

WPROWADZENIE

PODSTAWY NANOTECHNOLOGII

Nanotechnologia to nauka zajmująca się modyfikacją materiałów na poziomie atomowym lub supramolekularnym. Biorąc pod uwagę ostatnie kilka dziesięcioleci, podstawy nanotechnologii wyłoniły się jako autonomiczna gałąź nauki z wyraźnymi możliwościami badawczymi dla świata nauki i społeczeństwa. Interdyscyplinarne podejście, dociekliwość badań i większa świadomość społeczna sprawiły, że nanotechnologia stała się najbardziej pożądaną dziedziną. Ostatnie badania w dziedzinie nanotechnologii ujawniają ewidentne perspektywy osiągnięć, które są tylko wierzchołkiem góry lodowej dla naukowego bractwa i wielu innych, jak stwierdził dr Feymann: „Na dole jest dużo miejsca”. Dlatego świat nauki oczekuje na tę technologię jako „technologię następnego stulecia”. Nowość i ekskluzywność nanotechnologii dostrzeżono dzięki niesamowitym właściwościom obiektów w nanoskali. Kiedy materiały zostają zredukowane do nanopoziumu ze zjawiskiem uwięzienia kwantowego, materiały mają tendencję do atakowania większej powierzchni, zwiększając w ten sposób energię powierzchniową i wykazując różne zaawansowane właściwości. Nanomateriały udowodniły, że rozmiar naprawdę ma znaczenie dla każdego obiektu, gdy zostanie on przekształcony z materiału sypkiego w nanoskalę o magicznych właściwościach. Skuteczność rozmiaru zależy od właściwości materiału, takich jak optyczna, elektryczna, magnetyczna, temperatura topnienia, ciepło właściwe, mechanizmy biologiczne, reaktywność powierzchni i tak dalej. Szeroko zakrojone badania w tej dziedzinie nauki doprowadziły społeczność naukowców i akademików do zaakceptowania potencjału nanotechnologii dla dobra ludzkości i podniesienia standardu życia. Wpływ nanotechnologii rozszerza się na każdy aspekt ludzkiego życia dzięki zastosowaniu jej produktów w różnych ważnych branżach, takich jak opieka zdrowotna, biomedyczna, farmaceutyczna, elektronika i produkcja energii. Ponieważ mechanizmy produkcji i przetwarzania zajmują się koncepcjami inżynierskimi, inżynierowie stają przed obecnym wyzwaniem opracowania nowatorskiej strategii z wykorzystaniem nanotechnologii dla nowych produktów na rynku. Oprócz zrozumienia podstaw tej wspaniałej technologii, dziedzina ta wymaga bardziej kreatywnych pomysłów na rozwój technologii. Co więcej, krytyczne myślenie i kreatywność są uważane za kluczowe cechy w procesie uczenia się nanotechnologii. Ze względu na te istotne cechy jest uważany za interdyscyplinarną platformę odkrywania możliwości w naukach inżynierskich i technologii informacyjnej z szerszym aspektem, z korzyścią dla społeczeństwa.

ROLA NANOTECHNOLOGII W MEDYCYNIE I OPIECE ZDROWOTNEJ

Nanotechnologia odgrywa znaczącą rolę w opiece zdrowotnej i medycynie translacyjnej. Wykorzystanie rozmiarów nanocząstek i przerw między strukturami o rozmiarach nanometrycznych to inne sposoby uzyskiwania nowych właściwości i fizycznego dostępu do tkanek i komórek. Kropki kwantowe są wykorzystywane do wizualizacji dostarczania leków ze względu na ich fluorescencję i zdolność śledzenia bardzo małych struktur biologicznych. Wtórne skutki nowych technik obejmują podnoszenie obaw związanych z bezpieczeństwem, takich jak toksyczność, które należy rozwiązać, zanim techniki te zostaną zastosowane w praktyce medycznej. Nowe obszary obejmują opracowywanie realistycznego modelowania molekularnego „miękkiej” materii, uzyskiwanie informacji uśrednionych niezwiązanych z zespołami w nanoskali, rozumienie dostaw energii i konwersji do komórek (fotony i lasery) oraz mechanizmów regeneracji. Rak jest jedną z głównych przyczyn zgonów w dzisiejszym świecie. Według statystyk dotyczących raka z 2017 r. około 9,6 mln osób zmarło z powodu różnych form raka [6]. Nanotechnologia okazała się jedną z najskuteczniejszych metod dostarczania leków. Nanocząstki - biorąc pod uwagę ich stosunek powierzchni do objętości, ich rozmiar i kształt — umożliwiają wielokrotną funkcjonalność i łatwą zmianę ich właściwości. Można je zaprogramować tak, aby odróżniały złośliwe komórki rakowe od zdrowych komórek człowieka.

Nanotechnologia umożliwia szybkie testowanie chorób za pomocą technik obrazowania, co zapewnia, że choroby te zostaną wykryte na wcześniejszym etapie, aby umożliwić zastosowanie mniej wymijających technik potrzebnych do wyleczenia ich u źródła lub po prostu spowodowania minimalnych szkód. W tej części zostaną opisane różne zastosowania i ich unikalne właściwości, które sprawiają, że nanocząstki w różnych formach nadają się do pełnienia swojej funkcji. Egzosomy są rodzajem pęcherzyków zewnątrzkomórkowych i są użytecznymi mediatorami w komunikacji międzykomórkowej na duże odległości. Dobrze zmodyfikowany biokompatybilny egzosom zwiększa stabilność i skuteczność sond obrazujących dzięki wzmocnionemu mechanizmowi regulacyjnemu w celu pokonania błony komórkowej. Egzosomy o rozmiarach nanometrycznych są przydatne w identyfikacji biomarkerów wskazujących na raka trzustki. Opiera się to na teorii, że nanocząstka niesie kilka markerów peptydowych, które również znajdują się w dużym stężeniu na wczesnym etapie, a zatem można je wykryć. Podobnie czujniki nanoporowe i technologia sztucznej inteligencji (AI) są wykorzystywane do identyfikacji pojedynczych cząsteczek wirusa w miejscu użycia i szybkiej identyfikacji. Nanopor to por o wielkości nanometra; opiera się na zasadzie, że przepływ cieczy przez jej membranę mierzy prąd jonowy przechodzący przez jej pory. Ten czujnik jest niezwykle czuły, przepuszczając przez niego tylko cząsteczki wirusów, które są specyficzne dla czujnika. AI służy do identyfikacji rodzaju substancji wirusowej, która przechodzi przez nanopor. Technologia ta wykrywa to, co zostało pominięte przez ludzkie oko podczas analizy różnicy kształtu fali prądu, umożliwiając w ten sposób bardzo precyzyjną identyfikację, jak wspomniano wcześniej. Inną aplikacją nanoczujnika wykorzystywaną w diagnostyce raka jest metoda wczesnego wykrywania choroby, która wykorzystuje nanocząstki, które tworzą grudki, gdy łączą się z białkami lub innymi cząsteczkami, które wskazują na badaną chorobę. Ta nanotechnologiczna technika wykrywania magnetycznego ma być niedroga i prosta w wykonaniu, wykrywając biomarker o wielkości zaledwie 30 cząsteczek na centymetr sześcienny krwi. Roztwór zmienia kolor na niebieski, jeśli nanocząsteczki zbijają się wokół białka wskazującego na chorobę; roztwór jest czerwony, jeśli białko nie jest obecne. Ta technika pozwala lekarzom szybko i prawidłowo zorientować się, czy leczenie działa, czy nie. Nanorozbłysek to sferyczny kwas nukleinowy (SNA) ze złotą nanocząstką pośrodku i gęsto upakowanymi otoczkami oligonukleotydów z pojedynczym „rozbłysek” DNA. Była to pierwsza technika podejścia genetycznego, która izoluje i wykrywa żywe komórki rakowe ze złożonej macierzy, którą jest sama ludzka krew. Nanoflary szybko wychwytyują komórki [10]. „Wzięliśmy prawdopodobnie najważniejszą cząsteczkę na świecie, DNA, przearanżowaliśmy ją w kulisty kształt i zmodyfikowaliśmy, aby wykryć określone cząsteczki wewnątrz komórek” - mówi dr Chad Mirkin, naukowiec z Northwestern University i jeden z twórców tej diagnostyki. Nanoflary są wykorzystywane do wykrywania raka w krwiobiegu; markery zapalają się z powodu wysoce wydajnej właściwości fluorescencyjnej złota, gdy wchodzi w kontakt z pożądanym wewnątrzkomórkowym docelowym mRNA. Wraz z tą techniką w diagnostyce raka wykorzystywana jest również nanocząsteczka złota pokryta przeciwciałem monoklonalnym. Te powlekanie nanocząstki są wytwarzane w procesie naporowywania plazmowego. Powłoka nanocząstek złota tworzy wiązania kowalencyjne, aby wiązać się z innymi specyficznymi przeciwciałami docelowymi znajdującymi się w ludzkim ciele, zwłaszcza tymi, które wyrażają się znacznie bardziej, takimi jak komórki rakowe i angiogeneza. Działają jak nanorozbłysek, gdzie ilość odbitego światła mówi nam, jaka część próbki zawiera cząsteczki wirusa. Istnieją również inne nanocząstki pokryte przeciwciałami, które stosują podobną technikę wiązania. Nanowłókna pokryte przeciwciałami wiążą się z komórkami nowotworowymi, zatrzymując te komórki nowotworowe w celu dalszej analizy. Nanowłókna są bardzo elastyczne i mają bardzo wszechstronny skład polimerowy, porowatość, morfologię i łatwe działanie na powierzchni. Mają również bardzo porowatą i połączoną strukturę. Są one szczególnie używane do wychwytywania pojedynczych komórek nowotworowych. Te nanowłókna mogą być ładowane lekami w ich włóknistych matrycach: w celu dostarczenia tych leków do systemu w celu zabicia pozostałych komórek nowotworowych, wykrycia komórek nowotworowych i umieszczenia ich w łożu

nowotworowej. Nanorurki węglowe i nanocząsteczki złota zostały wykorzystane do wykrycia raka jamy ustnej w mniej niż godzinę. Jednowymiarowe są również nanorurki węglowe, które są biokompatybilne i mogą być transportowane w płynach biologicznych. Peptydy, kwasy nukleinowe i antygeny są transportowane z wysokim porządkiem i regulacją. Ich działanie nie zależy od typu komórki i grupy funkcjonalnej na powierzchni komórki. Inną formą stosowanej nanocząstki jest nanodrut. Nanodrut to układ jednowymiarowy, którego pole przekroju poprzecznego mieści się w zakresie nanometrów, a długość i szerokość w zakresie 1000 nm. Ze względu na wysoki stosunek powierzchni do objętości nanomateriału, materiał ten ma kwantowe właściwości elektryczne, mechaniczne i fizyczne. Niektóre właściwości obejmują szybkie wykrywanie i szybkie dostarczanie danych. Te nanodrut są szeroko stosowane ze względu na ich właściwości półprzewodnikowe w kontekście ich zastosowań. Im mniejsza struktura nanomateriału, tym większą kontrolę i łatwość użytkowania ma badacz. Czujnik nanoprzewodowy jest zdefiniowany jako: „EV są potencjalnie przydatne jako markery kliniczne. Skład cząsteczek zawartych w EV może stanowić sygnaturę diagnostyczną niektórych chorób” – wyjaśnia główny autor, Takao Yasui. „Ciągłym wyzwaniem dla lekarzy w każdej dziedzinie jest znalezienie nieinwazyjnego narzędzia diagnostycznego, które pozwoli im na regularne monitorowanie pacjentów” wykorzystywanego do diagnozowania raka pęcherza moczowego i prostaty w próbkach moczu. Podobnie jak w przypadku koncepcji wysokiego stosunku powierzchni do objętości nanomateriałów, mamy nanopręty. Nanorods to także struktury jednowymiarowe. Srebrne nanopręty dają podłużny powierzchniowy rezonans plazmonowy w zakresie spektralnym 400-700 nm. Srebrne nanopręty umożliwiają lepsze wykrywanie oddzielonych składników próbek krwi, takich jak wirusy, bakterie i składniki mikroskopowe, dzięki zastosowaniu lepszych sygnałów spektroskopii Ramana (SERS) o wzmocnionej powierzchni w szybki sposób. Sygnały są najwyższe, gdy rezonans plazmonowy metalu pasuje do długości fali wzbudzenia lasera wytwarzanego przez źródło. Innym zastosowaniem nanocząstek umożliwiającym ulepszone techniki spektrofotometrii jest zastosowanie nanocząstek tlenku żelaza do tworzenia lepszych obrazów ze skanów rezonansu magnetycznego (MRI). Skany MRI zazwyczaj wykorzystują pewnego rodzaju barwnik, aby umożliwić tworzenie kontrastu między komórkami. Są szeroko stosowane do diagnozy klinicznej bez faktycznej inwazji na ludzkie ciało. Nanocząsteczki tlenku żelaza pomagają w wykrywaniu komórek nowotworowych, chorób układu krążenia, a nawet chorób neurologicznych, a wszystko to działając na poziomie komórkowym. W związku z tym tworzą bardzo skuteczne środki kontrastowe w skanowaniu MRI. Podobnie, spektroskopia nanocząstek magnetycznych i spektroskopia magnetycznego rezonansu jądrowego (NMR) mogą być powiązane: mikropęcherzyki powstają, gdy cząstki przyczepiają się do nanocząstek magnetycznych. Mikropęcherzyki powstają w komórkach raka mózgu. NMR służy do wykrywania tych magnetycznych skupisk nanocząstek; dlatego możliwa jest wczesna diagnoza. Kropki kwantowe są wykorzystywane w obrazowaniu komórek rakowych. Posiadają techniki zarówno in vivo, jak i in vitro, które można zastosować. Udowodniono, że są korzystne ze względu na ich wyjątkowe właściwości elektroniczne i optyczne. Kropki kwantowe lokalizują guzy nowotworowe i wykonują testy diagnostyczne w próbkach z dużą precyzją i czułością. Kropki kwantowe kadmu, które stosowano początkowo, są bardziej toksyczne w porównaniu do ostatnio opracowanych krzemowych. Udowodniono, że celują w biomolekuły przy użyciu różnych tras omijających, co skutkuje zwiększoną wykrywalnością, a integracja tysięcy znaczników w jedną nanocząsteczkę skutkuje drastycznie wzmocnionym sygnałem. Wszystkie te procesy można monitorować w sposób nieinwazyjny w czasie rzeczywistym

Projektowanie nanoleków przez AI

System leków w nanokapsułkach odegrał znaczącą rolę w medycynie i opiece zdrowotnej. Podstawowy wymóg dla medycyny precyzyjnej może być dobrze powiązany z profilem w odniesieniu do układu molekularnego pacjenta. Rola biomarkerów specyficznych dla choroby jest nieunikniona, aby zapewnić

przejrzystość i pomysł na spersonalizowane leczenie. Biomarkery genetyczne obejmują różne formy polimorfizmu DNA występujące w sekwencji genetycznej człowieka. W oparciu o te warianty, takie jak polimorfizm pojedynczego nukleotydu, polimorfizm długości fragmentów restrykcyjnych, mikrosatelita itp., możemy analizować sekwencję genetyczną. Aby zrozumieć odrębną tożsamość molekularną pacjenta, przydatny jest profil choroby. Ten projekt obejmuje dane metabolomiczne, genomowe, epigenomiczne, transkryptomowe, proteomiczne i mikrobiomiczne. W przypadku omiki obejmującej całą populację istotny jest dostęp do procesu rozpoznawania odpowiednich biomarkerów choroby i ich dystrybucji wśród szerokiego spektrum analizowanych pacjentów. Na przykład profilowanie molekularne oparte na RNA pomaga w różnicowaniu populacji z szeroką klasyfikacją zdrowej społeczności i pacjentów ze zlokalizowanym i przerzutowym guzem potwierdzonym w ich organizmie. Sekwencjonowanie RNA jest standardową metodologią przyjętą do analizy profilowania molekularnego próbek od pacjenta z nowotworem. Dokładność lokalizacji guza potwierdza się za pomocą sekwencjonowania RNA z płytkami nowotworowymi (TEP) i płytkami krwi o zmienionym profilu RNA. Niezbędne jest skuteczne rozpoznawanie nowych biomarkerów za pomocą dokładnych i szybkich narzędzi do gromadzenia danych. Nanotechnologia zwiększa precyzję technologii sekwencjonowania wykorzystywanych do różnych profili gromadzenia danych. Jednocześnie nanotechnologia poprawia szybkość analizy danych dzięki lepszej modalności sekwencyjnej i narzędziom diagnostycznym. Na przykład metody sekwencjonowania pojedynczych cząsteczek w czasie rzeczywistym (SMRT) i metody sekwencjonowania nanoporowego to techniki sekwencjonowania trzeciej generacji, które okazały się bardziej wydajne. Mechanizm ten obejmuje bezpośrednią analizę pojedynczego nukleotydu DNA bez amplifikacji matrycy, zmniejszając w ten sposób błędy odczytu. System SMRT wykorzystuje metodę litografii wiązek elektronowych do przygotowania ubytków o wielkości 60–120 nm. Zostało to opracowane na cienkiej blaszce aluminiowej o rozmiarze 100 nm nałożonej na podłoże wykonane z krzemionki. W każdej wnęcie osadzony jest enzym polimerazy DNA w celu uzyskania specyficznej obserwacji podczas obrazowania optycznego barwnikiem fluorescencyjnym. Zatem dane w czasie rzeczywistym uzyskuje się z precyzją przez zachowanie właściwości genetycznych nukleotydu i przewyciężenie wyzwań związanych z sekwencjonowaniem kwasu nukleinowego. W metodzie sekwencjonowania nanoporowego, zastosowanie AI do procesu translacji surowego sygnału do sekwencji nukleotydowej jest kolejnym ważnym wpływem interdyscyplinarnego podejścia nanotechnologii. W związku z tym dokładność diagnozy pacjentów z profilowaniem biomarkerów wzrosła głównie dzięki połączeniu danych omicznych z różnych źródeł biologicznych w celu wygenerowania ujednoczonych profili.

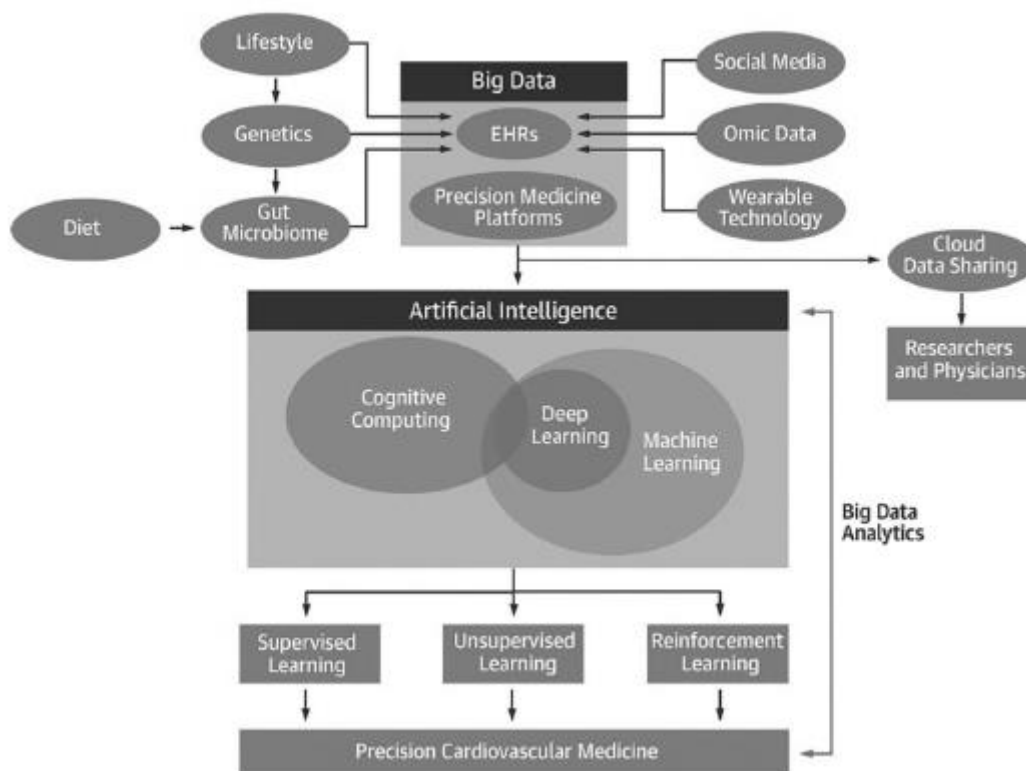
Sztuczna inteligencja

AI to szeroka gałąź informatyki zajmująca się symulacją ludzkiej inteligencji w maszynach, które są zaprogramowane do wykazywania cech związanych z człowiekiem. Termin ten został ukuty przez Johna McCarthy'ego podczas konferencji w 1956 roku. Celem AI jest tworzenie systemów, które mogą działać zarówno inteligentnie, jak i niezależnie. W kontekście człowieka uczenie się i rozwiązywanie problemów poprzez naśladowanie jego działań są klasyfikowane jako inteligencja demonstrowana przez maszyny. Urządzenia te postrzegają swoje otoczenie i podejmują odpowiednie działania, aby zwiększyć szanse powodzenia w realizacji celów. Bardziej rozbudowana definicja charakteryzuje sztuczną inteligencję jako „zdolność systemu do prawidłowej interpretacji danych zewnętrznych, uczenia się na podstawie takich danych i wykorzystywania tych wiedzy do osiągnięcia określonych celów i zadań poprzez elastyczną adaptację”. To badanie inteligencji można sklasyfikować jako przedmiot multidyscyplinarny, ponieważ można je postrzegać z wielu perspektyw, takich jak lingwistyka, filozofia, psychologia, matematyka i medycyna, ponieważ każdy z nich ma wpływ na modelowanie ludzkiej inteligencji na maszynie. Istnieją dwa sposoby działania AI: oparte na symbolach i oparte na danych. Uczenie maszynowe (ML) lub sztuczna inteligencja oparta na danych wymaga dużej ilości informacji

lub danych wielowymiarowych, które są wprowadzane do maszyny w celu określenia wzorców, aby dokonać klasyfikacji lub przewidywania oraz rozwiązać problemy. Technologia ta jest szybko stosowana w wielu dziedzinach, głównie ze względu na precyzję, lepszą wydajność, oszczędność czasu, a także zmniejszenie kosztów. Dziś technologia ta jest wykorzystywana w naszym życiu w postaci osobistych asystentów (Siri, Alexa itp.), lotnictwa i gier komputerowych. Został on również zintegrowany z medycyną w celu poprawy wyników leczenia pacjentów w celu zapewnienia lepszej opieki zdrowotnej poprzez usprawnienie procesu i osiągnięcie dużej dokładności w obrazach radiologicznych i tak dalej.

AI w medycynie

Dwa najważniejsze czynniki, które są ważne dla lekarzy, to wiedza i doświadczenie, ponieważ liczba leczonych pacjentów rośnie, im więcej wiesz i zapewniasz lepszą opiekę. Aspekty te są zdobywane przez całą karierę zawodową, co może wymagać czasu i wysiłku poprzez ciągłą edukację w określonym obszarze zainteresowań. Lepsze decyzje oparte na wiedzy można podejmować za pomocą odpowiednich danych pochodzących z medycyny opartej na dowodach (podręczniki, rękopisy itp.) i doświadczenia zdobytego w wyniku rzeczywistych wyników leczenia pacjentów, które obejmują akta pacjentów, wyniki laboratoryjne i obrazy radiologiczne. Pozyskiwanie ogromnych ilości danych jest podstawowym ograniczeniem ludzkiego umysłu oraz procesu uczenia się i zdobywanego przez lata doświadczenia. Jednak ta koncepcja jest podstawową zasadą zrozumienia sztucznej inteligencji i jej wnioskowania w medycynie. Opanowanie ogromnych ilości danych, przekształcanie ich w doświadczenie zamiast marnowania lat na ich zdobywanie oraz opracowywanie algorytmów w znacznie krótkim czasie z większą dokładnością to fundamenty sztucznej inteligencji. W medycynie technologia ta ma na celu poprawę wyników leczenia pacjentów poprzez wczesne wykrywanie i diagnozowanie poprzez ograniczenie błędów medycznych i kosztów oraz zmniejszenie zachorowalności i śmiertelności. Branża opieki zdrowotnej stoi dziś przed licznymi wyzwaniami: wzrostem i starzeniem się populacji, rosnącą złożonością i rosnącymi kosztami. Systemy te borykają się z presją na marże i poszukują technologii, które pomogą w dokonywaniu przełomów w zakresie wyników leczenia pacjentów oraz poprawie produktywności operacyjnej i klinicznej poprzez znajdowanie nowych obszarów wzrostu. W całym ekosystemie zdrowia staje się jasne, że sztuczna inteligencja i analityka zmieniają zasady gry, które przyniosą pozytywne wyniki pacjentom, dostawcom i opiekunom. Niezwykłą zaletą ekosystemu zdrowia jest dostępność danych dzięki digitalizacji dokumentacji pacjentów, danych obrazowych i dostępności informacji genomowych, które muszą być agregowane do analityki i algorytmów głębokiego uczenia (DL) w celu poprawy wyników, zmniejszenia nieefektywności i eliminują kosztowne i szkodliwe błędy. Rysunek 1 pokazuje Big Data wykorzystujące sztuczną inteligencję, które mogą być przechowywane za pośrednictwem elektronicznych kart zdrowia (EHR) lub platform medycyny precyzyjnej i udostępniane za pośrednictwem systemów chmurowych w celu analizy danych przez lekarzy lub badaczy, które umożliwiają medycynę precyzyjną w przypadku różnych chorób.

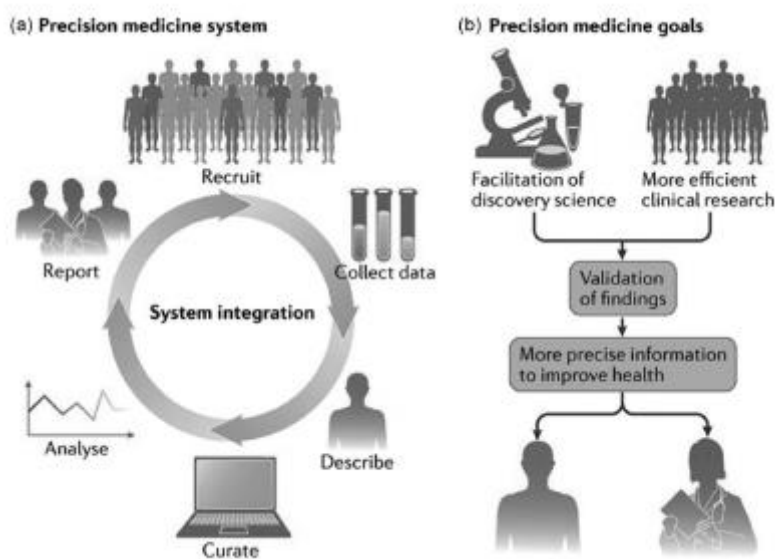


(EHR) wspomagają proces leczenia i diagnozy, ponieważ są oceniane przez ML dla każdej osoby ML jest jedynie asystentem lub pomocnikiem w opiece medycznej i w żaden sposób nie ma na celu zastąpienia lekarzy. Liczba radiologów pozostaje taka sama, podczas gdy skany radiologiczne stale rosną. W takim przypadku zastosowanie sztucznej inteligencji może skrócić czas, dzięki szybszej interpretacji danych i możliwości pracy przez całą dobę. Ponadto oprogramowanie nie jest blokowane przez ludzkie słabości, takie jak zakłócenia otoczenia lub przerwy i zmęczenie, które mogą utrudniać działanie, zmniejszając jego dokładność. W patologii systemy zintegrowane ze sztuczną inteligencją mogą pomóc w przeciwdziałaniu rosnącemu obciążeniu pracą, któremu towarzyszy niewystarczająca siła robocza. Za pomocą tych systemów można również wykonywać żmudne zadania, takie jak ocena morfologii i analiza ilościowa. Niemniej jednak patolodzy mogliby wykorzystać oceny wykonane za pomocą sztucznej inteligencji ze względu na jej zalety, takie jak powtarzalne wyniki i zmniejszona zmienność podczas diagnozowania chorób. Prowadzi to do zapobiegania błędnej diagnozie, promując w ten sposób wcześniejsze wykrycie i diagnozę poprzez zwrócenie uwagi lekarza na konkretną dziedzinę. Warto zauważyć, że techniki sztucznej inteligencji opracowane w obszarach niemedyce można zastosować do odkrywania leków na nowy koronawirus. Jednak w przypadku przechowywania sztuczna inteligencja może być czymś więcej niż tylko eksperymentalną. Infekcja krzyżowa jest bardzo realna w przypadku tej wysoce zaraźliwej choroby, dlatego pracownicy medyczni są bardzo narażeni z powodu zwykłego braku sprzętu ochronnego. Maszyny AI są bardzo przydatne w tym scenariuszu, w którym zbierają zainfekowaną bieliznę i śmieci medyczne, a nawet same się dezynfekują. Nie tylko ograniczają infekcje krzyżowe, ale także zmniejszają obciążenie pracą. Ich umiejętność czytania map i planowania najskuteczniejszych tras sprawia, że są wydajne.

MEDYCINA PRECYZYJNA

Na początku XX wieku średnia długość życia według Światowej Organizacji Zdrowia wynosiła 35 lat, ale pod koniec stulecia prawie się podwoiła. Możliwość tę można było osiągnąć jedynie dzięki lepszym warunkom sanitarnym, terapiom i lekoms oraz rozwojowi medycyny prewencyjnej, takiej jak

szczepionki, które miały na celu wspomaganie i promowanie zdrowszego stylu życia. Medycyna intuicyjna była praktykowana w przeszłości, gdzie leczenie odbywało się zgodnie z wiedzą, którą posiadał lekarz w momencie wystąpienia objawów u pacjenta. Medycyna oparta na faktach jest dość popularna w badaniach medycznych, w których przeprowadzono badania naukowe i znaczące próby kliniczne. Ponieważ postęp w medycynie dominuje, płacimy cenę za wydłużenie średniej długości życia, przeznaczając około 50% naszego budżetu na opiekę zdrowotną w celu leczenia nieuleczalnej choroby. Aby zająć się takimi problemami w XXI wieku, leki muszą koncentrować się na osiągnięciu czterech zasad określonych przez dr Leroy Hooda: przewidywanie, zapobieganie, personalizacja i uczestnictwo, aby przejść od tradycyjnej medycyny do systemu ukierunkowanego na chorobę z bardziej spersonalizowane podejście. Pod uwagę będą brane charakterystyczne cechy lub genomy pacjenta, w tym styl życia, a medycyna jest praktykowana według tych algorytmów. Naukowcy dowiedzieli się z badań, że pomimo zdiagnozowania tej samej choroby, u takich osób choroby te wyglądają zupełnie inaczej na poziomie molekularnym. Obecne metody leczenia lub tradycyjne, uniwersalne podejście do astmy, cukrzycy i innych chorób opierają się na oczywistych objawach, standardowych testach i powszechnie stosowanych lekach. Postępy obliczeniowe w dziedzinie biologii do analizy danych stworzyły dogodną drogę do interpretacji zmienności genotypu specyficznego dla choroby. Lek ten pomaga w zapewnieniu spersonalizowanych planów profilaktyki i leczenia w celu poprawy ukierunkowanej opieki nad konkretną chorobą lub osobą. Precision Medicine Initiative (PMI) zdefiniowało medycynę precyzyjną jako „innovacyjne podejście, które uwzględnia indywidualne różnice w genach, środowisku i stylu życia ludzi”. Medycyna precyzyjna opiera się na gromadzeniu, łączeniu i analizowaniu różnego rodzaju informacji dotyczących jednostki w celu lepszego zrozumienia stanu zdrowia.



Daje możliwość zrozumienia chorób w radykalnie odmiennym podejściu, które może być bardziej skuteczne, z zamiarem opracowania dostosowanych interwencji uwzględniających różnice między różnymi ludźmi i ich stanami. Ułatwia to opracowywanie nowych leków i zwiększa zrozumienie interakcji genomiki i reakcji na te leki, mając na celu sprostanie różnym wyzwaniom zdrowotnym. Nowoczesne podejście do zrozumienia modalności zdrowotnych zostało osiągnięte poprzez zapewnienie właściwego leczenia właściwemu pacjentowi we właściwym czasie. Możliwość bardziej efektywnego wykorzystania wskaźników społecznych związanych z pacjentem przyjmuje bardziej holistyczne podejście, w którym relacje i pewne doświadczenia mają niezwykle wpływ na zdrowie i samopoczucie osoby.

Zastosowania Medycyny Precyzyjnej

W ciągu ostatnich kilkudziesięciu lat w coraz szybszym tempie prowadzono badania nad mechanizmami patogenezy nowotworów i zrozumieniem onkogenów w miarę wzrostu śmiertelności z powodu nowotworów na całym świecie. Odtąd odkrycie i opracowanie leków hamujących ekspresję tych onkogenów poprzez dezaktywację ich szlaków jest jedną z najbardziej korzystnych cech medycyny precyzyjnej, zgodnie z przewidywaniami Światowej Organizacji Zdrowia. Klinicznie stosowane leczenie przewlekłej białaczki szpikowej (CML) jest trafnym przykładem tej koncepcji. Innym ważnym wkładem z niezliczonymi możliwościami w medycynie precyzyjnej jest dziedzina inżynierii tkankowej i medycyny regeneracyjnej, która obejmuje dwa główne tematy zainteresowania: terapię narządu na chipie i terapię komórkami macierzystymi. Organ-on-a-chip cieszy się dużym zainteresowaniem, ponieważ jest coraz częściej wykorzystywany do badań przedklinicznych leków, udowadniając jego potencjalne zastosowanie w leczeniu medycyny precyzyjnej poprzez badanie, w jaki sposób leki te działają inaczej na tkanki pacjentów poprzez różnicowanie indukowanego trzpienia pluripo-tent komórki (iPC) z tkanki dorosłej, takiej jak skóra lub krew, do tkanki docelowej. Te specyficzne dla pacjenta systemy inżynierii tkankowej 3D z mikrokanalami można wykorzystać do wirtualnego i in vitro badania dowolnej substancji przed leczeniem klinicznym w celu ustalenia lepszego podejścia terapeutycznego do leczenia konkretnej choroby. Spersonalizowane komórki macierzyste wykorzystywane do regeneracji lub wymiany tkanek lub narządów również skupiają się na dostosowywalnym podejściu stosowanym w medycynie precyzyjnej. Wydaje się, że choroba przewlekła narasta, ponieważ obserwuje się wzrost złożoności pacjentów z powodu kilku czynników. Na przykład istnieją setki różnych typów nowotworów, a każdy z nich inaczej reaguje na leczenie, ponieważ każda ludzka i każda komórka nowotworowa ma unikalny profil genetyczny, z którym należy się uporać według określonego wzorca. Ponadto, potrzebne są ogromne ilości danych lub informacji w odniesieniu do rozwoju algorytmów do przewidywania i leczenia chorób na podstawie indywidualnych zmienności, takich jak styl życia, genetyka, reakcja na leki i tak dalej. Stąd alternatywą dla samodzielnych badań jest podejmowanie inicjatyw integracji i zestawienia danych z różnych jednostek medycznych. Zbieranie i analiza kilku baz danych w celu stworzenia nowych algorytmów za pomocą obecnie dostępnych narzędzi, takich jak przetwarzanie w chmurze, analiza Big Data i sztuczna inteligencja, poprawi i będzie promować bezpośrednią praktykę kliniczną. Kilka pojawiających się problemów można rozwiązać, tworząc podejścia komputerowe: metody analityczne i sztuczna inteligencja. Inteligencja zdrowotna „wykorzystuje narzędzia i metody sztucznej inteligencji i nauki o danych, aby zapewnić lepszy wgląd, zmniejszyć marnotrawstwo i czas oczekiwania oraz zwiększyć szybkość, wydajność usług, poziom dokładności i produktywność w opiece zdrowotnej i medycynie”. PMI ogłoszony przez Narodowy Instytut Zdrowia (PZH) w 2015 roku to program dostarczania środków mających na celu poprawę opieki zdrowotnej, poprawę i zwiększenie jej efektywności poprzez wykorzystanie najnowocześniejszych technologii i badań interdyscyplinarnych w różnych dziedzinach medycyny. Analizy Big Data (genetyka, czynniki środowiskowe i związane ze stylem życia) mogą być udostępniane do analizy danych, które mogą być wykorzystywane przez naukowców lub lekarzy za pośrednictwem systemów w chmurze, które są bezpieczne i bezpiecznie przechowywane za pośrednictwem platform medycyny precyzyjnej. Ta analiza danych wykorzystuje techniki sztucznej inteligencji, w tym ML, DL lub przetwarzanie kognitywne.

UCZENIE GŁĘBOKIE

Wynalazcy zastanawiali się, czy po uruchomieniu programowalne komputery były w stanie myśleć lub posiadać zdolności poznawcze do uczenia się, rozumienia i formułowania pojęć, stosując logikę i rozum. Sztuczna inteligencja to technika wykorzystywana do włączania ludzkiej inteligencji do maszyn, rozwijającej się dziedziny, w której obok wielu praktycznych zastosowań przeprowadza się kilka

aktywnych badań. To inteligentne oprogramowanie zostało opracowane w celu rozszerzenia automatyzacji produkcji, zrozumienia i sformułowania wzorców poprzez pomoc w diagnozowaniu i leczeniu chorób w medycynie poprzez wspieranie podstawowych badań naukowych. Ponadto sztuczna inteligencja miała na celu rozwiązywanie racjonalnych i złożonych problemów, biorąc pod uwagę różne wymiary, ponieważ ludzie wykazywali niekompetencję do takich zadań. Rozwiązanie tych intuicyjnych problemów można osiągnąć, umożliwiając maszynom uczenie się na podstawie ogromnych ilości danych, aby zdobyć doświadczenie i zrozumieć środowisko w odniesieniu do hierarchii pojęć, która umożliwia przetwarzanie skomplikowanych koncepcji przez prostsze, unikając potrzeby operatorów ludzkich interweniować i określać wiedzę wymaganą przez maszynę. Jak na ironię, abstrakcyjne zadania są najtrudniejsze dla człowieka, ale okazują się proste dla komputera. Jeśli narysujemy wykres ilustrujący sposób zbudowania tych pojęć, wykres ten wydaje się być głęboki i składa się z wielu warstw. Dlatego tego typu podejście jest określane jako Deep Learning, a sztuczna inteligencja jest nadzbiorem DL i ML. DL to rodzaj uczenia się maszynowego wyjaśniony przez modele z licznymi hierarchicznymi warstwami informacji w porównaniu z konwencjonalnym „płytkim” uczeniem się i w ciągu ostatnich kilku lat mocno wykorzystał naszą wiedzę o ludzkim mózgu, statystyce i matematyce stosowanej. ML obejmuje algorytmy i modele statystyczne używane przez maszyny do wykonywania zadań i zbierania informacji poprzez doskonalenie wraz z doświadczeniem, podczas gdy ML to klasa ML, która wykorzystuje sztuczną sieć neuronową, która automatycznie przetwarza i uczy się hierarchicznych cech pojęć lub danych składających się z wielu warstw składających się z nieliniowe i proste moduły, które pomagają w przekształcaniu danych w celu przedstawienia ważnych informacji wymaganych do rozróżnienia tych danych. Zarówno płytkie uczenie, jak i DL są podzbiorem sztucznej inteligencji i są zawarte w ML, w którym uczenie się odbywa się bez programowania. Obie te metody „wychwytyją wzorce ze skomplikowanych, wielowymiarowych surowych danych i wykorzystują je jako cechy odróżniające dane”. DL pojawiła się jako badanie trendów w korelacji z AI. Nastąpił ogromny wzrost i popularność ze względu na ewolucję komputerów w kierunku bardziej wydajnej maszyny z dużymi zestawami danych i technikami uczenia sieci. DL ma tę zaletę, że uczy się skomplikowanych wzorców z surowych danych dzięki wielu warstwom i przekształceniom, podczas gdy konwencjonalne płytkie uczenie składające się z kilku warstw wymaga ręcznie opracowanych funkcji wydobytych z danych. Niezależnie od różnych warstw, podejścia DL mogą być stosowane zarówno w nadzorowanych, jak i nienadzorowanych aplikacjach uczenia się. Nadzorowana metoda została zastosowana w informacjach zdobytych w przeszłości, aby przewidzieć jedną lub więcej etykiet lub wyników powiązanych z każdym punktem danych. W procesie szkolenia parametry są dostosowywane, aby precyzyjnie przewidzieć cel. W przeciwieństwie do tego, aplikacja nienadzorowana lub „eksploracyjna” była używana, gdy informacje wykorzystywane do szkolenia nie są sklasyfikowane ani oznaczone, gdy celem jest podsumowanie, wyjaśnienie lub zidentyfikowanie znaczących wzorców w zbiorze danych (jako grupowanie). W rzeczywistości DL może łączyć oba te kroki, aby skonstruować funkcje dostosowane do konkretnego problemu i połączyć je w „predyktor”, gdy odpowiednie dane są dostępne i oznaczone. Reprezentacje wyodrębnione z uczenia się nienadzorowanego można wykorzystać do innych nadzorowanych zadań. DL zazwyczaj reprezentuje głębokie sieci neuronowe, które naśladują funkcjonowanie ludzkiego mózgu złożonego z neuronów (wysyłają i odbierają sygnały elektrochemiczne) przy użyciu kilku warstw sztucznej sieci neuronów, które mogą generować automatyczną odpowiedź lub przewidywania z danych wejściowych. Podejście to wywodzi się z badań nad sztucznymi neuronami, które zaproponowano w 1943 roku jako model neuronu w naszym mózgu, który pomaga w przetwarzaniu informacji. W sieciach neuronowych warstwa wejściowa zawiera dane wejściowe wprowadzone do systemu, kierując go w stronę szeregu wielu ukrytych warstw, co ostatecznie prowadzi do warstwy wyjściowej, która przedstawia dane wyjściowe. Warstwa zawiera elementy lub węzły, które są połączone z warstwami bezpośrednio wcześniejszymi i głębszymi. Te węzły w warstwie wyjściowej zawierają zmienne, które mają być mierzone w określonym zbiorze

danych. Uczenie się wielu ukrytych warstw, w którym odbywa się przetwarzanie, istnieje w sieci neuronowej używanej do DL, w której każda warstwa jest odpowiedzialna za konstrukcję cech poprzednich warstw, jednocześnie przyczyniając się do udoskonalenia głębszych warstw poprzez procesy szkoleniowe. W konsekwencji cechy algorytmów mogą być automatycznie projektowane i dostosowywane do jednego lub większej liczby zadań. Te algorytmy sieci neuronowych mogą być rekurencyjną siecią neuronową (RNN), spłotową siecią neuronową (CNN) i głęboką siecią neuronową. Dominujące w rozpoznawaniu obrazów i mowy są RNN (pozwalające sieci neuronowej na zachowanie pamięci w czasie lub sekwencyjne dane wejściowe) oraz sieć konwolucyjna, które okazały się skuteczne w różnych zadaniach ML, takich jak tłumaczenie języka i tworzenie podpisów do obrazów. Różnorodność możliwości i wyzwania spowodują potrzebę doskonalenia DL, aby przenieść go na nowe granice.

Aplikacja

DL ewoluowała jako poszukiwana aplikacja w sztucznej inteligencji, ponieważ jest to rozwijająca się dziedzina i wydaje się obiecująca. Została z powodzeniem zastosowana do pokonania wyzwań stawianych przez metody ML w zadaniach rozpoznawania wizualnego i doprowadził do znacznej poprawy w różnych dziedzinach nauki i przemysłu, takich jak odkrywanie leków, bioinformatyka i rozpoznawanie mowy. Następnie w kilku zadaniach przetwarzania obrazu i wizji komputerowej techniki DL przewyższyły wszystkie dostępne metody dzięki swojej elastyczności i wysokiej dokładności, a rozwój nowych modułów umożliwił naukę głębokich pojęć poprzez efektywne wykorzystanie sprzętu, w tym graficznego. jednostki przetwarzania (GPU). Co najważniejsze, udział dużych ustrukturyzowanych zbiorów danych, takich jak ImageNet, ułatwił sukces tej techniki. Ta nowa technika uczenia maszynowego odgrywa potężną rolę w rozpoznawaniu obrazów (rozpoznawanie twarzy i wyszukiwanie obrazów w Google), autonomicznych samochodach, rozpoznawaniu mowy (Apple Siri, asystent Google, Amazon Alexa), aplikacjach mobilnych (aplikacja Cardiogram) i maszynach oprogramowanie wizyjne w kamerach i robotach. Co więcej, może być również używany do nienadzorowanych zadań uczenia się w celu wykrywania nowych interakcji między lekami poprzez trenowanie go w sposób nienadzorowany bez ograniczeń pamięci roboczej. Algorytmy te pomogą w sztucznym obrazowaniu w czasie rzeczywistym dzięki lepszej rozdzielczości, zmniejszając w ten sposób koszty i poprawiając jakość opieki. DL AI wykorzystuje Big Data do rozpoznawania wzorców w zespołach heterogenicznych i rozpoznawania obrazów. Wdrożenie DL dla analityki Big Data z jej nienadzorowanymi funkcjami ma niezwykły potencjał do identyfikacji nowych fenotypów i genotypów. Big Data może generować zautomatyzowane hipotezy zamiast konieczności ich inicjowania przez lekarzy i odtąd wspomagać podejmowanie lepszych decyzji klinicznych zamiast zastępowania lekarzy [58]. Zadania mogą być wykonywane bez ingerencji człowieka w przemyśle, takie jak nauka matematyki, pisanie podręczników do matematyki, czytanie publikacji, aby odpowiedzieć na pytania naukowe lub oglądanie filmów, aby odpowiedzieć na pytania. Kilka niezbędnych postępów i nowych technik spowodowało wzrost w tej dziedzinie i umożliwiło ich zastosowanie w dużych zbiorach danych, które są wystarczające do dopasowania szerokiego zakresu parametrów istniejących dla sieci neuronowych

Implementacja głębokiego uczenia się w medycynie


Na przestrzeni lat nastąpił szybki wzrost danych biomedycznych, które obejmują dokumentację medyczną i obrazy wraz z danymi omicznymi. Niemniej jednak złożony, niejednorodny i wielowymiarowy charakter tych danych sprawia, że interpretacja ich znaczenia klinicznego jest żmudna. DL pozwala modelom obliczeniowym złożonym z wielu warstw przetwarzania lub ukrytych „uczyć się reprezentacji danych z wieloma poziomami abstrakcji”. Można dostosować zastosowanie sztucznej inteligencji, która rozszerza się i jest szeroko stosowana, co zapewnia systemowi możliwość przechwytywania wzorców z danych biomedycznych i wykorzystywania ich w podejmowaniu decyzji

bez wyraźnego programowania. Dyscypliny bogate w dane, takie jak biologia i medycyna, są złożone pod względem informacji i często są błędnie interpretowane. Dlatego używamy DL w różnych zastosowaniach do różnych problemów biomedycznych; podstawowe procesy biologiczne i leczenie; i klasyfikacja pacjentów. Ten rodzaj uczenia się wykazuje większą elastyczność w porównaniu z innymi podejściami, które wymagają dużych zestawów danych szkoleniowych w celu wstawiania ukrytych warstw, a także dokładnego etykietowania aplikacji do uczenia nadzorowanego, a z wyżej wymienionych powodów DL stał się popularny, szczególnie w obszarach: biologia i medycyna (opieka zdrowotna i odkrywanie leków) przy niższym przyjęciu u innych. Tworzenie systemów DL pomaga klinicytom i biologom usprawnić zadania, które nie wymagają porady ekspertów, i priorytetyzować eksperymenty. Może być również stosowany do odpowiedzi na fundamentalne pytania biologiczne, w tym do rozpoznawania funkcjonalnych elementów genomowych, takich jak wzmacniacze i promotory lub szkodliwych skutków polimorfizmu nukleotydów oraz wykorzystywania głębokich RNN do przewidywania docelowych genów miRNA i CNN do przewidywania pozostałości białkowych. kontakty pozostałości i struktura drugorzędowa. Dokładna klasyfikacja i dokładna wiedza na temat chorób i podtypów chorób stanowią kluczowe wyzwanie w biomedycynie; W onkologii obecne podejścia, takie jak histologia, wymagają interpretacji przez ekspertów lub oceny markerów biomolekularnych lub ekspresji genów, które okazują się pracochłonne i krytyczne. Przykładem jest podejście PAM50 do klasyfikacji raka piersi; tych pacjentów podzielono na cztery podtypy w zależności od ekspresji 50 genów markerowych. Metody DL zostały wykorzystane w kilku badaniach w celu lepszej klasyfikacji pacjentów za pomocą podejścia nienadzorowanego. Te zautomatyzowane algorytmy odgrywają kluczową rolę i przyniosły imponujące wyniki w różnych dziedzinach poprzez wyodrębnienie znaczących wzorców, prowadząc do praktycznej wiedzy poprzez zrewolucjonizowanie sposobu, w jaki kategoryzujemy pacjentów w zależności od ich chorób i opracowujemy leczenie w poufnym środowisku, ale integracja wiąże się z wieloma wyzwaniami danych molekularnych i obrazowania z innymi typami, takimi jak EHR. Badania porównawcze sugerują, że w ciągu następnej dekady genomika prześcignie wszystkie inne dziedziny generowania i analizy danych, a taka złożoność stanowi wyzwanie, mimo że stwarza nowe możliwości. Niektóre wysiłki mają na celu identyfikację celów i interakcji leków lub rozpoznanie i przewidywanie reakcji na lek oraz przewidywanie bioaktywności leku; niektórzy używają DL struktur białkowych. Wdrożenie DL w medycynie ma na celu uwzględnienie następujących elementów: po pierwsze, nienadzorowane DL może promować badanie nowych czynników lub dodawać ukryte czynniki ryzyka do obecnych modeli. Po drugie, może klasyfikować nowe genotypy lub fenotypy niewydolności serca za pomocą nowych diagnostycznych parametrów echokardiograficznych, które potencjalnie mogą prowadzić do ukierunkowanej terapii. Wreszcie, te zautomatyzowane modele predykcyjne mogą być wykorzystywane do przewidywania ryzyka krwawienia i udaru mózgu, a także mogą pomóc w identyfikacji tych czynników ryzyka, włączając je w ten sposób do nowych modeli terapeutycznych. Wiele międzynarodowych firm technologicznych, takich jak Apple, Google i IBM, inwestuje, aby ułatwić rozwój medycyny precyzyjnej w analityce opieki zdrowotnej. Należy zauważyć, że lekarze posiadają wiedzę o tym, jak odpowiednio wykorzystywać sztuczną inteligencję do przeprowadzania analizy danych, optymalizacji aplikacji AI w diagnostyce klinicznej w celu przyspieszenia medycyny precyzyjnej i stawiania hipotez. Obliczenia kognitywne, ML i DL mogą potencjalnie usprawnić i ulepszyć sposób, w jaki medycyna jest praktykowana, a jednocześnie stawiać czoła wyzwaniom, jakie może ona stwarzać, prowadząc do większego wpływu.


Konwolucyjne sieci neuronowe

Wykazano dowody na skuteczność metod CNN pod względem dokładności w diagnozie, która jest na równi z praktykami medycznymi. Kiedy każda warstwa CNN ma filtry, które przechodzą przez wysokość i szerokość warstw, to właśnie kolor lub krawędź elementu może aktywować sieć. Wzorce pisma odręcznego pacjentów z chorobą Parkinsona badano przy użyciu metod CNN, badania obejmującego

szereg czasowy informacji dotyczących zdrowych i pacjentów z chorobą Parkinsona. Sieci neuronowe działają w taki sposób, że neurony odbierają dane wejściowe; ConvNet również działa w podobny sposób, ale architektura zakłada, że akceptuje obrazy jako dane wejściowe. Ta architektura ConvNet w sieciach CNN jest obecnie szeroko stosowana, aby zrozumieć, że dane wejściowe to obrazy .



Chociaż metodę crowdsourcingu można wykorzystać do badania większych zbiorów danych, istnieją najnowocześniejsze techniki w metodach DL, które zapewniają większą dokładność obrazów narządów ludzkich; praca H.R. Rotha i in. zyskał popularność w obrazach trzustki z propozycją ich architektury ConvNet.



Opracowano klasyfikatory obrazów z CNN, aby przeprowadzić klasyfikację raka skóry za pomocą eksperymentów o najmniejszych kosztach, a także starano się przewyższyć wszystkie testy CNN opracowane z innymi zestawami danych do tego czasu w terenie. Większość badań w CNN dotyczyła diagnozowania raka piersi, który jest najczęstszym rodzajem raka z łagodnymi/złośliwymi obrazami pochodzącymi z surowych pikseli . Obrazy monochromatyczne zostały przekonwertowane na kolorowe obrazy w celu poznania zestawów danych obrazu raka piersi przy użyciu popularnej architektury VGG16, która mogła obsługiwać obrazy o dużej głębi przy użyciu filtrów konwolucji 3×3 i tylko obrazów kolorowych. W związku z tym przeprowadzono wiele badań i nadal potrzebne są dalsze badania w diagnostyce raka przy użyciu obrazów wzorców CNN.

CNN w medycynie precyzyjnej

Podczas gdy CNN rozszerza swoją diagnostykę regionów białkowych o rozpoznawanie obrazów onkologicznych, systemy eksperckie eksperymentują z kompletną diagnozą na ciele pacjenta w celu znalezienia komórek rakowych i planów leczenia, które są następnie proponowane przez inteligentne systemy. Przed wszystkim szum i złożoność rozpatrywanych leków danych powoduje fałszywie dodatnią analizę podczas prognoz dotyczących leków precyzyjnych. Koncepty te pomagają w metabolomice i badaniach organizmów przy uwzględnieniu ich znaczenia w precyzyjnej medycynie precyzyjnej. To tutaj bardziej dokładne i ważne techniki sieci neuronowych zaczynają odgrywać dominującą rolę w filtrowaniu obrazów cząsteczek leków w celu przewidywania ich wpływu na narządy ludzkiego ciała w warunkach, zwłaszcza w onkologicznych lekach precyzyjnych. Badacze twierdzili, że

skuteczne prognozy i ustalenia można poczynić na podstawie samych struktur chemicznych. Badania dotyczyły zarówno obrazów leków 2D przesyłanych do CNN, jak i molekularnych odcisków palców do Losowych Lasów, które są popularnymi technikami DL. Wyniki dowiodły, że skuteczność struktur chemicznych tych metod determinuje funkcje leków i ich klasy mechanizmów. Dane transkryptomyczne leków stanowiły dane wejściowe do zastosowania we wzorcach CNN w celu zrozumienia i przewidzenia właściwości leków, które można wykorzystać w leczeniu różnych układów organizmu, takich jak układ nerwowy, układ kardiologiczny lub środek przeciwnowotworowy [66], działając w ten sposób jako precyzja Medycyna. Takie systemy, mogą przewidywać klasę funkcjonalną, skuteczność leku, zastosowanie terapeutyczne, toksyczność leku na organizm ludzki itp. Stwierdzono, że te techniki w CNN i systemach eksperckich są bardziej korzystne w leczeniu raka, gdy tradycyjne techniki endoskopowe mają swoje własne wady we wczesnej diagnostyce i leczeniu.

WNIOSEK

Techniki AI i DL wniosły duży wkład w dziedzinę medycyny, zwłaszcza w dziedzinie diagnostyki raka i medycyny precyzyjnej. Odnotowano duże postępy wraz z ewolucją technik, takich jak CNN w DL. Badania naukowe stworzyły większą platformę z technikami AI i CNN wprowadzającymi precyzyjne leki do zindywidualizowanych terapii. Badania te stanowią kwintesencję wsparcia wielu istniejących technik, aby zaciemnić wiarygodność obrazowania w dziedzinie onkologii. Badania te obejmują diagnozowanie raka za pomocą technik obrazowania wykorzystujących sztuczną inteligencję w celu dokładniejszego zrozumienia dotkniętych obszarów ludzkiego ciała. Popularne techniki sztucznej inteligencji, takie jak DL, a mianowicie CNN i Random Forests, odgrywają głębszą rolę w zrozumieniu struktury molekularnej leków przeciwnowotworowych w celu oceny ich wpływu na komórki rakowe, pomagając w ten sposób w precyzyjnych lekach. Badania dotyczyły również wzajemnych połączeń mózgu i ośrodkowego układu nerwowego za pomocą nanotechnologii. Nastąpił drastyczny postęp w dziedzinie medycyny dzięki integracji ML i AI z interfejsami komputerowymi wykorzystującymi nanotechnologię [81]. Ponieważ nie doszło jeszcze do konwergencji ML i nanoinżynierskich komponentów medycznych, ustanowienie systemów eksperckich i ustrukturyzowana rola w kilku aspektach nanotechnologii i badań nad lekami na poziomie molekularnym wciąż może przynieść arsenał nowych metodologii i ramy do zwalczania raka na bardzo wczesnym etapie dzięki medycynie precyzyjnej, zanim zaatakuje on inne ludzkie komórki.