

## Uczenie maszynowe w opiece zdrowotnej

### Streszczenie

Niniejszy artykuł prezentuje wybrane zastosowania uczenia maszynowego w obszarze opieki zdrowotnej. Omówiono w nim przykładowy proces uczenia maszynowego, przedstawiono przykłady praktycznych zastosowań tego typu rozwiązań. Pokazano, że algorytmy uczenia maszynowego mogą być pomocnym narzędziem w prognozowaniu prawdopodobieństwa wystąpienia chorób czy też zaleceń odnośnie do sposobów leczenia. Podkreślono, że zastosowanie systemów uczących się w opiece zdrowotnej jest ważne nie tylko ze zdrowotnego, ale także społeczno-ekonomicznego punktu widzenia.

**Słowa kluczowe:** uczenie maszynowe, prognozowanie, opieka zdrowotna

### 1. Wprowadzenie

Problemy, które występują w opiece zdrowotnej, charakteryzują się często wysokim poziomem złożoności, są trudne do opisu i często nie posiadają odpowiednich modeli teoretycznych, które pozwalałyby je rozwiązać w sposób wiarygodny. Z jednej strony dynamiczny rozwój medycyny zachęca do poszukiwania nowych wzorców postępowania diagnostyczno-terapeutycznych. Natomiast z drugiej strony coraz większe zbiory danych utrudniają eksplorację oraz analizę danych w sposób nieautomatyczny. Stąd też w ostatnim czasie coraz więcej uwagi przywiązuje się do projektowania i rozwoju systemów uczących się, których zastosowanie obejmuje różne zagadnienia z zakresu opieki zdrowotnej. Systemy takie potrafią w sposób dynamiczny dostosowywać się do zmieniających się warunków, a co za tym idzie ułatwiać analizowanie oraz rozwiązywanie złożonych problemów<sup>2</sup>.

---

<sup>1</sup> Uniwersytet Łódzki, Katedra Informatyki Ekonomicznej, Instytut Ekonomik Stosowanych i Informatyki, Wydział Ekonomiczno-Socjologiczny, karol.korczak@uni.lodz.pl.

<sup>2</sup> Zob. np. B. Efron, T. Hastie, *Computer Age Statistical Inference: Algorithms, Evidence, and Data Science*, Cambridge University Press, New York 2016.

Celem niniejszego artykułu jest analiza wybranych zastosowań uczenia maszynowego (*Machine Learning* – ML) w opiece zdrowotnej, wskazanie korzyści wynikających z wykorzystania tego typu rozwiązań, a także określenie ich potencjału społeczno-ekonomicznego. Osiągnięcie tego celu wymagało przeprowadzenia analizy bibliograficznej oraz przeglądu rozwiązań dostępnych na rynku. Przydatne okazały się także wiedza i doświadczenie, zdobyte podczas realizacji projektu z zakresu ML.

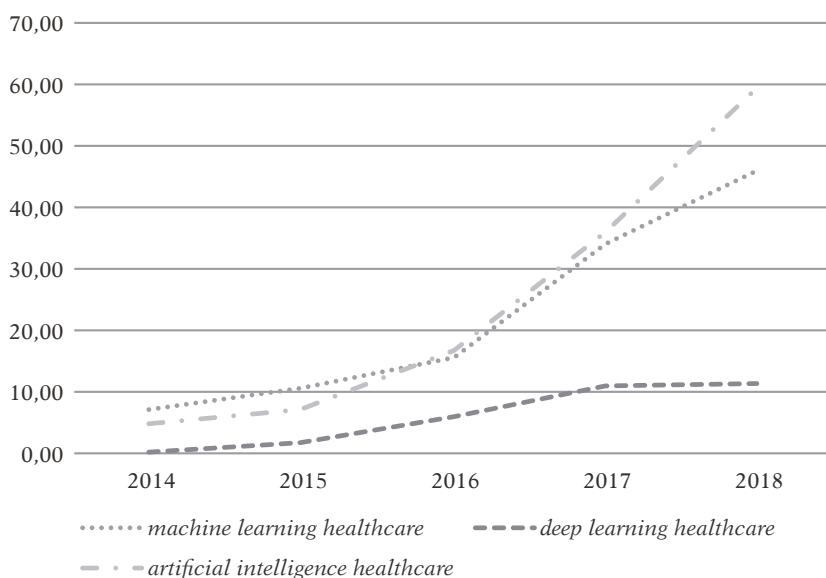
Niniejszy artykuł został podzielony na kilka zasadniczych punktów. W punkcie drugim przedstawione zostały definicje podstawowych pojęć związanych z uczeniem maszynowym. W trzecim punkcie została opisana przykładowa procedura uczenia maszynowego. Z kolei w punkcie czwartym zostały zaprezentowane wybrane przykłady zastosowań ML w opiece zdrowotnej. W ostatnim punkcie dokonano krótkiego podsumowania oraz wskazano potencjalne kierunki dalszych badań.

## 2. Podstawowe pojęcia

Wraz z dynamicznym rozwojem technologicznym pojawia się coraz więcej koncepcji wykorzystania rozwiązań z zakresu sztucznej inteligencji (*Artificial Intelligence* – AI) w różnych obszarach życia społeczno-gospodarczego, w tym także w opiece zdrowotnej. Systemy uczące się pozwalają rozwiązywać nie tylko problemy trudne do wykonania dla ludzi, ale także problemy łatwe, choć trudne w opisie formalnym (np. rozpoznawanie obrazów). Tego typu systemy bazują na algorytmach, które są w stanie – na podstawie surowych danych – wyodrębnić pewne wzorce. To z kolei pozwala im uczyć się rozwiązywania problemów oraz podejmowania decyzji, którym przypisywano do tej pory charakter subiektywny<sup>3</sup>. Wśród pojęć wchodzących w zakres sztucznej inteligencji wymienia się m.in. uczenie maszynowe oraz uczenie głębokie (*Deep Learning* – DL). Rysunek 1 przedstawia wyniki wyszukiwania zapytań w języku angielskim, kierowanych do wyszukiwarki Google. Uwzględniają one wszystkie wymienione terminy w połączeniu z wyrażeniem „opieka zdrowotna” (*healthcare*).

---

<sup>3</sup> I. Goodfellow, Y. Bengio, A. Courville, *Deep learning. Systemy uczące się*, Wydawnictwo Naukowe PWN, Warszawa 2018, s. 1–3.



**Rysunek 1. Zainteresowanie wybranymi hasłami w ujęciu czasowym**

Źródło: opracowanie własne na podstawie danych z Google Trends.

Jak widać na rysunku 1, w ostatnich latach największą popularnością wyszukiwań cieszą się hasła łączące opiekę zdrowotną z uczeniem maszynowym oraz sztuczną inteligencją.

Zagadnienie uczenia maszynowego jest znane od dawna zarówno w literaturze anglojęzycznej<sup>4</sup>, jak i polskojęzycznej<sup>5</sup>. Przyjmuje się, że zdolność komputerów do uczenia została określona mianem *Machine Learning* po raz pierwszy przez Arthura Samuela już w 1959 roku<sup>6</sup>. Jednakże w literaturze częściej jest przywoływana bardziej precyzyjna definicja tego terminu, zaproponowana przez Toma Mitchella. Według niej „mówi się, że program komputerowy uczy się z doświadczenia  $E$  w odniesieniu do pewnej klasy zadań  $T$  i miary efektywności  $P$ ,

<sup>4</sup> Zob. np. R.O. Duda, P.E. Hart, *Pattern Classification and Scene Analysis*, A Wiley-Interscience Publication, New York 1973; S. Russell, P. Norvig, *Artificial Intelligence. A Modern Approach*, Prentice-Hall, Englewood Cliffs, New Jersey 1995; J. Friedman, T. Hastie, R. Tibshirani, *The Elements of Statistical Learning*, Springer Series in Statistics, New York 2001.

<sup>5</sup> Zob. np. R.S. Michalski, *O naturze uczenia się – problemy i kierunki badawcze (1)*, „Informatyka” 1988, nr 2; P. Cichosz, *Systemy uczące się*, Wydawnictwa Naukowo-Techniczne, Warszawa 2000; M. Krzyśko, W. Wołyński, T. Górecki, M. Skorzybut, *Systemy uczące się. Rozpoznawanie wzorców, analiza skupień i redukcja wymiarowości*, Wydawnictwa Naukowo-Techniczne, Warszawa 2008.

<sup>6</sup> A.L. Samuel, *Some Studies in Machine Learning Using the Game of Checkers*, „IBM Journal of research and development” 1959, 3(3), s. 210–229.

jeżeli jego efektywność wykonywania zadań  $T$ , mierzona przez  $P$ , poprawia się wraz z doświadczeniem  $E$ "<sup>7</sup>. W praktyce ML jest bardzo często wykorzystywany przy budowie modeli predykcyjnych. Uczenie na podstawie danych pozwala zmieniać algorytm uczący, a co za tym idzie zwiększać precyzję prognoz.

Z kolei uczenie głębokie ma zastosowanie w rozwiązywaniu problemów bardziej złożonych, gdzie oprócz rozwiązania problemu, pojawiają się także trudności z uzyskaniem reprezentatywnych informacji z danych wejściowych algorytmu. Opiera się ono na sztucznych sieciach neuronowych (*Artificial Neural Network* – ANN). DL pozwala komputerowi na budowanie skomplikowanych pojęć na podstawie pojęć prostszych. Dekompozycja złożonych odwzorowań na serię odwzorowań prostszych, opisanych w różnych warstwach modelu, umożliwia rozwiązywanie nawet najbardziej skomplikowanych problemów<sup>8</sup>. Przykładem zastosowania DL może być analiza obrazów medycznych.

### 3. Przykładowa procedura uczenia maszynowego

Uczenie maszynowe, w zależności od zadanego problemu oraz danych wejściowych, może mieć charakter nadzorowany lub nienadzorowany. W pierwszym przypadku są znane dane wejściowe (wektory zmiennych  $X$ ) oraz ich dane wyjściowe (wektor zmiennej  $Y$ ), a algorytm uczy się funkcji mapowania zmiennych  $X$  do  $Y$ . Z kolei w drugim przypadku są znane dane wejściowe oraz nie są znane dane wyjściowe. Wówczas algorytm musi samodzielnie odkryć wzorce i relacje między danymi. Rysunek 2 przedstawia przykładową procedurę uczenia nadzorowanego. Uczenie w tym przypadku odbywa się jeden raz w miesiącu.

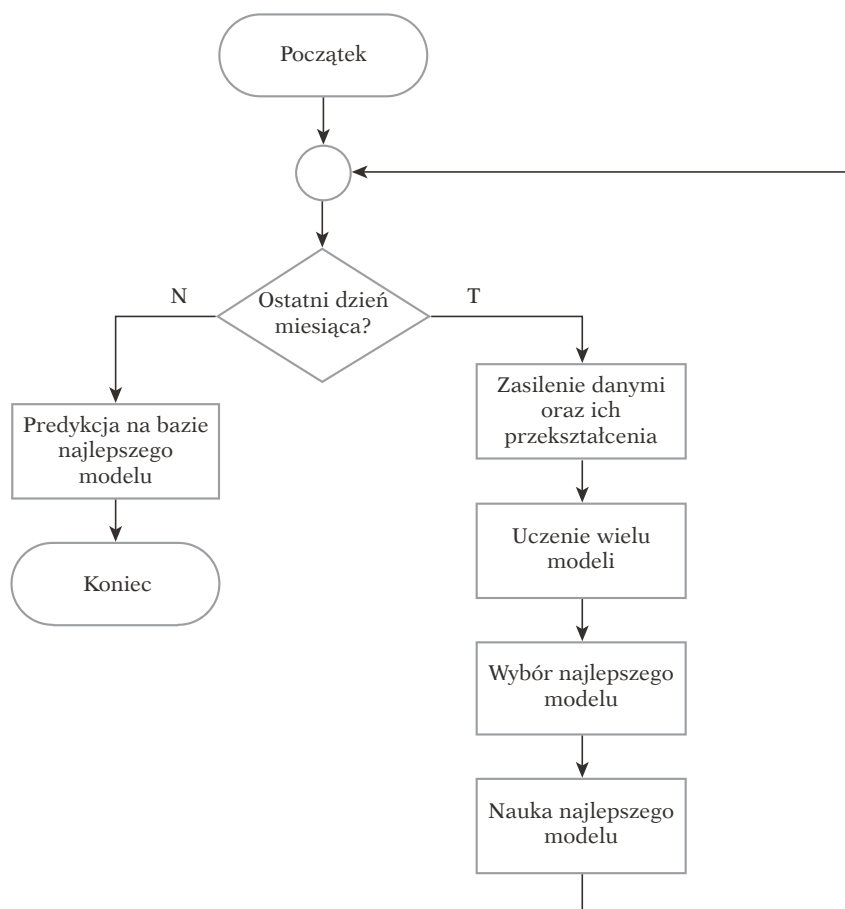
Pierwszy etap w przedstawionej na rysunku 2 procedurze uczenia maszynowego polega na zasileniu algorytmu danymi oraz dokonaniu ich przekształceń. Definiowanie zmiennych wejściowych może być związane z koniecznością wykonania przekształceń danych, polegających na przykład na wyliczaniu pożądaných wartości za pomocą formuł, standaryzacji danych, konwersji typów danych, definiowaniu własnych flag (kodowaniu zmiennych zero-jedynkowych) czy też uzupełnianiu braków danych. Zbiory zmiennych mogą być ustalane z wykorzystaniem metod automatycznego doboru zmiennych. Badacz może także definiować

---

<sup>7</sup> T.M. Mitchell, *Machine Learning*, McGraw-Hill Education, New York 1997, s. 2 [w tłumaczeniu autora].

<sup>8</sup> I. Goodfellow, Y. Bengio, A. Courville, *Deep learning...*, op. cit., s. 5–14.

własne zbiory zmiennych (specyfikacje), które będą wykorzystywane w procesie uczenia algorytmu. W tym etapie dokonuje się także wyboru algorytmów, tj. matematycznych metod rozwiązywania danego problemu. W przypadku uczenia nadzorowanego są to najczęściej problemy regresji lub klasyfikacji. Przykładem może być zastosowanie regresji logistycznej do wspomagania podejmowania decyzji odnośnie do zalecania cesarskiego cięcia<sup>9</sup>. W wyniku połączenia metody oraz zbioru zmiennych otrzymujemy model.




**Rysunek 2. Przykładowa procedura uczenia maszynowego**

Źródło: opracowanie własne.

<sup>9</sup> S. Mor-Yosef, A. Samueloff, B. Modan, D. Navot, J.G. Schenker, *Ranking the Risk Factors for Cesarean: Logistic Regression Analysis of a Nationwide Study*, „Obstetrics and Gynecology” 1990, 75(6), s. 944–947.

Drugi etap polega na nauce wszystkich modeli (metod oraz zbiorów zmiennych). Proces uczenia wymaga dokonania podziału próby na próbę uczącą<sup>10</sup> oraz próbę testową. Zakres próby ustala się w zależności od analizowanego zagadnienia. Przykładowy podział zaprezentowano na rysunku 3.



**Rysunek 3. Podział próby w eksperymentach prognostycznych**

Źródło: opracowanie własne.

Najpierw wykonuje się uczenie dla próby uczącej (dane z próby uczącej). W jego wyniku uzyskuje się oszacowania parametrów przy zmiennych objaśniających w każdym modelu<sup>11</sup>. Następnie jest dokonywana predykcja dla próby testowej (dane z próby testowej, parametry z próby uczącej).

Etap trzeci to ocena zdolności predykcyjnej modeli oraz wybór najlepszego modelu spośród wszystkich modeli, które poddano procesowi uczenia. W ten sposób jest wybierany model optymalny, tj. taki, który jest najlepiej dopasowany do danych z próby uczącej oraz ma najlepszą zdolność predykcyjną na zbiorze testowym. W przypadku regresji pod uwagę bierze się wartości błędów prognozy. Zazwyczaj jest to średni procentowy błąd (*Mean Percentage Error* – MPE), średni błąd bezwzględny (*Mean Absolute Error* – MAE) czy też średni bezwzględny błąd procentowy (*Mean Absolute Percentage Error* – MAPE). Im mniejsza wartość błędu, tym lepsza jakość predykcyjna modelu. Do oceny jakości modeli można wykorzystać zbiorcze miary jakości klasyfikacji, takie jak współczynnik trafności, precyzja klasyfikacji pozytywnej, precyzja klasyfikacji negatywnej czy też współczynnik F1.

W czwartym etapie jest dokonywane uczenie najlepszego modelu na pełnej próbie. Do tego celu wykorzystuje się dane z pełnej próby.

<sup>10</sup> Inaczej nazywanej próbą treningową.

<sup>11</sup> Oprócz parametrów występują także hiperparametry, które są wykorzystywane do sterowania procesem uczenia. Są one ustalane przez osobę nadzorującą ten proces.

Ostatni etap polega na dokonywaniu predykcji na bazie najlepszego modelu. Predykcję przeprowadza się na podstawie danych z pełnej próby oraz z wykorzystaniem parametrów z tej próby (uzyskanych w etapie czwartym). Generowanie rzeczywistych prognoz odbywa się w zależności od potrzeb decyzyjnych. Wracając do przykładu zaleceń cesarskich cięć, wskazywanie podpowiedzi może mieć miejsce dla każdej pacjentki w ciąży. Przy okazji system gromadzi kolejne dane, dzięki którym w przyszłości będzie można sugerować jeszcze dokładniejsze podpowiedzi.

#### 4. Przykłady wykorzystania ML w opiece zdrowotnej

Uczenie maszynowe wykorzystuje się do rozwiązywania różnych problemów w opiece zdrowotnej. Systemy uczące można spotkać w różnych podmiotach wykonujących działalność leczniczą oraz instytucjach związanych z sektorem zdrowia. Dalej przedstawiono kilka wybranych przykładów.

Pierwszy przykład wykorzystania technik ML w opiece zdrowotnej dotyczy możliwości prognozowania konieczności przyjęć do szpitali oraz rozpoczęcia stosowania kortykosteroidów. W analizach wykorzystano dane z programu COPD (*Chronic Obstructive Pulmonary Disease*). Obejmowały one 363 dni telemonitoringu 135 pacjentów. Ponadto dokonano połączenia bazy danych z telemonitoringu pacjentów z danymi na temat pogody. W wyniku przeprowadzonego badania okazało się, że zarówno standardowe algorytmy szacowania symptomów, jak i algorytmy uczenia maszynowego były dokładne w przewidywaniu decyzji o rozpoczęciu stosowania kortykosteroidów z 24-godzinnym wyprzedzeniem. Natomiast w przypadku prognozowania konieczności przyjęć do szpitala ML dostarczał dużo lepsze wyniki niż uwzględnione w badaniu metody tradycyjne. Ponadto wskazano, że uzyskiwanie bardziej dokładnych algorytmów ML wymaga dostępu do większych (np. międzynarodowych) baz danych<sup>12</sup>.

Kolejny przykład dotyczy wykorzystania ML w analizie dużego zbioru danych (*Big Data*) medycznych, pochodzących z wybranego szpitala w Chinach. Dane obejmowały ponad 20 mln rekordów medycznych ponad 30 tys. pacjentów

---

<sup>12</sup> P. Orchard, A. Agakova, H. Pinnock, C.D. Burton, C. Sarran, F. Agakov, B. McKinstry, *Improving Prediction of Risk of Hospital Admission in Chronic Obstructive Pulmonary Disease: Application of Machine Learning to Telemonitoring Data*, „Journal of Medical Internet Research” 2018, 20(9), e263.

(w latach 2013–2015). Zaproponowany algorytm uczący się miał za zadanie prognozowanie ryzyka udaru mózgu wśród pacjentów szpitala. Wczesne zakwalifikowanie pacjenta do grupy podwyższonego ryzyka pozwala odpowiednio wcześniej podejmować działania, które będą miały na celu ograniczenie ryzyka wystąpienia poważnych w skutkach zaburzeń czynności mózgu. Kluczowym wyzwaniem, wpływającym na jakość prognoz, było w tym przypadku połączenie danych ustrukturyzowanych z nieustrukturyzowanymi danymi tekstowymi (np. opis rozpoznania choroby). Przeprowadzenie eksperymentów prognostycznych wymagało także zastosowania odpowiednich metod, pozwalających uzupełnić braki danych<sup>13</sup>.

Innym przykładem może być zastosowanie ML do prognozowania prawdopodobieństwa odrzucenia przeszczepu nerki. Badanie obejmowało grupę 378 pacjentów z Iranu (w latach 1994–2011). W tym przypadku sztuczne sieci neuronowe okazały się lepszym narzędziem prognostycznym niż regresja logistyczna. Zidentyfikowano najważniejsze czynniki prognostyczne dla tego zjawiska. Były wśród nich: wiek pacjenta, poziom kreatyniny, czas zimnego niedokrwienia nerki i poziom hemoglobiny podczas wypisu. Przewidywanie niepowodzeń przeszczepów może przyczynić się do zwiększenia przeżywalności pacjentów oraz poprawy jakości ich życia<sup>14</sup>.

W nawiązaniu do definicji pojęć omówionych w punkcie drugim warto przedstawić także przykład zastosowania w opiece zdrowotnej uczenia głębokiego. Dotyczy on przewidywania wyniku przeszczepu serca. W analizach wykorzystano dane z rejestru UNOS (*United Network for Organ Sharing*). Obejmowały one ponad 27 tys. rekordów pacjentów (w latach 2009–2011). Także i w tym przypadku model głębokiego uczenia okazał się lepszym narzędziem prognozowania śmiertelności pacjentów w krótkim okresie niż wspomniana wcześniej regresja logistyczna. Wyniki tego modelu zostały upublicznione w postaci internetowego narzędzia, które może być używane w celu dopasowywania odbiorcy oraz dawcy narządów<sup>15</sup>.

W celu dopełnienia powyższego przeglądu zostanie także przedstawiony przykład rozwiązania, które łączy w sobie algorytmy uczenia maszynowego

<sup>13</sup> M. Chen, Y. Hao, K. Hwang, L. Wang, L. Wang, *Disease Prediction by Machine Learning over Big Data from Healthcare Communities*, „IEEE Access” 2017, 5, s. 8869–8879.

<sup>14</sup> L. Tapak, O. Hamidi, P. Amini, J. Poorolajal, *Prediction of Kidney Graft Rejection Using Artificial Neural Network*, „Healthcare Informatics Research” 2017, 23(4), s. 277–284.

<sup>15</sup> D. Medved, M. Ohlsson, P. Höglund, B. Andersson, P. Nugues, J. Nilsson, *Improving Prediction of Heart Transplantation Outcome Using Deep Learning Techniques*, „Scientific Reports” 2018, 8(1), 3613.



oraz uczenia głębokiego. Przykład dotyczy wykorzystania ML i DP w diagnostyce nowotworowej w ramach elektronicznej platformy wrocławskiego Cancer Center. Opracowane w tym centrum algorytmy pozwalają m.in. dokonywać segmentacji obrazów, znajdować obszary zainteresowania (*Region of Interest* – ROI), generować statystyczne opisy obrazów czy też zliczać oraz rozpoznawać typ komórek. Wykorzystuje się je do analizy obrazów medycznych w onkologii i radiologii, a w szczególności do analizy próbek tkanek w ramach badań histopatologicznych, analizy obrazów uzyskanych metodami rezonansu magnetycznego (*Magnetic Resonance Imaging* – MRI) oraz pozytonowej tomografii emisyjnej (*Positron Emission Tomography* – PET). Algorytmy te pozwalają lekarzom uzyskać dodatkowe opinie o obrazach oraz dokonać weryfikacji wstępnej diagnozy. Dzięki temu można szybciej postawić właściwą diagnozę, podjąć właściwe leczenie i nie narażać pacjenta na dodatkowy stres<sup>16</sup>.

Podsumowując, wykorzystanie algorytmów prognostycznych z zakresu ML zwiększa szanse m.in. wczesnego wykrywania chorób i zagrożeń zdrowia pacjentów czy też wspomaga podejmowanie decyzji klinicznych oraz planowanie działań profilaktycznych. Działania takie pozwalają pacjentom dłużej zachować sprawność fizyczną oraz intelektualną, a także poprawiać jakość ich życia. Warto podkreślić, że działania takie mają istotne znaczenie nie tylko ze zdrowotnego, ale także społeczno-ekonomicznego punktu widzenia. Dłuższe życie w zdrowiu pozwala jednostkom dłużej pozostać aktywnym w życiu społecznym i zawodowym. Od zdrowia jednostek zależy kondycja populacji. Ponadto porównując koszty profilaktyki oraz koszty medycyny naprawczej, warto szukać dobrych rozwiązań ML, których powszechne zastosowanie może mieć korzystny wpływ także na kondycję finansową systemu opieki zdrowotnej. Analiza przytoczonych przykładów pokazuje, że wykorzystanie w pełni potencjału ML zależy w dużej mierze od wielkości zbiorów danych historycznych, ich aktualizacji, a także jakości danych, które się w nich znajdują.

## 5. Podsumowanie i kierunki dalszych badań

W niniejszym artykule przedstawiono zagadnienie uczenia maszynowego oraz możliwości zastosowania tego typu rozwiązań w opiece zdrowotnej. Samo zagadnienie ML jest znane od dawna. Niemniej jednak dopiero w ostatnich latach

---

<sup>16</sup> cancercenter.ai (data odczytu: 25.11.2018).

zagadnienie to zyskało na popularności. Dzisiejsze rozwiązania technologiczne pozwalają na szybkie wykonywanie nawet najbardziej skomplikowanych obliczeń. Połączenie medycyny i technologii było tematem „uśpionym” przez lata i wiele wskazuje na to, że okres ten właśnie się kończy. W uczeniu maszynowym drzemie ogromny potencjał, z którego mogą korzystać wszyscy interesariusze systemu opieki zdrowotnej.

Obecnie w Polsce jest realizowanych wiele projektów z zakresu e-zdrowia. Występują one na różnych poziomach zarządzania, od inicjatyw indywidualnych, przez projekty lokalne, regionalne i krajowe, aż po przedsięwzięcia w ramach opieki transgranicznej. Bardzo często zakładają one wdrożenie standardów w zakresie komunikowania się różnych podmiotów realizujących zadania z zakresu opieki zdrowotnej oraz wymiany danych między nimi. Standaryzacja baz danych, ich łączenie czy też tworzenie baz centralnych pozwalają spojrzeć na pewne problemy z szerszej perspektywy. Z pewnością warto wykorzystać takie źródła danych i zasilać nimi algorytmy uczące się<sup>17</sup>. Dzięki temu personel medyczny będzie miał dostęp do dokładniejszych oraz bardziej reprezentatywnych informacji, które będą obejmowały całe grupy lub populacje pacjentów z podobnymi schorzeniami.

Wydaje się, że jednym z podstawowych kierunków rozwoju ML w opiece zdrowotnej, będzie opracowanie algorytmów uczących się dla kolejnych jednostek chorobowych. W przypadku jednostek, których specyfika jest podobna, można próbować zaadaptować istniejące już algorytmy. Niemniej jednak w rzeczywistości istnieje wiele jednostek chorobowych, które wymagają indywidualnego spojrzenia i opracowania zupełnie nowych algorytmów.

## Bibliografia

- Chen M., Hao Y., Hwang K., Wang L., Wang L., *Disease Prediction by Machine Learning Over Big Data from Healthcare Communities*, „IEEE Access” 2017, 5, 8869–8879.
- Cichosz P., *Systemy uczące się*, Wydawnictwa Naukowo-Techniczne, Warszawa 2000.
- Duda R.O., Hart P.E., *Pattern Classification and Scene Analysis*, A Wiley-Interscience Publication, New York 1973.

---

<sup>17</sup> Przykładem tego typu inicjatywy może być polsko-niemiecka platforma Medical 4.0. Jej zadaniem jest zapewnienie odpowiedniego (łatwego, szybkiego, bezpiecznego) dostępu do danych dla algorytmów DP oraz ML. Więcej na ten temat w: N. Labuda, T. Lepa, M. Labuda, K. Kozak, *Medical 4.0: Medical Data Ready for Deep and Machine Learning*, „Journal of Bioanalysis & Biomedicine” 2017, 9(6), s. 283–287.

- Efron B., Hastie T., *Computer Age Statistical Inference: Algorithms, Evidence, and Data Science*, Cambridge University Press, New York 2016.
- Friedman J., Hastie T., Tibshirani R., *The Elements of Statistical Learning*, Springer Series in Statistics, New York 2001.
- Goodfellow I., Bengio Y., Courville A., *Deep learning. Systemy uczące się*, Wydawnictwo Naukowe PWN, Warszawa 2018.
- Krzyśko M., Wołyński W., Górecki T., Skorzybut M., *Systemy uczące się. Rozpoznawanie wzorców, analiza skupień i redukcja wymiarowości*, Wydawnictwa Naukowo-Techniczne, Warszawa 2008.
- Labuda N., Lepa T., Labuda M., Kozak K., *Medical 4.0: Medical Data Ready for Deep and Machine Learning*, „Journal of Bioanalysis & Biomedical” 2017, 9(6), 283–287.
- Medved D., Ohlsson M., Höglund P., Andersson B., Nugues P., Nilsson J., *Improving Prediction of Heart Transplantation Outcome Using Deep Learning Techniques*, „Scientific Reports” 2018, 8(1), 3613.
- Michalski R.S., *O naturze uczenia się – problemy i kierunki badawcze (1)*, „Informatyka” 1988, nr 2.
- Mitchell T.M., *Machine Learning*, McGraw-Hill Education, New York 1997.
- Mor-Yosef S., Samueloff A., Modan B., Navot D., Schenker J.G., *Ranking the Risk Factors for Cesarean: Logistic Regression Analysis of a Nationwide Study*, „Obstetrics and Gynecology” 1990, 75(6), 944–947.
- Orchard P., Agakova A., Pinnock H., Burton C.D., Sarran C., Agakov F., McKinstry B., *Improving Prediction of Risk of Hospital Admission in Chronic Obstructive Pulmonary Disease: Application of Machine Learning to Telemonitoring Data*, „Journal of Medical Internet Research” 2018, 20(9), e263.
- Russell S., Norvig P., *Artificial Intelligence. A Modern Approach*, Prentice-Hall, Englewood Cliffs, New Jersey 1995.
- Samuel A.L., *Some Studies in Machine Learning Using the Game of Checkers*, „IBM Journal of Research and Development” 1959, 3(3), 210–229.
- Tapak L., Hamidi O., Amini P., Poorolajal J., *Prediction of Kidney Graft Rejection Using Artificial Neural Network*, „Healthcare Informatics Research” 2017, 23(4), 277–284.

## Źródło internetowe

cancercenter.ai.

\* \* \*

## Machine learning in healthcare

### **Abstract**

This article presents selected applications of machine learning (ML) in the area of healthcare. An exemplary machine learning process is discussed, examples of practical ML applications are presented. It has been shown that machine learning algorithms can be a helpful tool in predicting the likelihood of disease or recommendations for treatment. It was emphasized that the use of machine-learned systems in healthcare is important not only from the health, but also from the socio-economic point of view.

**Keywords:** machine learning, forecasting, healthcare