



یادگیری ماشین و هوش مصنوعی در خدمت پزشکی: ضرورت یا پتانسیل

TRANSLATION MEDICINE

BIOELECTRIC

مترجمان

سید علی ملکوتی
ملیکا حسینی



(۱) چکیده

در نتیجه روند دیجیتالی شدن سیستم مراقبت های بهداشتی در سراسر جهان، تخمین زده می شود که داده های بهداشتی تولید شده به ۲۳۱۴ اگزابایت داده جدید تولید شده در سال ۲۰۲۰ برسد. هدف توسعه مداوم سیستم های هوشمند، ارائه استدلال بهتر و استفاده موثرتر از داده های جمع آوری شده است. استفاده از آن تنها به تفسیر گذشته نگر یا ارائه نتایج تشخیصی محدود نمیشود، بلکه می توان آن را به تفسیر آینده نگر که پیش آگهی اولیه را ارائه می دهد، گسترش داد. گفته میشود پزشکانی که میتوانند از این سیستم ها کمک بگیرند، خود را در شکاف بین پرونده های بالینی و بررسی های فنی عمیق می بینند. چیزی که آنها فاقد آن هستند، نقطه شروع روشنی برای نزدیک شدن به دنیای یادگیری ماشینی در پزشکی است. روش شناسی و ساختار اصلی: هدف این مقاله ارائه بینشی آسان از هوش مصنوعی (AL) و یادگیری ماشینی (ML) در زمینه پزشکی، عمدتاً در چند سال گذشته، برای پزشکان علاقه مند است. برای این منظور، ابتدا مسیرهای توسعه کلی در مورد استفاده از مفهوم هوش مصنوعی و ML در سیستم های مراقبت های بهداشتی را مورد بحث قرار می دهیم. سپس رشته هایی را فهرست می کنیم که این فناوری ها در حال حاضر مورد آزمایش قرار گرفته اند یا حتی در آن ها مورد استفاده قرار گرفته اند، مانند هماتولوژی، نورولوژی، قلب و عروق، انکولوژی، رادیولوژی، چشم پزشکی، زیست شناسی سلولی و سلول درمانی.

(۲) مقدمه

معرفی فناوری اطلاعات در حوزه مراقبت های بهداشتی پیشرفت هایی را در جنبه های متعددی ارائه کرده است [۱]، از دیجیتالی کردن داده های بیمار در پرونده الکترونیک سلامت (EHR) [۲] تا ارائه تصمیم گیری بالینی [۳]. در نتیجه روند دیجیتالی شدن سیستم مراقبت های بهداشتی در سراسر جهان، داده های بهداشتی تولید شده در سال ۲۰۱۱، ۱۵۰ اگزابایت * ۱۵۰ برآورد شده است و تخمین زده می شود که در سال ۲۰۲۰ دارای ۲۳۱۴ اگزابایت داده جدید تولید شده باشد [۴-۵]. با این حال، پردازش کارآمد این داده ها به طوری که بتوان اطلاعات مفید و دانش جدید را استخراج کرد، یک چالش واقعی باقی می ماند. در واقع، حجم روزافزون داده های جمع آوری شده، توانایی سیستم های تحلیل داده های فعلی را تحمل می کند. در نتیجه، سیستم های مراقبت های بهداشتی به طور فزاینده ای تحت فشار قرار می گیرند که به آن غنی سازی اطلاعات گفته میشود. سندرم خفیف DRIP یعنی ما بیشتر از آنچه که بتوانیم اطلاعات را پردازش کنیم در دسترس داریم و این داده های پزشکی جمع آوری شده را می توان با ابزارهای مختلف و در سطوح مختلف تجزیه و تحلیل کرد [۶]. سطح اول به دست آوردن داده های فردی بیمار است که در آن سیستم های هشدار معمولی می توانند به افزایش توجه در زمانی که مقادیر خارج از محدوده طبیعی هستند، مانند مانیتورهای الکتروکاردیوگرافی قلب (ECG) کمک کند. در سطح دوم، منابع

داده های مختلف جمع آوری، ترکیب و پردازش می شوند به گونه ای که نتیجه می تواند به عنوان ورودی برای نوع دیگری از سیستم استفاده شود که تشخیص افتراقی پیشنهادی و نتیجه گیری را بر اساس مجموعه ای از قوانین ارائه می دهد. با حرکت به یک سلسله مراتب درخت مانند با استفاده از داده های ارائه شده، این سیستم ها می توانند در رسیدن به توضیح قابل قبولی از علائم وارد شده کمک کنند. این سیستم های مبتنی بر قانون «سیستم های خبره» نامیده می شوند. سیستم های خبره از تجربه یاد می گیرند تا از توانایی های تصمیم گیری متخصصان انسانی تقلید کنند. این سیستم ها اغلب قادرند به سؤالاتی که با «چه» شروع می شوند به جای «چگونه» پاسخ دهند و به طور همزمان دلیل تصمیم های خود را توضیح دهند. یکی دیگر از ویژگی های اساسی این سیستم ها این است که تجربیات جدید را یکپارچه می کنند و از این رو پایگاه دانش خود را غنی و تقویت می کنند. این به نوبه خود توانایی تصمیم گیری آنها را بهبود می بخشد. یک نمونه اولیه از چنین سیستم هایی، سیستم MYCIN [۷] میباشد.

این سیستم ها مبتنی بر فرآیند تبدیل داده ها هستند که به ارائه تشخیص و نتیجه گیری که بر مدل تثبیت شده «داده-اطلاعات-دانش-خرد» تکیه دارد کمک می کند. هدف بهبود مستمر کنونی سیستم های هوشمند ارائه استدلال بهتر و استفاده کارآمد از داده های جمع آوری شده است. هدف این است که سیستم های تصمیم گیری را قادر به اجرای آینده نگر و ارائه پیش آگهی اولیه (برخلاف رویکرد گذشته نگر که در آن سیستم ها فقط تشخیص و نتیجه گیری را ارائه می دهند) است [۸].

این دستاوردهای فنی به خوبی مستند شده است [۹]. با اینحال، یک آموزش ساده برای پزشکانی که به دنبال درک وضعیت واقعی این فناوری و کاربردهای بالقوه بیشتر هستند ضروری است. برای این منظور، در این بررسی پیشرفته، به پزشکان بینشی در مورد استفاده از هوش مصنوعی (AI) در زمینه پزشکی ارائه می دهیم. در حالی که به دنبال دستیابی به یک بررسی جامع از همه برنامه های پزشکی برای هوش مصنوعی نیست، این مقاله بینش های قابل فهمی را ارائه می کند که می تواند تبدیلات هوش مصنوعی را معنادارتر کند، که می تواند منجر به یک بحث سازنده در مورد چگونگی کاهش شکاف بین این دو شود. بنابراین، ما سعی خواهیم کرد تا برخی از تعاریف اساسی را روشن کنیم و یک بحث مختصر در مورد خطوط کلی توسعه در استفاده از مفاهیم یادگیری ماشین و هوش مصنوعی در سیستم های مراقبت بهداشتی بیان کنیم. سپس برخی از زمینه ها و نمونه هایی را فهرست می کنیم که در آنها این فناوری ها قبلاً مورد آزمایش قرار گرفته یا حتی اعمال شده اند، همانطور که در جدول ۱ خلاصه شده است.

هوش از جمله اصطلاحاتی است که در برابر هرگونه تلاش برای تعریف مقاومت می‌کند. یک جستجو ساده در وب می‌تواند ما را به صدها تعریف برساند که با توجه به دیدگاه‌های فردی متفاوت است (فلسفه، زیست‌شناسی، روانشناسی، ریاضیات، علوم کامپیوتر). با این حال، تنها بخاطر این پیشرفت فوق‌العاده، سعی خواهیم کرد تا تعاریف بسیاری را که در ادبیات یافت می‌شود جمع‌آوری کنیم. **هوش** توانایی ایجاد طرح‌های ثابت، حل مشکلات یا ایجاد محصولات است که در یک فرهنگ خاص یا یک زمینه تجاری ارزش دارند. از تداعی، حفظ، استدلال، درک، انتزاع، مفهوم‌سازی، تقریب، سیستم‌سازی و استنتاج منطقی استفاده می‌کند. این عناصر برای استخراج دانش جدید از حقایق شناخته شده استفاده می‌شوند [۱۰-۱۲].

از سوی دیگر، **هوش مصنوعی** به توانایی سیستم برای تفسیر صحیح داده‌های خارجی، یادگیری از این داده‌ها و استفاده از آن یادگیری‌ها برای دستیابی به اهداف و وظایف خاص با استفاده از سازگاری انعطاف‌پذیر اشاره دارد [۱۳]. مؤلفه اصلی هوش مصنوعی، یادگیری ماشینی (ML) است، همانطور که در شکل ۲ نشان داده شده است. **یادگیری ماشینی** زمانی است که از رایانه‌ها برای اعمال مدل‌های آماری بر روی داده‌ها استفاده می‌شود. این یکی از زیرشاخه‌های هوش مصنوعی است که در آن برنامه‌های کامپیوتری (الگوریتم‌ها) روابط بین داده‌های ورودی و خروجی را یاد می‌گیرند. ما می‌توانیم بین سه دسته از الگوریتم‌های ML تمایز قائل شویم: یادگیری نظارت شده، یادگیری بدون نظارت و یادگیری تقویتی. در آموزش نظارت شده، برنامه‌های کامپیوتری از طریق تجزیه و تحلیل نمونه‌های داده تعریف شده توسط یک سرپرست (معمولاً یک متخصص انسانی) در فرآیندی به نام آموزش، تداعی‌ها را یاد می‌گیرند. هنگامی که تداعی‌ها آموخته شدند، می‌توان از آنها برای پیش‌بینی نمونه‌های آینده در فرآیندی به نام تست استفاده کرد [۱۴]. در **یادگیری بدون نظارت**، برنامه‌های کامپیوتری تداعی‌ها را در داده‌ها بدون تعریف خارجی از تداعی‌ها یاد می‌گیرند. اغلب برای خوشه‌بندی استفاده می‌شود، یعنی استخراج همبستگی‌های کشف‌نشده در داده‌های ورودی به‌گونه‌ای که برای تشکیل زیرمجموعه‌های داده‌ای که ویژگی‌های مشترک دارند، استفاده می‌شود. در **یادگیری تقویتی**، سیستم یاد می‌گیرد که چگونه بر اساس سیگنال پاداش/تنبیه اسکالر رفتار کند. تنبیه را می‌توان به عنوان یک سیگنال پاداش منفی در نظر گرفت که عملی را تقویت می‌کند که از انجام آن اجتناب می‌کند [۱۵]. شایان ذکر است که زمینه خاصی از ML وجود دارد که اغلب برای مجموعه‌های پردازش داده‌های بزرگ به نام یادگیری عمیق (DL) استفاده می‌شود. DL یک سیستم محاسباتی مبتنی بر عصبی است که همبستگی بین داده‌ها را با آزمایش‌های تکاملی برای کاهش تابع هزینه تعیین می‌کند. **یادگیری عمیق** با مقادیر تصادفی (حالت‌های اولیه) شروع می‌شود تا زمانی که به وزن‌های صحیحی برسد که به بهترین نحو یک تابع هزینه از پیش تعریف شده را به حداقل برساند. این بدان معناست که سیستم به طور پیوسته در حال پیش‌بینی است و نحوه پیش‌بینی خود را با توجه به داده‌های ورودی تنظیم می‌کند [۱۶].

یادگیری عمیق ابزاری قدرتمند برای یادگیری مسائل پیچیده شناختی است [۱۷، ۱۸]. با این حال، مسائل داده مانند حجم کم داده، پراکندگی بالا و کیفیت پایین داده می تواند کارایی روش های یادگیری عمیق را محدود کند [۱۹-۲۴]. در نهایت، باید تاکید کرد که استفاده از ML فراتر از سیستم های تصمیم گیری است و می تواند در بسیاری از کاربردهای پزشکی مانند نانوربات ها (ربات های کوچک برای انجام وظایف خاص مانند تحویل دارو [۲۵] و در کمک به بیماران آسیب دیده استفاده شود). برنامه های کاربردی، در حالی که جالب هستند، اما خارج از محدوده این کار قرار دارند.



شکل ۱: هرم کلاسیک

در بخش بعدی، پس از مقدمه ای کوچک در مورد فرآیند جمع آوری داده های بیمار، زمینه های پزشکی زیر را که در آن ها فناوری های هوش مصنوعی در حال حاضر به کار می رود، بررسی می کنیم: پذیرش بیمار. رادیولوژی، هماتولوژی، نورولوژی، انکولوژی، زیست شناسی سلولی و سلول درمانی، قلب و عروق، چشم پزشکی.

۴) دریافت بیمار: به دست آوردن اطلاعات اولیه بیمار

فرآیند بالینی، اقداماتی است که توسط متخصصان مراقبت های بهداشتی به منظور ارزیابی و بهبود سلامت بیمار انجام می شود؛ دارای یک نقطه شروع (یک قرار ملاقات، ویزیت اضطراری و غیره)، رویه ها و یک نتیجه بالینی مورد انتظار است. در موارد معمولی، فرآیند با ارزیابی و به دست آوردن شروع می شود. این سیستم شامل یک مجموعه سوالات از پیش تعریف و تعیین شده می باشد که در طول آن، پزشک متخصص باید از بیمار بپرسد. از ۱۹۶۰ این مراحل وجود داشته است بطوریکه داده ها شکل دیجیتالی داشتند [۲۶]. اما هم اکنون نیز این دسته بندی اطلاعات وجود دارد زیرا برای پرستاران سخت خواهد بود که به اطلاعات مختلف همزمان دسترسی

داشته باشند. نقطه عطف این سیستم این است که میتواند روایت عامیانه بیمار را به فهرست اطلاعات از پیش تعیین شده رسمی تبدیل کند(فهرست رسمی تری از علل و علائم و تکامل زمانی آنها، سابقه پزشکی بیمار، و غیره).

Table 1
Summary of some important examples of the artificial intelligence techniques applications in precise medicine.

Author	Journal, Year	Domain	Technique	Technology	Topic
Wu et al.	Breast Cancer Res Treat, 2019	Radiology	Ultrasound	Logistic regression	Breast cancer
Moradi et al.	Medical Imaging, Computer-Aided Diagnosis SPIE 2019	Radiology	X ray	ML	Chest
Uthoff et al	Med Phys. 2019	Radiology	CT	ML	Lungs
Yang et al.	Medical imaging, Computer-Aided Diagnosis SPIE 2019	Radiology	MRI	ML	Brain
Diamond et al.	Int J Biomed Comput 94	hematology	Flow cytometry	AI	Leukemia
Diamond et al.	Cytometry 94	hematology	Flow cytometry	AI	Leukemia
Nguyen et al.	J Clin Pathol 97	hematology	Flow cytometry	AI	Leukemia
Gunčar et al.	Sci Rep 2018	Hematology	Laboratory	ML	Biological hematology
Arai et al.	Blood Adv 2019	Hematology	HSCT	ML	aGVHD
d'Onofrio et al.	Oxford: Butterworth Heinemann; 1998	Hematology	Hemoglobin disorder	NN	Laser cytometry and integrated isovolumetric
Zini et al.	Hematology 2005	Hematology	Hemoglobin disorder	NN	Laser cytometry and integrated isovolumetric
d'Onofrio et al.	Hematologica 1998	Hematology	AML	AI	cytometry
Kantardzic et al.	Comput Ind Eng 2002	Hematology	PV	DM	Laboratory findings
Shouval et al.	J Clin Oncol 2015	Hematology	HSCT	ML	ALL post-HSCT
Shouval et al.	Plos One 2016	Hematology	HSCT	ML	ALL post-HSCT
Subasi et al.	Neural Comput Appl. 2019	Neurology	Epilepsy	ML	Seizure detection
Avcu et al.	IEEE, ICASSP 2019	Neurology	Epilepsy	NN	Seizure detection
Ahmadi Rastegar	Npj Park Dis. 2019	Neurology	Parkinson's disease	ML	Progression prediction
Thompson et al.	Radiother Oncol. 2018	Oncology	radiotherapy	AI	Radiotherapy
Londhe et al.	Drug Discov Today 2019	Oncology	radiotherapy	AI	Radiotherapy
Araújo et al	PLOS ONE. 2017	Oncology	Histology	NN	Classification
de Ridder et al.	Brief Bioinform. 2013	Cell biology	Laboratory	ML	Detection by fluorescence
Oei et al.	PLOS ONE. 2019	Cell biology	Laboratory	NN	Microscope images
Sugimoto et al.	Cytotherapy. 2019	Cell therapy	Laboratory	ML	CAR-T
Lee et al.	Immunology. 2019	Cell biology	Immunology	DL	Tracking of immunological synapses
Yaseen et al.	Appl Sci. 2018	Cardiology	Heart Sound Signal	AI	Classification
Alfaras et al.	Front Phys 2019	Cardiology	ECG	ML	Arrhythmia
Sayres et al.	Ophthalmology. 2019	Ophthalmology	Diabetic Retinopathy	DL	Grading
Li et al.	IEEE Trans Med Imaging	Ophthalmology	Glaucoma	NN	Detection

به عنوان مثال، اگر بیمار بگوید: "فکر می کنم دیابت دارم"، یک پزشک متخصص میداند که این صرفاً صحبت های یک بیمار است

تا اینکه نتایج آزمایشگاهی آنرا بعنوان یک بیماری تشخیص دهد و

علائم آنرا تایید کند. با این حال، تصور کنید که بیمار این جزئیات را

در یک سیستم کامپیوتری وارد کند. سیستم چگونه این ورودی را


تفسیر می کند؟ اگرچه ما پیشرفت های فوق العاده ای در پردازش

زبان طبیعی یا (N.L.P) داشته ایم، اما هیچ سیستمی تاکنون نمی تواند

اصطلاحات پزشکی را استخراج کند؛ پس از جمع آوری داده ها،

سیستم تجزیه و تحلیل متن بالینی و استخراج اطلاعات را می

توان برای استخراج اطلاعات مفید از پرونده های الکترونیکی



شکل ۲: نشان دهنده روابط فراگیر بین هوش مصنوعی، یادگیری ماشین و یادگیری عمیق

بهداشتی بدون ساختار استفاده کرد؛ سپس این اطلاعات سازمان یافته می‌تواند به روش‌های مختلف برای تشریح پرونده یا حتی ارائه مدل‌سازی پیش‌بینی‌کننده در آینده بیمار بر اساس سوابق پزشکی فعلی مورد استفاده قرار گیرد [۲۴-۲۸].

۵) رادیولوژی

فرقی نمی‌کند که تصویربرداری پزشکی انجام شده توسط توموگرافی کامپیوتری (CT) یا توسط تشدید مغناطیسی باشد (MRI)، در هر حال تکنیک‌های هوش مصنوعی می‌توانند راهنما و کمک خوبی به پزشک در استخراج بینش مفید از تصویر باشند. به طور کلی، یک پزشک تصویر پزشکی را بعنوان ورودی به دستگاه پردازش می‌دهد، سپس سیستم ویژگی‌های تصویر را بررسی و استخراج می‌کند. بر اساس مقادیر این ویژگی‌ها (ملقب به فاکتورهاها)، می‌توان پیش‌بینی‌های درستی از تصویر انجام داد. این پیش‌بینی‌ها می‌توانند بصورت زیر باشند [۲۹]:

۱. تقسیم بندی: ترسیم مرزهای اطراف عناصر در تصویر

۲. برجسب زدن: شناسایی عناصر موجود در تصویر

۳. تشخیص و شناسایی: تشخیص بیماری خاص و پیش‌بینی مرحله آن

۴. به روی کاغذ آوردن نتایج تصاویر رادیولوژی

همزمان با شروع استفاده از ساده‌ترین و متداول‌ترین تکنیک‌های تصویربرداری پزشکی، یعنی تکنیک سونوگرافی، سیستمی اخیراً توسط Wu و همکاران وی [۳۰] ارائه شد که از رگرسیون لجستیک برای طبقه‌بندی سرطان پستان منفی سه‌گانه (TN) بر روی تصاویر سونوگرافی با حساسیت ۸۶/۹۶٪ و دقت ۸۲/۹۱ استفاده می‌کند. از جمله مثال‌های دیگر می‌توان به کار اخیر (DL) اشاره کرد که برای تشخیص اینکه کدام یک از تصاویر گرفته شده توسط اشعه ایکس نشان‌دهنده قفسه سینه سالم است، مورد استفاده قرار می‌گیرد [۳۱]. در این مثال اگرچه هنوز به تخصص و دقت پزشک نیاز هست، اما استفاده از این سیستم می‌تواند موجب شناسایی حدود ۵۰٪ از قفسه سینه‌های سالم شود و در نتیجه آن، تعداد مواردی که باید توسط پزشک طبقه‌بندی شود، کاهش پیدا کرده و موجب سهولت کار می‌گردد. تصاویر توموگرافی کامپیوتری (CT) نیز می‌توانند با استفاده از تکنیک‌های یادگیری DL به سادگی طبقه‌بندی شوند. $Uthoff$ و همکاران وی در کار خود در مورد تشخیص گره‌های بدخیم و خوش‌خیم ریه از یک سیستم مبتنی بر ML استفاده کرد که می‌تواند بر اساس ویژگی‌ها و فاکتورهای موجود در تصویر نشانگر آن باشند [۳۲]. این سیستم همانطور که گفته شد از تصویر گرفته شده از پارانشیم اطراف گره‌های ریه برای طبقه‌بندی گره‌ها استفاده می‌کند؛ نتایج حاکی از آن است که این سیستم دارای

حساسیت ۱۰۰٪ و دقتی بالغ بر ۹۶٪ است. در مورد (MRI)، Yang و همکاران وی سیستمی مبتنی بر یادگیری ماشین یا (ML) برای پیشبینی درجه گلیوبلاستوما ارائه کرد که با استفاده از تصاویر گرفته شده توسط (MRI) نتایجی با دقت ۹۲٪ به اپراتور میدهد.

۶) هماتولوژی

کاربرد اصلی هوش مصنوعی در هماتولوژی نسبتاً جدید و نوین است. شناسایی سلولی یکی از مواردی است که به طور جدی با تکنیک های AI تسریع شده است. در این زمینه سه کار اصلی توسط سه سیستم کاربردی برای موارد زیر بکار رفته است:

۱. فلوسیتومتری ایمونوفنوتیپ

۲. آنالیز مغز و استخوان

۳. تجزیه و تحلیل خون محیطی

این سه سیستم با یکدیگر و تاریخچه پزشکی با نتایج آزمایشگاهی موجود در پایگاه های داده تعامل و ارتباط دارند. هنگام ارزیابی ۱۰۰ بیمار لوسمی، این سه سیستم در ۹۴ مورد در تشخیص نهایی و با ۹۹ مورد با تفسیر پزشک اتفاق نظر و نتیجه داشتند. [۳۳-۳۵]. روش های یادگیری ماشین اخیراً برای تشخیص اختلالات خونی تنها بسته به یافته های آزمایشگاهی آزمایش شده اند و از آن دو رویکرد مورد استفاده قرار گرفته است؛ یکی از تمام آزمایش های خون موجود در آزمایشگاه استفاده میکرد و آنها را مورد بررسی قرار میداد و دیگری فقط از یک مجموعه محدود استفاده کرد که به طور معمول در طول مصرف دارو بیمار اندازه گیری می شد و دقت پیش بینی مربوطه ۸۸٪ و ۸۶٪ را هنگام در نظر گرفتن لیست پنج بیماری محتمل و ۵۹٪ به دست آورد. و ۵۷ درصد زمانی که فقط محتمل ترین بیماری را اپراتور در نظر گرفته بود [۳۶].

با استفاده از یادگیری ماشین، Arai و محققان در این زمینه، ک گروه ژاپنی متشکل از ۲۶۶۹۵ بیمار را برای پیش بینی خطر بیماری حاد پیوند در مقابل میزبان (aGVHD) را مورد تجزیه و تحلیل قرار دادند؛ الگوریتم تصمیم درختی متناوب ML (ADTree) رای توسعه مدل ها با استفاده از گروه آموزشی استفاده شد و ۱۵ عامل برای تشکیل مدل نهایی انتخاب شدند. از اینرو این مقاله نشان دهنده ارتباط بین خطر GVHD و بقای کلی پس از HSCT و نمرات پیش بینی aGVHD میباشد. بطور خلاصه، الگوریتم ها نمرات طبقه بندی خطر بالینی معقول و قوی را ایجاد کردند و به معرض نمایش گذاشتند [۳۷].

حوزه دیگر استفاده از شبکه های عصبی در خدمت آنالیز خون محیطی بود که در آن باید به دو رویکرد قابل توجه اشاره کرد. اولین مورد مربوط به تشخیص اختلال هموگلوبین از طریق سیتومتری لیزری با یک سیستم کروی یکپارچه همو جمعی است که تقریباً در

تمام موارد HbE، HbE دقیق است، و همچنین مرتبط با صفت b تالاسمی و IDA مرتبط با صفت b تالاسمی میا، و IDA مرتبط با a- تالاسمی میباشند [۳۸-۳۹].

مدل دوم یک مدل هوش مصنوعی است که بر اساس سیتومتری بسته به ارزیابی نوری حجم گلبول های سفید و فعالیت پراکسیداز در کانال پراکس و چگالی هسته ای در کانال بازو برای تمایز، طبق طبقه بندی FAB، بین نمونه های لوسمی حاد میلو بلاستیک است. هنگامی که این روش روی نمونه های پاتولوژیک آزمایش شد، این سیستم به بازده تشخیصی ۹۱٪ رسید [۴۰]. یکی دیگر از کاربردهای ارزشمند این سیستم، یک مدل داده کاوی است که تشخیص پلی سیتی ورا (PV) را بر اساس هشت پارامتر از معیارهای گروه مطالعه PV (PVSG)، به علاوه جنسیت و مقدار هماتوکریت (Hct) افزایش می دهد؛ این سیستم اخیرا مورد آزمایش قرار گرفته است و هیچ تفاوتی با سیستمی که با استفاده از تنها ۴ پارامتر (هماتوکریت، تعداد پلاکت، طحال، و WBC) کار میکرد، نشان نداد بلکه با میزان دقتی برابر با ۹۸/۱ بمانند سیستم قبلی عمل کرد [۴۱].

در همین زمینه، گروه اروپایی پیوند مغز و اعصاب - خون (EBMT) یک مطالعه داده کاوی را بر روی گروهی از ۲۸۲۳۶ بیمار انجام دادند. در این کار، مدلی مبتنی بر ده متغیر منتخب به منظور ارزیابی و پیش بینی مرگ و میر کلی در ۱۰۰ روز پس از allo-HSCT استفاده؛ ثابت شد که این مدل برای این منظور کارآمدتر از امتیاز EBMT است (منطقه زیر منحنی ویژگی های عملکرد گیرنده ۰/۷۰۱ در مقابل ۰/۶۴۶؛ $P < 0.001$) [۴۲]. مطالعه دیگری که توسط EBMT با گروهی از بیماران لوسمی حاد انجام شد، نشان داد که تنها چند متغیر، مانند رژیم شرطی سازی، نوع اهداکننده و مرحله بیماری، میزان مرگ و میر مرتبط با درمان را متحمل میشوند و برشی از این بیماری قرار دارند، از اینرو به ورودی های متنوع دیگری نیز نیاز دارد [۴۳].

در نهایت، به نظر میرسد مشخصات ژن یک زمینه مفید و ارزشمند برای تحقیق و طبقه بندی پاتولوژی های خاص باشد. یکسان و جفت کردن مدل های هوش مصنوعی با رویکرد ریز آرایه DNA به ایجاد کلاس های آسیب شناسی جدید و حتی تجزیه و تحلیل سلول های بنیادی با استفاده از یادگیری ماشین کمک کرده است. یادگیری بدون نظارت در کشف طبقه بندی کلاس میلوماهای چندگانه به پنج زیرگروه با استفاده از انکوژن انتقال و بیان سیکلین استفاده شده است [۴۴]. اما یادگیری نظارت شده برای پیش بینی کلاس ها استفاده شده است؛ مانند موارد لوسمی میلو بلاستیک حاد. به احتمال زیاد در روش بعدی به منظور کمک به تمایز سلول های بنیادی با خطوط خاص، از مشخصات ژنتیکی پایه استفاده شود [۴۵].

۶) نورولوژی

یکی از ابزارهای تشخیصی مفید در نورولوژی، خواندن نوار الکتروانسفالوگرافی (EEG) است که ایده ای در مورد فعالیت الکتریکی مغز ارائه می دهد. بسیاری از تکنیک های ML برای تجزیه و تحلیل این سیگنال ها و ارائه یک پیش بینی پیاده سازی شده اند [۴۶]. در سال ۲۰۱۷، Subasi و همکاران او، الگوریتمی را برای تشخیص تشنج های صرع در پرونده های EEG با استفاده از دو تکنیک یادگیری ماشینی به نام های SVMs و (Support Vector Machines) و Gas الگوریتم های ژنتیک پیشنهاد کردند که دقت ۹۹/۳۸٪ را در مجموعه داده های الکتروانسفالوگرافی ثبت کرد. با این حال در یکی از انتشارات اخیر Avcu و همکاران وی، تکنیک ML دیگری به نام شبکه های عصبی کانولوشنال (CNNs) ارائه کردند که می تواند تشنج را تنها با استفاده از دو کانال با دقت ۹۳/۳ درصد تشخیص دهد. برای مشاهده سایر روش هایی که تکنیک های یادگیری ماشینی به متخصصان مغز و اعصاب کمک می کنند، باید به عنوان مثال از بیماری پارکینسون (PD) یاد کنیم [۴۷].

Prashanth با همکاری گروه پژوهشی وی، یک سیستم از یادگیری ماشینی را ارائه کرد که میتواند با دقتی برابر با ۹۶/۴۰٪ احتمال PD را پیش بینی و شناسایی کند. این روش از ویژگی های غیرحرکتی و عدم وجود حس بویایی استفاده میکند و علاوه بر آن، میتواند ضمن اندازه گیری مایع مغزی نخاعی (CSF)، از داده های نشانگرهای تصویربرداری دوپامینرژیک استفاده کند و نتایج را به نمایش در بیاورد [۴۸]. اکنون، پس از تشخیص بیماری، می توان از سیستم ML دیگری برای پیش بینی پیشرفت بیماری استفاده کرد؛ بطوریکه سیستم ارائه شده توسط Rastegar و همکاران وی، از سیتوکین های سرم از یک نقطه زمانی مشخص (خط پایه) در عرض یک سال برای پیش بینی نتایج در دوسال آینده آن استفاده میکرد [۴۹].

۷) انکولوژی

استفاده از هوش مصنوعی و یادگیری ماشینی برای مبارزه با سرطان عمدتاً به عنوان یک رویکرد جذاب در عصر مهارکننده های مولکول کوچک، ژن درمانی و بیوتراپی های مهندسی شده در نظر گرفته شده است. این تکنیک ها در حال حاضر در زمینه انکولوژی تشعشع در تقسیم بندی تصویر و بهینه سازی دوز رادیوتراپی استفاده می شوند که در آن هوش مصنوعی و یادگیری ماشینی به اندازه کافی استانداردهای مرسوم را برآورده کرده اند و ثابت کرده اند که در اکثر موقعیت ها کارآمدتر از برنامه ریزی دستی هستند [۵۰]. توسعه نانوربات (Nanobot) نمونه ای از کاربرد فیزیکی هوش مصنوعی در سرطان شناسی است. نانوربات ها برای رسیدگی به موارد زیر استفاده می شوند:

۱. مشکل افت نفوذ و عدم انتشار عوامل درمانی هدف در محل کاربرد

۲. هدف قرار دادن تومورها با کمبود عروقی اما نشان دهنده تکثیر فعال [۵۱]

برای بیمارانی که تحت عمل گاسترکتومی قرار می‌گیرند، ثابت شده است که یک تکنیک خاص یادگیری ماشین در جداکردن و تعیین طبقه بندی مبتنی بر خطر در مورد پیش‌بینی بقای بیمار می‌تواند بهترین باشد [۵۲]. یک الگوریتم آسیب شناسی DL Research با استفاده از تصاویر پزشکی برای شناسایی گسترش سرطان سینه به غدد لنفاوی مجاور، به سیستم آموزش داده شده است و نتیجه آن نمره ۸۹٪ با میزان دقت ۷۳٪ برای توانایی در آسیب شناسی شد [۵۳].

CNN ها رایج ترین شکل یادگیری تحت نظارت هستند. کاربرد آنها در اندازه گیری و ردیابی تومورهای مغزی، گلیوما، و تومورهای کبدی هستند که به صورت دو بعدی همانند نسخه سه بعدی تصاویر پزشکی، با نتایج جالبی در بسیاری از آزمایش ها ر مقایسه با روش های نیمه خودکار مبتنی بر RECIST مورد بررسی قرار گرفت [۵۴-۵۶].

۸) زیست شناسی سلولی و سلول درمانی

در زیست شناسی سلول و سلول درمانی، انواع تکنیک های غربالگری و تجزیه و تحلیل تصاویر سلول ها در مقیاس زیاد وجود دارد. در نتیجه، استفاده از ML برای شناسایی بهترین تصویر غربالگری ضروری بود؛ تکنیک هایی همچون تجزیه و تحلیل ترکیبات و انواع سلول بطوریکه بتوان میان خطوط سلولی تمایز برای آنها قائل شد. بنابراین، پیشرفت های میدانی بسیار زیادی در این زمینه وجود دارد. بعنوان مثال برخی از میکروسکوپ های خودکار ML که در حال حاضر بصورت تجاری درآمده اند، می‌توانند بیش از ۱۰۰۰۰۰ تصویر سلولی را در روز تجزیه و تحلیل کنند [۵۷]. فناوری تصویربرداری زیستی می‌تواند به طور موثر وظایف تجزیه و تحلیل تصویر خاص، مانند تشخیص اشیا، تجزیه و تحلیل حرکت، و اندازه‌گیری ویژگی‌های مورفومتریک را انجام دهد. شناختی که ML بجای تنظیم دستی استفاده میکند، پارامترهای آن برای شناسایی سلول ها و اشیا بکار نمی‌روند، بلکه برای وظایف پیچیده تر برای تجزیه و تحلیل داده های چند بعدی مورد استفاده قرار می‌گیرند که از ابزارهای پردازش معمولی قوی‌تر است [۵۹-۶۱]. وظیفه مهم ML در زیست شناسی سلولی تعیین این است که آیا یک اختلال تجربی (به عنوان مثال اصلاح ژنتیکی) منجر به یک فنوتیپ سلولی خاص (تشخیص با فلورسانس) می‌شود [۶۲]؟

اخیرا یک روش از یادگیری ماشین بر روی تصاویر میکروسکوپی فلورسانس نشاندار شده با اکتین از یک رده سلولی اپیتلیال مورد آزمایش قرار گرفته است که یک پستان طبیعی انسان و دو خط سرطان سینه انسان با سطوح مختلف پرخاشگری را به ما نشان می‌دهد؛ این مطالعه نشان می‌دهد که این تکنیک در کار طبقه بندی سلولی در مقایسه با یک متخصص انسانی بهتر عمل می‌کند [۶۳]. چنین فناوری ممکن است برای ایجاد و تقویت روش‌های جدید تولید و کنترل کیفیت سلول‌درمانی‌ها مانند سلول‌های گیرنده آنتی ژن کایمریک T (CAR-T) مورد استفاده قرار گیرد؛ رویکردی که به کار گرفته شده است و به طور موثر ویژگی‌های T-CAR فعال بالینی را نشان داده است. (به عنوان مثال وضعیت گلیکولیز، فنوتیپ حافظه اولیه و فرسودگی کمتر مشخصات) [۶۴-۶۵].

یادگیری ماشین همچنین می تواند برای درمان سلول های بنیادی استفاده شود؛ رویکردی که اخیراً مورد آزمایش قرار گرفته است، تنوع بالایی در هویت سلولی نشان می دهد که بطور طبیعی می تواند با ایجاد تغییر در دینامیک تنظیم، ایجاد شود. این تکنیک در فهم بیولوژی سلول فردی، پویایی جمعی خطوط سلولی و محیط ها بسیار قوی تر میباشد [۶۶].

۹) کاردیولوژی

کلیدهای تشخیصی اصلی در دسترس متخصصان قلب عبارتند از: سیگنال های الکتریکی قلب الکتروکاردیوگرافی ECG و سمع قلب. ابزارهای ML به تجزیه و تحلیل و طبقه بندی سیگنال هم برای اولی و هم برای دومی کمک می کنند. پزشک میتواند با استفاده از گوشی پزشکی دیجیتال یعنی فونوکاردیوگرام سمع قلب را انجام دهد و برای ضبط این صداها از PCG استفاده کند تا بتواند صداها را طبیعی و غیرطبیعی را از همدیگر تشخیص دهد. در سال ۲۰۱۸، Yassen و همکاران وی، ک سیستم مبتنی بر ML ارائه کرد که سیگنال های قلبی را طبقه بندی می کند و اختلالات قلبی را با دقت ۹۷ درصد تشخیص می دهد [۶۷]. برای اضافه کردن به موارد فوق باید متذکر شد که ECG سیگنال هایی را پردازش میکند که متخصصان قلب میتوانند آنها را بخوانند. در واقع این مقادیر وارد دستگاه می شوند و در دامنه خطی زمان نشان داده می شوند. این مقادیر را می توان به عنوان ورودی به الگوریتم یا ساختارها استفاده کرد که می تواند Signal Patten را تجزیه و تحلیل کرده و سپس آن را طبقه بندی کند. در اوایل سال جاری، آلفارس و همکاران ایشان، یک مدل ML ارائه کرد که می تواند سیگنال های ECG را طبقه بندی کند و آریتمی را با استفاده از یک سرخ تشخیص دهد، در حالی که متخصصان قلب معمولاً باید مجموعه ۱۲ لید را بخوانند تا رکورد ECG را کامل بخوانند. این مدل به حساسیت ۹۲/۷ درصد و پیشبینی مثبت ۸۶/۱ درصد برای ضربان های نابجای بطنی با استفاده از سرب II و حساسیت ۹۵ دست یافت؛ همچنین ۷ درصد پیشبینی مثبت و ۷۵/۱ درصد هنگام استفاده از لید سربی V1 [۶۸].

۱۰) چشم پزشکی

ناهنجاری چه بینایی باشد، چه بیماری های دیگری که بر روی چشم تاثیر میگذارند، فرقی ندارد چراکه رشته چشم پزشکی نیز سهم مناسبی از علم یادگیری ماشین داشته است؛ چه بسا کاربردی تر و پیچیده تر از بقیه رشته ها نیز میباشد [۶۹-۷۰]. چشم پزشکان در حال حاضر از دستگاه هایی برای شناسایی سریع و کارآمد ناهنجاری های بینایی استفاده می کنند. اما وقتی صحبت از بیماری های دیگر می شود، شکایات مربوط به عوارض ناشی از دیابت قندی بر روی چشم است؛ به ویژه رتینوپاتی دیابتی (DR). Sayers و همکاران او، نشان دادند که چگونه می توان با استفاده از یک الگوریتم یادگیری عمیق، درجه سخت ترین DR ها را با بالاترین دقت تشخیص داد [۷۱]. علاوه بر این، Li و همکاران وی، اخیراً یک مدل CNN ارائه کرده اند که با استفاده از رویکرد مبتنی بر شبکه عصبی کانولوشن می تواند گلوکوم را تشخیص دهد [۷۲].

هنگامی که پزشکان متخصص درباره پیشرفت ما در مورد یادگیری ماشین یا ML و هوش مصنوعی یا AI بحث و گفتگو میکنند، سوال پیش می آید که آیا ما آماده چنین پیشرفتی هستیم؟ و آیا بطور کامل و بصورت حرفه ای از این علم استفاده می کنیم؟ پاسخ این است که هنوز محدودیت های زیادی وجود دارد تا بطور کامل در حوزه مراقبت های بهداشتی گنجانده شود. همه اینها نیاز به دستورالعمل هایی در چارچوب قانون و اخلاق نیاز دارد تا درموارد بحرانی به آن پرداخته شود؛ همچنین اینکه آموزش چند سطحی که زمینه مناسبی را در مورد این فناوری در اختیار پزشکان قرار دهد ضروری است. و سپس این سوال وجود دارد که چگونه می توان آن را به طور ایمن و دلسوزانه در عمل بالینی روزانه ادغام کرد؟ و زیرساخت مناسب برای پیاده سازی این سیستم ها چیست؟ برای اضافه کردن به این، بار مالی به همان اندازه موضوعی است که باید حداقل در مرحله تنظیم در نظر گرفته شود [۷۳].

با نگاهی مثبت، چنین سیستم هایی به پزشکان در صرفه جویی در زمان و تلاش کمک و در فرآیند تصمیم گیری کمک می کند. با توجه به نمونه های بسیار زیادی که این سیستم ها با آن ها آموزش می دهند، مشاهدات آن ها از آنچه که هر پزشک به تنهایی در طول زندگی حرفه ای خود شاهد بوده است بیشتر است و می تواند سود زیادی داشته باشد [۷۴]. به نظر می رسد هوش مصنوعی به تنهایی یا با مشارکت ML راه حلی موثر برای افزایش کیفیت پزشکی شخصی شده و برای تسریع ریتم تکامل برای تکنیک های پیچیده تشخیصی و درمانی مانند در زمینه ژنتیک، مولکول های کوچک و درمان های فوق هدف باشد.

به نظر ما، تحولات دیجیتالی در خدمت پزشکی هستند و برای تضمین حداکثری آن، باید اثربخشی و هدایت دقیق فناوری اطلاعات به منظور غلبه بر محدودیت ها، براساس تخصص بالینی باشد.

REFERENCES

- [1] Buntin MB, Burke MF, Hoaglin MC, Blumenthal D. The benefits of health information technology: a review of the recent literature shows predominantly positive results. *Health Aff (Millwood)*. 2011;30(March (3)):464–71.
- [2] Hayrinen K, Saranto K, Nykanen P. Definition, structure, content, use and impacts of electronic health records: a review of the research literature. *Int J Media Inf Lit* 2008;77(May (5)):291–304.
- [3] Musen MA, Middleton B, Greenes RA. Clinical decision-support systems. In: Shortliffe EH, Cimino JJ, editors. *Biomedical informatics* [internet]. London: Springer London; 2014. p. 643–74. . [cited 2019 Dec 7]. Available from: http://link.springer.com/10.1007/978-1-4471-4474-8_22.
- [4] [StanfordMedicineHealthTrendsWhitePaper2017.pdf](https://med.stanford.edu/content/dam/sm/sm-news/documents/StanfordMedicineHealthTrendsWhitePaper2017.pdf) [Internet]. [cited 2019 Oct 12]. Available from: <https://med.stanford.edu/content/dam/sm/sm-news/documents/StanfordMedicineHealthTrendsWhitePaper2017.pdf>.
- [5] Kumar MA, Vimala R, Britto KRA. A cognitive technology based healthcare monitoring system and medical data transmission. *Measurement* 2019;146 (November):322–32.
- [6] Goodwin S. Data rich, information poor (DRIP) syndrome: is there a treatment? *Radiol Manage* 1996;18(June (3)):45–9.
- [7] *Computer-Based Medical Consultations: Mycin* [Internet]. Elsevier; 1976 [cited 2019 Dec 7]. Available from: <https://linkinghub.elsevier.com/retrieve/pii/B9780444001795X5001X>.
- [8] Ronquillo C, Currie LM, Rodney P. The evolution of data-information Knowledge-Wisdom in nursing informatics. *ANS Adv Nurs Sci* 2016;39 (March (1)):E1–E18.
- [9] Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nat Med* 2019;25(January (1)):24–9.
- [10] Benedek M, Jauk E, Sommer M, Arendasy M, Neubauer AC. Intelligence, creativity, and cognitive control: the common and differential involvement of executive functions in intelligence and creativity. *Intelligence* 2014;46 (September):73–83.
- [11] Patanella D, Ebanks C, Kosorok Mellor J, Kilanowski-Press L, Reicherzer S, Nadal KL, et al. Gardner’s theory of multiple intelligences. In: Goldstein S, Naglieri JA, editors. *Encyclopedia of child behavior and development* [internet]. Boston, MA: Springer US; 2011. p. 681–2. . [cited 2019 Dec 2] Available from: http://link.springer.com/10.1007/978-0-387-79061-9_1870.
- [12] Jackson S. *Human, Machine Thinking* P. N. Johnson-Laird, 1993 Hillsdale, NJ: Lawrence Erlbaum Associates ISBN 0-8058-0921, £19.95. *Connect Sci*. 6 (1994) January(1):107–9.
- [13] Haenlein M, Kaplan A. A brief history of artificial intelligence: on the past, present, and future of artificial intelligence. *Calif Manage Rev* 2019;61(August (4)):5–14.
- [14] Panch T, Szolovits P, Atun R. Artificial intelligence, machine learning and health systems. *J Glob Health [Internet]* 2018;8(December (2)). . [cited 2019 Dec 2];. Available from: <http://jogh.org/documents/issue201802/jogh-08-020303.pdf>.
- [15] Doya K. Reinforcement learning: computational theory and biological mechanisms. *HFSP J* 2007;1(1):30.
- [16] Fogassi L, Ferrari PF, Gesierich B, Rozzi S, Chersi F, Rizzolatti G. Parietal lobe: from action organization to intention understanding. *Science* 2005;308(April (5722)):662–7.
- [17] Chen D, Liu S, Kingsbury P, Sohn S, Storlie CB, Habermann EB, et al. Deep learning and alternative learning strategies for retrospective real-world clinical data. *Npj Digit Med [Internet]* 2019;2(December (1)). . [cited 2019 Dec 2] Available from: <http://www.nature.com/articles/s41746-019-0122-0>.
- [18] De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med* 2018;24(September (9)):1342–50.
- [19] Yang X, Jeong JJ, Lei Y, Liu T, Curran WJ, Mao H, et al. Machine-learning-based classification of glioblastoma using MRI-based radiomic features. In: Hahn HK, Mori K, editors. *Medical imaging 2019: computer-aided diagnosis* [internet]. San Diego, United States: SPIE; 2019. p. 152. . [cited 2019 Oct 13]. Available from: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/10950/2513110/Machine-learning-based-classification-of-Glioblastoma-using-MRI-based-radiomic/10.1117/12.2513110.full>.
- [20] Xiao C, Choi E, Sun J. Opportunities and challenges in developing deep learning models using electronic health records data: a systematic review. *J Am Med Inform Assoc* 2018;25(October (10)):1419–28.
- [21] Shameer K, Johnson KW, Glicksberg BS, Dudley JT, Sengupta PP. Machine learning in cardiovascular medicine: are we there yet? *Heart* 2018;104(July (14)):1156–64.

- [22] Wiens J, Shenoy ES. Machine learning for healthcare: on the verge of a major shift in healthcare epidemiology. *Clin Infect Dis* 2018;66(Januar (1)):149–53.
- [23] Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: review, opportunities and challenges. *Brief Bioinform*. 2018;19(November (6)):1236–46.
- [24] Miotto R, Li L, Kidd BA, Dudley JT. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *SciRep* 2016;6 (May (1)):26094.
- [25] Subramani K, Mehta M. Nanodiagnosics in microbiology and dentistry. *Emerging nanotechnologies in dentistry* [Internet]. Elsevier; 2018. p. 391–419. . [cited 2019 Dec 7] Available from: <https://linkinghub.elsevier.com/retrieve/pii/B9780128122914000194>.
- [26] Baird HW, Garfunkel JM. Electronic data processing of medical records. *N Engl J Med* 1965;272(June (23)):1211–5.
- [27] Savova GK, Masanz JJ, Ogren PV, Zheng J, Sohn S, Kipper-Schuler KC, et al. Mayo clinical text Analysis and Knowledge Extraction System (cTAKES): architecture, component evaluation and applications. *J Am Med Inform Assoc* 2010;17(September (5)):507–13.
- [28] Ashfaq A, Sant'Anna A, Lingman M, Nowaczyk S. Readmission prediction using deep learning on electronic health records. *J Biomed Inform* 2019;97 (September)103256.
- [29] Lee J-G, Jun S, Cho Y-W, Lee H, Kim GB, Seo JB, et al. Deep learning in medical imaging: general overview. *Korean J Radiol* 2017;18(August (4)):570–84.
- [30] Wu T, Sultan LR, Tian J, Cary TW, Sehgal CM. Machine learning for diagnostic ultrasound of triple-negative breast cancer. *Breast Cancer Res Treat* 2019;173 (January (2)):365–73.
- [31] Moradi M, Wong KCL, Syeda-Mahmood T, Wu JT. Identifying disease-free chest x-ray images with deep transfer learning. In: Hahn HK, Mori K, editors. *Medical imaging 2019: computer-aided diagnosis* [internet]. San Diego, United States: SPIE; 2019. p. 24. . [cited 2019 Oct 13] Available from: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/10950/2513164/Identifying-disease-free-chest-x-ray-images-with-deep-transfer/10.1117/12.2513164.full>.
- [32] Uthoff J, Stephens MJ, Newell JD, Hoffman EA, Larson J, Koehn N, et al. Machine learning approach for distinguishing malignant and benign lung nodules utilizing standardized perinodular parenchymal features from CT. *Med Phys* 2019(June) mp.13592.
- [33] Diamond LW, Mishka VG, Seal AH, Nguyen DT. Multiparameter interpretative reporting in diagnostic laboratory hematology. *Int J Biomed Comput* 1994;37 (November (3)):211–24.
- [34] Diamond LW, Nguyen DT, Andreeff M, Maiese RL, Braylan RC. A knowledge-based system for the interpretation of flow cytometry data in leukemias and lymphomas. *Cytometry* 1994;17(November (3)):266–73.
- [35] Nguyen DT, Diamond LW, Cavenagh JD, Parameswaran R, Amess JA. Haematological validation of a computer-based bone marrow reporting system. *J Clin Pathol* 1997;50(May (5)):375–8.
- [36] Guncar 9 G, Kukar M, Notar M, Brvar M, Cernelc 9 P, Notar M, et al. An application of machine learning to haematological diagnosis. *Sci Rep* [Internet] 2018;8 (January). . [cited 2019 Oct 13] Available from: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5765139/>.
- [37] Arai Y, Kondo T, Fuse K, Shibasaki Y, Masuko M, Sugita J, et al. Using a machine learning algorithm to predict acute graft-versus-host disease following allogeneic transplantation. *Blood Adv* 2019;3(November (22)):3626–34.
- [38] d'Onofrio G, Zini G. *Morphology of the blood*. Oxford: Butterworth Heinemann; 1998. [39] Zini G. Artificial intelligence in Hematology. *Hematology* 2005;10(October (5)):393–400.
- [40] d'Onofrio G, Zini G. Diagnostic value of peroxidase and size parameters from a new hematological analyzer. . p. 238–9.
- [41] Kantardzic M, Djulbegovic B, Hamdan H. A data-mining approach to improving Polycythemia Vera diagnosis. *Comput Ind Eng*. 2002;43(September (4)):765–73.
- [42] Shouval R, Labopin M, Bondi O, Mishan-Shamay H, Shimoni A, Ciceri F, et al. Prediction of allogeneic hematopoietic stem-cell transplantation mortality 100 days after transplantation using a machine learning algorithm: a European group for blood and marrow transplantation acute leukemia working party retrospective data mining study. *J Clin Oncol Off J Am Soc Clin Oncol*. 2015;33 (October (28)):3144–51.
- [43] Shouval R, Labopin M, Unger R, Giebel S, Ciceri F, Schmid C, et al. Prediction of Hematopoietic Stem Cell Transplantation Related Mortality- Lessons Learned from the In-Silico Approach:

- A European Society for Blood and Marrow Transplantation Acute Leukemia Working Party Data Mining Study. Bertolini F, editor. PLoS One 2016;11(March (3))e0150637.
- [44] Barillé-Nion S, Barlogie B, Bataille R, Bergsagel PL, Epstein J, Fenton RG, et al. Advances in biology and therapy of multiple myeloma. *Hematol Am Soc Hematol Educ Program*. 2003;248–78.
- [45] Ramalho-Santos M, Yoon S, Matsuzaki Y, Mulligan RC, Melton DA. “Stemness”: transcriptional profiling of embryonic and adult stem cells. *Science* 2002;298 (October (5593)):597–600.
- [46] Subasi A, Kevric J, Abdullah Canbaz M. Epileptic seizure detection using hybrid machine learning methods. *Neural Comput Appl* 2019;31(January (1)):317–25.
- [47] Avcu MT, Zhang Z, Chan DWS. Seizure detection using least eeg channels by deep convolutional neural network. ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). . p. 1120–4.
- [48] Prashanth R, Dutta Roy S, Mandal PK, Ghosh S. High-accuracy detection of early parkinson’s disease through multimodal features and machine learning. *Int J Media Inf Lit* 2016;90(June):13–21.
- [49] Ahmadi Rastegar D, Ho N, Halliday GM, Dzamko N. Parkinson’s progression prediction using machine learning and serum cytokines. *Npj Park Dis*. 2019;5 (December (1)):14.
- [50] Thompson RF, Valdes G, Fuller CD, Carpenter CM, Morin O, Aneja S, et al. Artificial intelligence in radiation oncology: a specialty-wide disruptive transformation? *Radiother Oncol* 2018;129(December (3)):421–6.
- [51] Londhe VY, Bhasin B. Artificial intelligence and its potential in oncology. *Drug Discov Today* 2019;24(January (1)):228–32.
- [52] Uhlén M, Björling E, Agaton C, Szilyarto CA-K, Amini B, Andersen E, et al. A human protein atlas for normal and cancer tissues based on antibody proteomics. *Mol Cell Proteomics MCP*. 2005;4(December (12)):1920–32.
- [53] Araújo T, Aresta G, Castro E, Rouco J, Aguiar P, Eloy C, et al. Classification of breast cancer histology images using Convolutional Neural Networks. PLoS One 2017;12(June (6))e0177544.
- [54] Işın A, Direkoglu C, Şah M. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Comput Sci* 2016;102 (January):317–24.
- [55] Vivanti R, Joskowicz L, Karaaslan OA, Sosna J. Automatic lung tumor segmentation with leaks removal in follow-up CT studies. *Int J Comput Assist Radiol Surg* 2015;10(September (9)):1505–14.
- [56] Weizman L, Ben-Sira L, Joskowicz L, Precel R, Constantini S, Ben-Bashat D. Automatic segmentation and components classification of optic pathway gliomas in MRI. *Med Image Comput Comput-Assist Interv MICCAI Int Conf Med Image Comput Comput-Assist Interv*. 2010;13(Pt 1):103–10.
- [57] Lock JG, Strömblad S. Systems microscopy: an emerging strategy for the life sciences. *Exp Cell Res* 2010;316(May (8)):1438–44.
- [58] Myers G. Why bioimage informatics matters. *Nat Methods* 2012;9(July (7)):659–60.
- [59] Franklin J. The elements of statistical learning: data mining, inference and prediction. *Math Intell*. 2005;27(March (2)):83–5.
- [60] Domingos P. A few useful things to know about machine learning. *Commun ACM* 2012 October;55(10):78.
- [61] Neumann B, Walter T, Hériché J-K, Bulkescher J, Erfle H, Conrad C, et al. Phenotypic profiling of the human genome by time-lapse microscopy reveals cell division genes. *Nature* 2010;464(April (7289)):721–7.
- [62] de Ridder D, de Ridder J, Reinders MJT. Pattern recognition in bioinformatics. *Brief Bioinform*. 2013;14(September (5)):633–47.
- [63] Oei RW, Hou G, Liu F, Zhong J, Zhang J, An Z, et al. Convolutional neural network for cell classification using microscope images of intracellular actin networks. Horvath D, editor. PLoS One 2019;14(March (3))e0213626.
- [64] Sugimoto K. Machine learning-driven label-free cell sorting for CAR-T cell manufacturing. *Cytotherapy* 2019;21(May(5)):S39.
- [65] Lee M, Lee Y-H, Song J, Kim G, Jo Y, Min H, et al. DeepIS: deep learning framework for three-dimensional label-free tracking of immunological synapses [Internet]. *Immunology* 2019(February), doi:http://dx.doi.org/ 10.1101/539858 [cited 2019 Oct 13]. Available from:.
- [66] Stumpf PS, MacArthur BD. Machine learning of stem cell identities from singlecell expression data via regulatory network archetypes. *Front Genet* 2019;10 (January):2.

[67] Yaseen Son G-Y, Kwon S. Classification of heart sound signal using multiple features. *Appl Sci (Basel)* 2018;8(November (12)):2344.

[68] Alfaras M, Soriano MC, Ortín S. A fast machine learning model for ECG-Based heartbeat classification and arrhythmia detection. *Front Phys* 2019;7 (July):103.

[69] Promising Artificial Intelligence-Machine Learning-Deep Learning Algorithms in Ophthalmology. *Asia-Pac J Ophthalmol* [Internet]. 2019 [cited 2019 Oct 13]; Available from: https://journals.lww.com/apjoo/Fulltext/2019/05000/Promising_Artificial_Intelligence_Machine.13.aspx.

[70] Artificial Intelligence in Ophthalmology: Accuracy, Challenges, and Clinical Application. *Asia-Pac J Ophthalmol* [Internet]. 2019 [cited 2019 Oct 13]; Available from: https://journals.lww.com/apjoo/Fulltext/2019/05000/Artificial_Intelligence_in_Ophthalmology_.2.aspx.

[71] Sayres R, Taly A, Rahimy E, Blumer K, Coz D, Hammel N, et al. Using a deep learning algorithm and integrated gradients explanation to assist grading for diabetic retinopathy. *Ophthalmology* 2019;126(April (4)):552–64.

[72] LiL,XuM,LiuH,LiY,WangX, JiangL, et al.Alarge-scaledatabase anda CNNmodel for attention-based Glaucoma detection. *IEEE Trans Med Imaging* 2019 1–1.

[73] Miller DD. The medical AI insurgency: what physicians must know about data to practice with intelligent machines. *Npj Digit Med* [Internet] 2019;2 (December (1)). . [cited 2019 Dec 7] Available from: <http://www.nature.com/articles/s41746-019-0138-5>.


[74] Rajkomar A, Dean J, Kohane I. Machine learning in medicine. *2019;380(14):1347–58.N Engl J Med*

WRITERS

Tamim Alsuliman

Dania Humaidan

Layth Sliman



ارتباط با ما

برای اطلاعات بیشتر



Department_bme



Info@dep-bme.ir



department_bme



Www.dep-bme.com