال.	پیش‌بینی چالش، ECML PKDD 2015	حمل و نقل	مسیر تاکسی‌سر ویس
https://www.microsoft.com/en-us/download/details.aspx?id=52367	یک مسیر GPS توسط دنباله‌ای از نقاط با مهر زمانی	مایکروسافت	حمل و نقل	مسیرهای GeoLife GPS
https://www.microsoft.com/en-us/research/publication/t-drive-trajectory-data-sample/	شامل مسیر یک هفته ای 10,357 تاکسی	مایکروسافت	حمل و نقل	داده‌های مسیر T-Drive
http://www.ibr.cs.tu-bs.de/users/mdoering/bustraces/	مسیرهای اتوبوس از اداره حمل و نقل شیکاگو به مدت 18 روز با نرخ بین 20 تا 40 ثانیه.	M. دوئرینگ	حمل و نقل	داده‌های ردیابی اتوبوس شیکاگو
https://github.com/fivethirtyeight/uber-tlc-foil-response	حدود 20 میلیون حمل مسافر اوبر در شهر نیویورک در طی 12 ماه.	FiveThirty-Eight	حمل و نقل	اطلاعات سفر اوبر
https://figshare.com/articles/Traffic_Sign_Recognition_Testsets/4597795	سه مجموعه داده شامل علائم راهنمایی و رانندگی کره در روز، کره در شب و آلمان در روز بر اساس قوانین راهنمایی و رانندگی وین.	کی. لیم	حمل و نقل	بازشناسی علائم راهنمایی و رانندگی
http://sensors.ini.uzh.ch/databases.html	مجموعه داده رانندگی پایان به پایان دیویس	جی. بیناس	حمل و نقل	DD17

... IoT، چرا که DL برای دستیابی به دقت بیشتر به داده‌های بیشتری نیاز دارد. علاوه بر این، داده‌های بیشتر از بیش‌برازش مدل‌ها جلوگیری می‌کند. این نقصان مانعی برای استقرار و پذیرش تحلیل IoT بر اساس DL به شمار می‌رود، زیرا اعتبارسنجی و ارزیابی تجربی سیستم باید در دنیای واقعی امیدبخش باشد. دسترسی به مجموعه داده‌های دارای کپی‌رایت یا ملاحظات حفظ حریم خصوصی نیز دغدغه‌هایی هستند که بیشتر در حیطه‌های مرتبط با داده‌های انسانی مانند مراقبت بهداشتی و آموزش رایج است. همچنین، سبدهای از مجموعه داده‌های مناسب کمک زیادی به توسعه‌دهندگان و محققان خواهد بود. یک فهرست کلی از مجموعه داده‌های مفید در ویکی‌پدیا گردآوری شده است [214]. برای راحتی محققان در کاربردهای یادگیری ماشین در اینترنت اشیا، کلکسیون‌های از مجموعه داده‌های رایج مناسب جهت استفاده برای DL در جدول 9 ارائه شده است.

2) پیش‌پردازش:

آماده‌سازی داده‌های خام در قالب نمایش مناسب جهت تغذیه مدل‌های DL چالش دیگری برای کاربردهای IoT است. اکثر رویکردهای DL برای دستیابی به نتایج خوب به نوعی پیش‌پردازش نیاز دارند. به عنوان مثال، تکنیک‌های پردازش تصویر توسط CNNها زمانی عملکرد بهتری دارد که داده‌های ورودی در سطح پیکسل نرمال شوند، به یک بازه خاص تغییر مقیاس یابند یا به یک نمایش استاندارد تبدیل شوند [37] [60]. برای کاربردهای IoT، پیش‌پردازش پیچیده‌تر است زیرا این سیستم با داده‌هایی از

منابع مختلف سروکار دارد که ممکن است هنگام نمایش داده‌های گم شده دارای فرمت‌ها و توزیع‌های مختلفی باشد.

3) یادگیری عمیق امن و با حفظ محرمانگی:

حصول اطمینان از امنیت و محرمانگی داده‌ها یک دغدغه اصلی در بسیاری از کاربردهای IoT است، زیرا کلان داده IoT برای تحلیل از طریق اینترنت منتقل می‌شود، و بنابراین در سراسر جهان قابل مشاهده است. با وجود استفاده از گمنام‌سازی در بسیاری از کاربردها، این تکنیک‌ها می‌توانند هک شده و به‌عنوان داده‌های ناشناس بازشناسایی شوند. علاوه بر این، مدل‌های آموزشی DL نیز در معرض حملات خرابکارانه، مانند تزریق داده‌های غلط و یا ورودی‌های نمونه خصمانه هستند، که از این طریق بسیاری از الزامات کارکردی و یا غیرکارکردی IoT (مثل دسترس‌پذیری، قابلیت اطمینان، اعتبار، اعتماد، و غیره) ممکن است به مخاطره بیفتند. در واقع، مدل‌های DL ویژگی‌ها را از داده‌های خام یاد می‌گیرد، و بنابراین قادر به یادگیری از هر داده نامعتبر تغذیه شده به آن است. در این حالت، مدل‌های DL باید با سازوکارهایی برای کشف داده‌های غیرعادی یا نامعتبر تقویت شوند. یک مدل DL پایش داده همراه با مدل اصلی باید در چنین سناریوهایی کار کند. پیپرنات و همکاران [215] آسیب‌پذیری DNN‌ها را در شرایط حمله بررسی کرده‌اند که در آن مهاجم سعی در ارائه ورودی‌هایی دارد که به طبقه بندی خروجی نادرست منجر شده و از این رو باعث خراب شدن صحت طبقه بندی شود. توسعه تکنیک‌های بیشتر برای دفاع و پیشگیری از اثر این نوع حملات بر مدل‌های DL برای کاربردهای IoT قابل اطمینان ضروری است.

به رغم پیشرفت‌های اخیر در DL برای کلان داده، هنوز چالش‌های قابل توجهی وجود دارد که باید برای بلوغ این فناوری حل و فصل شود. هر مشخصه کلان داده IoT چالشی بر تکنیک‌های DL تحمیل می‌کند. در ادامه این چالش‌ها را مشخص می‌کنیم.

حجم عظیم داده‌ها، چالش بزرگی برای DL به‌ویژه برای پیچیدگی زمان و ساختار ایجاد می‌کند. تعداد زیاد داده‌های ورودی، تعداد گسترده خصوصیات آنها و میزان بالای دسته‌بندی آنها منجر به یک مدل DL بسیار پیچیده شده و بر کارایی زمان اجرا تأثیر می‌گذارد. اجرای DL در فریم‌ورک‌های توزیع شده یا خوشه‌های CPUها با پردازش موازی، راهکاری مناسب است که توسعه یافته است [7]. حجم بالای کلان داده IoT چالش دیگری نیز به همراه دارد، که عبارتست از داده‌های نویزدار و بدون برچسب. حتی اگر DL در تحمل داده‌های نویزدار و یادگیری از داده‌های بدون برچسب بسیار خوب باشد، مشخص نیست که مدل‌های DL در حضور این داده‌های غیرعادی تا چه حد می‌توانند دقیق باشند.

تنوع فرمت‌های داده IoT که از منابع مختلف به دست می‌آیند، چالش مدیریت تعارضات بین منابع مختلف داده را نشان می‌دهد. در صورت عدم تعارض در منابع داده، DL از توانایی کار مؤثر بر روی داده‌های نامتجانس برخوردار است.

سرعت بالای کلان داده IoT، یعنی نرخ بالای تولید داده، چالش پردازش و تحلیل داده‌ها با سرعت بالا را نیز به همراه دارد. یادگیری آنلاین راه‌حلی برای سرعت بالا بوده و برای DNNs ارائه

شده است. با این حال، تحقیقات بیشتری برای تقویت DL با تکنیک‌های یادگیری آنلاین و یادگیری ترتیبی لازم است.

صحت کلان داده IoT نیز چالش‌هایی را برای تحلیل DL ارائه می‌دهد. اگر داده‌های ورودی از یک منبع قابل اعتماد تهیه نشوند، تحلیل کلان داده IoT مفید نخواهد بود. اعتبارسنجی و موثق بودن باید در هر سطح تحلیل کلان داده بررسی گردد، به ویژه هنگامی که با جریان‌های آنلاین داده ورودی به موتور تحلیلی سروکار داریم [216].

علاوه بر این، تنوع کلان داده IoT (تنوع در نرخ جریان داده ها) چالش‌هایی برای تحلیل آنلاین ایجاد می‌کند. در مورد جریان‌های داده عظیم، تکنیک‌های DL و به ویژه روش‌های آنلاین، از پس آنها بر می‌آیند. در این سناریوها، تکنیک‌های نمونه‌گیری داده سودمند خواهد بود.

در نهایت، چالش اصلی مدیران کسب و کار در به کارگیری کلان داده این است که چگونگی استفاده از تحلیل کلان داده جهت افشای ارزش آن و بهبود کسب‌وکارشان برای آنها روشن نیست [217]. فراتر از آن، ممکن است موتور تحلیلی اطلاعات انتزاعی تولید کند که برای ذینفعان واجد اهمیت نیست، و یا برایشان به حد کافی واضح نیست.

5) یادگیری عمیق برای دستگاه‌های IoT:

توسعه DL در دستگاه‌های IoT چالش جدیدی برای طراحان دستگاه IoT ایجاد کرده، تا الزامات استفاده از DNNها در دستگاه‌های دارای منبع محدود را مدنظر قرار دهند. انتظار می‌رود با

افزایش هر روزه حجم مجموعه داده ها، این الزامات افزایش یابند و الگوریتم‌های جدیدی به عنوان بخشی از راهکارهای DL در IoT به وجود آیند.

6) محدودیت‌های یادگیری عمیق:

با وجود نشان دادن نتایج چشمگیر در بسیاری کاربردها، مدل‌های DL هنوز محدودیت‌های متعددی دارند. نگوین و همکاران [218] گزارشی در مورد اعتماد کاذب به DDN برای پیش‌بینی تصاویر غیرقابل تشخیص توسط انسان ارائه دادند. با تولید نمونه‌های گول زننده کاملاً غیرقابل تشخیص توسط انسان، DDN آنها را به عنوان اشیا آشنا دسته‌بندی می‌کند.

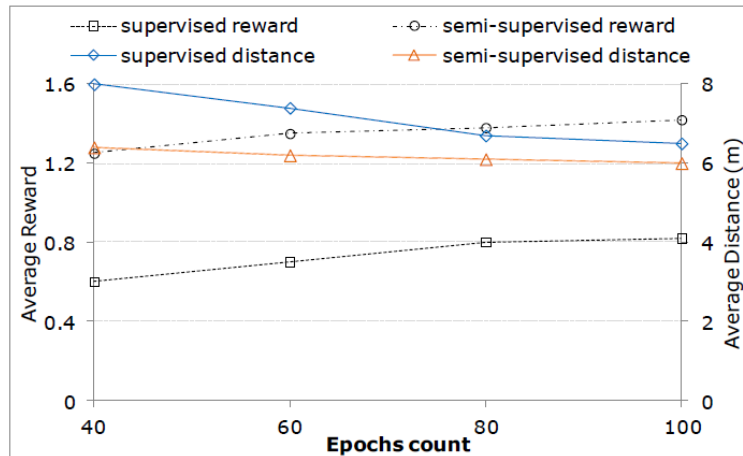
محدودیت دیگر تمرکز مدل‌های DL بر دسته‌بندی است، درحالی‌که بسیاری از کاربردهای IoT (مثلاً، پیش‌بینی بار الکتریکی، پیش‌بینی دما) نیاز به نوعی رگرسیون در مرکز تحلیل خود دارند. پژوهش‌های کمی سعی در غنابخشی DNNها با قابلیت رگرسیون داشته‌اند، مانند پژوهش گزارش شده در [219] که ترکیبی از DBN و رگرسیون بردار پشتیبان (SVR) برای کارهای رگرسیون پیشنهاد می‌کند. با این حال، برای روشن بسیاری از جنبه‌های از رگرسیون با DL، تحقیقات بیشتری لازم است.

ب - مسیرهای آینده

1) داده‌های موبایل IoT:

یک بخش قابل توجه از داده‌های IoT مربوط به دستگاه‌های موبایل است. بررسی روش‌های کارآمد جهت استفاده از کلان داده موبایل

به همراه رویکردهای DL، راهی برای ارائه خدمات بهتر در حیطه‌های IoT به‌ویژه در سناریوهای شهر هوشمند است. در [220]، قابلیت‌های مدل‌های DL در تحلیل کلان داده موبایل با استفاده از یک فریم‌ورک یادگیری توزیع شده که یک وظیفه تکراری MapReduce را روی چند کارگر موازی Spark اجرا می‌کند، بررسی شده است.



شکل 21. یادگیری تقویتی عمیق فقط با داده‌های دارای برچسب (نظارت شده) در مقابل داده‌های دارای برچسب و بدون برچسب (نیمه‌نظارتی). در هر دور، مدل نیمه‌نظارتی از هر دو لحاظ مجموع پاداش‌های دریافتی و نزدیکی به هدف عملکرد بهتری نسبت به مدل نظارت شده دارد.

(2) ادغام اطلاعات زمینه‌ای:

وضعیت محیط را نمی‌توان تنها با داده‌های حسگر IoT درک کرد. بنابراین، لازم است داده‌های اینترنت اشیا با منابع داده دیگر ادغام شود، یعنی، اطلاعات زمینه‌ای که درک از محیط را تکمیل

می‌کنند [12]. این ادغام همچنین می‌تواند به دلیل فضای جستجوی محدود موتور استدلال، به تحلیل سریع داده‌ها و استدلال سریع کمک کند. به عنوان مثال، یک دوربین هوشمند با قابلیت تشخیص حالت چهره می‌تواند در زمینه‌های مختلفی مانند گیت‌های امنیتی در خانه‌های هوشمند یا ساختمان‌های دولتی و یا در اتومبیل‌های هوشمند برای کمک به رانندگی ایفای نقش کند. در تمام این شرایط، اطلاعات زمینه‌ای تکمیلی (به عنوان مثال، زمان در روز، عادات روزمره، و غیره) به سیستم کمک می‌کند تا درباره بهترین اقدام قابل انجام بر اساس حالت شناسایی شده فرد استدلال نماید.

3) تدارک منابع آنلاین برای تحلیل اینترنت اشیا:

استقرار تحلیل داده سریع مبتنی بر DL در مه و ابر نیاز به تدارک آنلاین منابع مه یا ابر برای میزبانی جریان داده دارد. با توجه به ماهیت جریان داده‌های IoT، اطلاع از حجم دنباله داده‌ها از قبل مقدور نیست. در این راستا، به دسته جدیدی از الگوریتم‌ها نیاز داریم که براساس جریان فعلی داده‌ها کار کند و بر دانش قبلی جریان داده متکی نباشد. سازوکار DL و یک الگوریتم حراجی آنلاین به ترتیب در [88] و [221] برای پشتیبانی از تدارک آنلاین منابع مه و ابر برای کاربردهای IoT پیشنهاد شده است.

4) فریم‌ورک‌های تحلیلی نیمه‌نظارتی:

اکثر الگوریتم‌های تحلیلی نظارت شده هستند، و بنابراین به مقدار زیادی داده آموزشی دارای برچسب نیاز دارند که یا در دسترس نیستند و یا تهیه آنها هزینه هنگفتی دارد. بر اساس

گزارش IDC [89]، برآورده شده که تا سال 2012، فقط حدود 3% از کل داده‌ها در جهان دیجیتال حاشیه‌نویسی شده است، که حکایت از منبع ضعیف مجموعه داده‌های آموزش برای DL دارد. ترکیبی از الگوریتم‌های یادگیری ماشین پیشرفته دستگاه طراحی شده برای شرایط نیمه‌نظارتی، برای سیستم‌های شهرهای هوشمند مناسب است، که در آنها می‌توان از مجموعه داده‌های آموزشی کوچک استفاده کرد، درحالی‌که عامل یادگیری با استفاده از مقدار زیادی داده بدون برچسب، دقت خود را بهبود می‌بخشد [5]. شکل 21 نقش یادگیری نیمه‌نظارتی را در بهبود دقت خروجی برای یادگیری تقویتی عمیق [61] در آزمایش‌های مکانیابی داخل ساختمان نشان می‌دهد. در آزمایشات آنها، فقط 15% از داده‌ها دارای برچسب بودند، اما با بهره‌گیری از داده‌های بدون برچسب در الگوریتم، نتایج تقویت شدند.

5) تحلیل IoT قابل اتکا و قابل اطمینان:

با اتکای بیشتر بر CPS و IoT در مقیاس بزرگ، نیاز به سازوکارهایی برای حصول اطمینان از ایمنی سیستم در برابر حملات خرابکارانه و همچنین خرابی اهمیت بیشتری می‌یابد [222]. در این راستا می‌توان از طریق تحلیل حجم عظیم ردپاهای وقایع‌نگار سیستم‌های CPS و IoT، به منظور شناسایی و پیش‌بینی نقاط ضعف سیستم که در آنجا احتمال حمله یا نقص در عملکرد می‌رود، از رویکردهای DL استفاده کرد. این کار در پیشگیری یا ترمیم نقایص به سیستم کمک کرده و در نتیجه باعث افزایش میزان اتکاپذیری سیستم‌های CPS و IoT می‌شود.

6) شبکه‌های ارتباطی خودسازمانده:

با توجه به تعداد بسیار زیاد دستگاه‌های IoT، پیکربندی و نگهداری ارتباطات و شبکه M2M فیزیکی زمینه‌ای آنها سخت‌تر می‌شود. هرچند تعداد زیاد گره‌های شبکه و ارتباط آنها چالشی برای رویکردهای سنتی یادگیری ماشین است، اما فرصتی برای معماران DL مهیا می‌سازد تا با ارائه طیف وسیعی از کارهای خودکار مانند خودپیکربندی، خودبهبودسازی، خودترمیمی و توازن بار خودکار، شایستگی خود را در این زمینه به اثبات برسانند. والنته و همکاران [223] مروری بر رویکردهای سنتی یادگیری ماشین برای خودسازماندهی شبکه‌های سلولی ارائه کرده‌اند.

7) کاربردهای نوظهور IoT:

وسایل نقلیه هوایی بدون سرنشین: استفاده از وسایل نقلیه هوایی بدون سرنشین (پهپاد UAV) یک کاربرد امیدبخش است که می‌تواند ارائه خدمات در مناطق صعب‌العبور یا در شرایط وخیم را بهبود بخشد. پهپادها همچنین در بسیاری از کاربردهای تحلیل تصویر در زمان واقعی مانند کارهای نقشه‌برداری، عملیات جستجو و نجات، و بازرسی زیرساخت‌ها استفاده شده‌اند [224]. به کارگیری این دستگاه‌ها با چندین چالش روبروست، از جمله مسیریابی، صرفه‌جویی در مصرف انرژی، اجتناب از مناطق خصوصی و اجتناب از موانع [225] و غیره. DL می‌تواند تأثیر زیادی در این زمینه برای پیش‌بینی و تصمیم‌گیری در انجام وظایف جهت بهره‌برداری بهینه از پهپادها داشته باشد. علاوه بر این، پهپادها را می‌توان به عنوان پلتفرم‌های تحلیلی پروازی تلقی کرد که به‌طور بالقوه می‌توانند خدمات تحلیلی موقت رایانش مه و همچنین تحلیل توزیع شده ارائه دهند.

واقعیت مجازی/افزوده: واقعیت مجازی/افزوده حیطة کاربرد دیگری است که می‌تواند هم از IoT و هم از DL بهره گیرد. از دومی می‌توان در این حوزه جهت ارائه سرویس‌هایی مانند ردیابی شی [226]، تشخیص فعالیت، دسته‌بندی تصویر و تشخیص اشیا [227] و بسیاری موارد دیگر استفاده کرد. واقعیت افزوده می‌تواند تأثیر زیادی بر حوزه‌های متعددی از جمله آموزش، موزه‌ها، خودروهای متصل هوشمند، و غیره بگذارد.

روبات‌های سیار: از روبات‌های سیار در بسیاری از محیط‌های تجاری و صنعتی برای جابجایی مواد یا انجام کار در محیط‌های خطرناک استفاده می‌شود. از DL در کارهای پژوهشی زیادی به منظور توسعه نرم افزار کنترل هوشمند برای روبات‌های سیار استفاده شده است [228] [229]. توانایی ادراک محیط از طریق انواع حسگرهای مختلف، مانند لیدارها و دوربین‌ها، آنها را به مبحثی مهم برای ارزیابی کارایی تکنیک‌های CNN برای انواع کارهای مبتنی بر بینایی تبدیل کرده است. یک الزام جدی برای روبات‌های موبایل آن است که مدل‌های DL باید قادر به ارائه پاسخگویی در زمان واقعی باشند.

8. نتیجه‌گیری

DL و IoT در سالیان اخیر، توجه پژوهشگران فعالان تجاری را به خود جلب کرده، چرا که اثر مثبت این دو روند فناوری بر زندگی، شهرها، و جهان ما به اثبات رسیده است. IoT و DL یک زنجیره تولیدکننده - مصرفکننده داده‌ها را می‌سازند، که در آن IoT داده‌های خام تولید می‌کند که توسط مدل‌های DL تحلیل می‌شود و

مدل‌های DL انتزاع و بینش سطح بالا تولید می‌کنند که برای تنظیم دقیق و بهبود سرویس به سیستم‌های IoT خورنده می‌شود.

در این مقاله، خصوصیات داده‌های IoT و چالش‌های آن برای روش‌های DL را بررسی کردیم. به داده‌های سریع و جریان IoT و همچنین کلان داده IoT به‌عنوان دو دسته اصلی تولید داده IoT و الزامات آنها برای تحلیل به‌طور ویژه پرداختیم. همچنین چند معماری اصلی DL مورد استفاده در زمینه کاربردهای IoT و در ادامه تعدادی فریم‌ورک متن‌باز برای توسعه معماری DL ارائه دادیم. قسمتی دیگر از این مقاله شامل بررسی کاربردهای مختلف در بخش‌های مختلف IoT است که از DL استفاده کرده اند؛ در این زمینه، پنج سرویس بنیادی به همراه یازده حوزه کاربرد شناسایی کردیم. با تشخیص سرویس‌های بنیادی، و همچنین کاربردهای عمودی اینترنت اشیا و بررسی رویکردهای DL و موارد استفاده آنها، مبنایی برای سایر پژوهشگران به منظور درک اجزای اصلی سرویس‌های هوشمند IoT و به کارگیری تکنیک‌های مربوطه در مسائل خود ارائه کردیم. پارادایم جدید پیاده‌سازی DL در دستگاه‌های IoT بررسی شد و تعدادی رویکرد برای دستیابی به آن معرفی شد. DL مبتنی بر زیرساخت‌های مه و ابر برای پشتیبانی از کاربردهای IoT، قسمت دیگری از این مقاله بود. همچنین چالش‌ها و سمت‌وسوی تحقیقات آتی در مسیر DL برای کاربردهای IoT را شناسایی کردیم.

فهرست کلمات اختصاری

5G: نسل 5 (شبکه‌های سلولی)

AE: خودرمزگذار

AI: هوش مصنوعی

- AMQP: پروتکل پیشرفته صفبندی پیام
- ANN: شبکه عصبی مصنوعی
- BAC: کلسیفیکاسیون عروق پستان
- BLE: بلوتوث کم انرژی
- BPTT: پسانتشار در طول زمان
- CAE: خودرمزگذار انقباضی
- CDR: رکورد جزئیات تماس گیرنده
- CIFAR: موسسه تحقیقات پیشرفته کانادا
- CNN: شبکه عصبی پیچشی
- CoAP: پروتکل کاربردهای محدود شده
- CPS: سیستم سایبری-فیزیکی
- CRBM: ماشین بولتزمان محدود شرطی
- DAE: خودرمزگذار نویززا
- DBN: شبکه باور عمیق
- DL: یادگیری عمیق
- DNN: شبکه عصبی عمیق
- DNS-SD: کشف سرویس DNS
- DRL: یادگیری تقویتی عمیق
- ELM: یادگیری ماشین افراطی
- FDC: تشخیص و دسته‌بندی عیب
- FDI: تزریق داده غلط
- FNN: شبکه عصبی پیش‌خور
- GAN: شبکه خصمانه مولد
- GBM: ماشین تقویت‌کننده گرادیان
- GLM: مدل خطی تعمیم‌یافته
- GPU: واحد پردازش گرافیک

- HMM: مدل مارکوف پنهان
- HVAC: گرمایش، سرمایش و تهویه مطبوع
- INS: سیستم ناوبری اینرسی
- IoT: اینترنت اشیا
- IPA: دستیار شخصی هوشمند
- ITS: سیستم حمل‌ونقل هوشمند
- LSTM: حافظه کوتاه‌مدت طولانی
- M2M: ماشین به ماشین
- MAPE: میانگین قدرمطلق درصد خطا
- mDNS: DNS چندپخشی
- ML: یادگیری ماشین
- MLP: پرسپترون چندلایه
- MNIST: موسسه ملی استاندارد و فناوری اصلاح شده
- MOOC: دوره‌های درسی آنلاین باز جمعی
- MQTT: ترابرد دورسنجی صف پیام
- RBN: ماشین بولتزمان محدود
- ReLU: واحدهای خطی یکسو شده
- RL: یادگیری تقویتی
- RNN: شبکه عصبی بازگشتی
- SaaS: نرم افزار به‌عنوان سرویس
- SdA: خودرمزگذار نویززدای انباشته
- SGD: کاهش گرادیان تصادفی
- SVM: ماشین بردار پشتیبان
- SVR: رگرسیون بردار پشتیبان
- TPU: واحد پردازش تانسور
- UAV: وسیله نقلیه هوایی بدون سرنشین

VAE : خودرمزگذار متغیر

VGG : گروه هندسه بصری

VLC : ارتباط نور بصری

WSN : شبکه حسگر بی‌سیم

XMPP : پروتکل پیام‌رسانی و حضور توسعه‌پذیر