


REDAKCJA
MAŁGORZATA BUONIK-MINIERSKA
ANETA JURSKA-GAWRYSIAK
DAWID KOBYLAŃSKI



UCZENIE
MASZYNOWE
I MEDYCYNĄ
W NOWOCZESNYM
UJĘCIU


ARCHAEGRAPH
Wydawnictwo Naukowe

UCZENIE MASZYNOWE
I MEDYCYNA W NOWOCZESNYM UJĘCIU

REDAKCJA NAUKOWA

MAŁGORZATA BUDNIK-MINIERSKA
ANETA JURSKA-GAWRYSIAK
DAWID KOBYLAŃSKI

REDAKCJA
MARGARZATA BUDNIK-MINIERSKA
ANETA JURSKA-GAWRYSIAK
DAWID KOBYLAŃSKI



UCZENIE
MASZYNOWE
I MEDYCYNA
W NOWOCZESNYM
UJĘCIU

ARCHAEGRAPH
Wydawnictwo Naukowe

REDAKCJA NAUKOWA

PRZEWODNICZĄCA KOMITETU NAUKOWEGO:

MGR MAŁGORZATA BUDNIK-MINIERSKA

WICEPRZEWODNICZĄCA KOMITETU NAUKOWEGO:

MGR ANETA JURSKA-GAWRYSIAK

WICEPRZEWODNICZĄCY KOMITETU REDAKCYJNEGO:

DAWID KOBYLAŃSKI

SEKRETARZ KOMITETU REDAKCYJNEGO:

RAFAŁ STACHYRA

REDAKCJA TECHNICZNA

MGR INŻ. RAFAŁ MINIERSKI

DR MAŁGORZATA JEZIORSKA

DR DAWID PIETRAS

LEK. MAGDALENA KĘDZIORA

MGR KATARZYNA MAGOŃSKA

RECENZJA

DR INŻ. RAFAŁ ŚPIEWAK

KOREKTA REDAKTORSKA, SKŁAD I PROJEKT OKŁADKI

KAROL ŁUKOMIAK

© COPYRIGHT BY AUTHORS & ARCHAEGRAPH

ISBN: 978-83-67959-21-6

WERSJA ELEKTRONICZNA DOSTĘPNA NA STRONIE INTERNETOWEJ WYDAWCY:

www.archaeograph.pl

ARCHAEGRAPH
Wydawnictwo Naukowe

ŁÓDŹ, WRZESIEŃ 2023

SPIS TREŚCI

PRZEDMOWA.....	6
OPIEKA SKONCENTROWANA NA PACJENCIE.....	8
PAWEŁ KMIĘCIKOWSKI	
OCENA MOŻLIWOŚCI ZASTOSOWANIA MODELI OCR I NLP UCZENIA MASZYNOWEGO W DIGITALIZACJI MATERIAŁÓW ARCHIWALNYCH.....	19
GRZEGORZ GUCWA	
ZASTOSOWANIE TRANSFER LEARNING W ANALIZIE OBRAZÓW PATOMORFOLOGICZNYCH ZA POMOCĄ KONWOLUCYJNYCH SIECI NEURONOWYCH.....	35
ANNA GŁOWACKA	
WYZWANIA I OGRANICZENIA TECHNIK PRZETWARZANIA JĘZYKA NATURALNEGO W ANALIZIE DANYCH MEDYCZNYCH.....	45
ANNA GŁOWACKA	
ROLA SZTUCZNEJ INTELIGENCJI I KONWOLUCYJNYCH SIECI NEURONOWYCH W AUTOMATYZACJI ZAKŁADU PATOMORFOLOGII	56
ANNA GŁOWACKA	

PRZEDMOWA

Niniejszym przedstawiamy Państwu monografię naukową zatytułowaną *UCZENIE MASZYNOWE I MEDYCYNA W NOWOCZESNYM UJĘCIU*, w której znajdują Państwo pięć autorskich rozdziałów młodych adeptów nauki.

W pierwszym rozdziale autorstwa Pawła Kmieciakowskiego pt. *Opieka skoncentrowana na pacjencie* autor podniósł, że praktykowanie opieki skoncentrowanej na pacjencie jest uznane przez Światową Organizację Zdrowia, daje wiele wymiernych korzyści (np. wzrost jakości życia chorego, lepszą organizację systemu opieki zdrowotnej, dłuższy czas przeżycia, lepsze przestrzeganie przez pacjenta zaleceń lekarskich). Dodatkowo wpisuje się w realizowanie troski o uznane w polskim Kodeksie Etyki Lekarskiej, prawo do autonomii pacjenta, a także realizuje postulaty sprawiedliwości społecznej, takie jak równość, dostęp do opieki zdrowotnej czy prawa człowieka.

W kolejnym rozdziale monografii autorstwa Grzegorza Gucwa pt. *Ocena możliwości zastosowania modeli ocr i nlp uczenia maszynowego w digitalizacji materiałów archiwalnych* autor podkreśla, że jednym z głównych wyzwań stojących przed współczesną archiwistyką jest digitalizacja zbiorów tekstowych i udostępnienie ich w sposób sprawny w przestrzeni cyfrowej.

Ostatnią część monografii stanowią trzy rozdziały autorstwa Anny Głowackiej. W pierwszym rozdziale monografii pt. *Zastosowanie transfer learning w analizie obrazów patomorfologicznych za pomocą konwolucyjnych sieci neuronowych* autorka wskazuje, że stosowanie uczenia transferowego może zwiększyć wydajność CNN, prowadząc do dokładniejszych i bardziej wiarygodnych diagnoz. Celem drugiego rozdziału ostatniej części monografii pt. *Wyzwania i ograniczenia technik przetwarzania języka naturalnego w analizie danych medycznych* jest ocena wyzwań dla technik NLP w tej dziedzinie oraz określenie kierunku przyszłych badań. Natomiast celem trzeciego rozdziału ostatniej części monografii pt. *Rola sztucznej inteligencji i konwolucyjnych sieci neuronowych w automatyzacji zakładu patomorfologii* jest analiza wpływu sztucznej

inteligencji i CNN na automatyzację procesów w oddziale patomorfologicznym oraz analiza potencjalnych korzyści i wyzwań z tym związanych.

W imieniu Komitetu Redakcyjnego niniejszego tomu pragniemy podziękować wszystkim osobom zaangażowanym w proces jego wydania, w tym m.in. wydawnictwu, recenzentom oraz autorom.

REDAKCJA NAUKOWA:

MGR MAŁGORZATA BUDNIK-MINIERSKA

MGR ANETA JURSKA-GAWRYSIAK

DAWID KOBYLAŃSKI

PAWEŁ KMIĘCIKOWSKI

COLLEGIUM MEDICUM IM. LUDWIKA RYDYGIERA W BYDGOSZCZY
UNIwersytetu MIKOŁAJA KOPERNIKA W TORUNIU

OPIEKA SKONCENTROWANA NA PACJENCIE

Streszczenie: Celem pracy jest przedstawienie czytelnikowi koncepcji opieki skoncentrowanej na pacjencie, która wypływa z partnerskiego rozumienia relacji między lekarzem a pacjentem, stojąc w opozycji do paternalizmu medycznego i biomedycznego rozumienia choroby. Ten model opieki zdrowotnej po raz pierwszy został opisany w 1950 roku, przez kolejne dekady był różnie interpretowany, konceptualizowany oraz zamykany w konkretne ramy pojęciowe, wyróżniające jego najważniejsze elementy i wymiary, spośród których do najważniejszych należą: uważność na potrzeby pacjenta (również te нефizyczne), niesprowadzanie pacjenta do sumy dolegliwości, leczenie chorego, a nie choroby, aktywne zachęcanie do dzielenia się swoimi przeżyciami wewnętrznymi (zwłaszcza obawami i trudnościami), włączanie chorego w proces decyzyjny dotyczący przebiegu leczenia, troska o podwyższenie jakości jego życia na wielu płaszczyznach. Praktykowanie opieki skoncentrowanej na pacjencie jest uznane przez Światową Organizację Zdrowia, daje wiele wymiernych korzyści (np. wzrost jakości życia chorego, lepszą organizację systemu opieki zdrowotnej, dłuższy czas przeżycia, lepsze przestrzeganie przez pacjenta zaleceń lekarskich). Ponadto wpisuje się w realizowanie troski o, uznane w polskim Kodeksie Etyki Lekarskiej, prawo do autonomii pacjenta, a także realizuje postulaty sprawiedliwości społecznej, takie jak równość, dostęp do opieki zdrowotnej czy prawa człowieka.

Słowa kluczowe: opieka skoncentrowana na pacjencie, relacja lekarz-pacjent, paternalizm medyczny, etyka lekarska

WPROWADZENIE

Medycyna, jako dziedzina nauki zajmująca się zdrowiem i chorobą, od początków swojego istnienia obarczona była koniecznością funkcjonowania w konkretnych ramach patrzenia na przedmiot swoich badań, tj. pacjenta i relacje między jego chorobą a zdrowiem. Przez wieki paradygmaty te zmieniały się i ewoluowały, nierzadko koegzystując z poszczególnymi prądami myślowymi, sposobami patrzenia na człowieka oraz naturę i genezę choroby.

W tym rozdziale, po zarysowaniu koncepcji opieki skoncentrowanej na pacjencie, zaprezentowane zostaną jej kluczowe elementy i wymiary, następnie korzyści wynikające z przyjęcia tego modelu opieki, tak aby na koniec przedstawić omawiany problem w ujęciu etyki lekarskiej i sprawiedliwości społecznej.

ZARYS KONCEPCJI OPIEKI SKONCENTROWANEJ NA PACJENCIE

Uznając medycynę za naukę zajmującą się zdrowiem i chorobami niemożliwe jest oddzielenie jej od kwestii relacji lekarza z pacjentem, która jest najważniejszą przestrzenią sprawowania opieki zdrowotnej. Od tego, jaki przyjmie się sposób patrzenia na tę relację, zależy nie tylko forma leczenia, poziom decyzyjności przyznawanej obu jej stronom czy podmiotowość chorego, lecz także sam cel i przedmiot leczenia. XX wiek to wiek bardzo ważnych pytań w świecie medycyny. Czym jest zdrowie? Należy leczyć chorobę czy pacjenta? Czy pacjent ma być bezwzględnie podporządkowany lekarzowi? Te pozornie nieważne czy wręcz groteskowe zagadnienia – przede wszystkim w zestawieniu z takimi tematami jak produkcja szczepionek, leczenie nowotworów czy etyka lekarska (zwłaszcza po zbrodniach dokonanych przez niektórych medyków podczas II wojny światowej) – *de facto* dotyczyły samego sedna medycyny, a to, jaką odpowiedź uznano za prawidłową, wpływa dzisiaj na życie milionów osób na całym świecie.

Koncepcja opieki skoncentrowanej na pacjencie (PCC, *Patient-Centered Care*) po raz pierwszy pojawiła się w 1950 roku u Michaela Balinta, psychoanalityka, w kontekście jego pracy z lekarzami. W sposób empiryczny zajęto się nią po raz pierwszy po dwóch dekadach, gdy w 1970 roku Patrick Byrne i Barrie Long nagrali wizyty u 60 lekarzy rodzinnych w Wielkiej Brytanii, by dojść do wniosku, iż należy unikać postaw skoncentrowanych na lekarzu (np. zadawania pytań zamkniętych) i dążyć do postaw skoncentrowanych na

pacjencie (takich jak zadawanie pytań otwartych) (Pilnick 2023, s. 1-2). Takie spojrzenie na spotkanie pacjenta i lekarza było jednym z wielu form sprzeciwu wobec funkcjonującego przez wieki (choć do dzisiaj stosowanego w niektórych gabinetach lekarskich) modelu paternalistycznego, według którego lekarz bezwzględnie wiedział najlepiej, co jest dobre dla pacjenta, który ma się tylko podporządkować. Zajmujący powoli jego miejsce model partnerski podkreślał podmiotowość chorego, jego decyzyjność i powinność umożliwienia mu współdecydowania o swoim procesie leczenia.

Paradygmat opieki skoncentrowanej na pacjencie, obok usunięcia lekarza z miejsca osoby decyzyjnej, wiąże się również z uznaniem za przedmiot leczenia nie chorobę, lecz chorego. Gdy medyk leczy chorobę, za cel swoich działań stawia wyleczenie, które w różnych sytuacjach nie musi być jednak nadrzędnym priorytetem dla wielu pacjentów. Skupienie na pacjencie natomiast wymaga uznania nie tylko jego podmiotowości i decyzyjności, lecz także posiadania potrzeb poza fizycznymi, tj. psychicznych, społecznych czy duchowych. W takim ujęciu celem może stać się pomoc pacjentowi w uzyskaniu przez niego dobrobytu, będącego rzeczywistością dotykającą wszystkich jego potrzeb – nie tylko braku choroby. Różnicę w tych dwóch podejściach dobrze widać na przykładzie pacjentów onkologicznych. Dla dużej części z nich rzeczywiście nadrzędną wartością jest przeżycie, jednak dla chorych i ich rodzin niezwykle ważne jest także, by życie, które pozostało, przeżyć możliwie najlepiej (Hjermstad i in. 2023). Ważna jest zatem współpraca tych dwóch aspektów medycyny (dążenie do przeżycia oraz do możliwie najwyższego poziomu życia), która niestety w ujęciu paternalistycznym bądź skoncentrowanym na chorobie jest znacznie trudniejsza do uzyskania. Oczywiście, należy uczciwie przyznać, iż zdarzają się sytuacje, w których konkretni pacjenci chcą w pełni zaufać lekarzowi i niejako wyrzec się swojej decyzyjności. Z pewnych przyczyn może być to dla niektórych niekiedy lepsze, dawać poczucie bezpieczeństwa czy w inny sposób wpływać pozytywnie na ich dobrobyt. Jednak paradoksalnie jest to kolejna przestrzeń, w której opieka skoncentrowana na pacjencie może wieść prymat względem modelu paternalistycznego – w końcu skupienie na potrzebach pacjenta wiąże się z koniecznością uznania potrzeby bycia zaopiekowanym w sposób paternalistyczny, a dodatkowo tworzy między lekarzem a pacjentem przestrzeń do rozmowy – w klimacie wsparcia i empatii – o przyczynach takiego patrzania, którymi mogą być inne problemy (np. obezwładniający strach), do których w skoncentrowaniu na chorobie lekarz mógłby nie mieć tak dużego dostępu, gdyż potrzeby psychiczne

pacjenta czy jego niepokoje nie są wówczas tak ważnym przedmiotem opieki zdrowotnej.

ELEMENTY I WYMIARY PCC

Opieka skoncentrowana na pacjencie była wielokrotnie opisywana, interpretowana i konceptualizowana. Choć różni autorzy podkreślają różne jej aspekty i może być ona rozumiana na wiele sposobów, podkreślających wagę konkretnych elementów tego systemu, Światowa Organizacja Zdrowia (WHO, *World Health Organization*), uznała ją za kluczowy element walki o poprawę nierówności w opiece zdrowotnej, rozumiejąc ją jako podejście organizujące opiekę nad pacjentem wokół jego perspektywy i potrzeb oraz wspierające w podejmowaniu decyzji i uczestniczeniu w procesie leczenia. (Janerka, Leslie, Gill 2023, s. 2).

McCormack i in. w 2011 uporządkowali ogólne ramy opieki skoncentrowanej na pacjencie na kilku poziomach, włączając w nie m.in. odpowiednie relacje między pacjentem a personelem medycznym, udzielanie informacji choremu, uważność na jego uczucia (rozpoznawanie ich i reagowanie na nie) i aktywowanie samoopieki pacjenta. Kilkanaście lat wcześniej powstała natomiast koncepcja, autorstwa J. Watsona, wyróżniająca cztery zasadnicze elementy opieki skoncentrowanej na pacjencie – szacunek dla tożsamości i wartości pacjenta, rozpoznawanie jego indywidualnej, szczególnej reakcji na chorobę, wspierania niezależności chorego i pomagania mu w osiągnięciu maksimum swoich zdolności (Ghane, Esmaili 2020, s. 387).

Inni dodają takie aspekty jak edukacja pacjenta, zapewnianie łatwego dostępu do opieki zdrowotnej, tworzenie przestrzeni do dialogu z włączeniem wysłuchania pacjenta i jego rodziny, pomoc w zmniejszaniu lęku i stresu (Ghane, Esmaili 2020, s. 383-387). Podkreśla się także, co ma odzwierciedlenie w wynikach badaniach naukowych, że angażowanie chorego w proces decyzyjny powinno mieć charakter aktywny, a obawy pacjentów mają być nie tylko brane pod uwagę, lecz do ich ujawniania należy chorych wręcz zachęcać (Liang i in. 2022, s. 2).

Praktykowaniu opieki skoncentrowanej na pacjencie sprzyja przyjęcie biopsychospołecznego modelu choroby (Kidanimariam i in. 2023, s. 2). W przeciwieństwie do modelu biomedycznego etiologii schorzeń i zaburzeń doszukuje się on nie tylko na poziomie biologicznym, lecz także w psychicznych i społecznych aspektach funkcjonowania osoby i ich wpływu na spektrum zdrowia człowieka.

We wszystkich przytoczonych powyżej aspektach opieki skoncentrowanej na pacjencie widać pewien szczególny jej rys, polegający na charakterystycznym patrzeniu na pacjenta jako na *osobę*. W tym ujęciu chory nie jest sumą schorzeń, chorób i bólów, lecz jest przede wszystkim całością – sumą specyficznych dla siebie potrzeb (fizycznych, a także psychicznych, duchowych i społecznych), wyznawanych wartości, relacji, w których funkcjonuje i które na niego oddziałują, marzeń, uczuć i emocji (ze szczególną wrażliwością na strach, niepokój i lęk), uprzedzeń, poglądów i wielu innych. W tym ujęciu następuje zatem uznanie przychodzącego do gabinetu lekarskiego pacjenta nie za nosiciela choroby, którą lekarz ma wyleczyć, lecz za bardzo złożoną całość, *człowieka i osobę*, która istotnie przychodzi przede wszystkim z chorobą do wyleczenia, lecz niosąc ze sobą również wiele innych aspektów swojego życia (wszak choroba może oddziaływać na nie wszystkie) oraz wyjątkową dla siebie własną perspektywę patrzenia na swoje zdrowie. W tym momencie lekarz staje się kimś więcej niż specjalistą od leczenia choroby – towarzyszem cierpienia na wielu poziomach oraz w wielu przypadkach niemalże jedyną osobą, która może przyczynić się do wzrostu jakości życia pacjenta i towarzyszyć mu w drodze do jego dobrostanu. Mamy tutaj do czynienia zatem nie tylko ze zmianą patrzenia na pacjenta, lecz także ze zmianą patrzenia na lekarza, a uznanie również jego za *osobę* tworzy przestrzeń do powstania bardzo specyficznej relacji między nim a pacjentem, w której leczenie chorego (zamiast leczenia choroby) staje się rzeczywistością jeszcze bardziej intymną i ważną.

W metaanalizie z 2023 roku zidentyfikowano w literaturze trzy kluczowe elementy PCC – poznanie pacjenta jako jednostki, pracę z pacjentem oraz niejako warunki wstępne, dotyczące personelu medycznego, konieczne do praktykowania omawianego paradygmatu, m.in. kompetencje zawodowe, zaangażowanie czy umiejętności interpersonalne (Janera, Leslie, Gill 2023, s. 9-10). Bardzo ważna w realizacji wszystkich tych elementów jest odpowiednia komunikacja z pacjentem, zwłaszcza w świetle tego, iż w szpitalach na całym świecie nieefektywna komunikacja jest najczęstszą przyczyną zdarzeń niepożądanych, powodując uszkodzenia ciała i śmierć pacjentów. Z nieporozumieniem zaistniałym podczas komunikacji związane jest nawet 80% takich zdarzeń (Chien i in. 2022, s. 1414). Nauka i praktykowanie odpowiedniej komunikacji stają się zatem jedną z najważniejszych kompetencji lekarza, zwłaszcza w ujęciu komunikacji empatycznej, która pozwala medykowi efektywnie przyjąć perspektywę pacjenta, co jest konieczne w leczeniu pacjenta, a nie choroby, uznaniu jego podmiotowości i decyzyjności czy poznaniu specyficznej dla konkretnego chorego sytuacji i przeszkód na drodze do jego większego

dobrostanu. Warto podkreślić również to, iż skonceptualizowana w świecie zachodnim komunikacja empatyczna okazała się istotna również dla osób z afrykańskich kręgów kulturowych (por. Turner, Archer 2020, s. 7). Może to sugerować jej uniwersalizm, tym samym jeszcze bardziej podkreślając jej rolę w procesie leczenia.

KORZYŚCI WYNIKAJĄCE Z PRAKTYKOWANIA PCC

Wdrażanie opieki skoncentrowanej na pacjencie wiąże się z szeregiem wymiernych korzyści dla pacjenta, personelu medycznego i systemu ochrony zdrowia. Omawiany model leczenia został powszechnie uznany za podstawę wysokiej jakości opieki zdrowotnej do tego stopnia, że poziom koncentracji na pacjencie stał się ważnym miernikiem poziomu usług zdrowotnych. Ponadto PCC pozytywnie koreluje z wynikami chorych, ich bezpieczeństwem i zadowoleniem, a także z wydajnością systemu opieki zdrowotnej (Janerka, Leslie, Gill 2023, s. 2). Badania sugerują także, że opieka skoncentrowana na pacjencie wpływa na jego wyższe zadowolenie i niższe koszty opieki zdrowotnej (Bejarano i in. 2022, s. 17).

Możliwy schemat powiązań prowadzący do tak ważnych i oczekiwanych korzyści można ocenić w dużej mierze dość intuicyjnie, również na podstawie własnych doświadczeń jako pacjenta czy wsłuchując się w częste zarzuty wobec lekarzy. W ocenie medyków wielokrotnie podkreśla się przecież ich umiejętności interpersonalne, otwartość na pacjenta czy brak wymagania od niego wiedzy *stricte* medycznej. Chory, który w lekarzu może dostrzec osobę kulturalną i życzliwą, może dostrzec w nim również powiernika swojego cierpienia (na wielu płaszczyznach), kogoś godnego zaufania. To, że w tej profesji właśnie relacja z drugim człowiekiem jest przestrzenią oferowania usług zdrowotnych, niesie ze sobą bardzo ważny i konkretny imperatyw troski o to, by relacja z pacjentem służyła obojgu stronom. Stanięcie w relacji jako lekarz-partner, osoba, która chce swoją wiedzą pomóc, a nie tylko wydać polecenia, oraz okazać empatię i wsparcie, i, z drugiej strony, jako pacjent, który może poczuć się bezpiecznie, wysłuchany, zaopiekowany i nieoceniony (co bywa bardzo dużą obawą chorych, która wpływa na cały proces leczenia, np. z powodu nieprzyznania się do niestosowania zaleceń) – to rodzi przestrzeń do spotkania dwóch *osób*, a nie tylko świadczeniodawcy i świadczeniobiorcy. Powinno być to ważne również dla lekarzy, gdyż postawienie się w relacji zawodowej, nie uciekając od tego, że jest się *osobą* w całości, może być pomocne w sytuacji błędu, pomyłki czy niedopatrzania lekarza – medykowi wyrozumiałemu wiele

osób szybciej okaże wyrozumiałość niż medykowi emanującemu próżnością i bezgraniczną wiarą w swoje kompetencje.

Zaufanie pacjentów do klinicystów wzrasta, gdy klinicyści wspierają samostanowienie pacjentów, dając im poczucie autonomii, i starają się zrozumieć ich doświadczenia oraz komunikować się jasno i szczerze. Takie zaufanie i postrzeganie autonomii przez pacjentów może sprzyjać zadowoleniu lekarzy, co z kolei poprawia relacje lekarz-pacjent, prowadząc do przestrzegania leczenia przez pacjenta i lepszych wyników leczenia (Liang i in. 2022, s. 2).

Pozytywny wpływ praktykowania PCC na przebieg leczenia w wyjątkowy sposób widać u pacjentów z chorobami nieuleczalnymi oraz u chorych na uzależnienie od narkotyków. Branie pod uwagę w procesie leczenia również, oprócz choroby, całego pacjenta, zamiast skupiania się wyłącznie na jego schorzeniu, wiąże się u pacjentów nieuleczalnie chorych z większą ilością czasu spędzonego w domu, lepszą jakością życia, mniejszą liczbą uciążliwych objawów, a nawet dłuższym czasem przeżycia (Aass, Kaasa 2022). W kontekście osób z uzależnieniem od opioidów w trakcie terapii substytucyjnej metadonem widać natomiast, że możliwość przyczynienia się przez pacjenta do realizacji swojego planu leczenia niesie ze sobą szansę na lepsze przestrzeganie zaleceń dotyczących leczenia (Marshall, Maina, Sherstobitof 2021, s. 8).

ETYCZNY WYMIAR PCC

Dyskutując na temat sposobu patrzenia na relację z lekarzem oraz na stopień niezależności, współodpowiedzialności czy wręcz sprawczości, które pacjentowi się należą bądź nie, warto wziąć pod uwagę również etyczny wymiar omawianego problemu. Kodeks Etyki Lekarskiej zawiera bardzo konkretne ramy patrzenia na autonomię pacjenta. W punkcie 1. artykułu 13. czytamy: *Obowiązkiem lekarza jest respektowanie prawa pacjenta do świadomego udziału w podejmowaniu decyzji dotyczących jego zdrowia.* Dalsze artykuły zawierają wskazania dotyczące wymogu uzyskania zgody pacjenta na postępowanie diagnostyczne, lecznicze i zapobiegawcze, biorąc pod uwagę różne okoliczności, takie jak niepełnoletność pacjenta czy niezdolność do wyrażenia świadomej zgody (Kodeks Etyki Lekarskiej, Art. 13., 15., 37., 44.). W takim rozumieniu autonomii pacjenta, która jest jednym z jego podstawowych praw, paternalistyczny model opieki (przynajmniej w radykalnej wersji) jest nieetyczny i nie do przyjęcia.

Skoncentrowanie na pacjencie jest jednak czymś więcej niż model partnerski, stojący w opozycji do modelu paternalistycznego, gdyż zawiera również aspekt postawienia w centrum opieki pacjenta jako całości, zamiast jego choroby czy osoby lekarza. Takie patrzenie na relację z chorym pojmowane jest w kategoriach wartości moralnej przez wielu medyków, o czym świadczą badania na temat stosunku pielęgniarek wobec PCC (Ghane, Esmaceli, 2020, s. 387). Uważność na przeżycia wewnętrzne chorego, jego szeroko rozumiany system wartości, relacje, zobowiązania, potrzeby czy marzenia bywają przedstawiane w kategoriach etycznych, jako powinność moralna, wpływająca zwłaszcza z myśli personalistycznej, choć – co zostało ukazane powyżej, np. poprzez wymierne korzyści praktykowania PCC – inne systemy etyczne również mogą docenić ten paradygmat systemu opieki zdrowotnej.

Poza kategoriami etycznymi, opieka skoncentrowana na pacjencie jest doceniana również w kontekście zagadnienia sprawiedliwości społecznej. Ramy PCC są zgodne z jej zasadami w dziedzinie zdrowia, takimi jak prawa człowieka, dostęp do opieki zdrowotnej czy równość międzyludzka (Marshall, Maina, Sherstobitof 2021, s. 2). Praktykując PCC, tworzy się także przestrzeń do walki z zagrożeniami wpływającymi z paternalizmu medycznego, w którym – ze względu na brak należytej wrażliwości na preferencje i życzenia pacjentów – możliwe jest utrwalanie stereotypów i uprzedzeń związanych np. z płcią, kulturą, rasą czy statusem społeczno-ekonomicznym, które mogą wpływać na podejmowane decyzje (Marshall, Maina, Sherstobitof 2021, s. 2). Gdy w procesie leczenia uwzględnia się przeżycia wewnętrzne chorego, niejako oddaje mu się głos, konkretne poglądy i uprzedzenia medyka są w pewnym sensie detronizowane – lekarz staje z pacjentem w relacji partnerskiej, opartej na szacunku i współpracy.

PODSUMOWANIE

Opieka skoncentrowana na pacjencie to koncepcja dotycząca pojmowania miejsca chorego w relacji z medykami, stopnia przyznawanej mu odpowiedzialności, sprawczości, autonomii i współdecyzyjności oraz wagi patrzenia na pacjenta jako na *osobę*, całość, a nie jak na zbiór chorób i dolegliwości. Takie ujęcie pozwala dostrzec jego konkretne potrzeby fizyczne, psychiczne, duchowe i społeczne, zobaczyć, jak choroba wpływa na różne aspekty jego życia, dowiedzieć się, czego się boi, o czym marzy, czego mu brakuje. Takie patrzenie na pacjenta przyczynia się do poszerzenia zakresu działania lekarza – staje się on kimś więcej niż specjalistą od wyleczenia jednostki chorobowej,

gdyż w tym ujęciu ma szansę pomóc pacjentowi osiągnąć wyższą jakość życia i większy dobrobyt na wielu płaszczyznach, na które stan zdrowia oddziałuje. Praktykowanie PCC wiąże się z wieloma korzyściami, takimi jak wyższa jakość życia, mniejsze wydatki finansowe na chorego, lepsze przestrzeganie zaleceń lekarskich czy wzrost zaufania do lekarza. Niewątpliwie prawidłowo wdrażana PCC wiąże się z wysokimi kompetencjami komunikacyjnymi, zwłaszcza w zakresie komunikacji empatycznej, dlatego warto jej uczyć w czasie kształcenia przyszłych medyków. Ponadto opieka skoncentrowana na pacjencie wydaje się być należyta również z etycznego punktu widzenia, współpracując w dodatku z koncepcją sprawiedliwości społecznej i spełniając jej kryteria w kontekście opieki zdrowotnej.

BIBLIOGRAFIA

Aass N., Kaasa S.

2022 *Pasientsentrert behandling – er det mulig?*, Tidsskr Nor Legeforen.

Bejarano G., Csiernik B., Young J. J., Stuber K., Zadro J. R.

2022 *Healthcare students' attitudes towards patient centred care: a systematic review with meta-analysis*, BMC Medical Education 22:324.

Chien L. J., Slade D., Dahm M. R., Brady B., Roberts E., Goncharov L., Taylor J., Eggins S., Thornton A.

2022 *Improving patient-centred care through a tailored intervention addressing nursing clinical handover communication in its organizational and cultural context*, Journal of Advanced Nursing, 78.

Ghane G., Esmaili M.

2020 *Nursing students' perception of patient-centred care: A qualitative study*, Nursing Open, 7.

Hjermstad M. J., Aass N., Gravli T. H., Smeland S., Kaasa S.

2023 *Pasientsentrert kreftbehandling*, Tidsskr Nor Legeforen, (1).

Janerka C., Leslie G.D., Gill F. J.

2023 *Development of patient-centred care in acute hospital settings: A meta-narrative review*, International Journal of Nursing Studies 140.

Kidanemariam M., Pieterse A. H., van Staalduin D. J., Bos W. J. W., Stiggelbout A. M.

2023 *Does value-based healthcare support patient-centred care? A scoping review of the evidence*, BMJ Open 2023; Volume 13, Issue 7.

Kodeks Etyki Lekarskiej.

Liang Z., Xu M., Liu G., Zhou Y., Howard P.

2022 *Patient-centred care and patient autonomy: doctors' views in Chinese hospitals*, BMC Medical Ethics 23:38.

Marshall K., Maina G., Sherstobitof J.

2021 *Plausibility of patient-centred care in high-intensity methadone treatment: reflections of providers and patients*, Addiction Science & Clinical Practice volume 16, Article number: 42.

Pilnick A.

2023 *Reconsidering patient-centred care: Authority, expertise and abandonment*, Health Expectations.

Turner R. E., Archer E.

2020 *Patient-centred care: The patients' perspective – A mixed-methods pilot study*, African Journal of Primary Health Care & Family Medicine; 12(1): 2390.

PATIENT-CENTERED CARE

Summary: The aim of this paper is to present to the reader the concept of patient-centred care, which results from a partnership understanding of the relationship between doctor and patient, as opposed to the medical paternalism and biomedical understanding of the disease. This model of health care was first described in 1950 and over the following decades it has been interpreted variously, conceptualized and enclosed in a specific conceptual framework, distinguishing its most important elements and dimensions, among which the most important are: attentiveness to the patient's needs (including non-physical ones), not reducing the patient to the total number of ailments, treating the patient rather than the disease, actively encouraging to share their inner experiences (especially fears and difficulties), including the patient in the decision-making process regarding the course of treatment, caring for improving the quality of his or her life on many levels. The practice of patient-centred care is recognised by the World Health Organisation and has many measurable benefits (e.g. improved quality of life, better organisation of the healthcare system, longer survival times, better compliance with doctor's recommendations). Moreover, it is part of the realization of the right to autonomy of the patient, recognized in the Polish Code of Medical Ethics, and also implements the demands of social justice, such as equality, access to health care and human rights.

Keywords: patient-centred care, doctor-patient relationship, medical paternalism, medical ethics

OCENA MOŻLIWOŚCI ZASTOSOWANIA MODELI OCR I NLP UCZENIA MASZYNOWEGO W DIGITALIZACJI MATERIAŁÓW ARCHIWALNYCH

Streszczenie: Jednym z głównych wyzwań stojących przed współczesną archiwistyką jest digitalizacja zbiorów tekstowych i udostępnienie ich w sposób sprawny w przestrzeni cyfrowej. Chociaż jest to proces realizowany przez większość archiwów na całym świecie, to często ogranicza się on do umieszczenia na stronie cyfrowych archiwów pliku graficznego ze skanem tekstu opatrzonym sygnaturą i zdawkowym opisem. W celu usprawnienia oraz osiągnięcia większej jakości zarówno digitalizacji materiałów jak i organizacji cyfrowych archiwów niniejsza praca postuluje zastosowanie modeli uczenia maszynowego ukierunkowanych na optyczne rozpoznawanie znaków i przetwarzanie języka naturalnego. Zastosowanie obydwu tych technologii może w wydatny sposób przyczynić się do spełnienia postawionych tu celów, wspomagając pracę archiwistów przy oszczędności czasu oraz środków.

Słowa kluczowe: uczenie maszynowe, optyczne rozpoznawanie znaków, przetwarzanie języka naturalnego, archiwistyka, digitalizacja

WSTĘP

Współcześnie rozumiana metodyka archiwalna opiera się w swoich założeniach na opracowywaniu i rozwoju metod spełniania czterech podstawowych zadań stojących przed placówkami archiwalnymi: gromadzenia, przechowywania, opracowywania i udostępniania zbiorów oraz danych w nich zawartych (Robótka i in. 1989, s. 8-15). Problematyka digitalizacji

danych dotyka wszystkich powyżej wymienionych aspektów zarządzania archiwaliai, lecz w szczególnym stopniu poruszone zostaną tutaj dwa ostatnie. W obliczu rosnącego wpływu Internetu na naukę oraz jej rozwój coraz więcej badań dokonywanych jest częściowo lub w całości w oparciu o materiały i opracowania dostępne w sieci. Dzięki temu stanowi rzeczy zapotrzebowanie na archiwalia znajdujące się w przestrzeni cyfrowej stale rośnie, czemu współczesna archiwistyka przez ograniczenia technologiczne nie zawsze może wyjść naprzeciw. Niniejsza praca stawia sobie za cel omówienie tego problemu oraz jego potencjalnych rozwiązań przy zastosowaniu modeli uczenia maszynowego wyspecjalizowanych w optycznym rozpoznawaniu znaków oraz przetwarzaniu języka naturalnego. Ogólnie zostanie tu opisane uczenie maszynowe oraz jego wybrane działy i techniki oraz zastosowanie go w wymienionych powyżej zadaniach. W tym celu zostaną przedstawione przykłady badań nad z powodzeniem realizującym te funkcje dzięki uczeniu maszynowemu oraz prac przeglądowych omawiających je, a także zaproponowanie na bazie ich treści metodologii opisanej w nich w archiwistyce i rozwoju digitalizacji materiałów tekstowych.

WYBRANE ASPEKTY PRZETWARZANIA JĘZYKA NATURALNEGO, OPTYCZNEGO ROZPOZNAWANIA ZNAKÓW ORAZ UCZENIA MASZYNOWEGO

Przetwarzanie języka naturalnego (ang. *Natural Language Processing*, NLP) jest dziedziną nauki z pogranicza informatyki oraz lingwistyki. Jego zadaniem jest umożliwienie programom komputerowym rozpoznawania i rozumienia języka w formie pisanej i mówionej (w tym grafologii), a w bardziej zaawansowanej formie także wykorzystywanie go we własnej pracy. Jedną ze współcześnie stosowanych metod NLP jest tworzenie tzw. modeli przetwarzania języka naturalnego, bazujące w swoim założeniu na technologiach uczenia maszynowego.

Optyczne rozpoznawanie znaków (ang. *Optical Character Recognition*, OCR) to zestaw technik mających na celu rozpoznawanie poszczególnych znaków pisma bądź druku/maszynopisu lub pełnych słów w pliku graficznym. W XX wieku powszechne było stosowanie przez oprogramowanie OCR uprzednio zaprogramowanych szablonów znaków jako punktów odniesienia, wobec których porównaniu ulegał każdy rozpoznany przez program znak. (Berschmans i Kumar 2014, s. 1361-1365) Współcześnie bardzo często stosowaną metodą jest używanie modeli uczenia maszynowego ICR, zwłaszcza

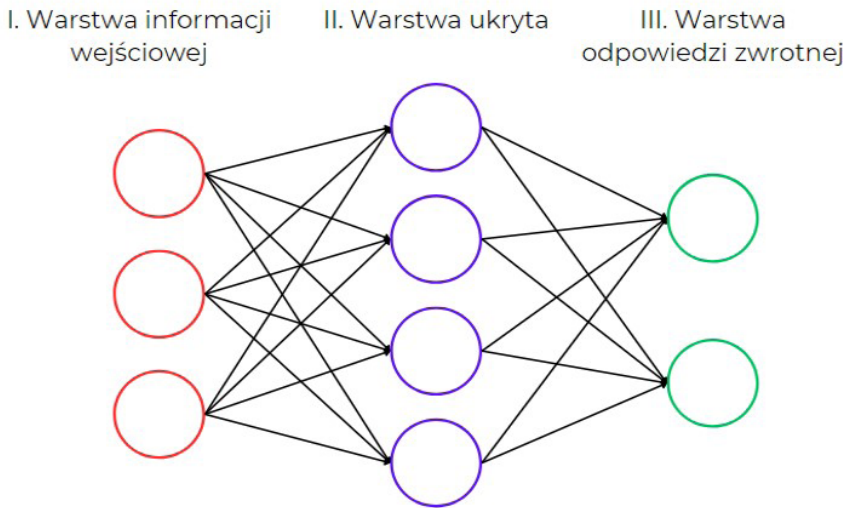
w przypadku pisma odręcznego. Ze względu na jego nieregularność, stosowanie uczenia maszynowego jako technologii dostosowującej się do analizowanych przez siebie materiałów stanowi popularniejszą i skuteczniejszą alternatywę dla nieelastycznych „tradycyjnych” programów OCR (Cabral i de Oliveira 2012, s. 237-240).

Uczenie maszynowe (dalej: UM) jest dziedziną badań nad sztuczną inteligencją skupiającą się na tworzeniu i rozwijaniu modeli samodzielnie wyciągających wnioski, tworzących na ich podstawie prognozy oraz podejmujących decyzje wykraczając dzięki pracy algorytmów tworzących model poza swoją pierwotną skuteczność. Zadaniem UM w tworzeniu i rozwoju sztucznej inteligencji jest umożliwienie jej nie tylko samodzielnego podejmowania przez nią decyzji, ale również usprawnienie tego procesu i jej wydajności. Modele uczenia maszynowego są szkolone za pomocą uprzednio przygotowanych dużych baz danych, by umożliwić im swobodne rozpoznawanie wszelkich prawidłowości wewnątrz nich, modyfikując swoje parametry na bazie zgodności odpowiedzi zwrotnej modelu z rzeczywistością. Wówczas mogą one wykorzystać swoją „wiedzę” do samodzielnego tworzenia prostych prognoz lub podejmowania decyzji przy pracy z nowymi, nieprzetworzonymi dotychczas materiałami.

Można wyróżnić trzy podstawowe rodzaje tzw. „klasycznego” uczenia maszynowego: nadzorowane uczenie się (ang. *supervised learning*), nienadzorowane uczenie się (ang. *unsupervised learning*) i uczenie się wzmacniające (ang. *reinforcement learning*). W przypadku nadzorowanego uczenia się algorytmy budujące model korzystają z oznakowanych przykładów materiałów, gdzie każdy z nich ma przypisany z góry ustalony wynik lub wartość docelową. W założeniu tworzy on uogólnienie na bazie podanych mu przykładów i na jego podstawie przetwarza on nowe dane w celu wyprodukowania odpowiedzi zwrotnej. Nienadzorowane uczenie się z kolei zakłada podstawianie algorytmom tworzącym model nieoznakowanych przykładów materiałów, w których ma on samodzielnie znaleźć nieznane wcześniej dla siebie korelacje i trendy, tworząc strukturę decyzyjną na podstawie procesów, dzięki którym je ustalił. Uczenie się wzmacniające zaś stanowi etap pośredni między obydwojema, gdzie algorytm nadal prowadzi pewną interakcję z nadzorcą procesu uczenia się, lecz praca algorytmów budująca model nie jest oceniana na podstawie zgodności z ogólnie oczekiwanym wynikiem, lecz z jego ewolucją: odpowiedzią zwrotną jest poziom spełnienia niesprecyzowanych od razu oczekiwań nadzorczy. (Simeone 2018, s. 649-650). O krok dalej idzie natomiast uczenie głębokie (ang. *deep learning*) opierające się w swoich założeniach

na zaawansowanych mechanizmach sieci neuronowych, wzorowanych w swojej konstrukcji na zasadach funkcjonowania ludzkiego układu nerwowego (Ilustracja 1). Poszczególne warstwy „neuronów” odpowiadają za przypisaną im część zadania pod którego spełnianie zaprojektowano sieć (np. rozpoznawania poszczególnych elementów twarzy na zdjęciach), współpracując ze sobą w budowaniu odpowiedzi zwrotnej (He i in. 2016, s. 770-771).

Ilustracja 1. Sieć neuronowa. Poszczególne neurony są ze sobą połączone "synapsami" symulującymi połączenia w ludzkim mózgu.



Źródło: opracowanie własne.

Istnieją dwa rodzaje sieci neuronowych używanych często w przetwarzaniu języka naturalnego. Pierwszym z nich są sieci rekurencyjne, modyfikujące w trakcie swojego działania nowe dane wejściowe za pomocą uzyskanej uprzednio odpowiedzi zwrotnej. Taka architektura przydaje się zwłaszcza przy przetwarzaniu powtarzalnych danych pokroju odręcznego pisma, ludzkiej mowy lub odróżniania od siebie stylów językowych (Dupond 2019, s. 218-230). Szczególnym jej typem, opisanym w niniejszej pracy jest technologia LSTM (ang. *Long Short-Term Memory*, przedłużonej pamięci krótkotrwałej). Powstała ona jako rozwiązanie jednego z kluczowych problemów sieci rekurencyjnej, to jest zatracanie gradientu. Jest to sytuacja, w której różnica między odpowiedzią zwrotną a modyfikowanymi przez nią danymi wejściowymi jest znikoma, co zatrzymuje proces samodzielnego uczenia się sieci. LSTM zachowuje część dawnej odpowiedzi zwrotnej do dalszego użytku modelu,

przedłużając jej żywotność i zapobiegając „zapętleniu się” modelu, co wydatnie wzmacnia jej osiągi w analizie pisma odręcznego (Graves i in. 2009, s. 854-866). Alternatywą dla sieci rekurencyjnych są sieci jednokierunkowe, które nie używają ponownie swojej odpowiedzi zwrotnej. Szczególnym ich typem są wykorzystywane w analizie obrazów sieci splotowe (ang. *convolutional networks*), w których „neurony” analizują jedynie przypisane sobie i zachodzące na siebie wycinki obrazu zamiast całości, splatając je ze sobą w kolejnej warstwie w łatwiejszy do przetworzenia obraz, efektywnie samemu ucząc się filtrowania obrazów (Albawi i in. 2017).

Ważną kwestią związaną ze szkoleniem modeli uczenia maszynowego pozostaje stworzenie odpowiedniego do szkolenia modelu UM zbioru danych, zwłaszcza zwracając uwagę na ich poprawność reprezentatywność względem przetwarzanych docelowo materiałów. Jest to o tyle ważne, że model wyszkolony na złym zbiorze danych nie będzie poprawnie działał. Innym problemem jest sprawa „przeuczenia” i „niedouczenia” (ang. *overfitting* and *underfitting*) modeli uczenia maszynowego, to jest dostosowania ich ponad miarę lub niedostosowania do danych treningowych, tym samym zaburzając zgodność z rzeczywistością odpowiedzi zwrotnych opartych na nieznanymi materiałach (Hastie i in. 2008, s. 10).

ODCZYT MATERIAŁÓW ARCHIWALNYCH I PRZETWARZANIE ICH NA PLIK TEKSTOWY

Powyżej opisane techniki stanowią zatem przyszłość digitalizacji danych. Możliwość przetworzenia skanu dowolnego tekstu pisanego odręcznie lub za pomocą maszyny do pisania na plik tekstowy jest kluczowa dla dalszego rozwoju wielu dziedzin nauki oraz administracji. Dzięki Internetowi zaś umieszczenie w chmurze oraz udostępnienie tak przekonwertowanych materiałów dla użytku powszechnego lub usprawnienia wewnętrznego funkcjonowania instytucji prywatnych oraz publicznych nie pozostawia wielkich trudności. By tak się stało, między innymi na archiwach spoczywa obowiązek przeprowadzenia digitalizacji swoich zbiorów oraz udostępnienia ich w przestrzeni cyfrowej. Poniżej przedstawiona zostanie propozycja zastosowania modeli UM przez archiwistów w obydwu postawionych w niniejszej pracy zadaniach.

Podczas digitalizacji materiałów archiwalnych niezwykle ważny jest aspekt opracowywania ich w sposób umożliwiający opiekunom zbiorów oraz ich użytkownikom wygodny dostęp do ich treści oraz operowanie na nich za pomocą narzędzi komputerowych. Problemem, z którym mierzy

się archiwistyka w tym zakresie, jest częsta niewspółmierność stosowanych przez nią metod do potrzeb użytkowników (w tym badaczy) oraz możliwości, jakie oferują współczesne technologie oraz *data science*. Podstawową i najbardziej oczywistą formą digitalizacji swoich zbiorów, jaka jest stosowana przez archiwa, pozostaje skanowanie dokumentu i tworzenie pliku graficznego (lub zbioru plików) na podstawie skanów, bez uniwersalnej reguły ustalającej np. jednolity format plików (Corrado i Sandy 2017, s. 30-35). Wadą takiego podejścia do instytucji materiału cyfrowego jest jego niska kompatybilność z wieloma narzędziami stosowanymi w przestrzeni cyfrowej. Komputerowa analiza danych, w tym stosowana często w lingwistyce i historii literatury makroanaliza, opiera się na stosowaniu plików tekstowych, co wymaga od badaczy korzystania z danych opracowanych odgórnie jako pliki tekstowe (Jockers 2013, s. 24-25;27). W związku z tym pomijane są materiały które uległy digitalizacji w formie graficznej, tym samym w znaczny sposób uszczuplając pulę potencjalnych materiałów, z których badacze są w stanie korzystać. Aby zapobiec takiemu stanowi rzeczy, digitalizacja zbiorów archiwalnych powinna docelowo koncentrować się na umieszczaniu w przestrzeni cyfrowej materiałów w formie plików tekstowych.

Ręczne opracowywanie archiwów i tworzenie przez badaczy osobiście materiałów cyfrowych będących dokładną kopią oryginału nie jest realistyczną metodą na osiągnięcie tego celu. Chociaż zaletą tego rozwiązania jest niezaprzeczalna dokładność (zwłaszcza, gdy takie opracowania podlegają recenzji oraz redakcji) i możliwość wzbogacenia ich o dodatkowe uwagi i komentarze ze strony opracowujących, jego wady są aż nazbyt oczywiste. Wymagany nakład sił i środków by w ten sposób dokonać digitalizacji archiwaliów w Polsce i na świecie może być potencjalnie gigantyczny. Ponadto czasochłonność takiego procesu i ograniczone możliwości personelu badawczego oraz edytorskiego wykwalifikowanego do opracowywania źródeł są czynnikami negatywnie rzutującymi na ręczną digitalizację materiałów archiwalnych w oczach potencjalnych patronów oraz inwestorów.

Rozwiązaniem tego problemu ograniczającym w znaczny sposób czas oraz ewentualne koszty poniesione przez archiwa może być zastosowanie technologii OCR. Przetwarzanie obrazu na tekst, będące główną funkcją optycznego rozpoznawania znaków może być zadaniem samym w sobie w przypadku cyfryzacji materiałów, efektywnie tworząc gotowy do przechowywania w przestrzeni wirtualnej plik tekstowy. Zastosowanie „tradycyjnych” technik OCR jako metody wspomagającej digitalizację archiwaliów oraz kładącą podstawy pod stworzenie całych cyfrowych baz danych jest poruszone w pracy

T. Blankego, M. Bryanta oraz M. Hedgesa *Ocropodium: open source OCR for small-scale historical archives*. W niej badacze przedstawili efektywność dostępnych wówczas narzędzi OCR *open source* na przykładowych zbiorach materiałów archiwalnych (m. in. protokołach irlandzkich debat parlamentarnych między 1921 a 1976 oraz skanach Aktu Unii Brytyjsko-Irlandzkiej) w porównaniu z testowym zbiorem dokumentów opracowanym przez Uniwersytet Nevady. Efektywność tych narzędzi w przetwarzaniu nowszych archiwaliów nie odbiegała od zanotowanej w przypadku zbioru testowego (w obydwu *circa* 90% zgodności z oryginałem), aczkolwiek miały one problem z konwersją na plik tekstowy materiałów drukowanych sporządzonych wcześniej niż w XX wieku, gdzie skuteczność tych narzędzi cechowała się rozstrzałem 40%-80%. Proponowaną przez nich alternatywą było tworzenie dedykowanych narzędzi OCR dla użytku pomniejszych archiwów przechowujących stare materiały źródłowe, z wyszczególnieniem autorskiego Ocropodium (Blanke i in. 2011 s. 79-86). Opublikowana przez ten sam zespół rok później praca potwierdziła zasadność stosowania dedykowanych narzędzi OCR w pracy archiwalnej ze starymi dokumentami, z przeprowadzeniem dwóch studiów przypadku monitorujących projekty digitalizacji materiałów: *The Strom Papers* oraz *European Holocaust Research Infrastructure* wykorzystujących Ocropodium. Potwierdzono, że wydajność cyfryzacji archiwaliów została zwiększona, a przepływ pracy wewnątrz ram projektowych został usprawniony (Blanke i in. 2012, s. 674-681). Pewną alternatywą dla tradycyjnych technik optycznego rozpoznawania znaków może być używanie modeli uczenia maszynowego, usprawniających swoją skuteczność pod nadzorem lub autonomicznie. Przykład udanego zastosowania tej technologii jest opisany w pracy badaczy Uniwersytetu Helsińskiego, gdzie model oparty o zasadę uczenia nadzorowanego osiągnął efektywność rzędu 95% w konwertowaniu na tekst zbioru skanów gazet szwedzkojęzycznych i fińskojęzycznych z lat 1771-1939 drukowanych przy użyciu różnych od siebie czcionek. Można zatem stwierdzić, że zastosowanie OCR przynosi zadowalające rezultaty w digitalizacji archiwaliów drukowanych.

Niestety, inaczej wygląda sprawa materiałów pisanych odręcznie. O ile w przypadku tekstów drukowanych zastosowanie jednolitej czcionki wydatnie ułatwia pracę prostym narzędziom OCR lub modelom uczenia maszynowego szkolonych w tym celu, o tyle pismo ręczne nie gwarantuje podobnej regularności, utrudniając im tym samym identyfikację znaków. Alternatywą dla nich jest zastosowanie opartego na sieciach neuronowych ICR. Chociaż jest to rozwiązanie o bardziej skomplikowanej architekturze i wymagające

większej mocy przerobowej od zwykłego OCR, to dzięki zastosowaniu uczenia maszynowego jest ono w stanie odczytać odręczny tekst po uprzednim wytrenowaniu w tym celu sieci neuronowej. Efektywność modeli ICR potwierdzają badania na piśmie odręcznym. Ptucha i in. szacują skuteczność stosowania opracowanych przez nich konwolucyjnej sieci neuronowej w odczytywaniu pisma ręcznego (teksty składające się na treningowy zbiór danych pisane były po angielsku i francusku) na minimum 96% zgodności z oryginałem w odczytywaniu znaków i 91% w odczytywaniu całych słów (Ptucha i in. 2018, s. 609-612). Analogiczne badanie na zbiorze zawierającym wypełniane ręcznie formularze (zamiast ciągłego tekstu) oszacowało skuteczność sieci neuronowej na 90% zgodności odpowiedzi zwrotnej z oryginałem (Kathait i Tiwari 2018, s. 10-13). W swoim artykule przeglądowym Memon i in. potwierdzają, że większość prac opisujących badania nad zastosowaniem sieci neuronowych w przetwarzaniu pisma odręcznego stosuje sieci splotowe, przypisując ten stan rzeczy ich większej skuteczności w pracy z plikami graficznymi w porównaniu z eksperymentami na sieciach rekurencyjnych (Memon i in. 2020, s. 142660). Można również zaobserwować sukcesy w stosowaniu sieci neuronowych ICR na ręcznie pisanych materiałach archiwalnych w języku hebrajskim (Suissa i in. 2022, s. 15-19), co otwiera drogę do digitalizacji dokumentów historycznych stworzonych w innych alfabetach niż łaciński.

Z powyższego wynika zatem, że stosowanie OCR oraz bardziej zaawansowanego ICR może stanowić cenne narzędzie w rękach archiwistów w procesie tworzenia archiwów w przestrzeni cyfrowej. Udostępnianie w niej uprzednio przetworzonych na pliki tekstowe materiałów w znaczny sposób powinno ułatwić pracę nad nimi przy użyciu nowoczesnych narzędzi informatycznych oraz dostęp do nich dla naukowców z całego świata, potencjalnie poszerzając ich perspektywę badawcze.

KLASYFIKACJA TEKSTÓW ZA POMOCĄ MODELI UCZENIA MASZYNOWEGO

Innym problemem, z jakim mierzy się archiwistyka podczas udostępniania zbiorów w przestrzeni cyfrowej jest kwestia sprawnego katalogowania treści i tworzenia do nich nieskomplikowanego dostępu. Sama publikacja archiwaliów (w formie graficznej lub pliku tekstowego) opatrzonych co najwyżej sygnaturą materiału lub jednozdaniowym opisem całej jednostki archiwalnej nie wystarczy, by badacze mogli się sprawnie poruszać w cyfrowym archiwum, utrudniając znacznie ich pracę i zastosowanie nowoczesnych narzędzi

szukających oraz analizy danych. Diana Kim zwraca uwagę na niekonsekwencje w samym katalogowaniu cyfrowych dokumentów przez archiwa brytyjskie oraz nieprzejrzyste ich opisywanie, co według niej czyni internetową kwerendę niewiele tylko lepszą względem osobistej (Kim 2022, s. 531-534). Popularną w ostatnich latach na wielu stronach internetowych techniką klasyfikacji materiałów staje się *tagowanie*, to jest oznaczanie ich krótkimi etykietami na które składa się najwyżej kilka słów, a przeważnie jedno (*tagami*). Dzięki *tagom* wyszukiwanie materiałów w sieci staje się ułatwione, gdyż stanowią one interaktywną reprezentację potencjalnie interesujących dla badacza zagadnień. Takie rozwiązanie zatem zwiększa ergonomię poruszania się w cyfrowym archiwum poprzez dowolny wybór zakresu wyświetlanych materiałów na zasadzie wybierania zbiorów wyznaczanych przez *tagi*. Aby proces oznaczania materiałów archiwalnych w ten sposób przebiegł sprawnie, podobnie jak w przypadku przetwarzania ich na tekst, powinien on ulec automatyzacji. Rozwiązaniem może być tutaj zastosowanie przetwarzania języka naturalnego przez modele UM, dzięki swojej efektywności i łatwości dostosowania się do różnych zadań.

Praca Wanga i in., ilustrująca zastosowanie sieci neuronowych w klasyfikacji tekstu, prezentuje podejście hybrydowe: zastosowanie sieci spłotowej w połączeniu z siecią LSTM w celu wykorzystania korzystnych właściwości obydwu z nich. Po wykorzystaniu osadzania wektorowego, to jest konwersji każdego słowa w tekście na unikatowy względem innych wektor informacyjny, komponent spłotowy ma na celu wydobyć najczęściej powtarzające się zwroty poprzez porównywanie częstotliwości występowania poszczególnych wektorów. Następnie komponent LSTM analizuje dzięki swojej rekurencyjnej strukturze kontekst, to jest słowa występujące w pobliżu najczęściej odnotowywanych, i na tej podstawie hybryda sieci generuje za pomocą warstwy neuronowej budującej znormalizowaną funkcję wykładniczą prawdopodobieństwo przynależenia tekstu do poszczególnych kategorii do których przyporządkowania był uczony model, tym samym *tagując* teksty o rozkładzie zgodności z ich tematyką wynoszącym 93%-98% w zależności od testowanej bazy danych (Wang i in, 2019). Celem wyszkolenia modelu UM dostosowanego do poszczególnych archiwów należy stworzyć zatem jak najszerszy i najbardziej szczegółowy zestaw możliwych *tagów* opisujących materiały w nich zawarte. Ze względu na wyspecjalizowaną naturę algorytmów uczenia maszynowego ciężko stworzyć uniwersalny model, który w różnych rodzajach archiwów równie skutecznie etykietowałby dokumenty. W związku z tym w celu efektywnego automatycznego ich *tagowania* na podstawie treści trzeba uczyć

modele wyspecjalizowane w wykrywaniu materiałów o konkretnym zakresie (np. w przypadku archiwaliów historycznych nekrologi).

Nie jest to jednak regułą w przypadku nazw własnych, imion oraz dat. Dzięki temu, że stanowią one specyficzny rodzaj informacji, narzędzia do ich wykrywania nabierają pewnej wszechstronności, mogą pracować na wielu rodzajach zbiorów archiwalnych. W tym celu istnieją modele NER (ang. *Named Entity Recognition*, Rozpoznawanie nazw własnych). NER jako jeden z działów przetwarzania języka naturalnego ma za zadanie rozpoznać i wyróżnić wszystkie nazwy własne zawarte w tekście, w tym imiona (Ilustracja 2). Tym samym jest to wydobycie niezwykle cennej dla katalogowania zbiorów archiwalnych informacji bez potrzeby szukania jej bezpośrednio w tekście. Zastosowanie uczenia głębokiego w rozpoznawaniu nazw własnych opisują w swojej pracy przeglądowej Li i in., analizując dostępne metody oraz ich skuteczność. Autorzy podkreślają, że stosowanie rekurencyjnych sieci neuronowych LSTM do tak prostego zadania gwarantuje wykrywalność nazw własnych i ich rodzaju (np. imię, miejsce, instytucja) na poziomie 99% dzięki ich zdolności do analizy kontekstu oraz struktury językowej zdania (Li i in. 2022, s. 66). Jednocześnie przykładem zastosowania rozpoznawania dat wewnątrz tekstu w praktyce jest praca naukowców z Weill Cornell Medical College, którzy opisują wyodrębnianie dat wewnątrz dużego zbioru dokumentacji medycznej za pomocą prostych, dostępnych komercyjnie modeli UM. Mimo nieskomplikowanych narzędzi osiągnęli oni minimalną skuteczność 83% w wykrywaniu dat dziennych, a maksymalną rzędu 92%. Warto zauważyć, że to konkretne badanie przedstawia wysoką skuteczność rozwiązań nieopierających się na dedykowanych sieciach neuronowych, gdzie sami autorzy podkreślają, że zastosowanie tego rozwiązania może zwiększyć jeszcze bardziej efektywność (Fu i in. 2020). Reasumując, ekstrakcja tego typu danych opiera się na prostszej, bardziej uniwersalnej technologii, tym samym możliwej do zastosowania na szerszą skalę w wielu placówkach archiwalnych. Połączenie obydwu tych zadań w jednym modelu mogłoby zaowocować narzędziem pozwalającym na bardzo szczegółowe oznaczenie materiałów na bazie tych charakterystycznych treści, dając tym samym dobrą podstawę do odróżniania ich względem siebie obok *tagów* streszczających całości zawartości.

Ilustracja 2. Przedstawienie graficzne działania procesu NER. Poszczególnymi kolorami zaznaczone są różne rodzaje nazw własnych oraz data.



Źródło: opracowanie własne.

W związku z tym można śmiało rzec, że przy zastosowaniu UM stworzenie cyfrowego archiwum o zwiększonej względem „tradycyjnego” ergonomii znajdowania danych przez badacza jest łatwiejsze. Sprawne etykietowanie danych za pomocą *tagów* stanowi tego podstawę, opisując w sposób zwięzły treść dokumentu dla celów organizacyjnych. Ponadto uzupełnienie słów kluczowych o takie cechy jak występujące w tekście nazwy własne, imiona oraz daty pomoże w wydatny sposób rozróżnić pomiędzy sobą materiały o podobnej tematyce. Zdecydowaną zaletą tego rozwiązania jest automatyzacja wielu procesów wymagających zwiększonych nakładów sił, czasu i środków ze strony archiwistów celem ich ukończenia, pokroju katalogowania archiwaliów w sposób odnoszący się do ich treści i interaktywny.

POTENCJALNE PRZESZKODY, WYZWANIA I TRUDNOŚCI W ZASTOSOWANIU UM W ARCHIWISTYCE

W powyższej części pracy przedstawiono zalety wynikające z sięgnięcia po NLP i modele uczenia maszynowego w celu usprawnienia procesu tworzenia cyfrowego archiwum, digitalizacji tekstów oraz ich streszczania w celu stworzenia rzetelnych i jednocześnie wygodnych w obsłudze katalogów cyfrowych. Nie znaczy to jednak, że jest to rozwiązanie wszechstronne, a przy stosowaniu go w digitalizacji archiwów trzeba wziąć pod uwagę również poniższe informacje.

Chociaż modele UM mając swoje zastosowanie w technologiach takich jak OCR czy automatyczna klasyfikacja tekstu, nie są one stuprocentowo nieomyłne. Mimo wysokiej skuteczności, sięgającej w wielu przypadkach powyżej 90%, wciąż można mówić o pewnych brakach w kompletności i jakości odczytywania archiwaliów i ich analizy. Traub i in. przestrzegają przed nadmiernym poleganiem na tak przetworzonych materiałach przez badaczy, argumentując to w swoim badaniu brakiem oficjalnych metod krytyki takich opracowań, i tym samym nadmiernej ufności ze strony świata naukowego

(Traub i in. 2015, s. 258-262). Ze strony archiwistyki ważne jest zatem, by praca modeli OCR oraz NLP była nadal sprawdzana pod kątem błędów. Jednocześnie nie znaczy to, że archiwa nie powinny jeszcze stosować tych metod – natura uczenia maszynowego zakłada stałe ulepszanie zarówno technologii, jak i samych algorytmów, poprzez ciągły ich użytek oraz weryfikację generowanych przez nie informacji zwrotnych. Tym niemniej modele UM optycznego rozpoznawania znaków oraz przetwarzania języka naturalnego w chwili obecnej powinny być traktowane jako narzędzie pomocnicze dla archiwisty o dużej wszechstronności i potencjale rozwoju, ale nie wyręczające go całkowicie w swojej pracy.

Jednocześnie Charles Jeurgens podkreśla, że digitalizacja archiwów nie powinna owocować całkowitym przeniesieniem nacisku na ich odpowiedniki w przestrzeni cyfrowej. Ostatecznie zadania placówek archiwalnych nie ulegną zmianie, a przechowywanie i utrzymywanie przez nie zbiorów w formie materialnej nadal powinno być priorytetem dla archiwistów. Według Jeurgensa ich marginalizacja, która może wyniknąć z zaniknięcia ze zbiorowej świadomości badaczy tej roli może doprowadzić do stopniowej utraty przez nie środków, tym samym narażając na szwank ich możliwości utrzymywania swoich materialnych zbiorów (Jeurgens, 2013).

PODSUMOWANIE

Uczenie maszynowe i jego zdolności w odczytywaniu dokumentów i przetwarzaniu ich treści metodą NLP ma niewątpliwie duże zastosowanie praktyczne dla archiwistyki, potencjalnie mogąc w znaczny sposób usprawnić jej funkcjonowanie, a nawet zmienić jej naturę jako nauki. Możliwości, jakie otwiera ono w procesie opracowywania i digitalizacji archiwaliów, są niebagatelne. Przeniesienie do przestrzeni cyfrowej materiałów dotychczas trudno dostępnych dla światowej społeczności badaczy bez potrzeby wydatnego zwiększenia nakładu sił, środków oraz czasu na ręczne przeprowadzenie tego procesu samo w sobie stanowi ambitny cel. Uczynienie tego jednocześnie w formie interaktywnej, przejrzystej w obsłudze oraz kompatybilnej z wieloma narzędziami analizy tekstu jest kolejną korzyścią, której osiągnięcie może rozwinąć wiele gałęzi nauki skupionych wokół analizy danych. Trzeba jednak pamiętać, że przez obecne ograniczenia technologiczne nadal wymagany jest nadzór nad pracą modeli UM oraz stała weryfikacja ich odpowiedzi zwrotnych. Podsumowując, modele OCR oraz NLP stanowią przydatne,

aczkolwiek jeszcze nie wolne od błędów narzędzie znacznie ułatwiające archiwistom wykonywanie ich pracy oraz rozwój archiwistyki jako gałęzi nauki.

BIBLIOGRAFIA

- Albawi S., Mohammed T.A., Al-Zawi S.
2017 Understanding of a convolutional neural network [w:] 2017 International Conference on Engineering and Technology (ICET), Antalya.
- Berchmans D., Kumar S.S.
2014 Optical character recognition: An overview and an insight [w:] 14 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT), Kanyakumari.
- Blanke T., Bryant M., Hedges M.
2011 *Ocropodium: open source OCR for small-scale historical archives*, „Journal of Information Science”, 38(1).
- Blanke T., Bryant M., Hedges M.
2012 *Open source optical character recognition for historical research*, „Journal of Documentation”, vol. 68 no. 5.
- Cabral G.G., de Oliveira A.
2012 Intelligent Character Recognition [w:] Digital Document Analysis and Processing, Recife.
- Corrado E.M., Sandy H.M.
2017 Digital Preservation for Libraries, Archives, and Museums, Londyn.
- Dupond S.
2019 *A thorough review on the current advance of neural network structures*, „Annual Reviews in Control” 14.
- Drobac S., Kauppinen P., Linden K.
2019 Improving OCR of historical newspapers and journals published in Finland [w:] DATeCH2019: Proceedings of the 3rd International Conference on Digital Access to Textual Cultural Heritage, Nowy Jork.
- Fu J.T., Sholle E., Krichevsky S., Scandura J., Champion T.R.
2020 *Extracting and classifying diagnosis dates from clinical notes: A case study*, „Journal of Biomedical Informatics” 110(2020).

- Graves A., Liwicki M., Fernandez S., Bertolami R., Bunke H., Schmidhuber J.
2009 *A Novel Connectionist System for Unconstrained Handwriting Recognition*, „IEEE Transactions on Pattern Analysis and Machine Intelligence”, 31 (5).
- Hastie T., Tibshirani R., Friedman J.H.
2009 *The Elements of Statistical Learning: Data mining, Inference, and Prediction*, Stanford.
- He K., Zhang X., Ren S., Sun J.
2016 *Deep Residual Learning for Image Recognition*, [w:] 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas.
- Jeurgens C.
2013 *The Scent of the Digital Archive. Dilemmas with Archive Digitisation*, „BMGN - Low Countries Historical Review” vol. 128-4(2013).
- Jockers M.L.
2013 *Macroanalysis. Digital Methods and Literary History*, Chicago.
- Kathait S.S., Tiwari S.
2018 *Application of Image Processing and Convolution Networks in Intelligent Character Recognition for Digitized Forms Processing*, „International Journal of Computer Applications”, vol. 179, no. 20.
- Kim D.S.
2022 *Taming Abundance: Doing Digital Archival Research (as Political Scientists)*, „PS: Political Science & Politics”, 55(3).
- Li J., Sun A., Han J., Li C.
2022 *A Survey on Deep Learning for Named Entity Recognition*, „IEEE Transactions on Knowledge and Data Engineering”, vol. 34, iss. 1.
- Memon J., Sami M., Khan R.A., Uddin M.
2020 *Handwritten Optical Character Recognition: A Comprehensive Systematic Literature Review* „IEEE Access” vol. 8.
- Ptucha R., Such F.P., Pillai S., Brockler F., Singh V., Hutkowski P.
2019 *Intelligent character recognition using fully convolutional neural networks*, „Pattern Recognition” vol. 88.

- Raj A., Sharma S., Singh J., Singh A.
 2023 *Revolutionizing Data Entry: An In-Depth Study of Optical Character Recognition Technology and Its Future Potential*, „International Journal for Research in Applied Science & Engineering Technology” vol. 11, iss. II.
- Robótka H., Ryszewski B., Tomczak A.
 1989 Archiwistyka, Warszawa.
- Simeone O.
 2018 *A Very Brief Introduction to Machine Learning With Applications to Communication Systems*, „IEEE Transactions on Cognitive Communications and Networking”, 4/2018.
- Suissa O., Zhitomirsky-Geffet M., Elmalech A.
 2022 *Toward a Period-specific Optimized Neural Network for OCR Error Correction of Historical Hebrew Texts*, „Journal on Computing and Cultural Heritage” vol. 15, iss. 2.
- Traub M.C., van Ossenbruggen J., Hardman L.
 2015 Research and Advanced Technology for Digital Libraries [w:] 19th International Conference on Theory and Practice of Digital Libraries, TPDL 2015, Poznań, Poland, September 14-18, 2015, Proceedings, Poznań.
- Van Strien D., Beelen K., Ardanuy M.C., Hosseini K., McGillivray B., Colavizza G.
 2020 Assessing the Impact of OCR Quality on Downstream NLP Tasks [w:] Proceedings of the 12th International Conference on Agents and Artificial Intelligence - Volume 1: ARTIDIGH, Valetta.
- Wang R., Li Z., Cao J., Chen T., Wan L.
 2019 Convolutional Recurrent Neural Networks for Text Classification, [w:] 2019 International Joint Conference on Neural Networks (IJCNN), Budapeszt.

EVALUATION OF THE POSSIBILITIES OF APPLYING OCR AND NLP MACHINE LEARNING MODELS IN THE DIGITIZATION OF ARCHIVE MATERIALS

Summary: One of the main challenges facing contemporary archival science is the digitization of text collections and making them available in an efficient manner in the digital space. Although this is a process implemented by most archives around the world, it is often limited to placing a graphic file with a scanned text with a signature and a casual description on the digital archives website. In order to improve and achieve higher quality of both the digitization of materials and the organization of digital archives, this work proposes the use of machine learning models focused on optical character recognition and natural language processing. The use of both of these technologies can significantly contribute to meeting the goals set here, supporting the work of archivists while saving time and resources.

Keywords: machine learning, optical character recognition, natural language processing, archival studies, digitization

ZASTOSOWANIE TRANSFER LEARNING W ANALIZIE OBRAZÓW PATOMORFOLOGICZNYCH ZA POMOCĄ KONWOLUCYJNYCH SIECI NEURONOWYCH

Streszczenie: Praca przeglądowa koncentruje się na potencjale technik uczenia transferowego w analizie obrazów patomorfologicznych za pomocą konwolucyjnych sieci neuronowych (CNN). Stosowanie uczenia transferowego może zwiększyć wydajność CNN, prowadząc do dokładniejszych i bardziej wiarygodnych diagnoz. Umożliwia ono badaczom wykorzystanie funkcji wyuczonych z dużych zbiorów danych, zmniejsza potrzebę stosowania obszernych adnotacji i pomaga ograniczyć ryzyko nadmiernego dopasowania modelu. Te zalety sprawiają, że uczenie transferowe jest wartościowym narzędziem, którego zastosowanie potencjalnie może rozwinąć dziedzinę patomorfologii.

Słowa kluczowe: uczenie transferowe, sztuczna inteligencja, medycyna, patomorfologia, konwolucyjne sieci neuronowe

1. WPROWADZENIE

Analiza obrazów patomorfologicznych odgrywa kluczową rolę w diagnostyce medycznej, ponieważ dostarcza cennych informacji umożliwiających identyfikację różnych chorób i schorzeń. Wraz z rozwojem technologii konwolucyjne sieci neuronowe (CNN) stały się potężnym narzędziem do

analizy obrazów medycznych Jest to rodzaj algorytmu głębokiego uczenia się, który może automatycznie uczyć się i wydobywać cechy z obrazów, umożliwiając dokładną klasyfikację, segmentację i zadania wykrywania (Litjens i in., 2017, s. 62).

Jednak jednym z największych wyzwań w analizie obrazów patologicznych jest ograniczona dostępność danych treningowych z adnotacjami. Są one niezbędne do szkolenia CNN, ale oznaczanie obrazów medycznych może być czasochłonne i wymaga wiedzy eksperckiej (Litjens i in., 2016, s. 73). Transfer wiedzy, nazywany również uczeniem transferowym (transfer learning) to technika, która wykorzystuje wstępnie wytrenowane modele na dużych zbiorach danych i dostosowuje je do nowych zadań z ograniczoną ilością danych. Pozwala to na osiągnięcie dużo lepszych wyników, przyspieszenie czasu trenowania modeli i w konsekwencji oszczędzenia zasobów obliczeniowych. Przenosząc wiedzę z wcześniej wytrenowanych modeli, uczenie się poprzez transfer może poprawić wydajność sieci CNN w zadaniach związanych z analizą obrazu patologicznego, nawet przy ograniczonych danych szkoleniowych (Nagaraju i Rao, 2022, s. 1465).

Celem niniejszej pracy jest przegląd istniejącej literatury na temat zastosowania uczenia transferowego w analizie obrazów patologicznych z wykorzystaniem CNN. Postawiono hipotezę główną: zastosowanie technik uczenia transferowego w analizie obrazów patomorfologicznych może zwiększyć wydajność CNN prowadząc do dokładniejszych i bardziej wiarygodnych diagnoz. W artykule omówione zostaną korzyści i wyzwania związane z wykorzystaniem uczenia się transferowego w analizie obrazów patomorfologicznych oraz możliwe przyszłe kierunki badań w tym obszarze.

2. PODSTAWY UCZENIA SIĘ TRANSFEROWEGO I DZIAŁANIA KONWOLUCYJNYCH SIECI NEURONOWYCH

Uczenie transferowe to technika uczenia maszynowego, która pozwala zastosować wiedzę zdobytą w ramach jednego zadania w innym, pokrewnym zadaniu (Litjens i in., 2017, s. 78). W kontekście sieci neuronowych uczenie się transferowe polega na wykorzystaniu wstępnie wyszkolonych modeli na dużych zbiorach danych jako punktu wyjścia do szkolenia w zakresie nowego zadania z ograniczonymi danymi (Yang i in., 2023, s. 1). Wykorzystując wyuczone funkcje wstępnie wytrenowanego modelu, uczenie transferowe

może poprawić wydajność sieci neuronowych w przypadku nowych zadań, nawet przy ograniczonych danych szkoleniowych (Yang i in., 2023, s. 2).

Konwolucyjna sieć neuronowa (Convolutional Neural Network, CNN) to rodzaj algorytmu głębokiego uczenia się, który zrewolucjonizował dziedzinę analizy obrazu. Szczególnie dobrze nadają się do analizy obrazów medycznych ze względu na zdolność automatycznego uczenia się i wydobywania cech z obrazów. Sieci CNN składają się z wielu warstw, w tym warstw spłotowych, warstw łączących i warstw w pełni połączonych, co umożliwia im uchwycenie hierarchii przestrzennych i wzorców na obrazach (Litjens i in., 2017, s. 85). Architektura sieci CNN może się różnić, a w analizie obrazów medycznych wykorzystywane są różne modele, takie jak V-Net, MobileNetV2 i inne (Yang i in., 2023, s. 3; Wang i in., 2022, s. 2).

Analizując obrazy patomorfologiczne, CNN wykazały ogromny potencjał w zadaniach takich jak klasyfikacja obrazu, wykrywanie obiektów, segmentacja i nie tylko (Litjens i in., 2017, s. 78). Sieci CNN mogą zapewnić dokładne rozwiązania obliczeniowe prostych problemów, takich jak wykrywanie jądra komórkowego, a także problemów wysoce skomplikowanych, takich jak ocena stopnia zaawansowania i klasyfikacja nowotworów (Nair i in., 2022, s. 1). Jednak szkolenie CNN od podstaw na zbiorach danych obrazów medycznych z ograniczoną liczbą adnotacji może być trudne i czasochłonne. W tym miejscu w grę wchodzi uczenie się transferowe, ponieważ pozwala ono przenieść wiedzę zdobytą z wcześniej wytrenowanych modeli na dużych zbiorach danych i dostosować ją do nowych zadań przy ograniczonej ilości danych (Yang i in., 2023, s. 3).

Stosując uczenie się transferowe w analizie obrazów patologicznych za pomocą CNN, badacze mogą korzystać z wyuczonych cech i reprezentacji z wcześniej wyszkolonych modeli, poprawiając dokładność i skuteczność diagnozy. Wykazano, że uczenie się transferowe zwiększa zdolność CNN do generalizacji, zwłaszcza w przypadku zbiorów danych na małą skalę (Yang i in., 2023, s. 3). Może również zwiększyć wyjaśnialność narzędzi diagnostyki komputerowej (CAD) w analizie obrazu histopatologicznego (Nair i in., 2022, s. 10). Co więcej, uczenie się transferowe może pomóc w rozwiązaniu problemu braku dużych zbiorów danych szkoleniowych w analizie obrazów medycznych, co ma kluczowe znaczenie dla powodzenia podejść opartych na CNN (Khan i in., 2021, s. 1987).

3. ZASTOSOWANIE UCZENIA SIĘ TRANSFEROWEGO W PATOMORFOLOGII

Uczenie transferowe znalazło szerokie zastosowanie w analizie obrazów medycznych, w tym w analizie obrazów patomorfologicznych. Zostało wykorzystane do klasyfikacji różnych typów nowotworów, takich jak rak piersi, rak skóry i rak płuc. Korzystając z wstępnie wytrenowanych modeli, sieci CNN mogą nauczyć się wyodrębnić istotne cechy z obrazów patologicznych i osiągać wysoką dokładność w zadaniach związanych z klasyfikacją nowotworów.

Przykładem skutecznego zastosowania uczenia transferowego w CNN jest badanie polegające na analizie obrazów krwinek. Wykorzystano modele CNN z wstępnie wytrenowanymi wagami z ImageNet. Uzyskano wyjątkową dokładność 90,79% proponowanego modelu. Przewyższyło to inne architektury CNN, takie jak ResNet i Inception V3. Udało się również poprawić zdolność uogólniania modeli dzięki technikom powiększania zbioru danych. (Yang i in., 2023, s. 4). Skuteczność uczenia transferowego w analizie obrazów patologicznych wykracza poza analizę komórek krwi. Zaproponowano również metodę klasyfikacji raka jelita grubego z wykorzystaniem wzmocnienia danych w oparciu o uczenie transferowe. Podejście to uwzględniło wysoce niezrównoważoną konfigurację zbioru danych i pozwoliło osiągnąć znaczną poprawę dokładności, wyniku F1 i pola pod krzywą (AUC) (Nergiz, 2022, s. 2080).

Innym przykładem jest zastosowanie uczenia transferowego w automatycznym wykrywaniu przerzutowego raka piersi na obrazach całych ślajdów biopsji węzła chłonnego wartowniczego. (Wang i in., 2016, s. 3) Osiągnięto wysoką wydajność zarówno w klasyfikacji całych obrazów ślajdów, jak i w zadaniach lokalizacji guza przy użyciu technik głębokiego uczenia się. Uczenia transferowe okazało się skuteczne również w klasyfikacji nowotworów skóry i piersi z wykorzystaniem modeli głębokiej splotowej sieci neuronowej (DCNN) (Alzubaidi i in., 2021, s. 5). Zaproponowane podejście znacząco poprawiło skuteczność obu scenariuszy klasyfikacji. Uczenie transferowe wykorzystano także w klasyfikacji zmian ultrasonograficznych piersi (Zhuang i in., 2020, s. 6257-6269). W tym badaniu zastosowano dekompozycję obrazu i uczenie transferowe, aby zwiększyć dokładność klasyfikacji zmian w piersiach.

Uczenie się transferowe z powodzeniem zastosowano w różnych badaniach w celu ulepszenia analizy obrazów patologicznych za pomocą konwoacyjnych sieci neuronowych (CNN). Na przykład Esteva i in. wykorzystali

uczenie się transferowe do wyszkolenia modelu CNN na dużym zestawie danych obejmującym ogólne obrazy, a następnie udoskonalił go na mniejszym zbiorze danych obejmującym obrazy raka skóry. Wstępnie wytrenowany model nauczył się ogólnych cech z dużego zbioru danych i dostosował je do konkretnego zadania, jakim jest klasyfikacja nowotworów skóry, co poprawiło dokładność.

4. KORZYŚCI ZE STOSOWANIA WSTĘPNIE WYTRENOWANYCH MODELI W PRZYPADKU OGRANICZONYCH DANYCH MEDYCZNYCH

Stosowanie wstępnie wytrenowanych modeli w procesie uczenia się transferowego jest szczególnie korzystne, gdy dostępne dane medyczne są ograniczone. Modele te nauczyły się już ogólnych funkcji z dużych zbiorów danych, które można przenieść do podobnych zadań. Wykorzystując te wstępnie wytrenowane modele jako punkt wyjścia, CNN mogą wykorzystać wyuczone funkcje i dostosować je do specyficznych cech innych obrazów. Pozwala to naukowcom wykorzystać wiedzę zdobytą i dostosować ją do konkretnej nowej dziedziny, takiej jak analiza obrazów patomorfologicznych. Uczenie się transferowe pozwala przenieść wiedzę zdobytą z wielkoskalowych zbiorów danych, takich jak ImageNet, do zadań związanych z analizą obrazów medycznych (Nagaraju i Rao, 2022, s. 1471). Wykorzystując wstępnie wytrenowane modele, można dostroić początkowe parametry głębokich warstw, co pomaga uniknąć konieczności szkolenia CNN od podstaw (Albahli i Albattah, 2021, s. 973-980).

W dziedzinie analizy obrazu medycznego oznakowane dane są często rzadkie, a ich uzyskanie jest kosztowne. Jest to szczególnie korzystne w dziedzinie medycyny, gdzie może występować ograniczona dostępność ekspertów, presja kosztowa i wątpliwości etyczne. Użycie wstępnie wyszkolonych modeli może znacznie zmniejszyć potrzebę stosowania dużego zbioru danych z adnotacjami. Szkolenie CNN od podstaw na zbiorach danych obrazów medycznych z ograniczoną liczbą adnotacji może być trudne i czasochłonne. Jednak zaczynając od wstępnie wyszkolonego modelu, badacze mogą go dostroić na ograniczonym zbiorze danych, który wymaga mniejszej liczby adnotacji. Takie podejście nie tylko oszczędza czas i zasoby, ale także poprawia zdolność generalizacji modelu. Znacząco zmniejsza to potrzebę posiadania dużego, oznakowanego zbioru danych do celów szkoleniowych, co często jest trudne do uzyskania w dziedzinie medycyny (Nagaraju i Rao, 2022, s. 1472).

Problem nadmiernego dopasowania pojawia się, gdy model uczy się zapamiętywać dane uczące, zamiast generalizować. Wstępnie wyszkolone modele mogą pomóc przezwyciężyć problem przeuczenia modelu, gdy dostępne dane są ograniczone. Rozpoczynając od modelu, który nauczył się już na podstawie dużego zbioru danych, ryzyko nadmiernego dopasowania do ograniczonych danych jest zmniejszone. Wstępnie wyszkolony model zapewnia dobry punkt inicjalizacji, umożliwiając skuteczniejsze uczenie się na podstawie ograniczonych danych. Przyczyną jest fakt, że wcześniej wytrenowany model nauczyły się już wyodrębnić odpowiednie cechy z dużego i zróżnicowanego zbioru danych, co poprawia jego zdolność do uogólniania na nowe obrazy patologiczne przy ograniczonych danych (Nagaraju i Rao, 2022, s. 1472).

Zastosowanie wstępnie wyszkolonych modeli może również prowadzić do znacznej poprawy dokładności diagnoz patologicznych. Na przykład połączenie przewidywań systemu głębokiego uczenia się z diagnozami patologów zaowocowało zmniejszeniem poziomu błędów ludzkich w diagnozach patologicznych (Wang, 2016, s. 5). Wykorzystanie wstępnie wytrenowanych modeli umożliwia transfer wiedzy z powiązanych zadań i zbiorów danych, poprawiając wydajność sieci CNN w analizie obrazów medycznych przy ograniczonych danych.

7. MOŻLIWE PRZYCZYNY POPRAWY LUB POGORSZENIA WYDAJNOŚCI MODELU PO ZASTOSOWANIU TRANSFERU WIEDZY

Po zastosowaniu transferu wiedzy w analizie obrazów patologicznych istotna jest ocena przyczyn poprawy lub pogorszenia wydajności modelu. Zrozumienie czynników, które przyczyniają się do zmian w wynikach, może zapewnić wgląd w skuteczność transferu wiedzy i wskazać dalsze kierunki badań. Warianty transferu wiedzy mogą obejmować różne wstępnie wyszkolone modele, różne warstwy dostrajania i różne ilości przekazywanej wiedzy (Zhuang 2021, s. 55).

Wybór wstępnie wyszkolonych modeli może mieć znaczący wpływ na wydajność modeli uczenia transferowego. Różne wstępnie wyszkolone modele mogą mieć różne architektury, wyuczone funkcje i poziomy uogólnienia. Ważne jest, aby ocenić skuteczność modeli uczenia się transferu przy użyciu różnych wstępnie wyszkolonych modeli, aby określić, który model najlepiej sprawdza się w konkretnym zadaniu, jakim jest analiza obrazów patologicznych. (Pan i Yang, 2010, s. 1349).

Jedną z możliwych przyczyn poprawy wydajności modelu po zastosowaniu transferu wiedzy jest transfer wyuczonych funkcji. Wstępnie wyszkolone modele nauczyły się już cech ogólnych z wielkoskalowych zbiorów danych, które mogą być istotne przy analizie obrazów patologicznych. Przenosząc te wyuczone funkcje, modele mogą korzystać z wiedzy zdobytej w ramach powiązanych zadań i zbiorów danych, co prowadzi do poprawy wydajności. Wstępnie wyszkolone modele przeszły już szkolenie na dużych zbiorach danych, co pomaga zapobiegać nadmiernemu dopasowaniu i poprawiać generalizację. Stosując wstępnie wyszkolone modele na docelowym zbiorze danych obrazu patologicznego, modele mogą dostosować się do specyficznych cech danych, jednocześnie korzystając z efektu regularyzacji przekazanej wiedzy (Tajbakhsh i in., 2016, s. 1299-1312).

Z drugiej strony spadek wydajności modelu po zastosowaniu transferu wiedzy można przypisać odmienności między domeną źródłową i docelową. Różnice w charakterystyce obrazu, takie jak rozdzielczość, szum i sposoby obrazowania, mogą wpływać na możliwość przenoszenia wiedzy. Ważne jest, aby ocenić skuteczność modeli uczenia się transferu i przeanalizować przyczyny spadku wydajności, aby zidentyfikować potencjalne ograniczenia i wyzwania w stosowaniu transferu wiedzy (Majeed, 2020, s. 1299). Co więcej, warstwy wybrane do dostrojenia mogą również wpływać na wydajność modeli uczenia się transferu. Dostrajanie można przeprowadzić na różnych warstwach wstępnie wyszkolonych modeli, od warstw płytkich po warstwy głębokie. Wybór warstw do dostrojenia powinien uwzględniać złożoność zadania i dostępność oznaczonych danych. Konieczna jest ocena wydajności modeli uczenia się transferu z różnymi warstwami w celu dostrojenia w celu zidentyfikowania optymalnej konfiguracji (Tajbakhsh i in., 2016, s. 1299-1312).

8. WNIOSKI

Na podstawie wyników potwierdzono stawianą hipotezę: zastosowanie technik uczenia transferowego w analizie obrazów patomorfologicznych może zwiększyć wydajność CNN prowadząc do dokładniejszych i bardziej wiarygodnych diagnoz. Umożliwia badaczom wykorzystanie funkcji wyuczonych z dużych zbiorów danych, zmniejsza potrzebę stosowania obszernych adnotacji i pomaga ograniczyć ryzyko nadmiernego dopasowania. Te zalety sprawiają, że uczenie się transferowe jest wartościowym podejściem w dziedzinie patomorfologii.

Uczenie się transferowe umożliwia zastosowanie wiedzy zdobytej na podstawie wstępnie wyszkolonych modeli do nowych zadań z ograniczoną ilością danych, poprawiając wydajność sieci CNN w analizie obrazów medycznych. Sieci CNN, posiadające zdolność do automatycznego uczenia się i wydobywania cech z obrazów, wykazały ogromny potencjał w różnych dziedzinach medycyny. Łącząc uczenie się transferowe i CNN, badacze mogą zwiększyć dokładność, wydajność i zdolność uogólniania analizy obrazu patomorfologicznego.

Wykorzystanie wstępnie wytrenowanych modeli w procesie uczenia się transferowego jest korzystne, gdy dane medyczne są ograniczone. Pozwala na wykorzystanie wyuczonych funkcji z wielkoskalowych zbiorów danych, zmniejsza ryzyko nadmiernego dopasowania i umożliwia transfer wiedzy z powiązanych zadań. Korzyści te przyczyniają się do poprawy wydajności i efektywności CNN w analizie obrazów patologicznych.

Ze względu na medycynę personalizowaną patomorfologdy stają w obliczu rosnącego obciążenia pracą i złożoności histopatologicznej diagnostyki nowotworów. Dlatego protokoły diagnostyczne muszą stawiać na pierwszym miejscu zarówno wydajność, jak i dokładność. Zastosowanie konwolucyjnych sieci neuronowych i uczenia transferowego jest jedną z technik pozwalających na zwiększenie obiektywności i skuteczności analizy preparatów histopatologicznych.

PODSUMOWANIE

Podsumowując, zastosowanie uczenia transferowego w analizie obrazów patologicznych przy użyciu CNN dało obiecujące wyniki w różnych zadaniach związanych z analizą obrazów medycznych. Umożliwia wykorzystanie wytrenowanych modeli, usprawnia generalizację i transferuje wiedzę z powiązanych zadań i zbiorów danych. Uczenie transferowe okazało się skuteczne w analizie komórek krwi, wykrywaniu raka prostaty i klasyfikacji raka jelita grubego. Znaczenie uczenia się transferowego w opracowywaniu skutecznych narzędzi do analizy obrazów patomorfologicznych jest oczywiste w jego zdolności do przezwycięzania ograniczeń danych i zwiększania wydajności modeli CNN.

BIBLIOGRAFIA

- Albahli, S. and Albattah, W.
2021 Deep transfer learning for covid-19 prediction: case study for limited data problems. *Current Medical Imaging Formerly Current Medical Imaging Reviews*, 17(8).
- Alzubaidi, L., Al-Amidie, M., Al-Asadi, A., Humaidi, A., Al-Shamma, O., Fadhel, M., Duan, Y.
2021 Novel transfer learning approach for medical imaging with limited labeled data. *Cancers*, 13(7).
- Zhuang F.
2021 "A Comprehensive Survey on Transfer Learning," in *Proceedings of the IEEE*, vol. 109, no. 1.
- Khan, S., Gulzar, Y., Turaev, S., Peng, Y.
2021 A modified hsift descriptor for medical image classification of anatomy objects. *Symmetry*, 13(11).
- Litjens, G., Kooi, T., Bejnordi, B., Setio, A., Ciompi, F., Ghafoorian, M., Sánchez, C.
2017 A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42.
- Majeed, T., Rashid, R., Ali, D., Asaad, A.
2020 Issues associated with deploying cnn transfer learning to detect covid-19 from chest x-rays. *Physical and Engineering Sciences in Medicine*, 43(4).
- Nagaraju, M. and Rao, B.
2022 An outlook of medical image analysis via transfer learning approaches. *Traitement Du Signal*, 39(5).
- Nair, A., Arvidsson, H., V., J., Tudzarovski, N., Meinke, K., Sugars, R.
2022 A graph neural network framework for mapping histological topology in oral mucosal tissue. *BMC Bioinformatics*, 23(1).
- Nergiz, M.
2022 Collaborative colorectal cancer classification on highly class imbalanced data setting via federated neural style transfer based data augmentation. *Traitement Du Signal*, 39(6).

- Pan, S. and Yang, Q.
2010 A survey on transfer learning. *Ieee Transactions on Knowledge and Data Engineering*, 22(10).
- Tajbakhsh, N., Shin, J., Gurudu, S., Hurst, R., Kendall, C., Gotway, M., Liang, J.
2016 Convolutional neural networks for medical image analysis: full training or fine tuning?. *Ieee Transactions on Medical Imaging*, 35(5).
- Wang, D.
2016 Deep learning for identifying metastatic breast cancer, *Computer Vision and Pattern Recognition*, 1606.05718.
- Yang S., You F., Sun D.
2023 Multi-classification recognition of blood cell images based on transfer learning, *Proc. SPIE 12610, Third International Conference on Artificial Intelligence and Computer Engineering (ICAICE 2022)*.
- Zhuang, Z., Kang, Y., Raj, A., Yuan, Y., Ding, W., Qiu, S.
2020 Breast ultrasound lesion classification based on image decomposition and transfer learning. *Medical Physics*, 47(12).

THE APPLICATION OF TRANSFER LEARNING IN THE ANALYSIS OF PATHOMORPHOLOGICAL IMAGES USING CONVOLUTIONAL NEURAL NETWORKS

Abstract: The review paper focuses on the potential of transfer learning techniques in the analysis of pathological images using convolutional neural networks. It enables researchers to leverage features learned from large datasets, reduces the need for extensive annotations, and helps reduce the risk of overfitting. By leveraging the knowledge gained from big data, transfer learning can increase CNN's efficiency in analysing pathological images, leading to more accurate and reliable diagnoses. These advantages make transfer learning a valuable approach in the field of pathology.

Key words: transfer learning, artificial intelligence, medicine,

WYZWANIA I OGRANICZENIA TECHNIK PRZETWARZANIA JĘZYKA NATURALNEGO W ANALIZIE DANYCH MEDYCZNYCH

Streszczenie: Praca przeglądowa ma na celu ocenę wyzwań i ograniczeń na drodze do przetwarzania języka naturalnego (NLP) w analizie dokumentacji medycznej. Dokumentacja kliniczna może być ważnym źródłem informacji zarówno dla praktyki klinicznej, badań naukowych, jak i dla zarządzania personelem i placówkami medycznymi. Zastosowanie metod głębokiego uczenia się (deep learning), integracja zaawansowanych technik i włączenie wielu źródeł danych może prowadzić do dokładniejszych prognoz i spersonalizowanej opieki zdrowotnej. Jednak nadal istnieją wyzwania do pokonania, takie jak zapotrzebowanie na duże i różnorodne zbiory danych, rozwiązanie problemów związanych z prywatnością i zapewnienie możliwości interpretacji modeli głębokiego uczenia się. Celem pracy jest ocena wyzwań dla technik NLP w tej dziedzinie oraz określenie kierunku przyszłych badań.

Słowa kluczowe: przetwarzanie języka naturalnego, sztuczna inteligencja, medycyna, dokumentacja medyczna

1. WPROWADZENIE

Dokumentacja medyczna jest zbiorem informacji dotyczących stanu zdrowia pacjenta oraz historii chorób. Składa się z notatek lekarzy, wyników badań, opisów procedur i terapii. Jest kluczowym źródłem danych medycznych, które umożliwiają ocenę pacjenta oraz podejmowanie decyzji klinicznych. Odgrywa kluczową rolę w podejmowaniu decyzji dotyczących

opieki zdrowotnej. Jednak ogromna ilość nieustrukturyzowanego tekstu w tych zapisach stanowi poważne wyzwanie dla analizy.

Przetwarzanie języka naturalnego (NLP) stało się potężnym narzędziem do automatyzacji analizy tekstu, umożliwiając efektywne wydobywanie z niego cennych informacji. NLP oferuje liczne korzyści - zwiększoną wydajność, ulepszoną ekstrakcję danych. Zastosowanie metod głębokiego uczenia się (deep learning), integracja zaawansowanych technik i włączenie wielu źródeł danych może prowadzić do dokładniejszych prognoz i spersonalizowanej opieki zdrowotnej. Jednak nadal istnieją wyzwania do pokonania na drodze do wdrożenia modeli NLP do praktyki klinicznej.

Celem rozdziału jest ocena wyzwań dla technik NLP w tej dziedzinie oraz określenie kierunku przyszłych badań. W niniejszej pracy postawiono następującą hipotezę: odpowiedź na wyzwania na drodze do wdrożenia przetwarzania języka naturalnego to zapotrzebowanie na duże i różnorodne zbiory danych, rozwiązanie problemów związanych z prywatnością i zapewnienie możliwości interpretacji modeli głębokiego uczenia się. Celem pracy jest przedstawienie barier na drodze do wdrożenia modeli przetwarzania języka naturalnego oraz perspektyw na rozwiązanie tych problemów w praktyce.

2. ZNACZENIE ANALIZY NLP DOKUMENTACJI MEDYCZNEJ

Na dokumentację medyczną składają się systematycznie rejestrowane dane osobowe pacjenta, jego historia medyczna, wyniki badań laboratoryjnych i obrazowych, postawiona diagnoza, zastosowane leczenie, karty wypisów ze szpitala, notatki o postępach w leczeniu oraz informacje uzupełniające. Służą jako istotny element dobrej opieki klinicznej i odgrywa kluczową rolę w komunikacji w systemie opieki zdrowotnej (Kasaye i in., 2022, s. 7). Dokładna i kompletna dokumentacja medyczna pozwala na zmniejszenie liczby błędów medycznych i zapewnienie wysokiej jakości opieki (Sinha i Shenoy, 2013, s. 324). Dokumentacja medyczna jest również ważnym dowodem medyczno-prawnym i przyczynia się do poprawy jakości usług świadczonych w placówkach opieki zdrowia (Hussein i in., 2018, s. 52). Dokumentacja medyczna obejmuje różnorodne rodzaje danych, takie jak dane kliniczne, wyniki badań laboratoryjnych, obrazowanie medyczne oraz dokumenty administracyjne. Każdy rodzaj danych ma swoje unikalne cechy i wyzwania związane z analizą.

Osobną kategorią jest dokumentacja przestrzegania zaleceń lekarskich. Rejestrowane są w niej aspekty dotyczące współpracy pacjenta i przyjmowania przez niego przepisanych leków. Ten rodzaj dokumentacji ma szczególne znaczenie w przypadku chorób przewlekłych, takich jak cukrzyca lub astma oskrzelowa. Przestrzeganie schematów leczenia ma kluczowe znaczenie w przypadku tych chorób (Alqarni i in., 2019, s. 2). Przestrzeganie zaleceń lekarskich można dokumentować za pomocą narzędzi, takich jak General Medication Adherence Scale (GMAS) (Alqarni i in., 2019, s. 5). GMAS ma na celu wszechstronną i systematyczną ocenę przestrzegania zaleceń lekarskich. Bierze pod uwagę takie czynniki, jak rozpoczęcie (czy pacjent zaczyna przyjmować lek zgodnie z zaleceniami), wdrażanie (jak dobrze pacjent przestrzega przepisanego schematu) i przerwanie (czy pacjent przedwcześnie przestaje przyjmować lek). Korzystając z GMAS, pracownicy służby zdrowia mogą uzyskać wystandaryzowaną miarę przestrzegania zaleceń lekarskich, co pozwala na lepszą ocenę i zrozumienie zachowań pacjentów (Vrijens i in., 2012, s. 701). Możliwa jest identyfikacja czynników, które mogą wpływać negatywnie i pozytywnie na przestrzeganie zaleceń lekarskich. Informacje te można następnie wykorzystać do poprawy poradnictwa dla pacjentów i zwiększenia świadomości znaczenia przyjmowania przepisanych leków (Alqarni i in., 2019, s. 7).

Wykorzystanie technik NLP pozwala na efektywne przetwarzanie i wyodrębnianie informacji z tych danych, wspierając diagnozę, leczenie i badania. Analiza danych medycznych umożliwia lepsze zrozumienie trendów zdrowotnych, identyfikację wzorców chorób i ocenę skuteczności terapii. Dane te stanowią cenny materiał badawczy, pozwalający na rozwinięcie wiedzy medycznej i weryfikację hipotez naukowych. Przetwarzania języka naturalnego w analizie danych medycznych stanowi kluczową przewagę w dziedzinie opieki zdrowotnej. Otwiera nowe perspektywy w diagnostyce, badaniach naukowych i zarządzaniu placówkami medycznymi. Wdrażanie technik NLP może poprawić jakość opieki nad pacjentem, zwiększyć efektywność badań medycznych oraz wspierać procesy decyzyjne w środowisku medycznym (Spyns, 1996, s. 285-301).

3. ELEKTRONICZNA DOKUMENTACJA MEDYCZNA

Dokumentacja medyczna może mieć formę elektronicznej dokumentacji medycznej (EMR) i dokumentacji papierowej. Zwykle przechowywana w systemach elektronicznej dokumentacji medycznej (EMR - electronic medical

record), które mogą obejmować ustrukturyzowane dane oraz nieustrukturyzowane notatki kliniczne. Choć wiele szpitali poczyniło postępy w digitalizacji dokumentacji, nadal równolegle istnieją formaty papierowe i elektroniczne (Park i in., 2019, s. 9). Elektroniczna dokumentacja medyczna (EHR) stanowi obiecujące narzędzie w poprawie dokładności i kompletności dokumentacji. Przechowywanie danych w formie cyfrowej ułatwia analizę, zarządzanie i dostępność informacji.

Dane medyczne są cennym źródłem informacji o stanie zdrowia pacjentów, diagnozach, terapiach oraz efektywności leczenia. Analiza tych danych umożliwi lekarzom, naukowcom i decydom medycznym lepsze zrozumienie trendów zdrowotnych, identyfikację wzorców chorób i ocenę skuteczności interwencji terapeutycznych. Dodatkowo stanowią niezastąpiony materiał badawczy, który umożliwia prowadzenie badań naukowych w dziedzinie medycyny. Analiza tych danych pozwala na weryfikację hipotez, odkrycie nowych związków klinicznych i rozwinięcie wiedzy medycznej. Wykorzystanie rozwiązań w zakresie elektronicznej dokumentacji medycznej i dokładnych praktyk kodowania może przyczynić się do utrzymania wysokiej jakości dokumentacji (Melonas i McNary, 2010, s. 47; Muir i in., 2013, s. 3).

Postępująca informatyzacja opieki zdrowotnej, powoduje, wzrost wiarygodność dokumentacji. Możliwe jest odczytanie historii zmian w treści dokumentacji za pomocą logów systemowych. Ogranicza to możliwość manipulowania dokumentacją medyczną. Odpowiedzialność prawna osób wykonujących zawody medyczne i podmiotów leczniczych, wpływa na polepszenie standardów prowadzenia dokumentacji medycznej. Osoby uprawnione do wprowadzania treści do dokumentacji medycznej robią to coraz obszerniej i coraz bardziej opisowo (Tymiński, 2018, s. 137). Rozwiązania w zakresie elektronicznej dokumentacji medycznej (EHR) są postrzegane jako obiecujące narzędzie mogące pomóc w poprawie dokładności i kompletności dokumentacji medycznej (Melonas i McNary, 2010, s. 51).

4. JAKOŚĆ I SKALA DANYCH

Pomimo wielu zalet NLP w analizie dokumentacji medycznej ma pewne ograniczenia. Jednym z ograniczeń jest potrzeba wysokiej jakości danych z adnotacjami do celów szkoleniowych i ewaluacyjnych. Rozwój i ocena systemów NLP często opierają się na ręcznie przypisywanych zestawach danych, co może być czasochłonne i wymagać dużych zasobów (Uzuner i in., 2008, s. 552). Ponadto wydajność systemów NLP w dużym stopniu zależy

od jakości i spójności podstawowych danych, w tym dokładności i kompletności dokumentacji klinicznej (Deléger i in., 2013, s. 9). Dokumentacja medyczna może zawierać błędy, niejednoznaczności i niepoprawnie sformułowane zdania. Niektóre informacje w dokumentacji medycznej mogą być pominięte lub niepełne. Może to prowadzić do niedokładnych lub błędnych analiz, szczególnie jeśli zadaniem technik NLP jest poprawne zrozumienie tekstu. Brak jednolitej standaryzacji formatu dokumentacji medycznej może prowadzić do problemów w normalizacji i porównywaniu danych.

Dokładna dokumentacja diagnozy, leczenia i kompletne informacje o pacjencie mogą pomóc zmniejszyć liczbę błędów diagnostycznych, poprawić opiekę nad pacjentem i zminimalizować ryzyko roszczeń prawnych (Melonas i McNary, 2010, s. 48; Muir i in., 2013, s. 4). Jednak niekompletna dokumentacja jest powszechnym problemem w placówkach opieki zdrowotnej na całym świecie (Hussein i in., 2018, s. 45). Dlatego należy dążyć do poprawy praktyki prowadzenia dokumentacji medycznej oraz zapewnienia jej dokładności i kompletności. Jednak niekompletna dokumentacja jest powszechnym problemem w placówkach opieki zdrowotnej na całym świecie (Hussein i in., 2018, s. 49). Dlatego należy dążyć do poprawy praktyki prowadzenia dokumentacji medycznej oraz zapewnienia jej dokładności i kompletności (Kasaye i in., 2022, s. 10).

Analiza dużych zbiorów dokumentacji medycznej wymaga potężnych zasobów obliczeniowych i czasowych. Skomplikowane modele NLP mogą wymagać dostępu do dużych zasobów obliczeniowych. Modele NLP mogą mieć trudności w zachowaniu kontekstu, szczególnie w przypadku długich dokumentów medycznych, co może prowadzić do błędnych interpretacji (Rajkomar, 2018, s. 8).

5. SKOMPLIKOWANA TERMINOLOGIA MEDYCZNA I ZRÓŻNICOWANIE JĘZYKA

Analiza dokumentacji medycznej wymaga zrozumienia różnych typów danych, takich jak wyniki badań, diagnozy czy historie chorób. Integracja tych różnorodnych źródeł danych w analizie NLP może być trudna. Terminologia medyczna stosowana w tych dokumentach może być skomplikowana i zróżnicowana w zależności od specjalizacji, regionu czy kontekstu w jakim została użyta. Modele NLP muszą radzić sobie z tą różnorodnością, co może być wyzwaniem. Specjalistyczna terminologia i informacje specyficzne

dla kontekstu wymuszają przeszkolenie i dostosowanie systemów NLP do danej dziedziny klinicznej (Savova i in., 2010, s. 510).

Dokumentacja medyczna może zawierać zdania o skomplikowanej strukturze, co może być trudne do zrozumienia przez modele NLP. Zmienność i złożoność języka medycznego stanowią wyzwanie dla systemów NLP. Terminologia medyczna może być wysoce specjalistyczna i może zawierać skróty, akronimy i żargon specyficzny dla specjalizacji. Systemy NLP mogą mieć trudności z dokładną interpretacją i przetwarzaniem tych specjalistycznych terminów, co prowadzi do błędów w analizie dokumentacji medycznej (Uzuner i in., 2011, s. 553). Może to wpływać na wydajność algorytmów NLP, co wymaga stworzenia solidnych technik przetwarzania wstępnego i normalizacji w celu rozwiązania tych problemów.

Analiza medyczna wymaga specjalistycznej wiedzy z dziedziny medycyny. Modele NLP mogą mieć trudności w poprawnym zinterpretowaniu skomplikowanych terminów i konceptów medycznych. Język medyczny może być wieloznaczny, co może prowadzić do błędów interpretacyjnych przez modele NLP. Ponadto systemy NLP mogą napotkać wyzwania związane z obsługą odmian językowych, takich jak błędy ortograficzne, skróty lub niestandardowe użycie języka w tekście klinicznym. Ponadto *użycie negacji i niepewności w języku medycznym* może dodatkowo skomplikować proces analizy, ponieważ systemy NLP mogą mieć trudności z prawidłową identyfikacją i obsługą tych cech językowych (Savova i in., 2010, s. 509).

W celu zapewnienia wysokiej dokładności analiz, modele NLP mogą wymagać weryfikacji i nadzoru procesu uczenia przez ekspertów z dziedziny medycyny, co może być czasochłonne i kosztowne. Ponadto ważnymi kwestiami są interpretowalność i wyjaśnialność modeli NLP w analizie dokumentacji medycznej. Modele NLP często działają jak czarne skrzynki, co utrudnia zrozumienie podstawowego procesu decyzyjnego (Uzuner i in., 2008, s. 556). Zdolność do interpretacji i wyjaśnienia przewidywań modeli NLP ma kluczowe znaczenie dla budowania zaufania i zapewnienia etycznego wykorzystania tych modeli w placówkach opieki zdrowotnej (Uzuner i in., 2008, s. 556). Dalszy rozwój modeli NLP specyficznych dla danej specjalizacji medycznej i rodzaju przetwarzanej dokumentacji jest niezbędny do zapewnienia dokładnej i wiarygodnej analizy.

6. BRAK DOSTĘPU DO DANYCH I KWESTIE PRYWATNOŚCI PACJENTÓW

Rośnie zainteresowanie wykorzystaniem przetwarzania języka naturalnego (NLP) do automatyzacji wydobywania informacji z dokumentacji medycznej, takich jak identyfikowanie problemów pacjentów i powiązań między lekami a stanami chorobowymi (Wright i in., 2011, s. 859). Jednak wprowadzając technologię NLP do analizy medycznej, konieczne jest zagwarantowanie bezpieczeństwa danych, aby uniknąć wycieku wrażliwych informacji. Kwestie prywatności i bezpieczeństwa są ważnymi czynnikami podczas korzystania z NLP w analizie dokumentacji medycznej. Zawiera ona wrażliwe informacje o pacjencie, a stosowanie technik NLP budzi obawy dotyczące prywatności i poufności danych (Uzuner i in., 2008, s. 555).

Często dostęp do danych medycznych jest ograniczony ze względu na przepisy o prywatności i zasady etyczne. Może utrudnić to proces treningu modeli NLP. Informacje zawarte w dokumentacji medycznej mogłyby zostać wykorzystane niezgodnie z prawem i tym samym naruszyć przepisy dotyczące ochrony danych osobowych. Zgoda na wykorzystanie informacji zawartych w dokumentacji medycznej do badań jest konieczna (Willison i in., 2003, s. 373). Dodatkowo późniejsze usunięcie danych konkretnego pacjenta może być trudne (Kass i in., 2003, s. 429). Problemem jest również brak ustandaryzowanych formatów ekstrakcji danych (Wright i in., 2011, s. 863).

Konieczna jest zgoda na wykorzystanie informacji zawartych w dokumentacji medycznej do tworzenia, trenowania i walidowania modeli NLP (Willison i in., 2003, s. 373). Przyszłe badania powinny koncentrować się na *rozwiązywaniu problemów związanych z prywatnością*, poprawie dostępności danych i opracowaniu standardowych metod pozyskiwania i analizy danych (Kass i in., 2003, s. 432). *Zapewnienie odpowiedniej* deidentyfikacji i anonimizacji danych pacjentów ma kluczowe znaczenie dla ochrony prywatności pacjentów, a jednocześnie umożliwia wtórne wykorzystanie danych do celów badawczych. Rozwój zautomatyzowanych systemów identyfikacji opartych na technikach NLP może pomóc w rozwiązaniu tych problemów (Uzuner i in., 2008, s. 556).

8. WNIOSKI

Mimo że NLP oferuje wiele możliwości w analizie dokumentacji medycznej, istnieje szereg wyzwań i ograniczeń, które trzeba brać pod uwagę.

Rozwiązanie tych problemów wymaga integracji wiedzy medycznej, technologii NLP i ścisłej współpracy między ekspertami medycznymi a specjalistami od analizy danych. Wyzwania związane z dokładnym wyodrębnianiem informacji, przechwytywaniem informacji semantycznych wyższego poziomu i radzeniem sobie ze złożonością języka medycznego mogą mieć wpływ na wydajność systemów NLP.

Jednak trwające badania i integracja zaawansowanych technik mogą pomóc rozwiązać te ograniczenia i poprawić dokładność i skuteczność NLP w analizie dokumentacji medycznej. Potrzeba wysokiej jakości danych z adnotacjami, poprawy wydajności komponentów NLP, obsługi różnic językowych oraz zapewnienie prywatności i bezpieczeństwa. Ponadto interpretowalność i wyjaśnialność modeli NLP w analizie dokumentacji medycznej to obszary kluczowe dla budowania zaufania i zapewnienia etycznego stosowania. Należy zająć się wyzwaniami, aby zapewnić dokładność i niezawodność systemów NLP w analizie dokumentacji medycznej.

Przyszłość badań nad wykorzystaniem NLP w analizie dokumentacji medycznej rysuje się obiecująco. Metody głębokiego uczenia się, zautomatyzowana ekstrakcja informacji, integracja z innymi źródłami danych oraz postępy w medycynie spersonalizowanej to obszary, na których się koncentrujemy. Należy jednak zająć się wyzwaniami związanymi z jakością danych, wydajnością, różnicami językowymi i prywatnością. Przyszłe badania powinny koncentrować się na rozwiązywaniu problemów związanych z prywatnością, poprawie dostępności danych i opracowaniu standardowych metod pozyskiwania i analizy danych. Dalsze badania i rozwój w tych obszarach przyczynią się do powstania nowych, skuteczniejszych i bardziej niezawodnych modeli NLP. Pomimo omówionych ograniczeń NLP może zrewolucjonizować świadczenie opieki zdrowotnej i podejmowanie decyzji.

PODSUMOWANIE

Przyszłość rozwoju NLP w analizie danych medycznych rysuje się obiecująco. Zastosowanie metod głębokiego uczenia się, integracja zaawansowanych technik i włączenie wielu źródeł danych może prowadzić do dokładniejszych prognoz i spersonalizowanej opieki zdrowotnej. Jednak nadal istnieją wyzwania do pokonania, takie jak zapotrzebowanie na duże i różnorodne zbiory danych, rozwiązanie problemów związanych z prywatnością i zapewnienie możliwości interpretacji modeli głębokiego uczenia się. Dalsze badania i postępy w NLP przyczynią się do postępu w analizie danych medycznych

i poprawy opieki nad pacjentem. Rozwiązanie tych ograniczeń i wyzwań prowadzi do rozwoju solidnych i niezawodnych systemów NLP do analizy dokumentacji medycznej.

BIBLIOGRAFIA

- Alqarni, K., AlQarni, E., Naqvi, A., Alshayban, D., Ghorri, S., Haseeb, A., Jamshed, S.
2019 Assessment of medication adherence in saudi patients with type II diabetes mellitus in khobar city, saudi arabia. *Frontiers in Pharmacology*, 10.
- Deleger L, Brodzinski H, Zhai H
2013 Developing and evaluating an automated appendicitis risk stratification algorithm for pediatric patients in the emergency department. *J Am Med Inform Assoc*. 2013;20(e2):e212-e220.
- Hussein, R., Majeed, A., Mahmoud, R., Saihoud, S., Al-Hamadi, N.
2018 Assessment of the documentation completeness level of the medical records in basrah general hospital. *The Medical Journal of Basrah University*, 36(2).
- Kasaye, M., Beshir, M., Endehabtu, B., Tilahun, B., Guadie, H., Awol, S., Yilma, T.
2022 Medical documentation practice and associated factors among health workers at private hospitals in the amhara region, ethiopia 2021. *BMC Health Services Research*, 22(1).
- Kass, N., Natowicz, M., Hull, S., Faden, R., Plantinga, L., Gostin, L., Slutzman, J.
2003 The use of medical records in research: what do patients want? *The Journal of Law Medicine & Ethics*, 31(3).
- Melonas, J. and McNary, A.
2010 Taking action to avoid recurring risks in medical professional liability claims. *Neurology*, 75(Issue 18, Supplement 1).
- Muir, K., Gupta, C., Gill, P., Stein, J.
2013 Accuracy of international classification of diseases, ninth revision, clinical modification billing codes for common ophthalmic conditions. *Jama Ophthalmology*, 131(1).

- Park, Y., Kim, Y., Yi, B., Kim, S.
2019 Clinical decision support functions and digitalization of clinical documents of electronic medical record systems. *Healthcare Informatics Research*, 25(2), 115.
- Rajkomar, A., Oren, E., Chen, K., Dai, A., N, H., Liu, P., Dean, J.
2018 Scalable and accurate deep learning with electronic health records. *NPJ Digital Medicine*, 1(1).
- Savova, G., Masanz, J., Ogren, P., Zheng, J., Sohn, S., Kipper-Schuler, K., Chute, C.
2010 Mayo clinical text analysis and knowledge extraction system (ctakes): architecture, component evaluation and applications. *Journal of the American Medical Informatics Association*, 17(5).
- Sinha, R. and Shenoy, N.
2013 Assessment of oncology medical records as per nabh standards. *Journal of Health Management*, 15(3).
- Spyns, P.
1996 Natural language processing in medicine: an overview. *Methods of Information in Medicine*, 35(04/05).
- Tymiński R.
2018 Znaczenie dowodu z dokumentacji medycznej w sprawach cywilnych o błąd medyczny, „Medyczna Wokanda” 2018, nr 11.
- Uzuner, Ö., South, B., Shen, S., DuVall, S.
2011 2010 i2b2/va challenge on concepts, assertions, and relations in clinical text. *Journal of the American Medical Informatics Association*, 18(5).
- Vrijens, B., Geest, S., Hughes, D., Przemyslaw, K., Demonceau, J., Ruppard, T., Urquhart, J.
2012 A new taxonomy for describing and defining adherence to medications. *British Journal of Clinical Pharmacology*, 73(5).
- Willison, D., Keshavjee, K., Nair, K., Goldsmith, C., Holbrook, A.
2003 Patients' consent preferences for research uses of information in electronic medical records: interview and survey data. *BMJ*, 326(7385).

- Wright, A., Pang, J., Feblowitz, J., Maloney, F., Wilcox, A., Ramelson, H., Bates, D.
- 2011 A method and knowledge base for automated inference of patient problems from structured data in an electronic medical record. *Journal of the American Medical Informatics Association*, 18(6).

CHALLENGES AND LIMITATIONS OF NATURAL LANGUAGE PROCESSING TECHNIQUES IN HEALTH DATA ANALYSIS AND FURTHER RESEARCH DIRECTIONS

Abstract: The review paper aims to assess the challenges and limitations on the way to natural language processing (NLP) in the analysis of medical records. Clinical documentation can be an important source of information both for clinical practice, research, as well as for the management of personnel and medical facilities. The use of deep learning methods, the integration of advanced techniques and the inclusion of multiple data sources can lead to more accurate predictions and personalized healthcare. However, there are still challenges to be overcome, such as the need for large and diverse data sets, addressing privacy concerns, and ensuring that deep learning models can be interpreted. The aim of the article is to assess the challenges for NLP techniques in this field and to determine the direction of future research.

Keywords: natural language processing, artificial intelligence, medicine, medical records

ROLA SZTUCZNEJ INTELIGENCJI I KONWOLUCYJNYCH SIECI NEURONOWYCH W AUTOMATYZACJI ZAKŁADU PATOMORFOLOGII

Streszczenie: Praca przeglądowa ma na celu ocenę roli sztucznej inteligencji i konwolucyjnych sieci neuronowych w procesie automatyzacji pracy zakładu patomorfologicznego. Sztuczna inteligencja (AI) i spłotowe sieci neuronowe (CNN) okazały się potężnymi narzędziami w analizie obrazów medycznych. Zastosowanie CNN może zwiększyć możliwości patologów, poprawić dokładność diagnozy i skrócić czas oczekiwania na nią. Integracja sztucznej inteligencji w praktyce oddziału patologii obejmuje kompleksowe podejście, które obejmuje transformację cyfrową, walidację cyfrowego przepływu pracy i algorytmów sztucznej inteligencji, rekrutację ekspertów w dziedzinie sztucznej inteligencji oraz skuteczne programy komunikacji i szkoleń. Wykonując te kroki, oddziały patologii będą mogły skutecznie wykorzystać moc sztucznej inteligencji, aby poprawić dokładność diagnozy, zwiększyć efektywność przepływu pracy, a ostatecznie zapewnić lepszą opiekę nad pacjentem. Celem pracy jest analiza wpływu sztucznej inteligencji i CNN na automatyzację procesów w oddziale patomorfologicznym oraz analiza potencjalnych korzyści i wyzwań z tym związanych.

Słowa kluczowe: konwolucyjne sieci neuronowe, sztuczna inteligencja, medycyna, patomorfologia

1. WPROWADZENIE

Patomorfologia odgrywa kluczową rolę w diagnozowaniu chorób. Polega na badaniu tkanek i komórek w celu wykrycia nieprawidłowości oraz określenia charakteru i stopnia zaawansowania chorób. Patomorfolodzy analizują

obrazy medyczne, takie jak preparaty histopatologiczne, aby postawić trafną diagnozę i opracować odpowiednie plany leczenia.

Sztuczna inteligencja (AI) i splotowe sieci neuronowe (CNN) okazały się potężnymi narzędziami w analizie obrazów medycznych. Sztuczna inteligencja odnosi się do rozwoju systemów komputerowych, które mogą wykonywać zadania, które zazwyczaj wymagają ludzkiej inteligencji, takie jak rozpoznawanie obrazów i podejmowanie decyzji. Sieci CNN to rodzaj algorytmów głębokiego uczenia się, które wykazały niezwykle sukcesy w zadaniach związanych z analizą obrazu (Litjens i in., 2017, s. 60-88; Gulshan i in., 2016, s. 1-3).

W ostatnich latach duże zainteresowanie zyskało wykorzystanie sztucznej inteligencji i CNN w obszarze analizy obrazu medycznego. Technologie te mają potencjał do automatyzacji i usprawnienia różnych procesów na oddziale patomorfologicznym. Mogą pomagać patologom w klasyfikacji obrazów, wykrywaniu obiektów, segmentacji, rejestracji i innych zadaniach, prowadząc do dokładniejszych i skuteczniejszych diagnoz (Litjens i in., 2017, s. 75; Madabhushi i Lee, 2016, s. 170-175).

Celem niniejszej pracy poglądowej jest analiza wpływu sztucznej inteligencji i CNN na automatyzację procesów w oddziale patomorfologicznym oraz analiza potencjalnych korzyści i wyzwań z tym związanych. W niniejszej pracy podjęto się próby weryfikacji następującej hipotezy: sztuczna inteligencja i konwolucyjne sieci neuronowe mogą zautomatyzować pracę zakładu patomorfologicznego, umożliwić przyspieszenie procesów oraz wzrost dokładności i skuteczności stawianych diagnoz. Pracę przygotowano z wykorzystaniem metody przeglądu literatury, korzystając z internetowych baz danych PubMed oraz GoogleScholar.

2. SZTUCZNA INTELIGENCJA W MEDYCYNIE

Wprowadzenie AI do praktyki medycznej niesie ze sobą kilka korzyści. Po pierwsze, algorytmy AI mogą szybko i dokładnie analizować duże ilości danych, co prowadzi do skuteczniejszych i precyzyjnych diagnoz. Może to pomóc w ograniczeniu błędów diagnostycznych i poprawie wyników leczenia pacjentów. Po drugie, sztuczna inteligencja może pomóc pracownikom służby zdrowia w podejmowaniu decyzji opartych na dowodach, dostarczając im odpowiednich i aktualnych informacji z literatury medycznej i wytycznych klinicznych. Może to usprawnić podejmowanie decyzji klinicznych i poprawić opiekę nad pacjentem (Gulshan i in., 2016, s. 2-3).

Opracowano algorytmy głębokiego uczenia się, które mogą pomóc patologom w interpretacji i diagnozowaniu obrazów. Algorytmy te mogą dokładnie wykrywać nieprawidłowości i pomagać w stawianiu dokładniejszych i terminowych diagnoz (Chartrand i in., 2017, s. 2113-2131). CNN to rodzaj algorytmów głębokiego uczenia się, które wykazały duże sukcesy w zadaniach analizy obrazu (Janowczyk i Madabhushi, 2016, s. 1-18). Szczególnie dobrze nadają się do analizy preparatów histopatologicznych ze względu na ich zdolność do automatycznego uczenia się i wydobywania cech z obrazów. Sieci CNN składają się z wielu warstw połączonych ze sobą neuronów, które wykonują operacje splotowe w celu wyodrębnienia lokalnych cech z obrazu wejściowego. Funkcje te są następnie przepuszczane przez w pełni połączone warstwy w celu wykonania zadań klasyfikacji lub regresji (Hao i in. 2022, s. 1-6).

Sztuczną inteligencję wykorzystano także do opracowania modeli predykcyjnych służących do prognozowania chorób i wyników leczenia. Analizując duże ilości danych pacjentów, algorytmy AI mogą identyfikować wzorce i przewidywać prawdopodobieństwo progresji choroby lub reakcji na określone metody leczenia.

3. PROCES INTEGRACJI SZTUCZNEJ INTELIGENCJI W PRACY ZAKŁADU PATOMORFOLOGII

Wdrożenie i integracja sztucznej inteligencji (AI) w codziennej pracy patomorfologa wymaga starannego planowania tego procesu. Po pierwsze, aby umożliwić wykorzystanie sztucznej inteligencji w patologii, konieczna jest transformacja cyfrowa. Obejmuje ona kodowanie kreskowe i skanowanie preparatów histopatologicznych. Konwersja obrazów preparatów do formatu cyfrowego jest możliwa dzięki użyciu nowoczesnych skanerów. Cyfrowa patologia umożliwia zdalny dostęp do skanów, ułatwia ich udostępnianie i konsultowanie z innymi specjalistami oraz przyspiesza odszukiwanie danych wcześniejszych z konsultacji (Schüffler i in., 2023, s. 564-567).

Następnym krokiem jest walidacja cyfrowego przepływu pracy i algorytmów sztucznej inteligencji. Przy walidacji pracy w patologii cyfrowej można stosować się do wytycznych dostarczonych przez organizacje takie jak College of American Pathologists (CAP) i Royal College of Pathologists. Pozwoli to na stworzenie planu nowych procedur, uwzględniających możliwości CNN. Same algorytmy AI powinny zostać poddane walidacji w odpowiednich

badaniach, aby zapewnić ich dokładność i niezawodność (Schüffler i in., 2023, s. 564-567).

Włączenie sztucznej inteligencji do praktyki patologicznej wymaga również rekrutacji ekspertów w dziedzinie sztucznej inteligencji i dziedzin pokrewnych, takich jak inżynieria i matematyka. Eksperti ci mogą współpracować z patologami w celu opracowania i wdrożenia algorytmów sztucznej inteligencji, które odpowiadają konkretnym wyzwaniom diagnostycznym. Ponadto skuteczne programy szkoleń są niezbędne do pomyślnej integracji sztucznej inteligencji. Patologów i innych pracowników służby zdrowia należy edukować w zakresie pozytywnego wpływu sztucznej inteligencji na procesy szpitalne i potencjalnych korzyści, jakie może ona przynieść w opiece nad pacjentem. Celem tych działań jest świadome wdrożenie CNN w zakładzie patomorfologii odpowiednie przeszkolenie osób mających korzystać z oprogramowania (Medina i in., 2022, s. 54-68).

Wykonując te kroki, oddziały patologii będą mogły skutecznie wykorzystać moc sztucznej inteligencji, aby poprawić dokładność diagnozy, zwiększyć efektywność przepływu pracy, a ostatecznie zapewnić lepszą opiekę nad pacjentem.

4. KORZYŚCI WYNIKAJĄCE Z INTEGRACJI CNN W PRAKTYCE SPECJALISTY PATOMORFOLOGII

4.1. Mapy ciepła

Preparaty histopatologiczne są powszechnie stosowane w patologii do diagnozowania i badania chorób. Szkiełka te zawierają próbki tkanek, które są barwione i badane pod mikroskopem. Wraz z postępem patologii cyfrowej rośnie zainteresowanie wykorzystaniem technik głębokiego uczenia się, takich jak konwolucyjne sieci neuronowe (CNN), do analizy i interpretacji preparatów histopatologicznych.

Jednym z zastosowań CNN w analizie preparatów histopatologicznych jest generowanie map cieplnych. Mapy cieplne stanowią wizualną reprezentację obszarów obrazu, które mają największy wpływ na decyzję o klasyfikacji podejmowaną przez CNN. Może to być przydatne w identyfikowaniu obszarów zainteresowania, takich jak komórki nowotworowe, na preparacie histopatologicznym.

Do generowania map ciepła CNN wykorzystuje się technikę zwaną mapowaniem aktywacji klas ważonych gradientem (Grad-CAM) (Janowczyk

i Madabhushi, 2016, s. 1-18). Grad-CAM oblicza gradienty klasy docelowej w odniesieniu do map obiektów ostatniej warstwy spłotowej w CNN. Gradienty te są następnie wykorzystywane do ważenia map obiektów, podkreślając regiony najważniejsze dla decyzji dotyczącej klasyfikacji. Ważone mapy cech są następnie łączone w celu wygenerowania mapy cieplnej.

Zastosowanie CNN i map cieplnych w analizie preparatów histopatologicznych dało obiecujące wyniki. Analiza tkanek oparta na głębokim uczeniu się przy użyciu CNN była w stanie przewidzieć przebieg raka jelita grubego (Bychkov i in., 2018). Wygenerowane mapy cieplne zapewniły wgląd w obszary tkanki, które w największym stopniu wskazywały na wynik choroby.

Istnieją jednak wyzwania związane z zastosowaniem CNN do analizy preparatów histopatologicznych. Różnice w przygotowaniu slajdów, barwieniu i skanowaniu w różnych witrynach i platformach mogą mieć wpływ na działanie CNN. Ponadto wybór odpowiedniego powiększenia, zarządzanie błędami w adnotacjach i identyfikacja odpowiedniego zestawu szkoleniowego to ważne kwestie podczas szkolenia CNN (Janowczyk i Madabhushi, 2016, s. 1-18).

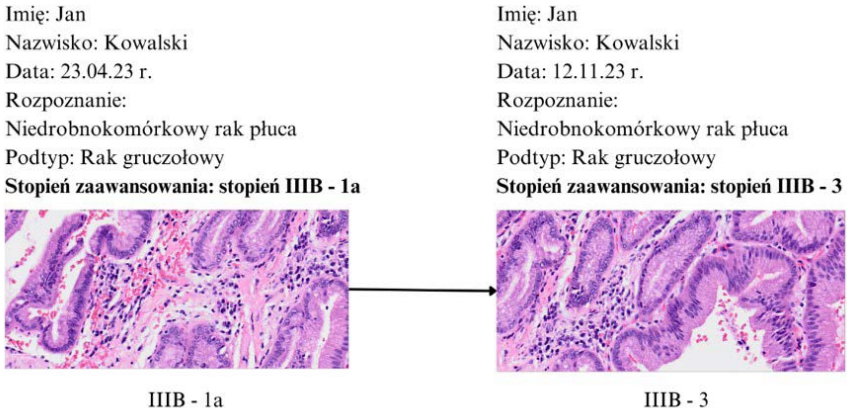
4.2. Porównywanie obrazów w czasie – ocena progresji choroby

Wykorzystanie CNN do śledzenia postępu choroby na preparatach histopatologicznych polega na analizie kolejnych slajdów tego samego pacjenta w czasie. Trenując CNN na zbiorze danych zawierających slajdy histopatologiczne pacjentów ze stwierdzoną progresją choroby, sieć może nauczyć się identyfikować wzorce i cechy wskazujące na postępowanie choroby. Może to obejmować zmiany w morfologii komórkowej, architekturze tkanek lub obecność określonych biomarkerów. Przykładowy schemat wykorzystania CNN do oceny progresji przedstawiono na Fot. 1.

Jednym z potencjalnych podejść jest wykorzystanie CNN do wyodrębnienia cech ze slajdów histopatologicznych, a następnie śledzenie zmian tych cech w czasie. Porównując cechy wyodrębnione z różnych punktów czasowych, może być możliwe zidentyfikowanie wzorców lub trendów wskazujących na postępowanie choroby. Podejście to z powodzeniem zastosowano w innych obszarach patologii, takich jak prognostyczna analiza obrazów histopatologicznych w raku wątrobowokomórkowym (Lu, 2020, s. 3-5).

Fot. 1. Przykład wykorzystania CNN do śledzenia postępu choroby na preparatach histopatologicznych. Na przestrzeni siedmiu miesięcy zmienia się stopień zaawansowania.

WYKORZYSTANIE CNN DO ŚLEDZENIA POSTĘPU CHOROBY NA PREPARATACH HISTOPATOLOGICZNYCH



Źródło: opracowanie własne

4.3. Automatyczne sprawdzanie poprawności oceny

Wykorzystanie konwolucyjnych sieci neuronowych (CNN) do automatycznego sprawdzania poprawności oceny patologa na preparatach histopatologicznych to obszar badań obiecujący w zakresie poprawy trafności diagnostycznej i ograniczenia błędów ludzkich (Janowczyk i Madabhushi, 2016, s. 1-18).

W tym kontekście CNN można przeszkolić w zakresie uczenia się wzorców i cech ze slajdów histopatologicznych, które wskazują na konkretne diagnozy lub klasyfikacje dokonywane przez patologów. Porównując ocenę CNN z oceną patologa, można zidentyfikować rozbieżności lub błędy w interpretacji.

Aby wdrożyć to podejście, wymagany jest zbiór danych obejmujący preparaty histopatologiczne wraz z prawidłową oceną patologa. CNN szkoli się w zakresie tego zbioru danych, ucząc się wiązać określone cechy obrazu z prawidłową diagnozą lub klasyfikacją. Po przeszkoleniu CNN może być używany do automatycznej analizy nowych preparatów histopatologicznych i przeprowadzania własnej oceny. Ocenę tę można następnie porównać z oceną patologa w celu zidentyfikowania wszelkich rozbieżności. Schemat sprawdzania poprawności oceny patomorfologa przez CNN ilustruje rycina Fot. 2.

Może to potencjalnie poprawić dokładność diagnozy i ograniczyć błąd ludzki. Patolodzy mogą czasami przeoczyć subtelne cechy lub dokonywać subiektywnych ocen, a CNN może służyć jako cenna druga opinia lub pomoc w procesie podejmowania decyzji. Należy jednak zauważyć, że CNN nie mają na celu zastępowania patologów, ale raczej pomaganie im w pracy. Ostateczną diagnozę i decyzję powinien zawsze podjąć patolog, biorąc pod uwagę ocenę CNN jako dodatkową informację.

Fot. 2. CNN może zostać wykorzystane jako „druga opinia” – porównując ocenę CNN z oceną patologa, można zidentyfikować rozbieżności lub błędy w interpretacji.

Źródło: opracowanie własne

Wyzwania związane z wdrażaniem tego podejścia obejmują problemy z przygotowaniem preparatów, różnicami w barwieniu i skanowaniu w różnych miejscach oraz zmiennością biologiczną w prezentacji różnych stopni choroby (Janowczyk i Madabhushi, 2016, s. 1-18). Czynniki te mogą wprowadzać zmienność i wpływać na działanie CNN. Ponadto należy dokładnie rozważyć możliwość interpretacji wyników CNN i włączenie jej oceny do przepływu pracy klinicznej.

Wykorzystanie CNN do automatycznego sprawdzania poprawności oceny patologa na preparatach histopatologicznych jest obiecujące w zakresie poprawy dokładności diagnostycznej i ograniczenia błędów ludzkich. Konieczne są dalsze badania i rozwój, aby sprostać wyzwaniom związanym ze zmiennością przygotowania preparatów i zapewnić płynną integrację CNN z przebiegiem pracy klinicznej.

5. WYZWANIA I BARIERY ZWIĄZANYCH Z WPROWADZENIEM CNN DO PRACY NA ZAKŁADZIE PATOLOGII

Wprowadzenie sztucznej inteligencji (AI) i spłotowych sieci neuronowych (CNN) do automatyzacji pracy Zakładu Patomorfologii nie jest pozbawione wyzwań. Jednym z głównych problemów jest dostępność i jakość danych. Algorytmy sztucznej inteligencji wymagają dużych i różnorodnych zbiorów danych, aby skutecznie szkolić i weryfikować modele. Uzyskanie wysokiej jakości danych medycznych z adnotacjami może jednak stanowić wyzwanie ze względu na obawy dotyczące prywatności, dostępność danych i potrzebę adnotacji ekspertów (Litjens i in., 2017, s. 69-72). Ponadto brak

ujednoliconych formatów danych i interoperacyjności między różnymi systemami może utrudniać integrację sztucznej inteligencji z przepływami pracy w patologii (Kim i in., 2022, s. 3). Zbiór danych na których został wytrenowany dany model CNN może nie być optymalny dla danego zakładu patomorfologii i nie być reprezentatywny dla analizowanych preparatów histopatologicznych.

Kolejnym wyzwaniem jest potrzeba solidnej walidacji i ram regulacyjnych. Algorytmy sztucznej inteligencji muszą zostać poddane rygorystycznym badaniom weryfikacyjnym, aby zapewnić ich dokładność, niezawodność i możliwość uogólnienia (Litjens i in., 2017, s. 77 – 80). Organy regulacyjne odgrywają kluczową rolę w zapewnianiu bezpieczeństwa i skuteczności wyrobów medycznych opartych na sztucznej inteligencji (Berbis i in., 2023, s. 5). Opracowanie standardowych wytycznych i protokołów walidacji i regulacji sztucznej inteligencji w patologii jest niezbędne do budowania zaufania i ułatwiania powszechnego przyjęcia tej technologii.

Wyzwania techniczne istnieją również przy wdrażaniu sztucznej inteligencji i CNN w praktyce patologicznej. Wymagania obliczeniowe dotyczące szkolenia i uruchamiania modeli CNN mogą być wymagające i wymagać infrastruktury obliczeniowej o wysokiej wydajności oraz specjalistycznego sprzętu. Integracja sztucznej inteligencji z istniejącymi systemami i przepływami pracy w patologii może wymagać znacznych modyfikacji technicznych i interoperacyjności z innymi systemami informacji w opiece zdrowotnej (King i in., 2023, s. 1-5). Transformacja cyfrowa zbiorów zakładu patomorfologii wymaga posiadania nowoczesnego skanera pozwalającego optymalizować ten proces. Aby możliwe było zastosowanie CNN w codziennej praktyce patomorfologa każdy preparat histopatologiczny musi zostać najpierw zeskanowany (Cruz-Roa i in. 2017, s. 1-3).

Oprócz wyzwań technicznych należy pokonać bariery organizacyjne i ludzkie. Bariery organizacyjne obejmują potrzebę infrastruktury i zasobów wspierających wdrażanie AI na oddziałach patologii. Obejmuje to dostępność cyfrowych systemów patologicznych, pojemność przechowywania dużych zbiorów danych oraz wsparcie informatyczne w zakresie utrzymywania i aktualizacji algorytmów sztucznej inteligencji (Kim i in., 2022, s. 4). Bariery ludzkie obejmują potrzebę szkolenia i edukacji patologów i innych pracowników służby zdrowia. Patolodzy mogą wymagać dodatkowego szkolenia, aby zrozumieć możliwości i ograniczenia sztucznej inteligencji oraz skutecznie współpracować z systemami sztucznej inteligencji w swoich procesach diagnostycznych (King i in., 2023, s. 1-5). Opór przed zmianami i obawa przed

zmianą miejsca pracy mogą również stanowić bariery w przyjęciu sztucznej inteligencji w patologii (Aldhafeeri, 2022, s. 3-5). Należy zapewnić aktywny udział specjalistów w integracji sztucznej inteligencji, kluczowa jest jasna komunikacja i zaangażowanie patologów.

Ważnymi barierami, które należy wziąć pod uwagę, są również względy etyczne i prawne. Zastosowanie sztucznej inteligencji w patologii rodzi pytania o prywatność pacjentów, bezpieczeństwo danych i odpowiedzialne wykorzystanie algorytmów sztucznej inteligencji (Berbis i in., 2023, s. 1-5). Istotne jest zapewnienie zgodności z przepisami dotyczącymi ochrony danych i wytycznymi etycznymi jest niezbędne do utrzymania zaufania pacjentów i ochrony wrażliwych informacji medycznych. Wiąże się to ze stworzeniem specjalistycznych wytycznych, określających procedury obowiązujące podczas pracy wspieranej przez sztuczną inteligencję.

Automatyzacja pracy zakładu patomorfologii poprzez zastosowanie CNN napotyka różne wyzwania i bariery. Należą do nich dostępność i jakość danych, ramy walidacyjne i regulacyjne, wymagania techniczne, infrastruktura organizacyjna, czynnik ludzki i względy etyczne. Sprostanie tym wyzwaniom i barierom ma kluczowe znaczenie dla zapewnienia pomyślnej integracji sztucznej inteligencji w praktyce patologicznej i uwolnienia jej pełnego potencjału w zakresie poprawy dokładności diagnostyki, wydajności pracy i opieki nad pacjentem.

6. PERSPEKTYWY DALSZEGO ROZWOJU W OBSZARZE AUTOMATYZACJI PATOMORFOLOGII Z WYKORZYSTANIEM AI

Dziedzina automatyzacji wykorzystującej sztuczną inteligencję (AI) i splotowe sieci neuronowe (CNN) w patologii czeka na dalszy rozwój i innowacje. Postępy w sztucznej inteligencji i algorytmach głębokiego uczenia się okazały się już bardzo obiecujące w zakresie poprawy dokładności diagnostyki, wydajności pracy i opieki nad pacjentem. Istnieje jednak kilka obszarów, w których można spodziewać się dalszego postępu.

Jednym z obszarów przyszłego rozwoju jest integracja danych multimodalnych. Obecnie algorytmy AI analizują przede wszystkim obrazy medyczne, takie jak preparaty histopatologiczne czy skany radiologiczne. Jednak połączenie danych obrazowych z innymi rodzajami danych, takimi jak dane genomyczne lub proteomiczne, może zapewnić pełniejsze zrozumienie chorób i umożliwić spersonalizowane strategie leczenia. Integracja różnorodnych

źródeł danych i rozwój modeli sztucznej inteligencji, które będą w stanie skutecznie analizować i interpretować dane multimodalne, będą głównym przedmiotem przyszłych badań.

Kolejnym obszarem przyszłych innowacji jest rozwój możliwych do wyjaśnienia modeli sztucznej inteligencji. CNN są często uważane za modele czarnej skrzynki, ponieważ brakuje im przejrzystości w procesie decyzyjnym. Umiejętność interpretowania i wyjaśniania decyzji podejmowanych przez modele sztucznej inteligencji jest kluczowa dla zdobycia zaufania i akceptacji ze strony patologów i innych pracowników służby zdrowia. Prowadzone są wysiłki badawcze mające na celu opracowanie wyjaśnialnych modeli sztucznej inteligencji, które mogą zapewnić wgląd w funkcje i wzorce wykorzystywane przez modele do formułowania prognoz (Madabhushi i Lee, 2016, s. 170-175).

Co więcej, zastosowanie sztucznej inteligencji w patologii może wykroczyć poza diagnozę i klasyfikację. Sztuczna inteligencja może potencjalnie pomóc w prognozowaniu, planowaniu leczenia i monitorowaniu postępu choroby. Analizując duże ilości danych pacjentów, algorytmy sztucznej inteligencji mogą identyfikować wzorce i przewidywać skutki choroby, umożliwiając medycynę spersonalizowaną i poprawiając wyniki pacjentów (Berbis i in., 2023, s. 6). Przyszłe badania będą skupiać się na rozszerzeniu zakresu zastosowań sztucznej inteligencji w patologii, aby objąć całe kontinuum opieki nad pacjentem.

Wprowadzenie sztucznej inteligencji i automatyzacji w patologii niewątpliwie wpłynie na rolę patologów. Choć niektórzy mogą obawiać się, że sztuczna inteligencja zastąpi patologów, dominuje pogląd, że sztuczna inteligencja raczej wzmocni i wzmocni możliwości patologów, niż ich zastąpi. Dzięki automatyzacji rutynowych i powtarzalnych zadań patolodzy będą mieli więcej czasu na skupienie się na złożonych przypadkach i podejmowaniu kluczowych decyzji.

CNN może pomóc patolodom w analizie obrazów, rozpoznawaniu wzorców i interpretacji danych, dostarczając im cennych spostrzeżeń i wspierając ich oceny diagnostyczne i prognostyczne (Coudray i in., 2018, s. 1559-1567). Patolodzy staną się bardziej „konsultantami diagnostycznymi”, wykorzystującymi sztuczną inteligencję jako narzędzie do poszerzania swojej wiedzy specjalistycznej i poprawy opieki nad pacjentem.

Rola patologów również będzie ewoluować i obejmować nadzór i weryfikację algorytmów sztucznej inteligencji. Patolodzy odegrają kluczową rolę w opracowywaniu, walidacji i regulowaniu modeli sztucznej inteligencji,

aby zapewnić ich dokładność, niezawodność i etyczne zastosowanie (Berbis i in., 2023, s. 6). Zapewnią niezbędną wiedzę specjalistyczną i kontekst kliniczny, aby kierować rozwojem i wdrażaniem sztucznej inteligencji w praktyce patologicznej.

Dodatkowo patolodzy staną się edukatorami i mentorami w dziedzinie AI. Będą odpowiadać za szkolenie i edukację kolejnego pokolenia patologów w zakresie stosowania i interpretacji algorytmów AI. Patolodzy będą również współpracować z ekspertami w dziedzinie sztucznej inteligencji i naukowcami zajmującymi się danymi, aby opracować nowe modele i algorytmy sztucznej inteligencji dostosowane do konkretnych potrzeb praktyki patologicznej (Berbis i in., 2023, s. 6).

6. WNIOSKI

Sztuczna inteligencja i CNN wykazały niezwykłą skuteczność w automatyzacji różnych zadań w patologii. Technologie te wykazały ogromny potencjał w wykrywaniu i klasyfikacji chorób. Stwierdzono, że wydajność zautomatyzowanych systemów opartych na sztucznej inteligencji jest doskonała, a niektóre systemy nawet przewyższają specjalistów ludzkich pod względem dokładności i wydajności (Khanagar i in., 2021, s. 508-522).

Integracja sztucznej inteligencji może zwiększyć możliwości patologów, dostarczając cennych spostrzeżeń, wspierając oceny diagnostyczne i prognozy oraz poprawiając opiekę nad pacjentem. Sztuczna inteligencja może potencjalnie zwiększyć rolę patologów, umożliwiając im skupienie się na złożonych przypadkach, podejmowaniu kluczowych decyzji i interakcjach z pacjentami. Patolodzy będą odgrywać kluczową rolę w opracowywaniu, walidacji i regulowaniu modeli sztucznej inteligencji, zapewniając ich dokładność, niezawodność i etyczne wykorzystanie.

Sztuczna inteligencja może zrewolucjonizować praktykę medyczną, poprawiając dokładność diagnostyczną, pomagając w podejmowaniu decyzji dotyczących leczenia i umożliwiając medycynę spersonalizowaną. Aby zapewnić pomyślną integrację sztucznej inteligencji w medycynie, należy jednak dokładnie rozważyć wyzwania związane z jakością danych, ramami regulacyjnymi i względami etycznymi.

Patolodzy staną się konsultantami diagnostycznymi, wykorzystując sztuczną inteligencję jako narzędzie do poszerzania swojej wiedzy specjalistycznej i poprawy opieki nad pacjentem. Będą także odgrywać kluczową rolę w nadzorowaniu i walidacji algorytmów sztucznej inteligencji, a także

w szkoleniu i kształceniu kolejnego pokolenia patologów w zakresie stosowania i interpretacji sztucznej inteligencji.

Integracja sztucznej inteligencji w praktyce oddziału patologii obejmuje kompleksowe podejście, które obejmuje transformację cyfrową, walidację cyfrowego przepływu pracy i algorytmów sztucznej inteligencji, rekrutację ekspertów w dziedzinie sztucznej inteligencji oraz skuteczne programy komunikacji i szkoleń. Wykonując te kroki, oddziały patologii będą mogły skutecznie wykorzystać moc sztucznej inteligencji, aby poprawić dokładność diagnozy, zwiększyć efektywność przepływu pracy, a ostatecznie zapewnić lepszą opiekę nad pacjentem.

PODSUMOWANIE

Przyszłość automatyzacji w patologii z wykorzystaniem sztucznej inteligencji i CNN niesie ze sobą ogromne nadzieje w zakresie dalszego rozwoju i innowacji. Integracja danych multimodalnych, rozwój możliwych do wyjaśnienia modeli sztucznej inteligencji oraz rozwój zastosowań sztucznej inteligencji w patologii to obszary, na których należy się skupić w przyszłości. Połączenie danych obrazowych z innymi rodzajami danych, takimi jak dane genomiczne lub proteomiczne, może zapewnić pełniejsze zrozumienie chorób i umożliwić spersonalizowane strategie leczenia. Opracowanie możliwych do wyjaśnienia modeli sztucznej inteligencji zwiększy przejrzystość i zaufanie do systemów sztucznej inteligencji.

Podsumowując, integracja sztucznej inteligencji może zwiększyć możliwości patologów, poprawić dokładność diagnozy i ostatecznie zapewnić lepszą opiekę nad pacjentem.

BIBLIOGRAFIA

Aldhafeeri, F.

2022 Perspectives of radiographers on the emergence of artificial intelligence in diagnostic imaging in saudi arabia. *Insights Into Imaging*, 13(1).

Berbis, M., McClintock, D., Bychkov, A., Cheng, J., Delahunt, B., Egevad, L., Shen, J.

2023 Computational pathology in 2030: a Delphi study forecasting the role of AI in pathology within the next decade. *EBioMedicine*.

- Chartrand, G., Cheng, P., Vorontsov, E., Drozdal, M., Turcotte, S., Pal, C., Tang, A.
2017 Deep learning: a primer for radiologists. *Radiographics*, 37(7).
- Coudray, N., Ocampo, P., Sakellaropoulos, T., Narula, N., Snuderl, M., Fe-nyö, D., Tsirigos, A.
2018 Classification and mutation prediction from non-small cell lung cancer histopathology images using deep learning. *Nature Medicine*, 24(10).
- Cruz-Roa, A., Gilmore, H., Basavanthally, A., Feldman, M., Ganesan, S., Shih, N., Madabhushi, A.
2017 Accurate and reproducible invasive breast cancer detection in whole-slide images: a deep learning approach for quantifying tumor extent. *Scientific Reports*, 7(1).
- Gulshan, V., Peng, L., Coram, M., Stumpe, M., Wu, D., Narayanaswamy, A., Webster, D.
2016 Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *Jama*, 316(22).
- Hao, X., Xu, L., Liu, Y., Luo, C., Yin, Y., Chen, X., Tao, X.
2022 Construction of diagnosis model of moyamoya disease based on convolution neural network algorithm. *Computational and Mathematical Methods in Medicine*, 2022.
- Janowczyk A, Madabhushi A.
2016 Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases. *J Pathol Inform*. 2016.
- Khanagar, S., Al-Ehaideb, A., Maganur, P., Vishwanathaiah, S., Patil, S., Bashesen, H., Bhandi, S.
2021 Developments, application, and performance of artificial intelligence in dentistry – a systematic review. *Journal of Dental Sciences*, 16(1).
- Kim, I., Kang, K., Song, Y., Kim, T.
2022 Application of artificial intelligence in pathology: trends and challenges. *Diagnostics*, 12(11).

- King, H., Wright, J., Treanor, D., Williams, B., Randell, R.
 2023 What works where and how for uptake and impact of artificial intelligence in pathology: review of theories for a realist evaluation. *Journal of Medical Internet Research*.
- Litjens, G., Kooi, T., Bejnordi, B., Setio, A., Ciompi, F., Ghafoorian, M., Sánchez, C.
 2017 A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42.
- Lu L., Daigle B. J.
 2020 Prognostic analysis of histopathological images using pre-trained convolutional neural networks: application to hepatocellular carcinoma. *PeerJ*. 2020 Mar 12;8:e8668.
- Madabhushi, A. and Lee, G.
 2016 Image analysis and machine learning in digital pathology: challenges and opportunities. *Medical Image Analysis*, 33.
- Medina, P., Medina, E., & Pacanowski, T.
 2022 Building meaningful brands through disseminating artificial intelligence-related content. an essay about cancer hospitals. *Journal of Advanced Research in Social Sciences*, 6(1).
- Schüffler, P., Steiger, K., Weichert, W.
 2023 How to use ai in pathology. *Genes Chromosomes and Cancer*, 62(9).

THE ROLE OF ARTIFICIAL INTELLIGENCE AND CONVOLUTIONAL NEURAL NETWORKS IN THE AUTOMATION OF THE PATOLOGY DEPARTMENT

Abstract: The review paper aims to assess the role of artificial intelligence and convolutional neural networks in the process of automating the work of a pathology department. Artificial intelligence (AI) and convolutional neural networks (CNN) have proven to be powerful tools in the analysis of medical images. The use of CNN can increase the capabilities of pathologists, improve the accuracy of diagnosis and shorten the waiting time for it. The integration of AI into pathology practice involves a comprehensive approach that includes digital transformation, validation of digital workflow and AI algorithms, recruitment of AI experts, and effective communication and training programs. By following these steps, pathology departments will be able to effectively harness the power of AI to improve diagnosis accuracy, increase workflow efficiency, and ultimately provide better patient care. The aim of the article is to analyze the impact of artificial intelligence and CNN on the automation of processes in the pathology department and to analyse the potential benefits and challenges associated with it.

Keywords: convolutional neural networks, artificial intelligence, medicine, pathology

ISBN 978-83-67959-21-6