


Zastosowanie technologii Deep Learning do identyfikacji dachów azbestowych na zdjęciach lotniczych

Mariusz Tomczyk
Urząd Miasta w Kielcach



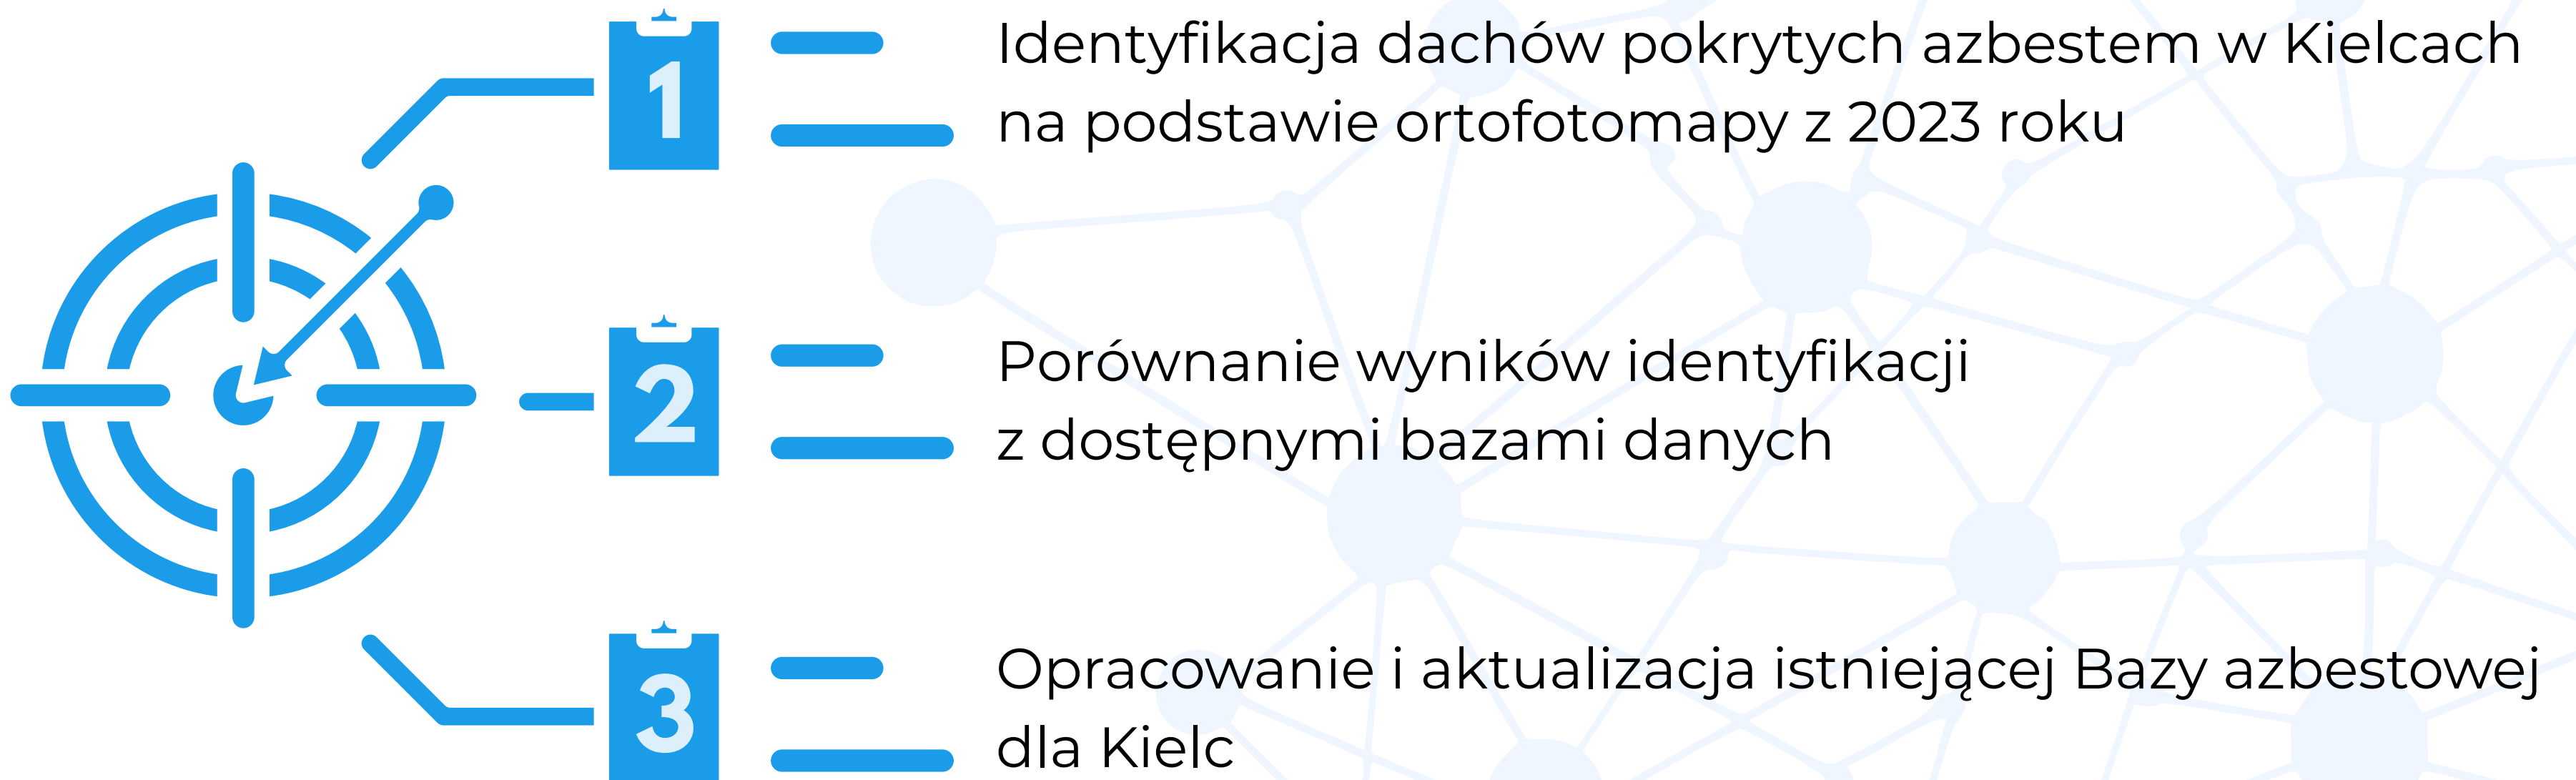
Kielce






Zastosowanie technologii Deep Learning do identyfikacji dachów azbestowych na zdjęciach lotniczych


| Zakres analizy





Zastosowanie technologii Deep Learning do identyfikacji dachów azbestowych na zdjęciach lotniczych

| Podstawa analizy



do 2032 r.

Obowiązek usunięcia
wyrobów azbestowych
do końca 2032 r.



do 31.01
każdego roku

Obowiązek złożenia
sprawozdania z inwentaryzacji
wyrobów zawierających
azbest do 31 stycznia każdego
roku – za rok poprzedni



78%

Nieprawidłowości
w realizacji Programu
Oczyszczania Kraju
z Azbestu na lata
2009–2032

W liczbach

Wszystkie wyroby	Masa (tys. ton)
Zinwentaryzowane	14,34
Unieszkodliwione	4,55
Pozostałe do unieszkodliwienia	9,88


W Kielcach zidentyfikowano łącznie

11,33
tys. ton

pokryć dachowych
zawierających azbest

Ilość pokryć dachowych zawierających azbest
pozostałych do unieszkodliwienia

- Płyty azbestowo-cementowe faliste
- Płyty azbestowo-cementowe płaskie




6,82
tys. ton



Przygotowanie bazy referencyjnej





Weryfikacja pokryć
azbestowych na Google
Street View



Ręczna wektoryzacja
dachów pokrytych
azbestem



Eksport kaflów oraz masek segmentacyjnych dachów
pokrytych azbestem (512x512 px)



Kielce




Konwertowanie masek do formatu txt

2

```
27
28 # Najpierw sprawdź, które maski nie są całkowicie czarne
29 for mask_file in mask_files:
30     mask_path = os.path.join(input_folder, mask_file)
31     mask = cv2.imread(mask_path, cv2.IMREAD_GRAYSCALE)
32
33     if np.max(mask) > 0: # Jeśli maska nie jest czarna, dodaj ją do listy
34         valid_masks.append(mask_file)
35
36 # Przetwarzaj tylko maski, które zawierają obiekty
37 for mask_file in valid_masks:
38     mask_path = os.path.join(input_folder, mask_file)
39     mask = cv2.imread(mask_path, cv2.IMREAD_GRAYSCALE)
40
```



Format maski
segmentacyjnej
w formacie PNG



Format maski
segmentacyjnej
w formacie TXT

```
0 0.16376201953125
0.79777644140625
0.1607572109375
0.998046875
0.419170673828125
0.998046875
0.428185095703125
0.790264423828125
0.16376201953125
0.79777644140625
```


Zapis
do formatu
TXT

Wyodrębnianie
konturów obiektów


Normalizacja
współrzędnych

Eksport danych w formacie adnotacji zgodnym z YOLOv8

3




0 0.16376201953125
0.79777644140625
0.1607572109375
0.998046875
0.419170673828125
0.998046875
0.428185095703125
0.790264423828125
0.16376201953125
0.79777644140625




8399

Liczba zdjęć (512x512)



10000


Liczba adnotacji



70%

Zestaw danych
szkoleniowych

5903



20%

Zestaw danych
walidacyjnych


1656



10%

Zestaw danych
testowych

840



Trenowanie modelu segmentacji w architekturze YOLO11m



|Ultralytics


Import danych
w formacie YOLOv8
dla modelu segmentacji



mAP50

82(B) 85(M)

Średnia precyzja
przy dopasowaniu
 $IoU \geq 0.5$



85(B) 88(M)

Precyzja(trafność)

Model rzadko zgłasza
fałszywe pozytywy



|Google Colab


Trening modelu
w architekturze YOLO11m
z wykorzystaniem
gotowego środowiska



mAP50-95

65(B) 62(M)


Średnia precyzja
przy dopasowaniu
 $IoU 0.5-0.95$



82(B) 79(M)

Czułość(wykrywalność)


Model wykrywa większość
prawidłowych obiektów



|ONNX

Eksport wytrenowanego
modelu do formatu
ONNX

B - Boundix Boxes (ramki ograniczające)
M - Masks (segmentacja)



DEEPNESS

Deep neural remote sensing QGIS plugin

Wdrażanie modelu i detekcja dachów azbestowych


5



Confidence threshold

(próg pewności)

0,4



Intersection over Union


(Współczynnik Jaccarda)

0,35

Proces segmentacji był realizowany stopniowo dla wydzielonych sekcji miasta o wymiarach 500x 500 m

500 m
420
sekcji
500 m

~100
godzin





Kielce




Ręczna weryfikacja uzyskanych wyników i ich korekta

W wyniku analizy wykryto **2,8 tys. ton** dachów azbestowych na terenie miasta





Raport z przeprowadzonej analizy



Czy od 2015 r.
z obszaru Kielc usunięto

2,23
tys. ton


płyt azbestowych?




Segmentacja AI (2023 r.)

Wyniki analizy

	funkcja budynku	tys. ton
	Budynki mieszkalne	1,03
	Budynki gospodarcze	0,76
	Budynki niemieszkalne	0,50
	Inne niewykazane w EGIB i BDOT500	0,26
	Budynki magazynowe	0,13
	Łącznie	2,80




Porównanie baz danych



Masa materiałów azbestowych
na podstawie geometrii dachów

3,39
tys. ton

55,9% obiektów zgłoszonych w bazie azbestowej
znajdowało pokrycie w wynikach segmentacji AI





Inwentaryzacja (2015 r.)

Porównanie baz danych

W przypadku inwentaryzacji wyrobów zawierających azbest z 2015 roku, dane przypisane były do działek ewidencyjnych

W 2015 roku dachy pokryte azbestem zinwentaryzowano na **3009** działkach



2015
3009

Wyniki segmentacji ortofotomapy przeprowadzonej z wykorzystaniem AI potwierdziły obecność pokryć azbestowych na **56,8%** tych działek

43.2%

1,42
tys. ton

Działki na których
nie wykryto azbestu
podczas segmentacji AI

3,61
tys. ton

56.8%

Działki na
których wykryto
azbest podczas
segmentacji AI



Kielce




Inwentaryzacja (2015 r.)

Porównanie baz danych

W przypadku inwentaryzacji wyrobów zawierających azbest z 2015 roku, dane przypisane były do działek ewidencyjnych

W 2015 roku dachy pokryte azbestem zinwentaryzowano na **3009** działkach




2015

3009

W 2015 r. nie stwierdzono azbestu na **1348** działkach ujawnionych podczas analizy ortofotomapy z 2023 r.

Czy w tym zakresie
zastosowanie AI okazuje się
skuteczniejsze niż praca
ludzka?



Co przekładało się na:

0,68 tys.
ton

odpadów azbestowych




Kielce




Podsumowanie

AI nie zastępuje całkowicie pracy ludzkiej, lecz znacząco ją wspiera i optymalizuje proces inwentaryzacji azbestu w mieście



Kryterium	AI	Praca ludzka
Szybkość	Bardzo wysoka (w zależności od sprzętu)	Niska
Koszt	Niski (po wdrożeniu)	Wysoki
Dokładność	Wysoka (ok. 80%)	Bardzo wysoka
Skalowalność	Bardzo wysoka	Niska
Możliwość błędów	Błędy klasyfikacji, fałszywe pozytywy	Błędy ludzkie, pominięcia
Weryfikacja wyników	Automatyczna i szybka, ale wymaga kontroli	Ręczna, czasochłonna

Dziękuję za uwagę!



Mariusz Tomczyk

Urząd miasta w Kielcach

Biuro Rozwoju Miasta

mariusz.tomczyk@um.kielce.pl



Kielce

