



# Zastosowania narzędzi SI w nauce

Michał Kruk

# Zastosowania narzędzi SI w nauce

- Szkoła Główna Gospodarstwa Wiejskiego w Warszawie jest idealnym miejscem do wdrażania narzędzi sztucznej inteligencji w zastosowaniach naukowych
- Powodem tego jest ogromna liczba dyscyplin naukowych, które mogą być wspierane przez AI
- Wszędzie gdzie praca naukowa opiera się na danych w postaci obrazów, sygnałów, szeregów czasowych lub danych statystycznych można wprowadzić metody uczenia maszynowego
- Najnowsze osiągnięcia (NLP) pozwalają również stosować AI wszędzie tam, gdzie mamy do czynienia z tekstem
- Przykłady pokazane w prezentacji pochodzą z pracy własnej autora i zostały wybrane, aby najlepiej pokazać możliwość zastosowania SI w różnych dyscyplinach. Nie oznacza to jednak, że inteligentne metody tylko tam mają zastosowanie.
- **SI to nie tylko NLP (ChatGPT)!!!!**




# SI w nauce

- **Rozpoznawanie obrazów i analiza wizualna:** Klasyfikacja obrazów lub obiektów w obrazach. Obrazowanie biomedyczne, satelitarne, mapy, plany.
- **Analiza sygnałów** – Zastosowanie do prognozowania lub klasyfikacji sygnałów pochodzących od urządzeń np. wiertel, frezarek.
- **Prognozowanie** – Meteorologia, giełda
- **Przetwarzanie i analiza dużych zbiorów danych:** Analiza ogromnych zbiorów danych naukowych, wykrywanie wzorców, zrozumienie zależności i wnioskowanie na podstawie danych. Klasyfikacja, regresja, klastrowanie i prognozowanie.
- **Modelowanie i symulacje:** Modelowanie złożonych zjawisk i symulowania procesów, które są trudne do zbadania w rzeczywistości. Na przykład, uczenie maszynowe może pomóc w symulowaniu reakcji chemicznych, prognozowaniu pogody, modelowaniu ekosystemów itp.
- **Genetyka:** SI jest używana do analizy genomów, identyfikacji biomarkerów chorób oraz symulowania interakcji leków z białkami i innymi cząsteczkami.
- **Wsparcie w podejmowaniu decyzji:** Systemy SI mogą wspomagać w podejmowaniu decyzji poprzez analizę danych, generowanie rekomendacji, modelowanie alternatywnych scenariuszy itp.
- **Rozpoznawanie mowy i przetwarzanie języka naturalnego:** Narzędzia SI mogą być wykorzystywane do analizy tekstu, identyfikacji trendów, analizy sentymentu wśród badanych itp.

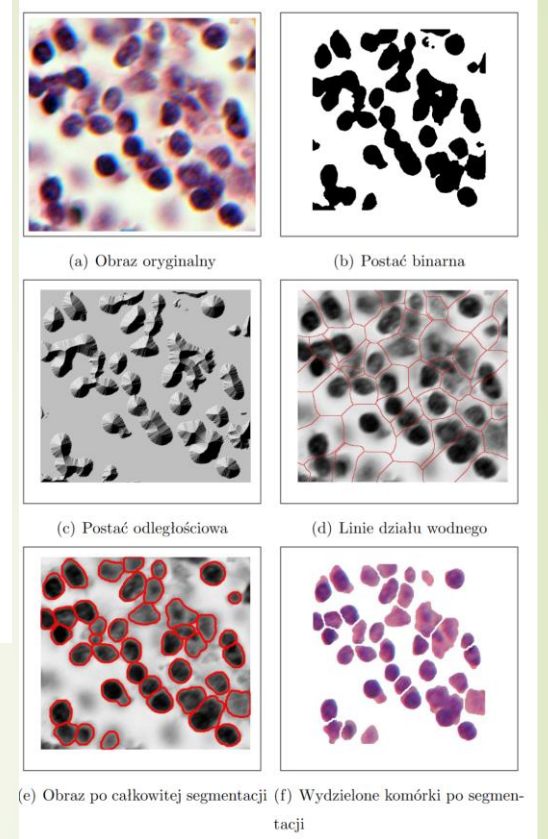
# Dwa podejścia

- Klasyczne
  - Zalety:
    - Uczy my model od początku
    - Potrzebny mniejszy zbiór danych
    - Wskazujemy najważniejsze cechy obiektów
  - Wady:
    - Konieczność generowania cech
    - Często trudność w segmentacji obiektów w obrazach

Przykłady: MLP, RBF, SVM, Drzewa i lasy losowe, klasyfikatory odległościowe – kNN, analizy dyskryminacyjne – LDA, QDA, SDA



Rys. 4.1. Ilustracja kolejnych etapów ekstrakcji komórek krwiotwórczych poprzez operacje morfologiczne: a) obraz wejściowy, b) obraz binarny, c) wynik filtracji morfologicznej, d) odwrotna mapa odległości, e) wynik działania operacji działów wodnych, f) wydzielone komórki





# Dwa podejścia

- ▶ Głębokie

- ▶ Zalety


- ▶ Brak cech
    - ▶ Brak konieczności segmentacji

- ▶ Wady

- ▶ Do zbudowania modelu od początku wymagane są ogromne ilości (rzędu milionów) danych - możliwość zastosowania transfer learningu
    - ▶ Korzystamy z gotowych modeli, nie budujemy od początku



Przykłady: Sieci konwolucyjne (Convolutional Neural Networks - CNN), Rekurencyjne sieci neuronowe (Recurrent Neural Networks - RNN), Sieci typu Long Short-Term Memory (LSTM), Sieci generatywne przeciwdziałające sieciom (Generative Adversarial Networks - GAN)

# Metody łączone



- Modele można łączyć
- Końcowy wynik działania może być wynikiem głosowania poszczególnych modeli (lub głosowania ważonego)

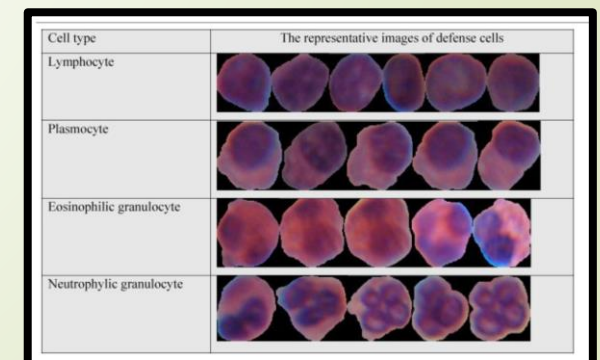
# Przykład – system wspierający diagnostykę chorób idiopatycznych jelit




- Automatyczny system rozpoznający i zliczający komórki obronne organizmu w podścielisku tkanki:
  - Limfocyty
  - Plazmocyty
  - Granulocyty kwasochłonne
  - Granulocyty obojętnochłonne
- Im większy naciek, tym większy stan zapalny
- Istotne wykrycie granulocytów, zwłaszcza obojętnochłonnych
- Dokładność systemu 92%

Table 7. The confusion matrix of the best ensemble (PCA) of classifiers at the testing data.

	L	P	E	N
L	490	13	4	4
P	11	390	9	10
E	2	4	243	4
N	4	6	5	172



# Przykład - system wspierający diagnostykę raka nerki, zestawienie z ekspertami



**Table VI** *Cohen Kappa Values for the Results of Recognition of 4 Fuhrman Grades (4-Tiered System)*


	AS	Expert 1	Expert 2	Expert 3
AS	—	0.4246	0.5049	0.4230
Expert 1	0.4246	—	0.3660	0.2499
Expert 2	0.5049	0.3660	—	0.2476
Expert 3	0.4230	0.2499	0.2476	—

**Table VII** *Cohen Kappa Values for the Results of Recognition of Two Cumulated Fuhrman Grades (Two-tiered System)*

	AS	Expert 1	Expert 2	Expert 3
AS	—	0.6299	0.6284	0.4585
Expert 1	0.6299	—	0.5015	0.4310
Expert 2	0.6284	0.5015	—	0.3394
Expert 3	0.4584	0.4310	0.3394	—




# Segmentacja i parametryzacja struktur histologicznych w obrazach mikroskopowych prostaty dla oceny skali Gleasona



- Wykrywanie struktur histologicznych wycinków prostaty
- Na podstawie wykrytych obiektów ocena nowotworu prostaty w skali Gleasona

# Przykłady rozwiązań: rozpoznanie mikroorganizmów glebowych




► Dokładność klasyfikacji przypadku 12 klas: 98,41%

► Dokładność klasyfikacji w przypadku 13 klas (12 zdefiniowanych mikroorganizmów + nieokreślona klasa mieszana złożona z 5 innych gatunków): 97,96%

# Przykłady rozwiązań - rozpoznanie rodzajów gleby

- ▶ Cel: Stworzenie systemu automatycznej klasyfikacji rodzajów gleby na podstawie zdjęć
- ▶ Przykład rozpoznania 12 klas gleby (opracowane metody przetwarzania umożliwiły uzyskanie blisko 100% dokładności)



# Przykład – zastosowanie pudełkowego wymiaru fraktalnego do rozpoznawania zmian ciśnieniowych w obrazach dna oka

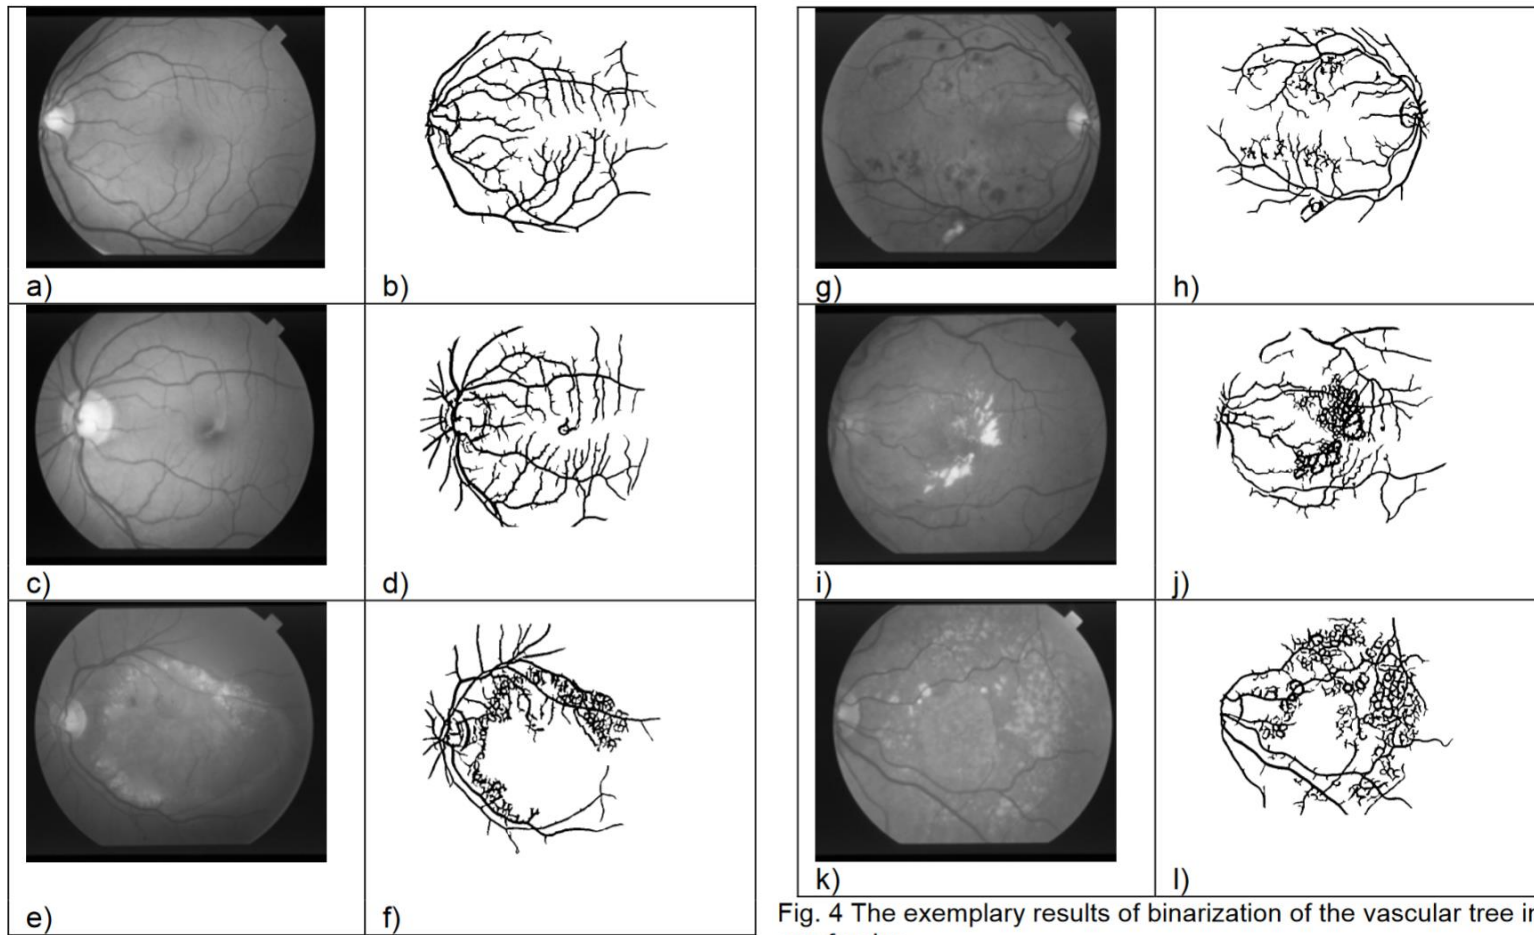



Fig. 4 The exemplary results of binarization of the vascular tree in eye fundus

Table 3 The confusion matrix of the classification of the healthy versus non-healthy on the basis of box-counting dimension

	Healthy	Non-healthy
Healthy	40	3
Non-healthy	5	76

# Meblarstwo – wykrywanie wad lakieru

Fig. 2.



Examples of images of the surfaces belonging to three classes: (a) very good, (b) good and (c) bad.


► Pokrycie lakierem, od lewej:

- Prawidłowe
- Dobre
- Złe

Tab. 1. Confusion matrix  $C_{ij}$  for the three classes: *good*  $c = 1$ , *acceptable*  $c = 2$  and *bad*  $c = 3$ .

	$c$	Actual class		
		1	2	3
Classification result	1	275	2	0
	2	7	274	3
	3	0	2	245

# Segmentacja mięśnia wołowiny za pomocą głębokiej sieci neuronowej



➤ Kolumny od lewej:

➤ Zdjęcia surowe

➤ Segmentacja poprzez AI

➤ Ground truth



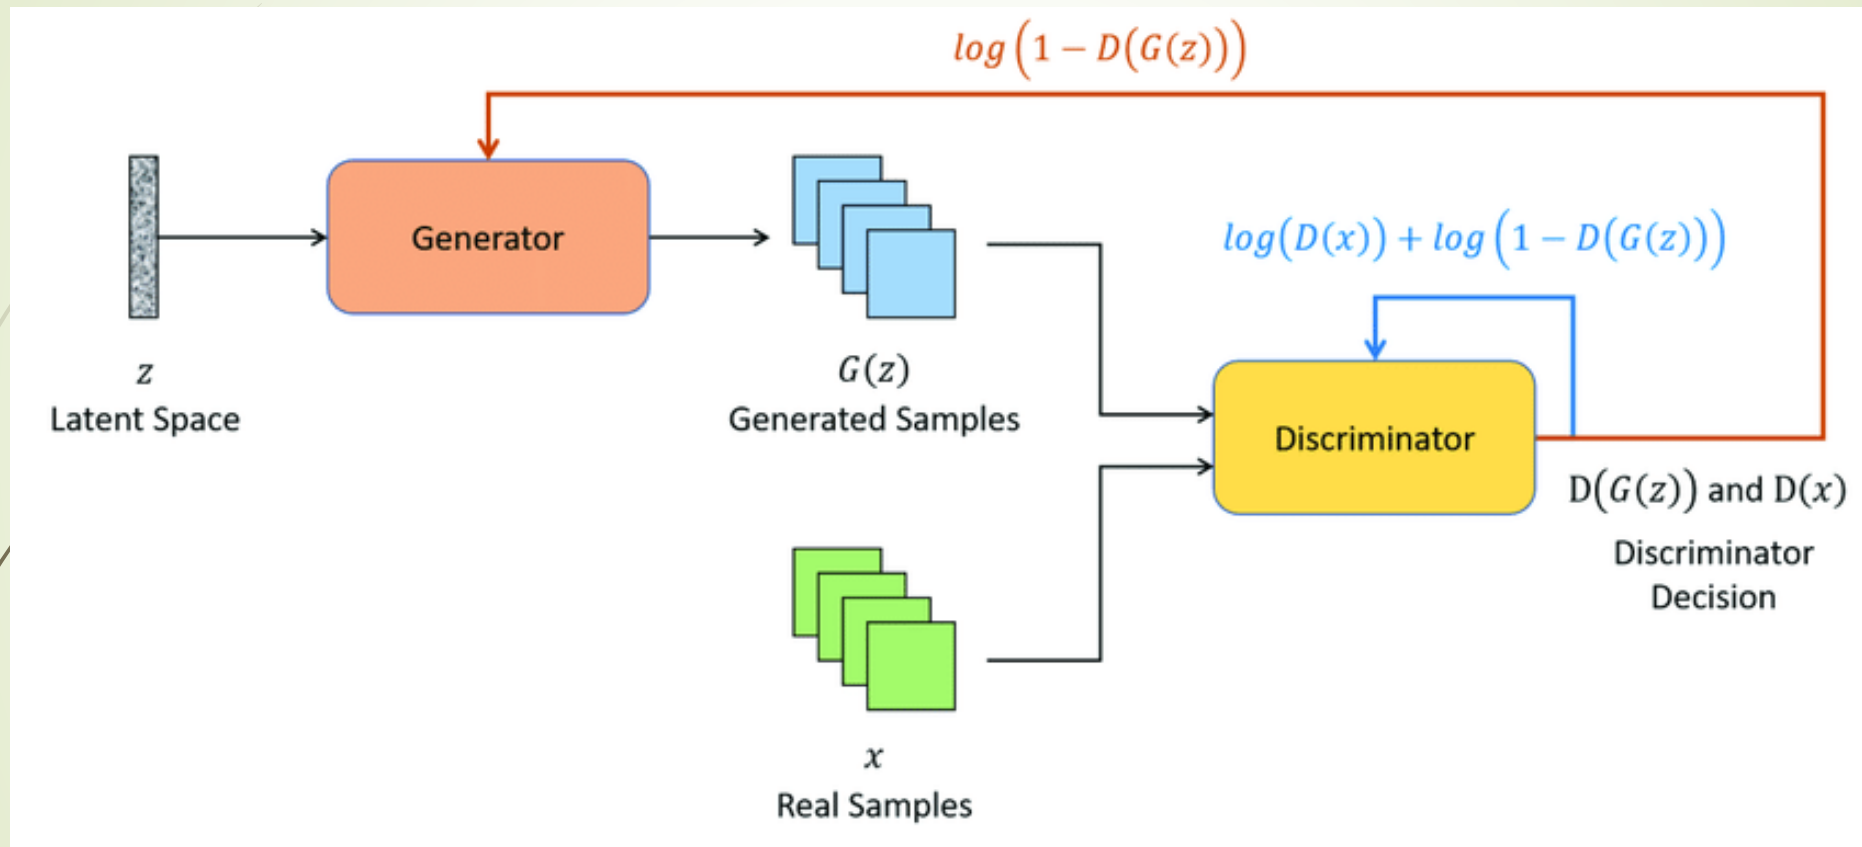


# Co w przypadku małego zbioru danych? - augmentacja

- Augmentacja klasyczna – np. interpolacja, przekształcenia geometryczne (obroty, przesunięcie)
- Augmentacja poprzez sieci GANa



## Architektura GAN




Architektura GAN składa się z dwóch sieci – Generatora i Dyskryminatora. Dyskryminator dostaje na wejściu dane z oryginalnego zestawu lub wygenerowane przez Generator i jego celem jest odróżnienie prawdziwych od syntetycznych. Celem Generatora jest oszukanie Dyskryminatora by nie był w stanie odróżnić generowane dane od prawdziwych.

## Problem dostępności danych medycznych

Na potrzeby stosowania sztucznej inteligencji w rozwiązaniach medycznych jednym z największych wyzwań stanowi dostępność danych do uczenia modeli.

Wiąży się to z wieloma czynnikami:

- Prywatność danych osobowych pacjentów.
- Wysoka cena prowadzenia badań.
- Rzadkość niektórych chorób.
- Złe zbalansowanie zbioru danych
- Różnice charakterystyk i konfiguracji sprzętu, na którym robione są badania.



Przykładowe skany RTG klatki piersiowej pacjentów z COVID-19 z COVID-19 Radiography Database<sup>1</sup>. Różnorodność skanów oraz niewielka ilość dostępnych danych utrudnia trenowanie modeli uczenia maszynowego, które by mogły diagnozować COVID-19 automatycznie, wspomagać podejmowanie decyzji w zależności od stanu pacjenta, itd.

<sup>1</sup> -M.E.H. Chowdhury, T. Rahman, A. Khandakar, R. Mazhar, M.A. Kadir, Z.B. Mahbub, K.R. Islam, M.S. Khan, A. Iqbal, N. Al-Emadi, M.B.I. Reaz, M. T. Islam, "Can AI help in screening Viral and COVID-19 pneumonia?" IEEE Access, Vol. 8, 2020, pp. 132665 - 132676.

-Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S.B.A., Islam, M.T., Maadeed, S.A., Zughair, S.M., Khan, M.S. and Chowdhury, M.E., 2020. Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection using Chest X-ray Images.

## Potencjalne rozwiązanie - Generatywne Sieci Przeciwstawne (GAN)

Generative Adversarial Network (GAN) – rodzaj sieci neuronowej służącej do generowania syntetycznych danych na podstawie już istniejących. Ta koncepcja wymyślona przez Iana Goodfellowa w 2014 roku<sup>2</sup> i od tego momentu rozwinęła się wielokrotnie.

Najnowsze wersje architektury GAN pozwalają generować syntetyczne obrazy nieodróżnialne od prawdziwych.



Syntetyczne skany RTG klatki piersiowej pacjentów z COVID-19 wygenerowane na podstawie zbioru danych z poprzedniego slajdu. Wygenerowane obrazki zapełniają jakość danych zbliżonych do oryginalnych, anonimowość pacjentów (ludzie z obrazków tak naprawdę nie istnieją) oraz dużą ilość dostępnych danych (ilość generowanych obrazków ograniczona jest przez jedynie pojemność dysku twardego).



# Inne zastosowania

- ▶ NLP – natural language processing – Chat GPT
  - ▶ Przydatny wszędzie tam, gdzie potrzeba dużo tekstu
    - ▶ Raport PKA
    - ▶ Opisy wniosków
    - ▶ Tłumaczenia
  - ▶ Zawsze należy dokładnie zweryfikować wygenerowany tekst, dodać szczegóły
  - ▶ Często generuje zmyśloną literaturę (rozwiązanie - Scholar AI plugin)
    - ▶ Przydatna wiedza w weryfikacji pracy dyplomowej



DZIĘKUJĘ ZA UWAGĘ