عنوان:

یادگیری ماشین و یادگیری عمیق

تاریخ انتشار: 2021

مجله: Springer

مترجم: سارینا آپرین، سپیده سالمی
وانیا زینت بخش، حنانه محمود آبادی

دپارتمان مهندسی پزشکی
@Department_BME

یادگیری ماشین و یادگیری عمیق

Christian Janiesch . Patrick Zschech . Kai Heinrich

مترجمین: سارینا آپرین . سپیده سالمی . وانیا زینت بخش . حنانه محمود آبادی

دریافت: ۱۳۹۹/۷/۱۶ | پذیرش: ۱۳۹۹/۱۲/۲۹

چکیده

امروزه، سیستم‌های هوشمند که قابلیت‌های هوش مصنوعی را ارائه می‌کنند اغلب به یادگیری ماشینی متکی هستند. "یادگیری ماشین" بیان‌گر توانایی سیستم‌هایی است که از داده های آموزشی دارای مشکل خاص استفاده کرده تا ساختِ مدل تحلیل‌پذیر و مسائل مربوط به آن به صورت خودکار انجام شود. یادگیری عمیق یک مفهوم از یادگیری ماشینی بر اساس شبکه‌های عصبی مصنوعی است. مدل‌های یادگیری سطحی و رویکردهای تحلیل داده‌های مرسوم برای بسیاری از کاربردهای مدل‌های یادگیری عمیق بهتر عمل می‌کنند. در این مقاله، ما اصول یادگیری ماشینی و یادگیری عمیق را خلاصه میکنیم تا درک گسترده‌تری از روش زیربنای سیستم‌های هوشمند فعلی ایجاد کنیم. به طور ویژه، ما یک تمایز مفهومی بین اصطلاحات مرتبط و مفاهیم فراهم می‌کنیم، فرآیند ساخت خودکار مدل تحلیل‌پذیر از طریق یادگیری ماشین و یادگیری عمیق را توضیح میدهیم، و درباره چالش هایی که زمان اعمال چنین سیستم‌های هوشمندی در بازار الکترونیک و تجارت شبکه‌ای به وجود می‌آید بحث می‌کنیم. این‌ها طبیعتاً فراتر از جنبه‌های تکنولوژی هستند و مسائل مربوط به تعامل انسان‌ها و ماشین‌ها و سرویس‌دهی هوش مصنوعی را برجسته می‌کنند.

واژگان کلیدی: یادگیری ماشینی . یادگیری عمیق . هوش مصنوعی . شبکه‌های عصبی مصنوعی . ساخت مدل تحلیل‌پذیر

طبقه‌بندی JEL C6 . C8 . M15 . O3

دپارتمان مهندسی پزشکی

dep-bme.com

صفحه ۲۱-۱، ۱۴۰۰

*مسئول مکاتبات: admin@dep-bme.com

مقدمه

مسئول ادیت: سارینا آپرین

زمانی که بخواهیم تفاوت یک ماشین اسپرت و یک ماشین معمولی را به یک کودک توضیح دهیم، باید در نظر بگیریم که اگر به جای تلاش برای فرمول‌بندی کردن قوانینی که یک ماشین اسپرت را تشکیل می‌دهد، راحت‌تر است که مثال‌هایی درباره ماهیت ماشین اسپرت و ماشین معمولی و اینکه از چه چیزهایی تشکیل شدند نشان دهیم.

به‌طور مشابه، به جای کدگذاری کردن دانسته‌ها در کامپیوترها، یادگیری ماشین (ML) به دنبال این است تا به صورت خودکار رابطه‌ها و الگوهای معنادار از مثال‌ها و نظریه‌ها را یاد بگیرد (Bishop 2006). پیشرفت‌های اخیر در ML سیستم های هوشمندی با توانایی آگاهی و شناسایی مانند انسان‌ها را فراهم کرده است که وارد زندگی کاری و شخصی ما می‌شوند و تعاملات شبکه‌ای را در بازارهای الکترونیکی به تمام شیوه‌های ممکن شکل می‌دهند، همراه با افزایش تصمیم‌گیری شرکت‌ها برای بهره‌وری، پیوند، و حفظ کارمندان (Shrestha et al. 2021)، سیستم‌های دستیارِ آموزش‌پذیرِ سازگار با تنظیمات شخصی کاربر (Fischer et al. 2020)، و تجارت عواملی که بازارهای معاملات مالی سنتی را تکان می‌دهند (Jayanth Balaji et al. 2018).

توانایی چنین سیستم‌هایی برای حل پیشرفته مشکلات، که به طور کلی هوش مصنوعی (AL) نامیده می‌شود، بر اساس مدل‌های تحلیل‌پذیر است که پیش بینی‌ها، قوانین، پاسخ‌ها، پیشنهادات، یا نتایج مشابه را تولید می‌کنند. اولین تلاش‌ها برای ساختن مدل‌های تحلیل‌پذیر به صراحت برنامه‌نویسی که به عنوان روابط، روش‌ها و منطق تصمیم‌گیری در سیستم های هوشمند از طریق قوانین دست‌ساز بود، متکی بودند (به عنوان مثال، سیستم‌های ویژه برای تشخیص بیماری) (Russell and Norvig 2021). با تقویت شدن قابلیت عملی بودن چارچوب‌های برنامه نویسی جدید، در دسترس بودن داده‌ها، و دسترسی گسترده به قدرت پردازش لازم، امروزه مدل های تحلیل‌پذیر بیشتر با استفاده از چیزی که به طور کلی با اسم ML شناخته می‌شود، ساخته می‌شوند (Brynjolfsson and McAfee 2017; Goodfellow et al. 2016). ML بار توضیح دادن را از روی دوش انسان برمیدارد و دانش او را به شکلی که قابل دسترسی ماشین باشد، شکل می‌دهد و اجازه می‌دهد تا سیستم‌های هوشمند به صورت کارآمدتری توسعه داده شوند.

طی دهه های گذشته، عرصه ML انواع پیشرفت‌های قابل توجهی را در الگوریتم‌های یادگیری پیچیده و تکنیک های پیش پردازش کارآمد به ارمغان آورده است. یکی از این پیشرفت‌ها تکامل شبکه عصبی مصنوعی (ANNs) به سمت معماری شبکه عصبی عمیق با توانایی یادگیری پیشرفته خلاصه شده با عنوان یادگیری عمیق (DL) است (Goodfellow et al. 2016; LeCun et al. 2015). در حال حاضر، برای کاربردهای ویژه در محیط‌های بسته، DLبا بهتر کردن توانایی‌های انسان، عملکرد فوق بشری نشان می‌دهد (Madani et al. 2018; Silver et al. 2018). با این حال، چنین مزایایی بهایی نیز دارد، زیرا برای اجرای موفقیت آمیز مدل های تحلیل‌پذیر در محیط های تجاری واقعی باید بر چالش های زیادی غلبه کرد. این چالش ها، شامل برگزیدن بهترین انتخاب از میان گزینه‌های زیاد و متنوع، زیر و رو کردن داده‌ها، کاهش دارایی‌های جعبه سیاه (Black box)، و استفاده مجدد از مدل‌های از پیش تنظیم شده است.

صرف نظر از ظاهر تبلیغاتی آن، دانشمندان و حرفه ای‌ها نیازمند یک فهم قوی از مفاهیم اساسی، پروسه‌هایی و مخصوصاً چالش هایی برای اجرای چنین تکنولوژی هستند. علیرغم این زمینه، هدف از این مقاله این است که یک درک اساسی از ML و DL را در موقعیت بازارهای الکترونیکی منتقل کند. به این صورت، جامعه می‌تواند از این دستاوردهای فنی سود ببرد – چه به هدف بررسی کردن دارایی‌های داده‌های بزرگ و چند بعدی جمع آوری شده در اکوسیستم دیجیتال یا برای طراحی سیستم‌های هوشمند جدید برای بازارهای الکترونیکی. به دنبالِ پیشرفت های اخیر این زمینه، این مقاله روی ساختن مدل‌های تحلیلی و چالش‌های اجرای سیستم هوشمند بر اساس ML و DL تمرکز می‌کند. زمانی که این زمینه را از دیدگاه فنی بررسی می‌کنیم، درباره موارد مرتبط با پذیرش هوش مصنوعی، سیاست و تاثیر آن بر سازمان توضیح نمی‌دهیم (برای مفاهیم بیشتر مقایسه کنید با Stone et al. 2016)

در بخش بعدی، یک تمایز مفهومی بین اصطلاحات و مفاهیم مرتبط فراهم می‌کنیم. سپس، پروسه ساخت مدل تحلیل‌پذیر خودکار را با برجسته کردن خصوصیات ML و DL، بررسی می‌کنیم. پس از آن، به بحث کردن درباره چالش‌های بسیاری که هنگام اجرای سیستم‌های هوشمند درون سازمان‌ها یا بازارهای الکترونیکی اتفاق می‌افتد، ادامه می‌دهیم. به این ترتیب، ما به جای آن که سیستم های مهندسی شده را به عنوان تنها دیدگاه بررسی کنیم، به فاکتورهای محیطی اجرایی و کاربردی توجه می‌کنیم. سپس مقاله را با یک نتیجه‌گیری مختصر، خلاصه می‌کنیم.

تمایز مفهومی

برای ارائه یک درک اساسی از این رشته لازم است چندین اصطلاح و مفهوم مرتبط را از یکدیگر متمایز کرد. برای این منظور ابتدا پایه های اساسی هوش مصنوعی را ارائه کنیم قبل از اینکه الف) الگوریتم های یادگیری ماشین، ب) شبکه های عصبی مصنوعی و ج) شبکه های عصبی عمیق را تشخیص دهیم. رابطه سلسله مراتبی بین این اصطلاحات در نمودار وِن در شکل ۱ خلاصه شده است.

به طور کلی هوش مصنوعی شامل هر تکنیکی است که رایانه‌ها را قادر می سازد تا رفتار انسانی برتر پیدا کنند، تا بتوانند وظایف پیچیده را به طور مستقل یا با حداقل مداخله انسانی حل کنند (Russel Norvig 2021). به این ترتیب به انواع مشکلات مرکزی از جمله بازنمایی دانش، استدلال، یادگیری، برنامه‌ریزی، ادراک و ارتباطات مربوط می شود و به ابزارها و روش‌های مختلفی اشاره می کند (به عنوان مثال استدلال مبتنی بر حالات، سیستم های مبتنی بر قانون، الگوریتم های ژنتیکی، مدل های فازی، سیستم های چند عاملی) (Chen et al. 2008)

تحقیقات اولیه هوش مصنوعی عمدتاً بر روی عبارات رمزگذاری شده در زبان های رسمی متمرکز بود، که یک کامپیوتر می‌تولند بعداً به طور خودکار بر اساس قوانین استنتاج منطقی درباره آنها استدلال کند. این همچنین به عنوان رویکرد بر پایه دانش شناخته می شود (Goodfellow et al. 2016).

شکل ۱. نمودار ون مفاهیم و کلاس های یادگیری ماشین (الهام گرفته شده از Goodfellow et al. 2016, p. 9)

با این حال این پارادایم (Paradigm) با محدودیت های متعددی مواجه است زیرا انسان ها به طور کلی تلاش میکنند تا تمام دانش ضمنی خود را که برای انجام وظایف پیچیده مورد نیاز است توضیح دهند (Brynjolfsso McAfee 2017). یادگیری ماشینی بر چنین محدودیت هایی غلبه می کند. به طور کلی بخواهیم بگوییم، یادگیری ماشین (ML) به این معنی است که عملکرد یک برنامه کامپیوتری با تجربه و توجه به برخی از کلاس ها و معیار های عملکرد بهبود می یابد (Jordan and Mitchell 2015). به این ترتیب، هدف آن خودکارسازی کار ساخت مدل تحلیلی برای انجام وظایف شناختی مانند تشخیص شی یا ترجمه زبان طبیعی است. این امر با استفاده از الگوریتم‌هایی که به طور مکرر از داده‌های اموزشی ویژه مسئله یاد میگیرند به دست می آید که به کامپیوترها اجازه می‌دهد تا بینش‌های پنهان و الگوهای پیچیده را بدون برنامه‌ریزی صریح پیدا کنند (Bishop 2006). به خصوص در کارهای مربوط به داده‌های دارای ابعاد بالا مانند طبقه‌بندی، رگرسیون، و خوشه‌بندی، ML کاربرد خوبی نشان می‌دهد. با یادگیری از محاسبات قبلی و استخراج قوانین از پایگاه‌های داده عظیم میتوان به تولید تصمیمات قابل اعتماد و قابل تکرار کمک کرد. به همین دلیل، الگوریتم‌های ML با موفقیت در بسیاری از زمینه‌ها مانند تشخیص کلاهبرداری، امتیازدهی اعتبار، تجزیه و تحلیل بهترین پیشنهادات بعدی، تشخیص گفتار و تصویر، یا پردازش زبان طبیعی (NLP)، به کار گرفته شده‌اند.

بر اساس مشکل داده شده و داده‌های موجود، می‌توانیم سه نوع ML را تشخیص دهیم: یادگیری نظارت شده، یادگیری بدون نظارت و یادگیری تقویتی. در حالی که بسیاری از برنامه های کاربردی در بازار های الکترونیکی از یادگیری نظارت شده استفاده می کنند (Brynjolfsson McAfee 2017)، به عنوان مثال، برای پیش‌بینی بازار های سهام (Jayanth Balaji et al. 2018)، برای درک استنباط مشتری (Ramaswamy DeClerck 2018)، برای تجزیه و تحلیل نیازهای مشتری(Kuhl et al. 2020)، یا برای جستجوی محصولات (Bastan et al. 2020)، روش‌های پیاده سازی متنوعی وجود دارد، به عنوان مثال، بازار سازی با یادگیری تقویتی (Spooner et al. 2018) یا تقسیم‌بندی بازار بدون نظارت با استفاده از نظرات

مشـــتریان (Ahani et al. 2019). برای مرور کلی هر سه نوع به جدول ۱ مراجعه کنید.

بسـته به فرآیند یادگیری، این رشـته کلاس‌های مختلفی از الگوریتم‌های ML را ارائه می‌کنـد، کـه هر یـک دارای مشـخصـات و انواع مختلفی هسـتند، از جمله مدل‌های رگرســیون، الگوریتم های مبتنی بر نمونه، درخت‌های تصمیم، روش‌های بیزی (Bayesian) و ANNs.

خانواده شبکه‌های عصبی مصنوعی، از آنجایی که ساختار انعطاف‌پذیرشـان اجازه می‌دهد تا برای طیف گسـترده‌ای از زمینه‌ها در هر ســـه نوع ML تغییر کنند، از اهمیت خاصـی برخوردار اسـت. ANNs با الهام از اصـل پردازش اطلاعات در سیستم‌های بیولوژیکی از نمایش‌های ریاضی واحدهای پردازش متصـــل به نام نورون‌های مصـــنوعی تشکیل شده‌اند. مانند سیناپس‌ها در مغز، هر ارتباط بین نورون‌ها ســـیگنال‌هایی را منتقل می‌کند که قدرت آنها می تواند توســـط وزنی که به طور مداوم در طول فرآیند یادگیری تنظیم می‌شـود، تقویت یا کاهش یابد. سـیگنال ها تنها زمانی توسـط نورون های بعدی پردازش می‌شـوند که از آسـتانه مشـخصـی که توسـط یک تابع فعال سـازی تعیین می‌شـــود فراتر رود. بـه طور معمول، نورون‌هـا در شبکه‌هایی با لایه‌های مختلف سازماندهی می شوند. یک لایه ورودی معمولاً ورودی داده‌ها را دریافت می کند (به عنوان مثال، تصـاویر محصـولات یک فروشـگاه آنلاین) و یک لایه خروجی نتیجه نهایی را تولید می‌کند (به عنوان مثال دسـته‌بندی محصـولات). در این بین صـفر یا چند لایه مخفی وجود دارد که وظیفه یادگیری یک نگاشـــت غیر خطی بین ورودی و خروجی را بر عهـده دارنـد (Bishop 2006; Goodfellow et al. 2016). تعداد لایه‌ها و نورون‌ها، در میان گزینه‌های ویژگی دیگر، مانند نرخ یادگیری یا تابع فعال‌سازی، توسط الگوریتم یادگیری قابل یادگیری نیســـت. آنها فراپارامترهای یک مدل را تشـکیل می‌دهند و باید به صـورت دسـتی تنظیم شـوند یا توسط یک روال بهینه‌سازی، تعیین شوند.

شبکه‌های عصبی عمیق معمولاً از بیش از یک لایه پنهان تشـکیل شـده‌اند، که در معماری‌های شـبکه، به صـورت عمیق، تودرتو سـازمان دهی شـده‌اند. علاوه بر این، آنها معمولاً در مقایســـه با ANNs ســـاده، حاوی نورون‌های پیشـــرفته‌تری هســـتند. یعنی، ممکن اســـت از عملیات پیشرفته (مثلا پیچش) یا فعال‌سازی های مختلف در یک نورون به جای یک تابع فعال‌سازی ساده، اسـتفاده کنند. این ویژگی‌ها به شـبکه‌های عصـبی عمیق اجازه می‌دهند تا با داده‌های ورودی خام تغذیه شـوند و به طور خودکار نمایشـــی را کشـــف کنند که برای کار یادگیری مربوطه، نیاز اسـت. این قابلیت اصـلی شـبکه اسـت که معمولاً به عنوان یادگیری عمیق شـناخته می شـود. ANNs سـاده (مثلاً، رمز گـذاری هـای خودکـار کم عمق) و ســـایر الگوریتم‌های ML (مثلاً، درختان تصـــمیم) را می توان تحت عنوان یادگیری ماشـینی کم عمق قرار داد. زیرا آنها چنین عملکردهایی را ارائه نمی دهند. از آنجایی که هنوز هیچ مرزبندی دقیقی بین این دو مفهوم در ادبیات وجود ندارد، (به Schmidhuber 2015 نیز مراجعه کنید) در شـکل ۱ از خط چین اسـتفاده می کنیم. در حالی که برخی از الگوریتم‌های کم عمق ML به طور ذاتی توسـط انسـان قابل تفسـیر هسـتند و بنابراین جعبه‌های سـفید تصـــمیم‌گیری در اکثر الگوریتم‌های پیشـــرفته ML به خودی خود غیر قابل ردیابی هسـتند، مگر اینکه توضـیح دیگری داده شـود و، بنابراین، یک جعبه سـیاه را تشـکیل می‌دهد.

جدول ۱. نگاه کلی به انواع یادگیری ماشین

طبقه‌بندی	توضیحات
یادگیری تحت نظارت	*یادگیری تحت نظارت* به یک مجموعه داده آموزشی نیاز دارد که نمونه‌هایی برای ورودی و همچنین پاسخ‌های برچسب‌گذاری شده یا مقادیر هدف برای خروجی را پوشش می‌دهد. یک مثال می‌تواند پیش‌بینی کاربران فعالی، که برای یک ماه در یک پلتفرم تجاری، اشتراک خریده‌اند باشد، به عنوان خروجی که (به عنوان متغیر هدف یا متغیر y در نظرگرفته می شود) بر اساس ویژگی‌های ورودی مختلف مانند تعداد محصولات فروخته شده یا نظرات مثبت کاربران، (اغلب به آنها به عنوان ویژگی‌های ورودی یا متغیر x اشاره می‌شود). سپس از جفت داده‌های ورودی و خروجی در مجموعه آموزشی برای کالیبره کردن پارامترهای باز مدل ML استفاده می شود. هنگامی که مدل با موفقیت آموزش داده شد، می‌توان از آن برای پیش‌بینی متغیر هدف y با توجه به نقاط داده جدید یا، بدون دیدن ویژگی های ورودی x استفاده کرد. با توجه به نوع یادگیری تحت نظارت می‌توانیم بین مسائل رگرسیون که در آن یک مقدار عددی پیش‌بینی میشود (مثلا تعداد کاربران) و مشکلات طبقه‌بندی که در آن نتیجه پیش‌بینی یک وابستگی طبقه طبقه‌ای مانند "نگاه کنندگان" یا "خریداران" تمایز قائل شویم.
یادگیری بدون نظارت	*یادگیری بدون نظارت* زمانی اتفاق می‌افتد که سیستم یادگیری قرار است الگوهایی را بدون هیچ برچسب یا مشخصات قبلی شناسایی کند. بنابراین داده‌های آموزش تنها شامل متغیرهای x با هدف یافتن اطلاعات ساختاری مورد علاقه، مانند گروه‌هایی از عناصری هستند که ویژگی‌های مشترکی دارند (که به عنوان خوشه‌بندی شناخته می شوند) یا نمایش داده‌هایی که از یک فضای با ابعاد بالا به فضای پایین تر نمایش داده می شوند. به عنوان کاهش ابعاد شناخته می شوند (Bishop 2006). یک مثال برجسته از یادگیری بدون نظارت در بازارهای الکترونیکی، استفاده از تکنیک‌های خوشه‌بندی برای گروه‌بندی مشتریان یا بازارها به بخش‌هایی به منظور ارتباط خاص گروه هدف است.
یادگیری تقویتی	در یک سیستم *یادگیری تقویتی*، به جای ارائه یک جفت ورودی و خروجی، وضعیت فعلی سیستم را توصیف می‌کنیم، یک هدف را مشخص می‌کنیم، فهرستی از اقدامات مجاز و محدودیت‌های محیطی آنها را برای نتایج آنها ارائه می‌دهیم، و به مدل ML اجازه می‌دهیم که فرآیند دستیابی به هدف را، با استفاده از اصل آزمون و خطا برای به حداکثر رساندن پاداش، تجربه کند. مدل‌های یادگیری تقویتی با موفقیت زیادی در محیط‌های بسته جهان مانند بازی‌ها به کار گرفته شده‌اند (Silver et al. 2018)، اما آنها همچنان با سیستم‌های چند عاملی مانند بازارهای الکترونیکی مرتبط هستند (Peters et al. 2013).

پس DL مخصوصاً در حوزه‌هایی با داده‌های بزرگ و ابعاد بالا مفید است. به همین دلیل است که شبکه‌های عصبی عمیق برای اکثر برنامه‌هایی که در آن داده‌های متن، تصویر، ویدیو، گفتار و صدا باید پردازش شوند، بهتر از الگوریتم های ML کم عمق عمل می کنند (LeCun et al. 2015).

با این حال برای ورودی داده‌های کم بعد، به ویژه در مواردی که در دسترس بودن داده‌های آموزشی محدود است، ML کم عمق همچنان می تواند نتایج برتری ایجاد کند (Zhang and Ling 2018)، که حتی قابلیت تفسیر بهتری نسبت به آنچه توسط شبکه‌های عصبی عمیق ایجاد می‌شود است (Rudin 2019).

علاوه بر این در حالی که عملکرد DL می‌تواند مافوق بشری باشد، مشکلاتی که به قابلیت‌های هوش مصنوعی قوی مانند درک تحت اللفظی و عمدی نیاز دارند، هنوز نمیتوانند حل شوند. همانطور که در استدلال اتاق چینی Searle (1980) به طور مشخص بیان شده است.

فرآیند ساخت مدل تحلیلی

در این بخش ما چارچوبی را در مورد فرآیند ساخت مدل تحلیلی برای برنامه نویسی صریح، ML کم‌عمق و DL ارائه می کنیم، زیرا سه مفهوم متمایز برای ساخت یک مدل تحلیلی را تشکیل می دهند (شکل ۲ را ببینید). با برنامه نویسی صریح استخراج ویژگی و ساخت مدل به صورت دستی توسط انسان هنگام ایجاد قوانین دست‌ساز برای مشخص کردن مدل تحلیلی انجام میشود.

ورود اطلاعات

بازارهای الکترونیکی نقاط تماس مختلفی را در بر میگیرند، مانند وب سایت‌ها، برنامه‌ها، و پلتفرم‌های رسانه‌های اجتماعی. جدای از داده‌های عددی رایج، آنها حجم وسیعی از داده‌های همه کاره، به ویژه داده‌های بدون ساختار و غیر مقطعی مانند سری‌های زمانی، تصویر و متن را تولید می کنند. این داده‌ها را می‌توان برای ساخت مدل تحلیلی به منظور پشتیبانی تصمیم‌گیری بهتر یا اهداف اتوماسیون تجاری، مورد بهره برداری قرار داد. با این حال، استخراج الگوها و روابط به صورت دستی، از ظرفیت شناختی اپراتورهای انسانی فراتر می رود. به همین دلیل است که پشتیبانی الگوریتمی هنگام برخورد با داده‌های بزرگ و با ابعاد بالا ضروری است.

داده های سری زمانی دلالت بر یک وابستگی و الگوهای متوالی در طول زمان دارد که باید برای شکل‌دهی پیش‌بینی‌ها شناسایی شوند، که اغلب منجر به مشکلات رگرسیونی یا وظایف طبقه‌بندی روند می‌شوند. نمونه‌های معمولی شامل پیش‌بینی بازارهای مالی یا پیش‌بینی رفتار فرایندی است (Heinrich et al. 2021). داده‌های تصویری اغلب در زمینه تشخیص اشیا یا شمارش اشیا با زمینه‌های کاربردی از تشخیص محصول برای پیش‌بینی عملکرد تا رلنندگی خودران مواجه می‌شوند (Grigorescu et al. 2020). داده‌های متنی هنگام تجزیه و تحلیل حجم زیادی از اسناد، مانند ایمیل‌های شرکتی یا پست‌های رسانه‌های اجتماعی وجود دارند. به عنوان مثال، کاربردهای آن عبارتند از تجزیه و تحلیل احساسات یا ترجمه ماشینی و خلاصه کردن اسناد (Young et al. 2018).

پیشرفت های اخیر در DL امکان پردازش داده‌ها از انواع مختلف را به صورت ترکیبی فراهم میکند، که اغلب به عنوان یادگیری متقابل از آن یاد می‌شود. این در برنامه‌هایی مفید است که محتوا در معرض اشکال مختلف نمایش است، مانند وب سایت های تجارت الکترونیک که اطلاعات محصول معمولاً با تصاویر، توضیحات مختصر و سایر متادیتاهای متنی تکمیلی نشان داده می‌شود. هنگامی که چنین بازنمایی‌های متقابلی آموخته می‌شوند، می‌توان از آن‌ها، مثلاً، برای بهبود وظایف بازیابی و توصیه، یا شناسایی اطلاعات نادرست و تقلب استفاده کرد (Bastan et al. 2020).

استخراج ویژگی

یک قدم مهم برای شناسایی کردن الگوها و روابط از منابع داده‌های بزرگ به صورت خودکار، استخراج ویژگی‌هاییست که می‌توانند برای ساختن مدل به کار

گرفته شوند. به صورت کلی، یک ویژگی، خصوصیتی را توصیف می‌کند که از داده‌های ورودی خام با هدف فراهم کردن یک ارائه مناسب به دست آمده. بنابراین، هدف استخراج ویژگی این است که اطلاعات نادرست را نگه داریم و عوامل تغییر مرتبط با یادگیری کلی فرآیند را جدا کنیم (Goodfellow et al. 2016). به عنوان مثال، زمان طبقه بندی کردن نظرات مفید مشتریان درباره یک آنلاین شاپ، موارد مناسب مفید می‌توانند انتخاب کلمات، طول نظر مشتری، و نحوه بیان خصوصیات در متن باشند.

ML کم عمق [Shallow ML] به شدت به چنین ویژگی‌های معینی متکی است، و بنابراین اجرای آن به یک فرآیند استخراج موفق وابسته است. تکنیک های متعددی برای استخراج ویژگی در طول زمان مطرح شدند که قابل اعمال روی انواع مختلفی از داده‌ها هستند. به عنوان مثال، هنگام تحلیل داده‌هایی در یک سری زمانی، اعمال کردن تکنیک‌هایی برای استخراج ویژگی‌های دامنه زمانی (مثلاً، میانگین، برد، معیار عدم تقارن در توزیع) و ویژگی‌های دامنه فراولنی (مثلاً، پیوستگی فراوانی) (Goyal and Pabla 2015)؛ برای تحلیل تصویر رویکردهای مناسب شامل هیستوگرام‌های شیب‌دار (HOG) (Dalal and Triggs 2005)، تبدیل ویژگی مقیاس نابسته (SIFT) (Lowe 2004)، و روش Viola-Jones می‌باشد (Viola and Jones 2001)؛ و در NLP (Natural language processing یا فرآیند زبان طبیعی)، استفاده از تعداد تکرار یک کلمه – برعکسِ تعداد تکرار در متون (TF-IDF)، بردار کلمات (Salton and Buckley 1988)، بیان نوع کلمه (POS)، و ویژگی‌های ماهیت یک کلمه (Wu et al. 2018). طراحی دستی ویژگی، کار خسته‌کننده‌ای است که معمولاً نیازمندِ تخصص در حوزه ویژه کاربرد فرآیند مهندسی می‌باشد. به همین دلیل، وقت‌گیر، پر زحمت و سخت در نظر گرفته می‌شود.

شبکه های عصبی عمیق با این محدودیت ویژگی مهندسی دست‌ساز کنار می‌آیند. معماری پیشرفته آنها، به آنها قابلیت یادگیری ویژگی‌های خودکار برای تفکیک کردن خصوصیات نمایش داده شده با کمترین میزان تلاش یک انسان می‌دهد. به همین دلیل DL بهتر می‌تولند به داده‌های زیاد، شلوغ، و طبقه‌بندی نشده رسیدگی کند. به طور کلی، فرآیند فراگیری ویژگی، به صورت زنجیره‌وار، و با جمع آوری ویژگی‌های چکیده سطح بالا و ادغام آنها با موارد ساده‌تر انجام می‌شود. با این حال، بسته به نوع داده‌ها و انتخا معماری DL، راهکارهای مختلفی برای یادگیری ویژگی در ارتباط با مرحله ساخت مدل وجود دارد.

ساخت مدل

طی ساخت مدل خودکار، ورودی توسط یک الگوریتم یادگیری استفاده می‌شود تا الگوها و روابطی که مرتبط با امر یادگیری است را شناسایی کند. همانطور که در بالا نیز بیان شد، برای این فرآیند، ML کم عمق (Shallow ML) نیازمند خصوصیاتی است که خوب طراحی شده باشد. بر این اساس، هر گروه از الگوریتم های یادگیری، روش‌های مختلفی برای ساخت مدل‌های تحلیلی اعمال می‌کنند. به عنوان مثال، هنگام ساخت یک مدل طبقه‌بندی شده، الگوریتم‌های درخت تصمیم، با تقسیم کردنِ تدریجی داده‌های ثبت شده و تفکیک کردن آنها به صورت همگن، به دنبال همدیگر و به شکل طبقاتی و درختی، بهترین استفاده را از فضای ویژگی‌ها می‌کنند. یک ماشین بردار پشتیبانی (Support vector machines – SVM) به دنبال ساختن یک اَبَر صفحه تشخیص‌دهنده میان داده‌های طبقات مختلف است که

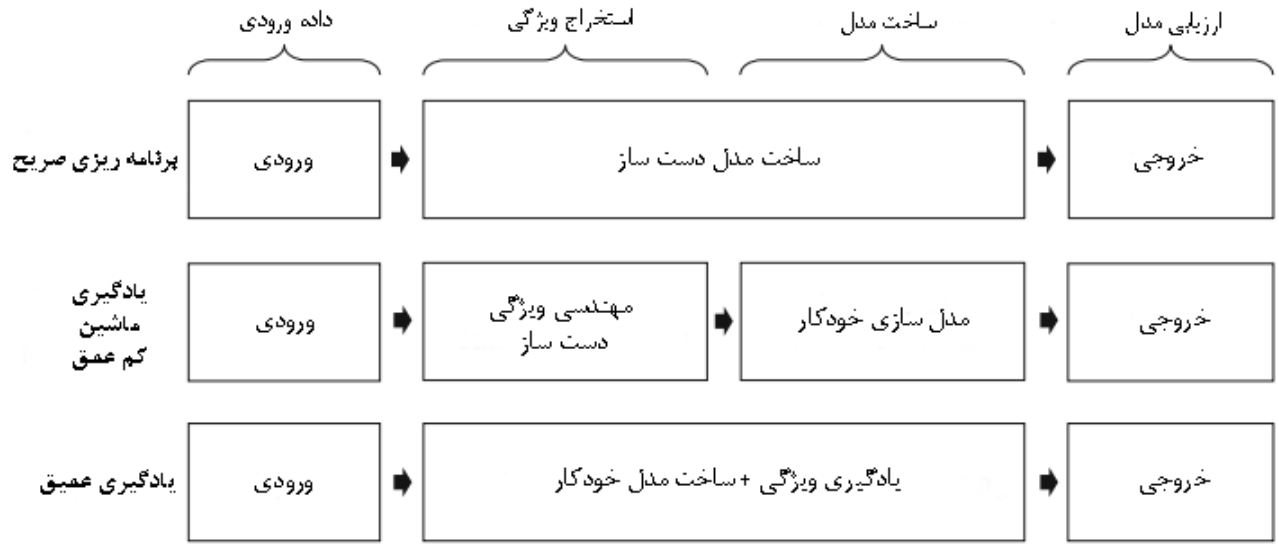

شکل ۲. فرآیند ساخت مدل تحلیلی (الهام گرفته شده از Goodfellow et al. 2016, p.10)

اغلب داده ورودی آنها به ویژگی سطح بالاتری برای تفکیک‌سازی بهتر، وارد می‌شوند. این مثال‌ها نشان می‌دهند که راه‌های مختلفی برای ساختن مدل تحلیل‌پذیر است، که هر کدام از آنها به نسبت دادهای ورودی و ویژگی‌هایشان، سود و زیان خودشان را دارند (Kotsiantis et al. 2006).

در مقابل، DL با توانایی یادگیری ویژگی خودکار خود، می‌تواند به صورت مستقیم موجبِ اجرای فرآیند ساخت مدل با داده ورودی خام شود. بنابراین، ساختار DL معمولاً به شکل سیستم‌های به هم پیوسته است که هر دو جنبه آن در یک خط، با هم ادغام می‌شوند. با این وجود، DL تنها می‌تواند برای استخراج یک ویژگی عرضه شده، که متعاقباً وارد یک زیرسازه یادگیری دیگر می‌شود، اعمال شود تا از نقاط قوت الگوریتم‌های ML رقیب، مانند درخت تصمیم‌گیری یا SVMs [ماشین بردار پشتیبانی]، استفاده بهینه کند.

ساختارهای متنوعی از DL به وجود آمدند (Leijnen and van Veen 2020; Pouyanfar et al. 2019; Young et al. 2018). با اینکه اساساً، همه ساختارها می‌توانند برای هر فرآیندی استفاده شوند، اما برای بعضی داده‌های خاص، مانند داده‌های سری زمانی یا تصویری، برخی ساختارها مناسب‌ترند. انواع مختلف معماری اکثراً با نوع لایه‌ها، بخش‌های عصبی، و ارتباطاتی که استفاده میکنند مشخص می‌شوند. نمودار شماره دو، پنج گروه از شبکه‌های عصبی پیچشی (CNNs)، شبکه عصبی بازگشتی (RNNs)، بازنمایی‌های توزیع‌شده، کدگذاری به صورت خودکار، و شی=بکه‌های مولد تخاصمی (GANs) را به صورت خلاصه نشان می‌دهد. این پنج گروه، کاربردهای امیدوار کننده‌ای در ارتباط با بازار الکترونیک فراهم می‌کنند.

ارزیابی مدل

برای ارزیابی کیفیت یک مدل ، چندین جنبه باید در نظر گرفته شود، مانند عملکرد، منابع محاسباتی و قابلیت تفسیر.

معیارهای مبتنی بر عملکرد ارزیابی میکند که چگونه یک مدل؛ هدف مشخص شده توسط کار یادگیری را برآورده می کند. در حوزه یادگیری تحت نظارت، دستورالعمل‌های کاملاً ثابتی براین منظور وجود دارد. در اینجا، استفاده از اعتبارسنجی مقاطع ***k-fold*** برای جلوگیری از برازش بیش از حد یک مدل و تعیین عملکرد آن در داده‌های خارج از نمونه ،که در نمونه‌های آموزشی گنجانده نشده است، معمولی خواهد بود. اعتبارسنجی متقابل، فرصتی را برای مقایسه قابلیت اطمینان مدل‌های ML، با ارائه نمونه‌های چندگانه داده‌های خارج از دامنه مورد نظر فراهم می‌کند که آزمایش‌های آماری مقایسه‌ای را ممکن می‌سازد (Garcia and Herrera 2008). مدل‌های رگرسیون با اندازه‌گیری خطاهای تخمینی مانند ریشه میانگین مربعات خطا (RMSE) یا میانگین درصد مطلق خطا (MAPE) ارزیابی می‌شوند، در حالی که مدل‌های طبقه‌بندی با محاسبه نسبت‌های مختلف نمونه‌های پیش‌بینی‌شده درست و نادرست، مانند دقت، یادآوری و امتیاز ***F1*** ارزیابی می‌شوند. علاوه بر این، استفاده از معیارهای حساس به هزینه مانند میانگین هزینه به ازای هر مشاهده پیش‌بینی‌شده، رایج است؛ که در موقعیت‌هایی که خطاهای پیش‌بینی با ساختارهای هزینه نامتقارن مرتبط هستند، مفید و قابل استفاده خواهد بود. (Shmueli and Koppius 2011). به عنوان مثال، در هنگام تجزیه و تحلیل معاملات در بازارهای مالی، هزینه های **عدم شناسایی یک معامله متقلبانه** به طور قابل ملاحظه ای بیشتر از هزینه های طبقه بندی نادرست **یک تراکنش غیر متقلبانه** است.

برای شناسایی یک مدل پیش‌بینی مناسب برای یک کار خاص، منطقی است که مدل‌های جایگزین با پیچیدگی‌های متفاوت را مقایسه کنیم، این به این معناست که کلاس‌های مدل رقیب و نیز انواع جایگزین از همان کلاس مدل را در نظر بگیریم. همانطور که در بالا معرفی شد، پیچیدگی یک مدل را می توان با ویژگی های مختلفی مانند نوع مکانیسم های یادگیری(به عنوان مثال، ML کم عمق در مقابل DL)، تعداد و نوع ویژگی های تولید شده یا استخراج شده دستی، و تعداد پارامترهای قابل آموزش، مشخص کرد. مانند وزن شبکه در شبکه های عصبی مصنوعی. مدل‌های ساده‌تر معمولاً به اندازه کافی انعطاف‌پذیر نیستند تا قوانین و الگوهای (غیر خطی) مرتبط با کار یادگیری را به تصویر بکشند. از سوی دیگر، مدل‌های بیش از حد پیچیده، خطر بیشتری برای نصب بیش از حد دارند. علاوه بر این، تفسیر استدلال آنها دشوارتر است (به بخش بعدی مراجعه کنید)، و احتمالاً از نظر محاسباتی گران‌تر هستند. هزینه های محاسباتی توسط نیازهای حافظه و زمان استنتاج برای اجرای یک مدل بر روی داده‌های جدید بیان می‌شود. این معیارها به ویژه هنگام ارزیابی شبکه‌های عصبی عمیق، که در آن چندین میلیون پارامتر مدل ممکن است پردازش و ذخیره شود، که تقاضاهای ویژه ای را برای منابع سخت افزاری ایجاد می کند، مهم هستند. در نتیجه، برای محیط‌های تجاری با منابع محدود (مانند محیط‌هایی که به شدت به دستگاه‌های تلفن همراه متکی هستند) بسیار مهم است که نه تنها یک مدل را در نقطه‌ای شیرین بین کم‌تنظیم شدن و بیش‌برازندگی انتخاب کنند. آنها همچنین باید پیچیدگی یک مدل را در رابطه با روابط مبادله بیشتر، مانند دقت در مقابل استفاده از حافظه و سرعت، ارزیابی کنند (Heinrich et al. 2019).

معماری (ساختار)	تعریف
شبکه عصبی کانولوشنال (Convolutional neural network)	CNNها عمدتاً برای کارهای مربوط به بینایی رایانه و تشخیص گفتار استفاده می شوند. آنها می‌توانند وظایف مربوط به مجموعه داده‌ها را با روابط فضایی، جایی که ستون‌ها و ردیف‌ها قابل تعویض نیستند، رسیدگی کنند (به عنوان مثال، داده‌های تصویر). هنگامی که تشخیص اشیاء در تصاویر را در نظر می گیریم، چند لایه اول شبکه مسئول استخراج ویژگی های اساسی در قالب لبه ها و گوشه ها هستند، و سپس به صورت تدریجی در ویژگی های پیچیده تر در چند لایه آخر که شبیه اشیاء مورد نظر واقعی هستند، جمع می شوند. به عنوان حیوانات، خانه‌ها یا اتومبیل‌ها، متعاقباً، ویژگی‌های تولید شده به‌طور خودکار برای اهداف پیش‌بینی برای تشخیص اشیاء مورد علاقه در تصاویر جدید استفاده می‌شوند.
شبکه عصبی مکرر (Recurrent neural network)	RNNها به صراحت برای ساختارهای داده متوالی مانند داده‌های سری زمانی، توالی رویدادها و زبان طبیعی طراحی شده اند. معماری آن‌ها حلقه‌های بازخورد داخلی را ارائه می‌دهد و بنابراین یادگیری الگوی متوالی را برای مدل‌سازی وابستگی‌های زمانی با تشکیل یک حافظه ممکن می‌سازد. معماری‌های RNN ساده مشکل‌ساز هستند، زیرا از شیب‌های ناپدید رنج می‌برند، که منجر به تأثیر کم یا بدون تأثیر حافظه‌های اولیه می‌شود. معماری‌های پیچیده‌تر مانند شبکه‌های حافظه کوتاه‌مدت بلند مدت (LSTM) با مکانیسم‌های توجه پیشرفته، به این مشکل کمک می‌کنند. آنها معمولاً برای پیش‌بینی سری‌های زمانی، پیش بینی رفتار فرآیند (Heinrich et al. 2021) و وظایف NLP مانند انتقال توالی و ترجمه ماشین عصبی استفاده میشوند (LeCun et al. 2015).
نمایندگی توزیع شده (Distributed representation)	نمایندگی‌های توزیع‌شده نقش اساسی در یادگیری ویژگی و مدل‌سازی زبان در وظایف NLP ایفا می‌کنند، جایی که موجودیت‌های زبانی مانند کلمات، عبارات و جملات به صورت نمایش‌های عددی در یک فضای معنایی یکپارچه در قالب جاسازی‌ها نمایش داده می‌شوند. به عنوان مثال، جاسازی‌های کلمه، کلمات گسسته را در بردارهای ویژگی متراکم با ابعاد کم رمزگذاری می‌کنند. بنابراین، برخلاف مدل‌های نمایش متن کلاسیک، مانند رمزگذاری‌های تک داغ و کیسه‌ی کلمات، جاسازی‌های کلمه بر مشکل رمزگذاری‌های پراکنده غلبه می‌کنند و در عین حال روابط معنایی بین کلمات را حفظ می‌کنند.

این بدان معناست که کلماتی که در زمینه‌های مشابه در یک پیکره رخ می‌دهند، در فضای برداری نیز نزدیک به یکدیگر قرار دارند. بر این اساس، مدل‌های زبانی پیشرفته را می‌توان برای انجام وظایف چالش‌برانگیز پایین‌دستی، مانند پاسخ‌گویی به سؤال، تحلیل احساسات، و شناسایی موجودیت‌های نام‌گذاری‌شده توسعه داد (Liu et al. 2020). نمایش های توزیع شده اغلب در ترکیب با RNNها برای انجام وظایف با وابستگی های متوالی اعمال می شوند.

رمزگذاری خودکار (Autoencoder)

رمزگذارهای خودکار مانند جاسازی‌های کلمه کار می کنند زیرا نمایش ویژگی متراکمی از داده‌های ورودی را ارائه می دهند. با این حال، آنها به داده‌های زبان طبیعی محدود نمی شوند، بلکه می‌توانند برای هر نوع ورودی اعمال شوند. چنین معماری‌هایی معمولاً شامل یک مرحله رمزگذاری هستند که در آن ورودی به یک نمایش کم‌بعد فشرده می‌شود و یک مرحله رمزگشایی که در آن شبکه سعی می‌کند ورودی اصلی را از ویژگی‌های آموخته شده بازسازی کند. به این ترتیب، شبکه مجبور می‌شود اطلاعات معنی‌داری را در بازنمایی پنهان نگه دارد، در حالی که نویزهای نامربوط را نادیده می‌گیرد (Goodfellow et al. 2016). رمزگذارهای خودکار معمولاً برای یادگیری ویژگی های بدون نظارت و کاهش ابعاد در ترکیب با سایر سیستم های یادگیری بعدی استفاده می شوند. با این حال، به دلیل تولنایی آنها در تعیین کمیت خطاهای بازسازی، که برای نمونه های غیرعادی به طور قابل توجهی بیشتر از نمونه های معمولی فرض می‌شود، می‌توان آنها را برای تشخیص ناهنجاری‌ها، مانند فعالیت‌های متقلبانه در بازارهای مالی نیز به کار برد (Paula et al. 2016).

شبکه متخاصم مولد
(Generative adversarial neural network)

شبکه‌های عصبی متخاصم مولد متعلق به خانواده مدل‌های مولد هستند که هدف آن یادگیری توزیع احتمال بر روی مجموعه‌ای از داده‌های آموزشی است، به طوری که شبکه بتواند به‌طور تصادفی نمونه‌های داده جدید را با تغییراتی تولید کند. برای این منظور، GAN ها از دو زیرشبکه رقیب تشکیل شده اند. شبکه اول یک شبکه مولد است که توزیع ورودی را گرفته و نمونه های جدیدی تولید می کند. شبکه دوم یک شبکه تشخیص است که سعی دارد نمونه های واقعی را از نمونه هایی که به طور مصنوعی تولید شده اند متمایز کند. هر دو شبکه با هم در یک بازی مجموع صفر غیرهمکاری آموزش می بینند که در آن سود یک شبکه ضرر شبکه دیگر را تعیین میکند.

بر این اســـاس، GANها احتمالاً دامنه‌هایی را متحول می‌کنند که در آن‌ها به طور مداوم محتوای جدید یا پیکربندی‌های محصـــول جدید ایجاد می‌شـود (به عنوان مثال، ترکیب هنر و موسـیقی، طراحی مد)، یا جایی که محتوا از یک نمایش به دیگری تبدیل می‌شود (مثلاً متن). به تصـویر برای توضـیحات محصـول) (پان ، ۲۰۱۹). با این حال، در عین حال، چنین رویکردهایی در هنگام سـوء اسـتفاده از آنها برای مقاصـد بدخواهانه، تهدیدات جدی با پیامدهای اجتماعی را نیز به همراه دارند. به ویژه، تولید محتوای «دیپ جعلی» در قلب ســـخنرانی های توهین آمیز و اخبـار گمراه کننـده برای دســـتکاری افکار عمومی یـا تحریف بازارهای مالی نگران کننده است.

چالش‌های سیستم‌های هوشمند مبتنی بر یادگیری ماشینی و یادگیری عمیق

بازارهای الکترونیکی در طلوع یک تغییر ناشـــی از فناوری به سمت بینش های مبتنی بر داده ارائه شده توسط سیستم های هوشـمند هسـتند (Selz 2020). امروزه، از ML و DL کم عمق برای ســاخت مدل‌های تحلیلی برای آنها اســتفاده می شــود و انتشـار بیشـتر آن قابل پیش‌بینی است. برای هر برنامه کاربردی دنیای واقعی، سیستم‌های هوشمند تنها با وظیفه ساخت مدل، مشخصات سیستم و پیاده‌سازی مواجه نیستند. آنها مستعد مشکلات متعددی هستند که ریشه در نحوه عملکرد ML و DL دارند که چالش‌های مرتبط با جامعه سـیسـتم‌های اطلاعاتی را تشـــکیل می‌دهند. آنها نه تنها به دانش فنی نیاز دارند، بلکه شـــامل جنبه های انســـانی و تجاری نیز می شـــوند که فراتر از محدودیت های سیستم هستند تا شرایط و اکوسیستم کاربرد را در نظر بگیرند.

مدیریت مثلث معماری، فرلپارامترها و داده های آموزشی

هنگام ساخت مدل‌های کم عمق ML و DL برای سـیسـتم‌های هوشـــمند، گزینـه‌هـای تقریبـاً بی‌پـایـانی برای الگوریتم‌هـا یـا معماری‌ها، فراپارامترها و داده‌های آموزشـی وجود دارد (Duin 1994; Heinrich et al. 2021). در عین حـال، فقـدان دســـتورالعمل‌های تعیین شـــده در مورد اینکه چگونه یک مدل باید برای یک مشـکل خاص سـاخته شـود تا نه تنها عملکرد و کارایی هزینه بلکه از استحکام و حریم خصوصی آن نیز اطمینان حاصـل شـود، وجود ندارد. علاوه بر این، همانطور که در بالا ذکر شـــد، اغلب چندین رابطه مبادله‌ای وجود دارد که باید در محیط‌های تجاری با منابع محدود در نظر گرفته شـــود، مانند کیفیت پیش‌بینی در مقابل هزینه‌های محاســـباتی. بنابراین، وظیفه ســـاخت مدل تحلیلی بســـیار مهم اســـت زیرا موفقیت تجاری یک سـیسـتم هوشـمند را نیز تعیین می کند. به عنوان مثال، مـدلی کـه می‌توانـد بـا دقت ۹۹.۹٪ عمـل کنـد، امـا برای تصمیم‌گیری طبقه‌بندی بسیار طول می‌کشد، بی‌فایده می‌شود و برابر بـا یـک مـدل دقت ۰٪ در زمینـه برنـامـه‌هـای کـاربردی حسـاس زمانی مانند نظارت فعال یا تضـمین کیفیت اسـت. در کارخانه های هوشـمند علاوه بر این، پیاده‌سـازی‌های مختلف را تنها زمانی می‌توان با دقت مقایسه کرد که فقط یکی از سه یال مثلث را در یک زمان تغییر داد و معیارهای یکســـانی را گزارش کرد. در نهایت، باید مهارت‌های لازم، پشـــتیبانی ابزار موجود، و تلاش پیاده‌سـازی مورد نیاز برای توسـعه و اصـلاح یک معماری DL خاص را در نظر گرفت (Wanner et al. 2020).

بنابراین، برنامه‌های کاربردی با دقت عالی که در یک محیط آزمایشگاهی یا روی مجموعه داده‌های مختلف به دست می‌آیند، ممکن است وقتی در یک محیط واقعی در بازارهای الکترونیکی به کار گرفته شوند، به موفقیت تجاری تبدیل نشوند، زیرا سایر عوامل ممکن است بر دستاوردهای نظری مدل ML برتری داشته باشند. این بدان معناست که محققان باید از ویژگی‌های موقعیتی کاربرد دنیای واقعی مدل‌ها برای توسعه یک سیستم هوشمند کارآمد آگاه باشند. نیازی به گفتن نیست که محققان نمی توانند همه عوامل را به طور پیشینی بشناسند، اما باید خود را با این واقعیت آشنا کنند که چندین گزینه معماری با انواع مختلف پایه وجود دارد که با سناریوهای مختلف مطابقت دارند و هر کدام دارای ویژگی های مشخصه خود هستند. علاوه بر این، معیارهای متعددی مانند دقت و امتیاز F1 باید بر روی داده‌های معیار ثابت در بین مدل‌ها قبل از انتخاب یک مدل بررسی شوند.

آگاهی از طرفداری و رانش در داده ها

از نظر ساخت مدل تحلیلی خودکار، فرد باید نسبت به طرفداری و حمایت‌هایی که با استفاده از داده‌های تولید شده توسط انسان در هر مدل از یادگیری ماشین و یادگیری عمیق وارد میشود، آگاه و دانا باشد. این طرفداری‌ها به شدت و به طور قوی توسط مدل‌ها پذیرفته خواهند شد (Fuchs 2018; Howard et al 2017). یعنی مدل‌ها همان تمایلات برگرفته از انسان را نشان خواهند داد که در داده‌ها از پیش تعیین شده‌اند یا حتی آنهارا تقویت میکنند. سوگیری شناختی، یک برداشت یا باور غیرقانونی است که فرد به دلیل گزارش ناقص حقایق یا به دلیل اکتشاف تصمیم‌گیری ناقص و نادرست اتخاذ میکند (Haselton et al. 2015). درحالی که سوگیری معرفی شده توسط داده ها مفهوم جدید و خاصی نیست، اگر داده‌های آموزشی به درستی انتخاب نشده باشند یا از قبل پردازش نشده باشند، دارای عدم تعادل کلاسی باشند، یا هنگامی که برداشت‌ها و استنتاج‌ها به طور مسئولانه بررسی نشده باشند، در زمینه یادگیری ماشین و یادگیری عمیق تقویت میشود. نمونه‌های بارز شامل نرم افزار استخدام هوش مصنوعی امازون میشود که تبعیض علیه زنان را نشان میدهد یا هوش مصنوعی Google Vision که برچسب‌های تصویر کاملا متفاوتی را بر حسب رنگ و پوست تولید میکند.

علاوه بر این اعتبار پیشنهادها و توصیه‌ها بر اساس داده‌ها در معرض انحراف، مفهومی است که یک سناریو را توصیف میکند، که در آن "رابطه بین داده های ورودی و متغیر هدف در طول زمان تغییر میکند" (Gama et al. 2014). به این معنا که مدل‌های ماشین یادگیری برای سیستم‌های هوشمند، ممکن است نتایج رضایت بخشی ایجاد نکند، هنگامی که داده های تاریخی، دیگر وضعیت فعلی را به اندازه کافی توصیف نمیکنند، برای مثال؛ به دلیل ورود رقبای جدید به بازار، در دسترس بودن قابلیت های تولید جدید، یا عدم وجود محدودیت های دولتی سابقه دار. رانش نباید ناگهانی باشد اما میتواند افزایشی، تدریجی یا دوباره رخ دهد(Gama et al. 2014) و بنابراین، تشخیص آن دشوار است. در حالی که تکنیک‌هایی برای یادگیری خودکار وجود دارد که شامل استفاده از پنجره های داده قابل اعتماد و توصیف مفهومی است(Widmer and Kubat 1996)، استراتژی خودکار برای کشف و حل مشکلات مرتبط با کسب و کار، یک چالش هستند(Pentland et al. 2020).

برای کاربرد هایی در بازار الکترونیکی در نظر گرفتن سوگیری از اهمیت بالایی برخوردار است،زیرا اکثر نقاط

داده دارای نقاط تماس انسانی هستند. اینها میتوانند به اندازه پست های رسانه های اجتماعی واضح باشند یا به عنوان متغیر های حذف شده پنهان شوند.علاوه بر این حملات مسموم سازی در حسن آموزش مجدد مدل میتوند برای درج هدفمند الکوهای انحرافی استفاده شود. این امر مستلزم آن است که داده‌های آموزشی باید برای چنین پیش داوری های انسانی، آماده شوند. برنامه های مبتنی بر این داده‌ها باید به صورت ذاتی به عنوان هوش مصنوعی بی طرف‌تر شناخته شوند. این نشان میدهد که محققان باید مجموعه داده‌های خود را بازبینی کنند و هرگونه طرفداری و سوگیری را که از آن آگاه هستند، عمومی کنند. مجدداً، غیر واقعی است که فرض کنیم همه اثرات سوگیری را میتوان در مجموعه داده‌های بزرگ با داده‌هایی با ابعاد بالا توضیح داد. با این وجود برای درک بهتر و اعتماد به یک مدل ML، شناسایی و برجسته شمردن آن دسته از اثراتی که ممکن است بر پیش‌بینی ها تاثیر بگذارند، مهم است. در نهایت همانطور که در هر بازار الکترونیکی دنیای واقعی میتوان انحراف ثلبت را فرض کرد، یک مدل آموزش دیده هرگز به پایان نمیرسد. شرکت ها باید استراتژی‌هایی را برای شناسایی، ردیابی و مقابله با رانش و انحراف مفهومی که بر کیفیت تصمیمات سیستم هوشمند آنها تاثیر میگذارد، ایجاد کنند. در حال حاضر، بررسی های دستی و بازآموزی دوره‌ای مدل غالب هستند.

غیرقلبل پیش‌بینی بودن پیش‌بینی‌ها و نیاز به توضیح‌پذیری

پیچیدگی مدل‌های DL و برخی مدل‌های کم عمق ML مثل جنگل‌های تصمیم تصادفی و SVMها که اغلب به عنوان ماهیت جعبه سیاه شناخته میشوند، پیش‌بینی نحوه عملکرد آنها در یک زمینه خاص را تقریبا غیر ممکن میکند(Adadi and Berrada 2018). این امر همچنن مستلزم این است که کاربران قادر به بررسی و توصیه‌های سیستم‌های هوشمند بر اساس این مدل‌ها نباشند. علاوه بر این، این امر آمادگی برای حملات خصمانه را که مدل های DL را فریب میدهند و میشکنند، بسیار دشوار میکند(Heinrich et al. 2020). آنها میتوانند به عنوان یک تهدید برای برنامه‌های کاربردی بالا، به عنوان مثال؛ از نظر اختلال در علائم خیابان، برای رانندگی خودران باشند. (Eykholt et al. 2018). بنابراین، ممکن است لازم باشد که تصمیم یک مدل جعبه سیاه را برای تسهیل پذیرش سازمانی توضیح دهیم. نه تنها انسان‌ها توضیحات ساده را به اعتماد و پذیرش یک مدل ترجیح میدهند، بلکه الزام توضیح پذیری ممکن است توسط قانون اجباری شود (Miller 2019).

حوزه هوش مصنوعی قابل توضیح (XAI)، با افزایش و تقویت مدل های DL برای ارائه توضیحاتی برای پیش‌بینی‌های خروجی سر و کار دارد. برای داده‌های تصویر، این شامل برجسته کردن مناطقی از تصویر ورودی است که مسئول ایجاد تصمیم خروجی خاص هستند (Adadi and Berrada 2018). باتوجه به داده‌های سری زمانی، روش‌هایی برای برجسته کردن گام‌های زمانی مهم خاص موثر بر پیش‌بینی توسعه داده شده اند(Assaf and Schumann 2019). یک رویکرد مشابه میتواند برای برجسته کردن کلمات در یک متن که منجر به خروجی‌های طبقه‌بندی خاص می‌شود مورد استفاده قرار بگیرد.

بنابراین، برنامه‌های کاربردی در بازارهای الکترونیکی که با الزامات مختلف حیاتی و تعامل انسانی باید به طور متمایز طراحی یا تقویت شوند تا به نگرانی های مربوطه رسیدگی شود. محققان باید به طور خاص در مدل‌های

DL، برای حساسیت و پاسخگویی خود، مرور کنند. احتمالاً، آنها باید یک مدل جعبه سفید قابل توضیح را بر روی یک مدل جعبه سیاه دقیق‌تر (Rudin 2019) یا تقویت کننده‌های (XAI) انتخاب کنند، تا پیش‌بینی‌های مدل را برای کاربرانش در دسترس تر کنند (Adadi and Berrada 2018).

محدودیت‌های منابع و انتقال یادگیری

در نهایت، ساخت و آموزش مدل‌های تحلیلی جامع با یادگیری ماشین یا ML کم‌عمق، پر هزینه است و به مجموعه داده‌های بزرگ برای جلوگیری از شروعی سرد دارد. خوشبختانه مدل‌ها نباید همیشه از ابتدا آموزش ببینند. مفهوم یادگیری انتقالی به مدل‌هایی که بر روی مجموعه داده‌های کلی آموزش دیده‌اند (مانند مجموعه داده‌های تصویری در مقیاس بزرگ) اجازه میدهد تا با استفاده از یک مجموعه بسیار کوچک‌تر که مخصوصِ مشکل است، برای کارهای خاص، تخصصی شوند (Pouyanfar et al. 2019). با این حال، استفاده از مدل‌های از قبل آموزش دیده شده، از منابع خارجی میتواند خطرآفرین باشد، زیرا مدل‌ها میتوانند در معرض تعصبات و حملات خصمانه قرارگیرند، همانطور که در بالا ذکر شد. برای مثال؛ ممکن است با اعمال رده‌بندی درست مدل‌های آموزش دیده، محدودیت‌های محیطی را به درستی ذکر نکنند، مثلاً، طبقه‌بندی نادرست تصاویر پزشکی. مداخلات داخلی برای هدایت سرکوب یا سرکوب پیش‌بینی‌ها نیز قابل تصور هستند. از این رو، در موقعیت‌هایی با ریسک بالا، استفاده مجدد از مدل‌های تحلیلی در دسترس عموم ممکن است یک گزینه نباشد .با این وجود، یادگیری انتقالی یک گزینه عملی را برای شرکت های کوچک و متوسط برای استقرار سیستم های هوشمند ارائه میکند یا شرکت‌های بزرگ را قادر می‌سازد تا مدل‌های تحلیل عمومی خود را برای کاربردهای خاص بازسازی کنند.

در زمینه یادگیری انتقالی، بازار ها و اکوسیستم‌های جدید هوش مصنوعی به عنوان یک سیستم (AIaaS) در حال ظهور هستند. این بازارها برای مثال، توسط مایکروسافت یا وب سرویس‌های آمازون، برنامه‌های کاربردی هوش مصنوعی ابری، پلتفرم‌های هوش مصنوعی و زیر ساخت‌های هوش مصنوعی را ارائه میدهند. علاوه بر مزایای مبتنی بر ابر برای استقرار، آنها همچنین امکان انتقال یادگیری از مدل‌های از قبل ایجاد شده را به سایر برنامه‌ها فراهم میکنند. یعنی به مشتریانی که منابع هوش مصنوعی محدودی دارند، اجازه میدهند مدل‌های از پیش آموزش دیده را خریداری کنند و آنها را در محیط‌های تجاری خود ادغام کنند (مثلاً مدل‌های NLP برای برنامه‌های ربات چت). انواع جدیدی از فروشندگان میتوانند در چنین بازارهایی شرکت کنند. برای مثال؛ با ارائه نتایج یادگیری انتقالی برای وظایف بسیار خاص دامنه، مانند تعمیر و نگهداری پیش بینی کننده برای ماشین های پیچیده. همانطور که در بالا ذکر شد، مصرف کنندگان مدل های DL انتخاب شده به طور خاص باید از خطراتی که طبیعت جعبه سیاه آنها ایجاد میکند، آگاه باشند و پروتکل های سخت‌گیرانه ای مشابه با اپراتورهای انسانی برای تصمیم‌گیری مشابه ایجاد کنند. از آنجایی که بازار AIaaS تنها در حال حضور است، دستورالعمل های انتقال مسئول آن هنوز ایجاد نشده‌اند (Amoros et al. 2020).

نتیجه‌گیری

با این مقاله بنیادی، ما یک مقاله گسترده برای یادگیری ماشین و یادگیری عمیق ارائه میدهیم. اغلب به عنوان فناوری هوش مصنوعی در نظر گرفته میشوند. هر دو

مدل های تحلیلی، زیر بنای سیستم های هوشمند معاصر و آینده را تامین میکنند. ما ماشـــین یادگیری، ماشـــین سطحی، یادگیری عمیق و همچنین الگوریتم‌ها و معماری آنها را مفهوم ســـازی کرده‌ایم. در نهایت ما با بحث در مورد چهار چالش اساسی برای سیستم‌های هوشمند مبتنی بر یادگیری ماشـــین و یادگیری عمیق در اکوسیستم های جهان واقعی به نفوذ مداوم در بازارهای الکترونیکی کمک میکنیم. در اینجا، به طور خاص، AlaaS یک بازار الکترونیکی جدید و کشـــف نشـــده را تشـــکیل میدهد و به شـــدت بر دیگر پایگاه‌های خدمات ایجاد شده تاثیر میگذارد. آنها برای مثال هوشمندی به اصطلاح خدمات هوشمند را با ارائه راه‌های جدید برای یادگیری داده‌های مشتری و ارائه مشاوره یا دستورالعمل به آنها بدون اینکه با صـــراحت برای انجام این کار برنامه ریزی شده باشند، افزایش میدهد. ما برآورد میکنیم که بسیاری از تحقیقات آتی در مورد بازارهای الکترونیکی با پس زمینه AlaaS و اکوســـیســـتم های آن خواهد بود و کاربردها، نقش ها، و مدل های تجاری جدید برای ســـیســـتم های هوشـــمند را بر اســـاس یادگیری عمیق طراحی میکند. تحقیقات آتی مرتبط باید به بررســـی و عامل در چالش‌هایی بپردازد که ما با ارائه دستورالعمل‌های روش شـــناختی ســـاختار یافته برای ســـاخت مدل‌های تحلیلی، ارزیابی، جمع آوری داده ها و پیش بینی ایمن و در دسترس کاربر ارائه کرده‌ایم.

مراجع

Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access,6*, 52138–52160.https://doi.org/10.1109/ACCESS.2018.2870052.

Ahani, A., Nilashi, M., Ibrahim, O., Sanzogni, L., & Weaven, S. (2019). Market segmentation and travel choice prediction in Spa hotels through TripAdvisor's online reviews. *International Journal of Hospitality Management*, 80, 52–77. https://doi.org/10.1016/j.ijhm.2019.01.003

Amorós, L., Hafiz, S. M., Lee, K., & Tol, M. C. (2020). Gimme that model!: A trusted ML model trading protocol. *arXiv:2003.00610 [cs]*. http://arxiv.org/abs/2003.00610

Assaf, R., & Schumann, A. (2019). Explainable deep neural networks for multivariate time series predictions. *Proceedings of the 28th International Joint Conference on Artificial Intelligence*, 6488–6490. https://doi.org/10.24963/ijcai.2019/932.

Bastan, M., Ramisa, A., & Tek, M. (2020). Cross-modal fashion product search with transformer-based Embeddings. *CVPR Workshop - 3rd workshop on Computer Vision for Fashion, Art and Design*, Seattle: Washington.

Bishop, C. M. (2006). Pattern recognition and machine learning *(Information science and statistics)*. Springer-Verlag New York, Inc.

Brynjolfsson, E., & McAfee, A. (2017). The business of artificial intelligence. *Harvard Business Review*, 1–20.

Surveys, 46(4), 1–37. https://doi.org/10.1145/2523813.

García, S., & Herrera, F. (2008). An extension on "statistical comparisons of classifiers over multiple data sets" for all pairwise comparisons. *Journal of Machine Learning Research, 9*(89), 2677–2694.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. The MIT Press.

Goyal, D., & Pabla, B. S. (2015). Condition based maintenance of machine tools—A review. *CIRP Journal of Manufacturing Science and Technology, 10*, 24–35. https://doi.org/10.1016/j.cirpj.2015.05.004.

Grigorescu, S., Trasnea, B., Cocias, T., & Macesanu, G. (2020). A survey of deep learning techniques for autonomous driving. *Journal of Field Robotics, 37*(3), 362–386. https://doi.org/10.1002/rob.21918.

Haselton, M. G., Nettle, D., & Andrews, P. W. (2015). The evolution of cognitive Bias. In: D. M. Buss (Ed.), *The handbook of evolutionary psychology* (pp. 724–746). Inc: John Wiley & Sons. https://doi.org/10.1002/9780470939376.ch25.

Heinrich, K., Graf, J., Chen, J., Laurisch, J., & Zschech, P. (2020). Fool me once, shame on you, fool me twice, shame on me: A taxonomy of attack and defense patterns for AI security. *Proceedings of the 28th European Conference on Information Systems (ECIS).*

Heinrich, K., Möller, B., Janiesch, C., & Zschech, P. (2019). Is Bigger Always Better? Lessons Learnt from the Evolution of Deep Learning Architectures for Image Classification. *Proceedings of the 2019 Pre-*

Chen, S. H., Jakeman, A. J., & Norton, J. P. (2008). Artificial intelligence techniques: An introduction to their use for modelling environmental systems. *Mathematics and Computers in Simulation, 78*(2–3), 379–400. https://doi.org/10.1016/j.matcom.2008.01.028.

Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), 1*, 886–893. https://doi.org/10.1109/CVPR.2005.177.

Duin, R. P. W. (1994). Superlearning and neural network magic. *Pattern Recognition Letters, 15(3)*, 215–217. https://doi.org/10.1016/0167-8655(94)90052-3.

Eykholt, K., Evtimov, I., Fernandes, E., Li, B., Rahmati, A., Xiao, C., Prakash, A., Kohno, T., & Song, D. (2018). Robust physical-world attacks on deep learning visual classification. *IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018*,1625–1634. https://doi.org/10.1109/CVPR.2018.00175.

Fischer, M., Heim, D., Hofmann, A., Janiesch, C., Klima, C., & Winkelmann, A. (2020). A taxonomy and archetypes of smart services for smart living. *Electronic Markets, 30(1),* 131–149.https://doi.org/10.1007/s12525-019-00384-5

Fuchs, D. J. (2018). The dangers of human-like Bias in machine-learning algorithms. *Missouri S&T's Peer to Peer, 2*(1), 15.

Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing*

351–367. https://doi.org/10.1007/s12525-019-00351-0.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature, 521*(7553), 436–444. https://doi.org/10.1038/nature14539.

Leijnen, S., & van Veen, F. (2020). The Neural Network Zoo. *Proceedings, 47* (1), 9. https://doi.org/10.3390/proceedings47010009.

Liu, Z., Lin, Y., & Sun, M. (2020). *Representation learning for natural language processing*. Springer Singapore. https://doi.org/10.1007/978-981-15-5573-2

Lowe, D. G. (2004). Distinctive image features from scale-invariant Keypoints. *International Journal of Computer Vision, 60*(2), 91–110. https://doi.org/10.1023/B:VISI.0000029664.99615.94.

Madani, A., Arnaout, R., Mofrad, M., & Arnaout, R. (2018). Fast and accurate view classification of echocardiograms using deep learning. *Npj Digital Medicine, 1*(1). https://doi.org/10.1038/s41746-017-0013-1.

Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence, 267*, 1–38. https://doi.org/10.1016/j.artint.2018.07.007.

Pan, Z., Yu, W., Yi, X., Khan, A., Yuan, F., & Zheng, Y. (2019). Recent Progress on generative adversarial networks (GANs): A survey. *IEEE Access, 7*, 36322–36333. https://doi.org/10.1109/ACCESS.2019.2905015.

Paula, E. L., Ladeira, M., Carvalho, R. N., & Marzagão, T. (2016). Deep learning anomaly detection as support fraud investigation in Brazilian exports and anti-money laundering. *ICIS SIGDSA Symposium.* https://aisel.aisnet.org/sigdsa2019/20

Heinrich, K., Zschech, P., Janiesch, C., & Bonin, M. (2021). Process data properties matter: Introducing gated convolutional neural networks (GCNN) and key-value-predict attention networks (KVP) for next event prediction with deep learning. *Decision Support Systems*, 143, 113494. https://doi.org/10.1016/j.dss.2021.113494.

Howard, A., Zhang, C., & Horvitz, E. (2017). Addressing bias in machine learning algorithms: A pilot study on emotion recognition for intelligent systems. *IEEE Workshop on Advanced Robotics and its Social Impacts (ARSO),* 1–7. https://doi.org/10.1109/ARSO.2017.802519.

Jayanth Balaji, A., Harish Ram, D. S., & Nair, B. B. (2018). Applicability of deep learning models for stock Price forecasting an empirical study on BANKEX data. *Procedia Computer Science, 143,* 947–953. https://doi.org/10.1016/j.procs.2018.10.340.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science, 349*(6245), 255–260. https://doi.org/10.1126/science.aaa8415.

Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Machine learning: A review of classification and combining techniques. *Artificial Intelligence Review, 26*(3), 159–190. https://doi.org/10.1007/s10462-007-9052-3.

Kühl, N., Mühlthaler, M., & Goutier, M. (2020). Supporting customeroriented marketing with artificial intelligence: Automatically quantifying customer needs from social media. *Electronic Markets,30*(2),

Management, 24(5), 513–523. https://doi.org/10.1016/0306-4573(88)90021-0.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. https://doi.org/10.1016/j.neunet.2014.09.003.

Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences, 3* (3), 417 – 424. https://doi.org/10.1017/S0140525X00005756.

Selz, D. (2020). From electronic markets to data driven insights. *Electronic Markets, 30*(1), 57–59. https://doi.org/10.1007/s12525-019-00393-4.

Shmueli, G., & Koppius, O. (2011). Predictive analytics in information systems research. *Management Information Systems Quarterly, 35*(3), 553–572. https://doi.org/10.2307/23042796.

Shrestha, Y. R., Krishna, V., & von Krogh, G. (2021). Augmenting organizational decision-making with deep learning algorithms: Principles, promises, and challenges. *Journal of Business Research, 123*, 588–603. https://doi.org/10.1016/j.jbusres.2020.09.068.

Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Lanctot, M., Sifre, L., Kumaran, D., Graepel, T., Lillicrap, T., Simonyan, K., & Hassabis, D. (2018). A general reinforcement learning algorithm that masters chess, shogi, and go through self play. *Science, 362*(6419), 1140–1144. https://doi.org/10.1126/science.aar6404.

15th IEEE International Conference on Machine Learning and Applications (ICMLA), 954–960. https://doi.org/10.1109/ICMLA.2016.0172.

Pentland, B. T., Liu, P., Kremser, W., & Haerem, T. (2020). The dynamics of drift in digitized processes. *MIS Quarterly, 44*(1), 19–47. https://doi.org/10.25300/MISQ/2020/14458.

Peters, M., Ketter, W., Saar-Tsechansky, M., & Collins, J. (2013). A reinforcement learning approach to autonomous decision-making in smart electricity markets. *Machine Learning, 92*(1), 5–39. https://doi.org/10.1007/s10994-013-5340-0.

Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., Reyes, M. P., Shyu, M.-L., Chen, S.-C., & Iyengar, S. S. (2019). A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys, 51*(5), 1–36. https://doi.org/10.1145/3234150.

Ramaswamy, S., & DeClerck, N. (2018). Customer perception analysis using deep learning and NLP. *Procedia Computer Science, 140*, 170–178. https://doi.org/10.1016/j.procs.2018.10.326.

Rudin, C. (2019). Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence, 1*(5), 206–215. https://doi.org/10.1038/s42256-019-0048-x.

Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.

Salton, G., & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. *Information Processing &*

52. https://doi.org/10.22215/timreview/1282

Widmer, G., & Kubat, M. (1996). Learning in the presence of concept drift and hidden contexts. *Machine Learning, 23*(1), 69–101. https://doi.org/10.1007/BF00116900.

Wu, M., Liu, F., & Cohn, T. (2018). Evaluating the utility of hand-crafted features in sequence labelling. *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing,* 2850–2856. https://doi.org/10.18653/v1/D18-1310.

Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing [review article]. *IEEE Computational Intelligence Magazine,* 13(3), 55–75. https://doi.org/10.1109/MCI.2018.2840738.

Zhang, Y., & Ling, C. (2018). A strategy to apply machine learning to small datasets in materials science. npj *Computational Materials,* *4*(1). https://doi.org/10.1038/s41524-018-0081-z.

Spooner, T., Fearnley, J., Savani, R., & Koukorinis, A. (2018). Market making via reinforcement learning. *Proceedings of the 17th International Conference on Autonomous Agents and MultiAgent systems*, 434–442. arXiv:1804.04216v1

Stone, P., Brooks, R., Brynjolfsson, E., Calo, R., Etzioni, O., Hager, G., Hirschberg, J., Kalyanakrishnan, S., Kamar, E., Kraus, S., Leyton Brown, Kevin, Parkes, D., Press, W., Saxenian, A. L., Shah, J., Milind Tambe, & Teller, A. (2016). *Artificial Intelligence and Life in 2030: the one hundred year study on artificial intelligence* (Report of the 2015–2016 study panel). Stanford University. https://ai100.stanford.edu/2016-report

Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition.* CVPR 2001, 1, I-511–I-518. https://doi.org/10.1109/CVPR.2001.990517.

Wang, S., Nepal, S., Rudolph, C., Grobler, M., Chen, S., & Chen, T. (2020). Backdoor attacks against transfer learning with pre-trained deep learning models. *IEEE Transactions on Services Computing,* 1–1. https://doi.org/10.1109/TSC.2020.3000900.

Wanner, J., Heinrich, K., Janiesch, C., & Zschech, P. (2020). How much AI do you require? Decision factors for adopting AI technology. *Proceedings of the 41st International Conference on Information Systems (ICIS).*

Westerlund, M. (2019). The emergence of Deepfake technology: A review. *Technology Innovation Management Review, 9*(11), 39–

ارتباط با ما

@department_bme

@department_bme

@department_bme

Info@dep-bme.ir

www.dep-bme.ir

دپارتمان مهندسی پزشکی