

DOI 10.21008/j.1897-0737.2020.104.0003

Estera KOT*, Krzysztof SIWEK*, Ewelina WINSKA**

ARCHITEKTURA PLATFORMY KORZYSTAJĄCEJ Z METOD UCZENIA MASZYNOWEGO DO PRZETWARZANIA OBRAZÓW BIOMEDYCZNYCH W CHMURZE

W artykule zaproponowana została architektura korzystająca z chmury Microsoft Azure umożliwiająca uruchomienie algorytmów uczenia maszynowego służących do wykrywania guzów mózgu z zestawu obrazów DICOM. Przedstawiony został proces wdrożenia modelu z uwzględnieniem integracji z infrastrukturą jednostki wykonującej badania medyczne. Zwrócono uwagę na bezpieczeństwo danych i ograniczenia typowe dla danych medycznych. Wskazano dalsze perspektywy rozwoju omawianego rozwiązania.

SŁOWA KLUCZOWE: obrazy biomedyczne, architektura, chmura, glejak, przetwarzanie obrazów, uczenie maszynowe.

1. WSTĘP

Międzynarodowa Unia do Walki z Rakiem (ang. *Union for International Cancer Control*), zrzeszająca 173 państwa, pierwotnie prognozowała, że jedna na trzy osoby zachoruje na raka. W 2015 r. brytyjski instytut NICE (ang. *National Institute for Health and Care Excellence*) ogłosił, że jedna na dwie osoby będzie zmagająca się z rakiem [1]. Od 2005 r. polskie Ministerstwo Zdrowia prowadzi program „Narodowy Program Zwalczania Chorób Nowotworowych” [2]. Pomimo działań w obszarze profilaktyki i zwiększania jakości wysokospecjalistycznego sprzętu medycznego służącego do leczenia chorób nowotworowych, liczba pacjentów ze zdiagnozowanym rakiem rośnie z roku na rok. Glejak wielopostaciowy – jeden z typów nowotworu złośliwego – należy do kategorii nowotworów ośrodkowego układu nerwowego i jest najbardziej agresywnym typem guza mózgu o IV stopniu złośliwości zdefiniowanym przez Światową Organizację Zdrowia [3]. Leczenie pacjentów z rozpoznaniem glejakiem wielopostaciowym zostało opisane w [4]. Zaproponowano także skuteczny algorytm segmentacji wyników badań obrazowania mózgu, którego zadaniem jest detekcja guza, wyznaczenie jego objętości oraz stworzenie wizualizacji 3D.

* Politechnika Warszawska

** Polsko-Japońska Akademia Technik Komputerowych

W artykule została przedstawiona architektura platformy chmurowej do przetwarzania obrazów biomedycznych i sposób jej wdrożenia w infrastrukturę jednostki realizującej badania oparte o pozytonową tomografię emisyjną (PET) i tomografię komputerową (CT). Platforma została zaprojektowana na potrzeby współpracy z Zakładem Medycyny Nuklearnej działającym w Centralnym Szpitalu Klinicznym Uniwersytetu Medycznego w Warszawie.

1.1. Uczenie maszynowe w medycynie

Sztuczna inteligencja (ang. *Artificial Intelligence*) jest dziedziną korzystającą z uczenia maszynowego, algorytmów opartych o głębokie sieci neuronowe, robotykę i widzenie komputerowe. Rys. 1 przedstawia wzajemne relacje wymienionymi dziedzinami informatyki. Kluczowym zagadnieniem z perspektywy omawianej platformy jest widzenie komputerowe (ang. *computer vision*) nazywane także rozpoznawaniem obrazów. Bazuje ono na symulacji ludzkiej inteligencji, sprzęcie komputerowym, algorytmach uczenia maszynowego i głębokich sieciach neuronowych.



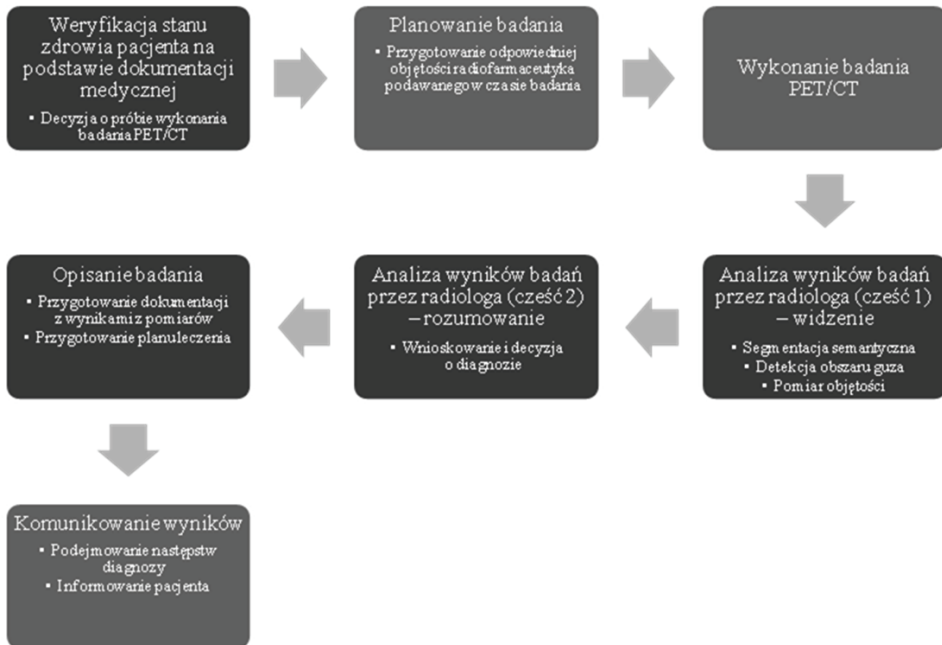
Rys. 1. Przedstawienie zależności między sztuczną inteligencją, a jej poddziedzinami

Opieka zdrowotna jest dziedziną, która wymaga użycia rozpoznawania obrazów w pierwszej kolejności. Automatyzacja i sztuczna inteligencja to podstawowe pojęcia opieki medycznej w wersji 5.0 [5], która umożliwiła m.in. wykonywanie automatycznej diagnozy, predykcji postępu choroby, jak również zdalnego monitoringu zdrowia pacjenta [6].

Kluczowymi problemami w aplikacjach przetwarzających obrazy biomedyczne jest pozyskiwanie danych, jakość danych, prywatność danych, bezpieczeństwo, kwestie etyczne i zarządzanie danymi [7].

Rys. 2 przedstawia uogólniony proces działań, jakie podejmowane są w przypadku skierowania pacjenta na wykonanie badania PET/CT. Analiza obrazu PET/CT przeprowadzana jest przez radiologa – eksperta danej dziedziny – przy

użyciu oprogramowania syngoMMWP VE40A, które jest uruchamiane na stacji roboczej syngo VE32E firmy Siemens.



Rys. 2. Uogólniony proces działania w przypadku wykonania badania PET/CT, tło ciemniejsze przedstawia kroki możliwe do zrealizowania przez sztuczną inteligencję, tło jaśniejsze przedstawia kroki konieczne do wykonania przez człowieka

2. DANE

2.1. Bezpieczeństwo danych

Kwestie bezpieczeństwa danych, w tym ich przechowywania i przesyłania [5], stanowią główną obawę przed użyciem platform chmurowych do przetwarzania danych medycznych, pomimo że podział odpowiedzialności i wytyczne względem systemów zabezpieczeń zostały zdefiniowane [8].

Systemy bazujące na informacjach medycznych podlegają szeregowi regulacji prawnych i międzynarodowym normom postępowania takim jak: ISO/IEC 27001, ISO/IEC 27002, ISO/IEC 22301, ISO 13606-1, ISO 13606-4 oraz ISO/IEC 27018. Korzystanie z chmury publicznej w celu przetwarzania danych medycznych przenosi odpowiedzialność za bezpieczeństwo oraz zgodność z obowiązującym prawem na dostawcę chmury. W zaproponowanej architekturze aplikacja używana do przesyłania danych medycznych komunikuje się z siecią dostawcy usług chmurowych poprzez interfejs programowania aplikacji (ang. *Application*

Programming Interface – API). W celu zapewnienia bezpieczeństwa tej aplikacji rekomendowane jest użycie protokołu HTTPS oraz podwójnego szyfrowania – zarówno po stronie klienta, jak i serwera. Niezbędne jest także połączenie sieci jednostki medycznej, z której dane są wysyłane, z siecią Microsoft Azure z użyciem tunelowania typu lokacja-lokacja (ang. *site-to-site VPN*).

2.2. Anonimizacja i maskowanie danych

Przed udostępnieniem danych jednostka wykonująca badania PET/CT zobowiązana jest do usunięcia lub nadpisania danych osobowych z plików. Odzyskanie usuniętych metadanych jest niemożliwe. Z tego powodu należy przeprowadzić analizę dostępnych zmiennych i ich wartości możliwych do odczytania z plików DICOM. Niektóre zmienne, takie jak odstępy między pikselami (ang. *pixel spacing*) są niezbędne do wykonania obliczenia pola powierzchni guza. Usunięcie takich zmiennych może uniemożliwić poprawne działanie algorytmu. W [9] przedstawiono sposoby anonimizacji obrazów zapisanych w formacie DICOM.

Metadane mogą zostać zaszyfrowane przy pomocy technik maskowania [10, 11]. Odszyfrowanie metadanych jest możliwe tylko w przypadku dostępu do klucza szyfrującego.

2.3. Jakość danych i augmentacja

Jakość danych (ang. *data quality*) jest kluczową kwestią w rozwoju skuteczności systemów medycznych [12]. W trakcie zbierania danych oraz testowania działania algorytmów, głównymi problemami w utrzymaniu jakości danych były zwielokrotnione wyniki badań oraz liczba plików wynikowych nierówna liczbie analizowanych obrazów DICOM.

Jednym z parametrów mającym wpływ na jakość danych jest różnorodność danych (ang. *data variety*). Kolejnym parametrem jest wielkość danych (ang. *data volume*). Podczas testowania algorytmów wykrywających guzy mózgu należy przeprowadzić eksperyment polegający na porównaniu wyników działania algorytmu na mózgach zdrowych pacjentów i pacjentów ze stwierdzonym guzem. Oczekiwany rezultat powinien być pozytywny (wykrycie guza) na wszystkich zestawach obrazów należących do chorych pacjentów i negatywny (brak guza) dla pozostałych zestawów obrazów. Ta prosta czynność, wykonana na dostatecznie dużej liczbie zdjęć, pozwala na jednoznaczne stwierdzenie, że algorytm wykrywa poprawne schorzenie i możliwe jest kontynuowanie procedury weryfikującej jego skuteczność. Ze względu na inwazyjność badania PET/CT, które jest wykonywane dopiero, gdy istnieją objawy wskazujące na obecność guza mózgu, nie jest ono przeprowadzane na zdrowych pacjentach i na pacjentach w początkowym stadium choroby. Z tego powodu różnorodność danych jest niska. Liczba zestawów

danych jest ograniczona przez liczbę badanych pacjentów, stąd również, jak często w przypadku danych medycznych, występuje także problem z wielkością danych.

Jakość danych znacznie redukuje liczbę kompletnych wyników badań. W przypadku pierwszego zestawu otrzymanych badań aż 68,2% obrazów okazało się niekompletne.


Rezultatem słabej jakości danych jest ograniczony zbiór danych treningowych, co istotnie wpływa na skuteczność algorytmów. Przy niewielkim zbiorze danych wykorzystanych do uczenia sieci możliwe jest jej przeuczenie, a to w konsekwencji uniemożliwia osiągnięcie celu uczenia, czyli uzyskania pożądanego stopnia generalizacji.

Jedną z metod, rozwiązującą problem małego zbioru danych, jest augmentacja (ang. *augmentation*). Polega ona na zwiększeniu liczebności istniejącego zbioru danych poprzez wykonanie transformacji geometrycznych, takich jak rotacja, przycinanie, a także innych: modyfikacja barw, jasności, kontrastu, na istniejącym zbiorze obrazów. W wyniku augmentacji powstają zmodyfikowane kopie obrazów wejściowych zachowujące cechy wymagane do uczenia sieci neuronowej i poprawnego działania algorytmu.

3. ARCHITEKTURA

3.1. Architektura referencyjna


Przedstawiona architektura platformy została zaprojektowana do analizy wyników badań PET i CT – czyli obrazów mózgu zapisanych w formacie DICOM. Rys. 3 przedstawia architekturę referencyjną, która jest uogólnieniem komponentów i procesów składających się na platformę chmurową do przetwarzania obrazów biomedycznych. Rys. 3 pokazuje także kroki procesu tworzenia modelu oraz użyte technologie i zależności między nimi.



Rys. 3. Architektura referencyjna platformy do przetwarzania obrazów biomedycznych PET/CT/MRI w chmurze publicznej Microsoft Azure

Na początku procesu obrazy są umieszczone w dedykowanym magazynie plików w chmurze (Azure Blob). Kolejno, przy użyciu serwisu Azure Machine Learning, kod algorytmu zostaje uruchomiony wewnątrz kontenerów korzystających z GPU. Serwis z interfejsem webowym pozwala na przesłanie nowych obrazów i ponowne uruchomienie algorytmu na nowych danych. Algorytm używa sieci U-NET do usuwania tkanki kostnej z obrazów. Następnie możliwe jest wykrycia guzów mózgu na zmodyfikowanych obrazach poprzez użycie metody aktywnego konturu z biblioteki Scikit. Augmentacja danych została zrealizowana przy użyciu metod z biblioteki Keras.

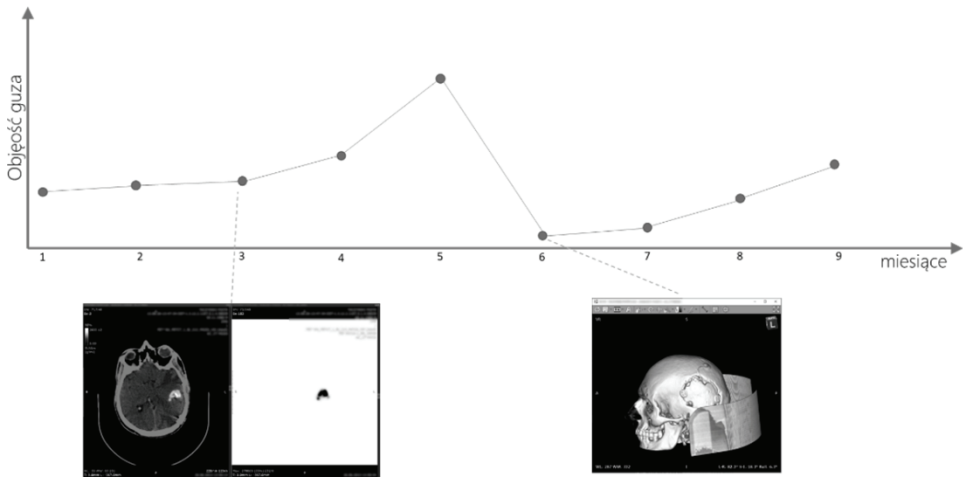
Maski użyte do wytrenowania modelu zostały zarysowane przez radiologa. Użyto automatycznego generатора masek, by uniknąć niedouczenia sieci. Rys. 4 przedstawia przykład wygenerowanych masek.



Rys. 4. Przykładowe maski dla guzów i tkanki kostnej. Obraz z lewej strony przedstawia maskę dla guza. Środkowy obraz obrazuje glijaka o niejednorodnej masie. Wizualizacja z prawej strony ukazuje maskę dla tkanek kostnych

W przypadku większego zbioru danych zastosowanie technik aktywnego uczenia (ang. *active learning*) jest sposobem na poprawę skuteczności modelu. Takie rozwiązanie może być zastosowanie przez implementację interfejsu webowego dla radiologa, w którym możliwe będzie zaznaczanie konturu guza.


Uzyskane objętości guza zostają zapisane w bazie danych Azure Storage Table, do której zostaje podpięty raport pokazujący zmiany objętości guza wśród pacjentów. Rys. 5 przedstawia przykładową wizualizację zmian objętości guza. Można zauważyć, że pacjent w szóstym miesiącu miał przeprowadzoną resekcję guza, przez co objętość znacznie malała. Widoczna jest także jedna z głównych cech glijaka – zdolność do szybkiego odradzenia i agresja we wzroście objętości.



Rys. 5. Kontrolowanie postępu choroby

3.2. Uczenie maszynowe jako usługa

Uczenie maszynowe jako usługa (ang. *machine learning as a service – MLaaS*) jest nowym pojęciem określającym możliwość trenowania modeli uczenia maszynowego wewnątrz usługi dostępnej w chmurze. Rys. 6 przedstawia przykład komunikacji z modelem udostępnionym jako MLaaS. MLaaS stanowi zewnętrzny serwis, z którym komunikacja odbywa się poprzez REST API. Możliwość komunikacji z modelem przy użyciu protokołu HTTP znacznie ułatwia możliwości na integracji z platformą wykorzystującą takie podejście, a tym samym przyczynia się do zwiększenia adopcji technologii wykorzystujących algorytmy uczenia maszynowego.




Rys. 6. Uczenie maszynowe jako usługa

REST API ujednolici sposób komunikacji z modelem. Sam model może być zbudowany przy użyciu różnych języków programowania czy bibliotek. To z kolei prowadzi do dużej fragmentaryzacji i rozproszenia zaimplementowanych algorytmów i metod statystycznych. Plik wynikowy będący reprezentacją wytrenowanego modelu może być opisany za pomocą dowolnego formatu i rozszerzenia.

3.3. Standaryzacja modeli uczenia maszynowego

Neural Network Exchange (ONNX) jest formatem standaryzującym modele uczenia maszynowego stworzonym w 2017 r. przez Microsoft, Facebook i AWS w celu ułatwienia wdrażania aplikacji wykorzystujących uczenie maszynowe [13]. ONNX Model Zoo jest kolekcją wcześniej wytrenowanych modeli w formacie ONNX, możliwych do zastosowania w obszarze klasyfikacji obrazów, detekcji obiektów, segmentacji i rozpoznawania mowy. ONNX konwertuje modele stworzone w najpopularniejszych bibliotekach takich jak TensorFlow, Keras czy MATLAB do jednego formatu. Azure Machine Learning umożliwia eksport modelu do pliku ONNX. Rys. 7 prezentuje koncepcję modelu ONNX i jego integrację z innymi technologiami.



Rys. 7. Model ONNX i możliwości jego użycia

ONNX Model Zoo z powodzeniem może być stosowany do realizowania wymagań z obszaru medycyny. Taki wybór architektoniczny pozwoli na możliwość wdrożenia rozwiązania na dowolnej chmurze i uruchomienia modelu na dowolnym systemie operacyjnym.

4. WNIOSKI

W artykule przedstawiono architekturę platformy chmurowej, której zadaniem jest przetwarzanie danych biomedycznych przy użyciu metod uczenia maszynowego. Platforma została zaimplementowana w chmurze Microsoft Azure, która zapewnia bezpieczeństwo przechowywania danych i zgodność z obowiązującymi

normami. Skuteczność algorytmów użytych do detekcji guza, mierzenia jego objętości i wizualizacji 3D została potwierdzona we wcześniejszych publikacjach. Stworzono aplikację webową do przesyłania danych do modelu oraz pokazano wykorzystanie wyników objętości guzów do kontrolowania postępu choroby.

Omówione zostały możliwości zastosowania sztucznej inteligencji w medycynie ze szczególnym uwzględnieniem pracy radiologa. Stworzone rozwiązanie nie zastąpi radiologa, ale może rekomendować diagnozę i stanowić punkt odniesienia przy podejmowaniu decyzji.

Zaproponowana architektura jest generyczna, przez co znajdzie zastosowanie do rozwiązywania problemów z użyciem metod uczenia maszynowego w chmurze Azure. Dalszy rozwój zaprezentowanej platformy zakłada użycie modeli z ONNX Zoo realizujących segmentacji obrazów, porównanie ich skuteczności i praca nad poprawieniem ich działań.

LITERATURA

- [1] Oficjalna strona internetowa brytyjskiego instytutu NICE <https://www.nice.org.uk/news/blog/1-in-2-people-will-get-cancer> (dostęp 28.02.2020).
- [2] Oficjalna strona internetowa Ministerstwa Zdrowia w Polsce <https://www.gov.pl/web/zdrowie/narodowy-program-zwalczania-chorob-nowotworowych-na-lata-2016-2024> (dostęp 28.02.2020).
- [3] Mesfin F.B., Al-Dhahir M.A., Cancer, Brain Gliomas, In: StatPearls [Internet], <https://www.ncbi.nlm.nih.gov/books/NBK441874/>, 2020.
- [4] Siwek K., Kot E., Algorytm segmentacji wyników badań CT i PET mózgu do wykrywania i wyznaczania objętości glejaka, Poznan University Of Technology Academic Journals, Poznan 2019.
- [5] Mohanta B., Das P., Patnaik S., Healthcare 5.0: A Paradigm Shift in Digital Healthcare System Using Artificial Intelligence, IOT and 5G Communication, pp. 191–196, 2020.
- [6] Shewale M. A. D., IOT based Smart and Secure Health Care System Analysis & Data Comparison, Int. J. Res. Appl. Sci. Eng. Technol., vol. 8, no. 1, pp. 394–398, 2020.
- [7] Sangeetha S., Kannimuthu S., Survey on Big Data Analytics and its Applications, Int. J. Comput. Appl., vol. 153, no. 12, pp. 9–12, 2016.
- [8] Computing M., Kumar R. S., Privacy-Preserving Healthcare Architecture Using Blockchain, vol. 9, no. 1, pp. 116–120, 2020.
- [9] Newhauser W., Jones T., Swerdloff S., Newhauser W., Cilia M., Carver R., Halloran A., Zhang R., Anonymization of DICOM electronic medical records for radiation therapy. *Computers in biology and medicine*, 53, 134–140, 2014.
- [10] Paul J., Data Masking in Cloud Computing, vol. 3085, no. 08, pp. 118–121, 2019.
- [11] Ravikumar G.K., Manjunath T.N., Hegadi R. Design of Data Masking Architecture and Analysis of Data Masking Techniques for Testing. *International Journal of Engineering Science*, 2011.
- [12] Warwick W., A Framework to Assess Healthcare Data Quality. *The European Journal of Social and Behavioural Sciences*. 13. 1730-1735., 2015.

- [13] Oficjalne repozytorium formatu ONNX z kodem źródłowym <https://github.com/onnx/models> (dostęp 28.02.2020).

ARCHITECTURE OF A PLATFORM THAT USES MACHINE LEARNING METHODS TO PROCESS BIOMEDICAL IMAGES IN THE CLOUD

This paper proposes architecture based on Microsoft Azure Cloud that uses machine learning algorithms to detect brain tumours from a set of DICOM images. The process of implementing the model is presented, including integration with the infrastructure of the unit performing medical research. Data security and limitations typical for medical data are described. Further development perspectives for the discussed solutions are indicated.

(Received: 11.03.2020, revised: 31.03.2020)