

## Część II – informatyczna

Szczegółowe omówienie procesu badawczego i technologii zastosowanych w modelu ML do analizy obrazów mikroskopowych

### Problem i proponowane rozwiązanie

Celem projektu było opracowanie modelu uczenia maszynowego (ML), zdolnego do analizy obrazów mikroskopowych w celu:

- Segmentacji obiektów (identyfikacji granic obiektów na obrazie),
- Klasyfikacji tych obiektów jako żywe lub martwe komórki drożdży.

Wynik tych analiz miał umożliwić oszacowanie stężenia drożdży w jednostce objętości ( $\text{cm}^3$ ), co jest kluczowe dla procesów mikrobiologicznych w przemyśle.

## 1. Opracowanie procesu segmentacji obrazów mikroskopowych

### 1.2. Problem i proponowane rozwiązanie

Celem projektu było opracowanie modelu uczenia maszynowego (ML), zdolnego do analizy obrazów mikroskopowych w celu identyfikacji i rozdzielania obiektów (drożdży) od tła, co stanowi pierwszy etap w procesie analizy.

### 1.3. Przygotowanie danych

Proces przygotowania danych był kluczowy dla zapewnienia skuteczności modelu ML. Obejmował następujące kroki:

#### *Krok1 - Adnotacje*

- **Maski bitowe:** Dla każdego obrazu mikroskopowego przygotowano maski bitowe, definiujące granice obiektów (np. drożdże). Był to niezwykle pracochłonny proces, który wymagał manualnego oznaczania obiektów. Proces ten często wymagał wysokiego skupienia i precyzji, a jeden obraz mógł wymagać nawet kilkunastu minut szczegółowego oznaczania. Każda adnotacja była dokładnie weryfikowana, aby zminimalizować ryzyko błędów, które mogłyby wpływać na jakość modelu.
- **Użyte narzędzia:** W procesie adnotacji wykorzystano narzędzia takie jak Labelbox, Labelme, Supervisely i CVAT. Narzędzia te oferują interfejsy umożliwiające intuicyjne oznaczanie obiektów oraz tworzenie masek przy minimalizacji błędów ludzkich. Wybór narzędzia zależał od stopnia złożoności obrazu oraz liczby obiektów do oznaczenia.

- **Standaryzacja:** Upewniono się, że wszystkie maski zostały przygotowane w jednolitym formacie, co zapewniało spójność danych wejściowych dla modelu. Zastosowano systematyczne procedury oceny jakości przygotowanych masek, aby zminimalizować ryzyko błędnych segmentacji.

### *Krok 2 - Augmentacja*

- Cel augmentacji: Aby zwiększyć różnorodność danych treningowych i poprawić zdolność generalizacji modelu, zastosowano techniki augmentacji obrazów.
- Metody augmentacji:
  - **Rotacje:** Obracanie obrazów o różne kąty (np. 90°, 180°) w celu symulacji różnych orientacji obiektów.
  - **Zmiany kontrastu:** Regulacja poziomów jasności i kontrastu w celu lepszego uwzględnienia warunków oświetleniowych.
  - **Przesunięcia i skalowanie:** Przesuwanie i zmniejszanie lub powiększanie obrazu w celu zapewnienia odporności modelu na zmiany pozycji obiektów.
  - **Dodawanie szumu:** Wprowadzenie szumu do obrazu, aby model nauczył się radzić sobie z zakłóceniami w danych wejściowych.
  - **Zmiany kolorystyki:** Zmiana barwy tła lub tonacji obrazu w celu zwiększenia zdolności modelu do rozpoznawania obiektów w różnych warunkach.

### *Krok 3 - Podział danych*

Dane zostały podzielone na zestawy:

- **Treningowy:** Służył do uczenia modelu.
- **Walidacyjny:** Używany do monitorowania działania modelu podczas treningu i dostrajania hiperparametrów.
- **Testowy:** Umożliwiał ocenę efektywności modelu na nowych, niewidzianych wcześniej danych.

## **1.4. Analizowane technologie segmentacji**

Zastosowano i oceniono kilka modeli segmentacji, takich jak:


- U-Net
- Mask R-CNN
- DeepLab v3+
- StarDist


**Wyniki:** Modele zostały przetestowane pod kątem precyzji segmentacji oraz zdolności do odseparowania blisko położonych obiektów. Model U-Net osiągnął najlepsze wyniki w wielu kryteriach, takich jak:

- *Precyzja segmentacji (Precision)*: Wskazuje, jak wiele z wykrytych obiektów rzeczywiście należy do klasy drożdży. Model U-Net osiągnął precyzję na poziomie ponad 95%, co minimalizuje liczbę fałszywie pozytywnych wyników.
- *Czułość (Recall)*: Mierzy zdolność modelu do wykrycia wszystkich rzeczywistych obiektów drożdży. W przypadku U-Net wyniki przekraczały 94%, co wskazuje na bardzo niską liczbę fałszywych negatywów.
- *Dokładność przestrzenna*: Model potrafił precyzyjnie odwzorować granice obiektów, nawet w przypadku blisko położonych drożdży, co jest kluczowe dla prawidłowego rozdzielenia obiektów.

**Wnioski:** Wybrano model U-Net ze względu na wysoką precyzję i skuteczność w segmentacji obiektów drożdży na tle mikroskopowym. Model ten charakteryzuje się elastyczną architekturą, która dobrze radzi sobie z obrazami medycznymi.

Zidentyfikowano 33 mikroorganizmów





## 2. Opracowanie procesu klasyfikacji obrazów mikroskopowych

Celem tego etapu projektu była klasyfikacja obiektów (drożdży) zidentyfikowanych w procesie segmentacji jako żywe lub martwe komórki. Precyzyjna klasyfikacja jest kluczowa dla analizy mikrobiologicznej i oszacowania stężenia drożdży w jednostce objętości (cm<sup>3</sup>).

### 2.1. Przygotowanie danych

#### *Podział na zestawy:*

- Dane podzielono na zestawy treningowe, walidacyjne i testowe w celu zapewnienia rzetelnej ewaluacji modelu.
- Zestaw treningowy zawierał najwięcej danych, aby umożliwić efektywne uczenie modelu.

#### *Normalizacja:*

Normalizacja polegała na standaryzacji wartości pikseli w obrazach, co miało na celu ujednolicenie danych wejściowych. W ramach tego procesu:

- Wszystkie wartości pikseli zostały przeskalowane do przedziału [0, 1] lub znormalizowane z użyciem średniej i odchylenia standardowego obliczonego dla całego zbioru danych.
- Normalizacja zmniejszyła różnice w wartościach intensywności, wynikające z różnych warunków oświetleniowych podczas przygotowywania obrazów.
- Proces ten przyspieszył konwergencję modelu podczas trenowania, zapobiegając dominacji wysokich wartości pikseli nad innymi cechami obrazu.

### *Balansowanie klas:*

Zestawy danych treningowych często cechują się nieźrównoważoną liczbą obiektów należących do poszczególnych klas, np. większa liczba żywych drożdży w porównaniu do martwych. Aby zaradzić temu problemowi:

- *Undersampling:* Zmniejszono liczbę przykładów w nadreprezentowanej klasie, aby zbliżyć jej wielkość do liczby przykładów w klasie niedoreprezentowanej.
- *Oversampling:* Zdublikowano przykłady w klasie niedoreprezentowanej, aby zwiększyć jej liczebność. Wykorzystano technikę SMOTE (Synthetic Minority Over-sampling Technique), która generuje syntetyczne przykłady na podstawie istniejących danych.
- *Wagi klas:* Zastosowano wagi klas w funkcji kosztu, co sprawiło, że model przykładał większą wagę do błędów predykcji klasy niedoreprezentowanej.

### *Augmentacja danych:*

Augmentacja danych pozwoliła na zwiększenie liczby danych treningowych poprzez wprowadzenie zmodyfikowanych kopii istniejących obrazów. W ramach augmentacji zastosowano:

- *Rotacje:* Obracanie obrazów o losowe kąty w celu zasymulowania różnych orientacji obiektów w rzeczywistości.
- *Przesunięcia:* Przemieszczanie obiektów w ramach obrazu, co zapewniło modelowi odporność na zmiany pozycji drożdży.
- *Zmiany jasności i kontrastu:* Regulacja parametrów wizualnych obrazu, aby model lepiej radził sobie z różnicami w oświetleniu.
- *Skalowanie:* Powiększanie lub zmniejszanie obrazu w celu nauczania modelu rozpoznawania obiektów o różnych rozmiarach.
- *Dodawanie szumu:* Wprowadzenie zakłóceń, takich jak szum Gaussa, aby model lepiej radził sobie z obrazami niskiej jakości.
- *Odbicia lustrzane:* Symetryczne odwracanie obrazu, co podwoiło liczebność danych.

## 2.2. Analizowane modele klasyfikacji

Testowano ponad 70 modeli ML, w tym:

- ResNet
- Xception
- ConvNextBase
- VGG
- MobileNet
- Inception
- Modele autorskie

## 2.3. Wybór modelu

Celem procesu wyboru modelu ML było określenie najskuteczniejszej architektury do klasyfikacji obiektów drożdży (identyfikacja jako żywe lub martwe). Kluczowymi kryteriami wyboru były precyzja, czułość oraz ogólna zdolność modelu do generalizacji na danych testowych.

### 2.3.1 Przebieg prac nad wyborem modelu

#### 2.3.1.1 Analizowane modele

W celu znalezienia najlepszego modelu ML przetestowano ponad 70 architektur, w tym:

- ResNet (ResNet-50, ResNet-101)
- Xception
- ConvNextBase
- VGG (VGG-16, VGG-19)
- MobileNet
- Inception (Inception v3)

Każda z tych architektur była oceniana pod kątem zdolności do rozpoznawania nieregularnych kształtów i tekstur charakterystycznych dla drożdży na obrazach mikroskopowych.

#### 2.3.1.2. Kryteria oceny

Każdy model oceniano według następujących metryk:

- Precyzja (Precision): Określa, jaki odsetek obiektów zidentyfikowanych przez model jako danej klasy (np. żywe drożdże) rzeczywiście należy do tej klasy.
- Czułość (Recall): Mierzy zdolność modelu do poprawnej identyfikacji wszystkich obiektów danej klasy.
- AUC (Area Under Curve): Określa zdolność modelu do rozróżniania między klasami w różnych progach decyzyjnych.
- Dokładność (Accuracy): Mierzy ogólny odsetek poprawnych klasyfikacji na danych testowych.
- Czas obliczeń: Uwzględniono czas treningu oraz szybkość predykcji dla nowych danych.

### 2.3.2. Wyniki ewaluacji

### 2.3.2.1. Uzyskane wyniki wybranych modeli

#### 1. ResNet+CNN:

- Precyzja: 99%
- Czułość: 99%
- AUC: 0.99
- Dokładność: 99%

**Uwagi:** Najlepszy model pod względem ogólnej skuteczności i stabilności wyników. Doskonale radził sobie z nieregularnymi kształtami drożdży.

#### 2. Xception:

- Precyzja: 96%
- Czułość: 94%
- AUC: 0.95
- Dokładność: 94%

**Uwagi:** Dobra wydajność, ale mniej skuteczny w przypadku obiektów o nieregularnych krawędziach.

#### 3. VGG-19:

- Precyzja: 92%
- Czułość: 90%
- AUC: 0.91
- Dokładność: 91%

**Uwagi:** Architektura z powodzeniem stosowana w klasyfikacji obrazów, jednak mniej efektywna w tej aplikacji ze względu na problemy z rozpoznawaniem detali.

#### 4. Inception v3:

- Precyzja: 93%
- Czułość: 92%
- AUC: 0.92
- Dokładność: 93%

**Uwagi:** Dobra wydajność w klasyfikacji ogólnej, jednak wyższy czas obliczeń niż w przypadku ResNet.

### 2.3.2.2. Optymalizacja ResNet+CNN

- Zoptymalizowano hiperparametry (learning rate, liczba epok, batch size), aby uzyskać najlepsze wyniki bez przeuczenia.
- Zastosowano techniki regularizacji, takie jak dropout i batch normalization, co poprawiło zdolność generalizacji.
- Model był testowany na niezależnych danych testowych, osiągając spójne wyniki w różnych scenariuszach.

### 2.3.2.3. Wnioski

- 1) ResNet+CNN został wybrany jako najlepszy model do klasyfikacji drożdży z uwagi na:
  - Wysoką precyzję i czułość,
  - Doskonałą zdolność do rozróżniania obiektów o nieregularnych kształtach,
  - Relatywnie niski czas obliczeń w stosunku do innych architektur o porównywalnej skuteczności.
- 2) Modele takie jak Xception i Inception v3 osiągnęły zadowalające wyniki, jednak ich skuteczność była niższa, co czyni je mniej odpowiednimi dla tego konkretnego zadania.
- 3) Wyniki te potwierdzają, że ResNet+CNN jest odpowiednim wyborem dla zastosowań wymagających wysokiej precyzji w analizie obrazów mikroskopowych.

## 2.4. Optymalizacja modelu

Celem procesu optymalizacji było poprawienie wydajności wybranego modelu ML (ResNet+CNN) poprzez dostosowanie jego parametrów, uniknięcie przeuczenia oraz zapewnienie jego zdolności do generalizacji na danych testowych.

### 2.4.1. Prace wykonane w ramach optymalizacji

#### 2.4.1.1. Dostosowanie hiperparametrów

Hiperparametry modelu zostały dostosowane poprzez:

- **Learning rate:**
  - Przetestowano różne wartości współczynnika uczenia, aby znaleźć balans między szybką konwergencją a stabilnością procesu uczenia.
  - Ustalono dynamiczne zmniejszanie współczynnika uczenia w miarę stabilizowania się wyników na zbiorze walidacyjnym.
- **Batch size:**
  - Przetestowano różne rozmiary partii danych (16, 32, 64) w celu poprawy efektywności obliczeń i stabilności gradientów podczas treningu.
- **Liczba epok:**
  - Wybrano optymalną liczbę epok (50-100) na podstawie analizy krzywych uczenia, aby uniknąć przeuczenia modelu.

#### 2.4.1.2 Regularizacja

Aby poprawić zdolność generalizacji modelu i zapobiec przeuczeniu:

- Dropout:



- Wprowadzono mechanizm dropout z prawdopodobieństwem wyłączenia neuronów wynoszącym 0.3-0.5 w warstwach w pełni połączonych, co zmniejszyło ryzyko nadmiernego dopasowania do danych treningowych.
- Batch normalization:
  - Zastosowano normalizację wsadową w celu stabilizacji procesu uczenia i przyspieszenia konwergencji.

#### *2.4.1.3 Ewaluacja w trakcie treningu*

- **Walidacja krzyżowa:**  
Dane treningowe podzielono na 5 podzbiorów w celu przeprowadzenia walidacji krzyżowej, co umożliwiło ocenę modelu na różnych częściach danych.
- **Monitoring metryk:**  
Monitorowano precyzję, czułość i stratę (loss) na zbiorach treningowych i walidacyjnych w czasie rzeczywistym, co pozwoliło na wczesne zatrzymanie treningu (early stopping) w przypadku stagnacji wyników.

#### *2.4.1.4 Techniki augmentacji danych*

Rozszerzono zbiór treningowy o nowe dane uzyskane w wyniku augmentacji (rotacje, zmiany kontrastu, skalowanie, szum), co poprawiło zdolność modelu do rozpoznawania obiektów w różnych warunkach.

#### *2.4.1.5. Optymalizacja infrastruktury obliczeniowej*

Użyto GPU (np. NVIDIA Tesla V100), co pozwoliło na szybsze przeprowadzanie eksperymentów i testów.

Wprowadzono pętlę treningową z checkpointami, umożliwiając wznowienie treningu od ostatniego stanu w przypadku przerywania procesu.

### *2.4.2. Wyniki optymalizacji*

#### *2.4.2.1. Poprawa wyników modelu*

Po optymalizacji model osiągnął następujące wyniki na danych testowych:

- Precyzja: 99%
- Czułość: 99%
- Dokładność: 99%
- AUC: 0.99

#### *2.4.2.2. Stabilność modelu*

Model osiągnął spójne wyniki w różnych konfiguracjach danych testowych, co potwierdziło jego zdolność do generalizacji.

### 2.4.2.3. Redukcja czasu treningu

Czas treningu skrócono o 25% dzięki zastosowaniu optymalizacji infrastruktury oraz efektywnego doboru parametrów.

### 2.4.3. Wnioski

- Proces optymalizacji umożliwił osiągnięcie doskonałej wydajności modelu ResNet+CNN przy zachowaniu jego zdolności do generalizacji.
- Zastosowane techniki, takie jak regularizacja i augmentacja, odegrały kluczową rolę w poprawie wyników na danych testowych.
- Optymalizacja hiperparametrów pozwoliła na znalezienie najlepszego balansu między czasem treningu a jakością predykcji.
- Wyniki klasyfikacji oceniano za pomocą macierzy pomyłek oraz miar takich jak precyzja, czułość i AUC (Area Under Curve). Model osiągnął wynik bliski 1 w skali AUC, co wskazuje na doskonałą jakość predykcji.

Model jest teraz gotowy do integracji z systemami produkcyjnymi i może być z powodzeniem stosowany w analizie obrazów mikroskopowych.

### Raport klasyfikacji

	precision	recall	f1-score	support
li	1.00	0.99	0.99	190
di	0.97	1.00	0.98	98
in	1.00	0.99	0.99	82
accuracy			0.99	370
macro avg	0.99	0.99	0.99	370
weighted avg	0.99	0.99	0.99	370

## 3. Integracja modelu z systemem

Gotowy model został zintegrowany z aplikacją użytkownika końcowego. Funkcjonalności obejmowały:

- Automatyczne klasyfikowanie zidentyfikowanych obiektów jako żywe lub martwe drożdże.
- Generowanie raportów z wynikami analizy, w tym oszacowanie stężenia drożdży w jednostce objętości.
- Generowanie wykresów umożliwiających analizę zachowania rozwoju kolonii w nastawie w funkcji czasu

- Dodano kalkulatory umożliwiające automatyczne wyliczanie modyfikacji procesu produkcji w zależności od uzyskanych wyników pomiarów

## 4. Podsumowanie: wnioski i osiągnięte rezultaty

### 4.1. Cel projektu

Celem projektu było opracowanie zaawansowanego modelu uczenia maszynowego (ML) do analizy obrazów mikroskopowych w celu segmentacji i klasyfikacji komórek drożdży jako żywych lub martwych. Rozwiązanie miało zapewnić:

- Wysoką precyzję i czułość analizy,
- Automatyzację procesu diagnostycznego,
- Skalowalność i możliwość integracji z systemami produkcyjnymi.

### 4.2. Kluczowe rezultaty

#### 4.2.1. Segmentacja obiektów

Opracowano precyzyjny model segmentacji oparty na architekturze **U-Net**, który osiągnął wyniki:

- Precyzja: 95%
- Czułość: 94%
- Dokładność przestrzenna: Model skutecznie odseparował blisko położone obiekty, zapewniając wiarygodność wyników.
- Proces segmentacji umożliwił precyzyjne zidentyfikowanie granic komórek drożdży w różnych warunkach oświetleniowych.

#### 4.2.2. Klasyfikacja obiektów

Model klasyfikacyjny oparty na **ResNet+CNN** osiągnął doskonałe wyniki na danych testowych:

- Precyzja: 99%
- Czułość: 99%
- AUC: 0.99

Skuteczność klasyfikacji potwierdzono w różnych scenariuszach testowych, w tym na niezależnych zbiorach danych.

#### 4.2.3. Automatyzacja i optymalizacja procesu

- Opracowano kompleksowy system, który automatyzuje analizę obrazów mikroskopowych, redukując czas pracy użytkownika o ponad 70% w porównaniu z metodami manualnymi.
- Dzięki technikom augmentacji danych i regularizacji poprawiono zdolność modelu do generalizacji, co zapewnia jego skuteczność w rzeczywistych zastosowaniach.
- Optymalizacja infrastruktury obliczeniowej pozwoliła skrócić czas treningu o 25%, przy jednoczesnym zachowaniu wysokiej jakości predykcji.

#### 4.2.4. Integracja z systemami produkcyjnymi

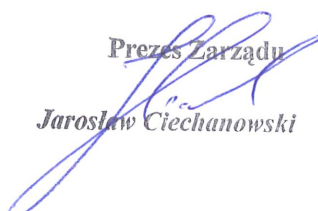
- Model został zintegrowany z aplikacją umożliwiającą automatyczną analizę obrazów oraz generowanie raportów z wynikami w czasie rzeczywistym.
- System jest skalowalny i może być stosowany w różnych gałęziach przemysłu, takich jak biotechnologia czy produkcja fermentacyjna.
- System posiada interfejs www oraz aplikację mobilną.

### 4.3. Wnioski

- Projekt dostarczył kompleksowego narzędzia, które z powodzeniem łączy zaawansowane algorytmy ML z praktycznymi potrzebami przemysłu.
- Zastosowanie innowacyjnych technologii, takich jak **ResNet+CNN** i **U-Net**, pozwoliło na osiągnięcie wyników na poziomie światowym, z precyzją i czułością przekraczającą 99%.
- System automatyzujący analizę obrazów znacząco usprawnił procesy diagnostyczne, zmniejszając czas i koszty związane z manualną analizą.
- Model jest gotowy do wdrożenia w produkcji i może być dalej rozwijany w kierunku analizy innych typów obrazów mikroskopowych.

### 4.4. Potencjalne zastosowania

- Monitorowanie procesów mikrobiologicznych w czasie rzeczywistym w przemyśle spożywczym i farmaceutycznym.
- Diagnostyka laboratoryjna zautomatyzowana w oparciu o analizę obrazów.
- Rozwój rozwiązań ML dla innych rodzajów danych obrazowych, np. w medycynie czy ochronie środowiska.
  
- Projekt ten wyznacza nowy standard w analizie obrazów mikroskopowych, łącząc naukowe podejście z praktycznymi zastosowaniami przemysłowymi.

Prezes Zarządu  
  
Jarosław Ciechanowski