

JAKUB TUSZYŃSKI

Skuteczność wybranych modeli AI w predykcji ofiar ataków terrorystycznych¹

Abstrakt

W artykule porównano skuteczność wybranych algorytmów uczenia maszynowego w predykcji ofiar ataków terrorystycznych. Celem autora było udzielenie odpowiedzi na pytanie, czy mogą one posłużyć jako jedno z narzędzi antyterrorystycznych. Dokonano eksploracyjnej analizy danych, omówiono wybrane trendy i charakterystykę zamachów terrorystycznych. Przedstawiono niektóre miary oceny algorytmów klasyfikacyjnych użytych w badaniu oraz wskazano potencjalne kierunki dalszych badań.

Słowa kluczowe:

AI,
uczenie
maszynowe,
terroryzm,
ofiary,
klasyfikacja

¹ Artykuł powstał na podstawie pracy magisterskiej pt. *Skuteczność wybranych modeli AI w predykcji ofiar ataków terrorystycznych*, obronionej na Wydziale Dziennikarstwa, Informacji i Bibliologii Uniwersytetu Warszawskiego. Autor wykorzystał fragmenty rozdziałów 3. i 6. Praca została nagrodzona w XII edycji konkursu Szefa ABW na najlepszą pracę doktorską, magisterską lub licencjacką dotyczącą bezpieczeństwa państwa w kontekście zagrożeń wywiadowczych, terrorystycznych, ekonomicznych.

Badanie ataków terrorystycznych

Ze względu na spory definicyjne na potrzeby niniejszego artykułu przyjmuje się, że zamach terrorystyczny to (...) *zamierzony akt przemocy lub groźba jej użycia ze strony podmiotu niepaństwowego*². W ramach tego artykułu przeprowadzono badanie mające na celu porównanie skuteczności różnych algorytmów sztucznej inteligencji w przewidywaniu ofiar ataków terrorystycznych. Do przeprowadzenia badania wykorzystano bazę danych Global Terrorism Database (dalej: GTD) utrzymywaną przez badaczy z konsorcjum START³, zawierającą informacje na temat zamachów terrorystycznych.

W ramach GTD przyjęto trzy kryteria, z których co najmniej dwa muszą być spełnione, żeby dane zdarzenie zostało uznane za atak terrorystyczny. Te kryteria to:

- akt przemocy miał na celu osiągnięcie celu politycznego, ekonomicznego, religijnego lub społecznego;
- akt przemocy zawierał dowody na zamiar wymuszenia, zastraszenia lub przekazania innego przesłania szerszej publiczności, innej niż bezpośrednie ofiary;
- akt przemocy wykroczał poza zakres międzynarodowego prawa humanitarnego⁴.

Oznaczono również te zdarzenia, w których liczba informacji okazała się niewystarczająca do jednoznacznego określenia, czy dane wydarzenie było atakiem terrorystycznym czy też nie, i są one możliwe do odfiltrowania przez użytkownika.

Założenia

W celu możliwie jak najdokładniejszego wyeliminowania przypadków błędnego zaklasyfikowania danego zdarzenia jako ataku terrorystycznego wykluczono te obserwacje, które nie spełniają wszystkich trzech kryteriów opisanych powyżej, oraz te, co do których autorzy bazy mieli wątpliwości.

² *Data Collection Methodology*, Global Terrorism Database, <http://www.start-dev.umd.edu/gtd/using-gtd/> [dostęp: 21 V 2022].

³ *History of the GTD*, Global Terrorism Database, <https://start.umd.edu/gtd/about/History.aspx> [dostęp: 11 V 2022].

⁴ *Data Collection Methodology...* Tłumaczenia w artykule pochodzą od autora (dop. red.).

Za ofiary ataku uznaje się wszelkie osoby niebędące terrorystami, które w wyniku zdarzenia zostały ranne lub zabite. Zbudowano kilka modeli uczenia maszynowego i porównano je za pomocą odpowiednich metryk.

Eksploracyjna analiza danych

Podczas eksploracyjnej analizy danych nacisk został położony na zrozumienie badanego zbioru danych. W pierwszej kolejności przeprowadzono analizę strukturalną.

Na rysunku 1 wyróżnia się następujące cechy zbioru:

- ponad 200 000 wierszy zarejestrowanych zamachów;
- 135 kolumn zawierających cechy opisujące dane zdarzenie;
- *dtypes* opisuje typy danych poszczególnych kolumn. Są to dane kategoryczne, mające skończoną liczbę kategorii – 9, kolumny zawierające liczby zmiennoprzecinkowe – 53, liczby całkowite występujące w 24 kolumnach i 49 kolumn zawierających dane mogące być zarówno ciągami znaków, jak i liczbami. Typ danych *object* jest przypisywany wówczas, kiedy nie można jednoznacznie przypisać żadnego innego typu danych;
- zbiór zajmuje ok. 200 megabajtów pamięci.

```
Int64Index: 201183 entries, 0 to 201182
Columns: 135 entries, eventid to related
dtypes: category(9), float64(53), int64(24), object(49)
memory usage: 197.1+ MB
```

Rysunek 1. Podstawowe statystyki opisujące zbiór danych.

Źródło: opracowanie własne.

W następnej kolejności odfiltrowano dane niespełniające wszystkich trzech kryteriów zamachu terrorystycznego oraz te, co do których autorzy bazy mieli wątpliwości. Usunięto również te kolumny, w których 50% lub więcej wierszy było pustych. Celem zredukowania zbioru danych było przyspieszenie wykonywanych na nim operacji. Ponadto większość algorytmów uczenia maszynowego zastosowanych w badaniu wymaga, żeby zbiór danych nie miał wartości pustych. Ich uzupełnienie za pomocą średniej,

mediany czy najczęściej występującej wartości przy tak dużej liczbie pustych obserwacji powodowałoby nieuprawnioną generalizację na podstawie niewielkiej ilości danych. Ta operacja zmniejszyła zbiór danych do 154 260 wierszy i 60 kolumn, a rozmiar pliku wyniósł niecałe 70 megabajtów.

W kolejnym kroku sprawdzono podstawowe wartości poszczególnych kolumn. Na osi x są widoczne nazwy kolumn, a na osi y są wyliczone statystyki: liczba obserwacji, średnia, odchylenie standardowe, wartość minimalna, pierwszy kwartył, mediana, trzeci kwartył oraz wartość maksymalna.

Na rysunku 2 widać, że zmienne *latitude* i *longitude* zawierają braki, które odpowiednio przetworzono poprzez usunięcie wierszy z brakującymi wartościami w tych zmiennych, dzięki czemu zostały użyte podczas modelowania. Warto również zwrócić uwagę na minimalną wartość zmiennej *vicinity*, która wynosi -9 (jest to widoczne w ostatnim wierszu kolumny *min*). Autorzy bazy w ten sposób oznaczają przypadki braku danych. Zostało to opisane w tzw. *Codebooku*⁵.

	count	mean	std	min	25%	50%	75%	max
eventid	154260.0	2.005463e+11	1.294940e+09	1.970000e+11	1.995042e+11	2.012022e+11	2.015091e+11	2.019123e+11
year	154260.0	2.005397e+03	1.294940e+01	1.970000e+03	1.995000e+03	2.012000e+03	2.015000e+03	2.019000e+03
imonth	154260.0	6.443965e+00	3.392222e+00	0.000000e+00	4.000000e+00	6.000000e+00	9.000000e+00	1.200000e+01
iday	154260.0	1.553523e+01	8.803117e+00	0.000000e+00	8.000000e+00	1.500000e+01	2.300000e+01	3.100000e+01
extended	154260.0	5.527032e-02	2.285079e-01	0.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00
country	154260.0	1.297654e+02	1.116024e+02	4.000000e+00	7.800000e+01	9.700000e+01	1.400000e+02	1.004000e+03
region	154260.0	7.321360e+00	2.438782e+00	1.000000e+00	6.000000e+00	8.000000e+00	1.000000e+01	1.200000e+01
latitude	151329.0	2.369732e+01	1.798608e+01	-5.315461e+01	1.184079e+01	3.153824e+01	3.451689e+01	7.403359e+01
longitude	151329.0	3.227138e+01	5.485520e+01	-1.578583e+02	9.735680e+00	4.414823e+01	6.914701e+01	1.793667e+02
specificity	154259.0	1.447591e+00	9.567426e-01	1.000000e+00	1.000000e+00	1.000000e+00	1.000000e+00	5.000000e+00
vicinity	154260.0	6.333463e-02	2.803160e-01	-9.000000e+00	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00

Rysunek 2. Fragment statystyk zmiennych liczbowych.

Źródło: opracowanie własne.

Na rysunku 3 przedstawiono statystyki dla zmiennych tekstowych: liczba obserwacji, liczba unikalnych wartości, najczęściej występująca wartość oraz jej częstotliwość.

W zbiorze danych część zmiennych występuje pod postacią liczbową i tekstową. Jest to np. zmienna *region_txt* (rysunek 3) i zmienna *region* (rysunek 2). Uwzględniono to przed modelowaniem ze względu na możliwą korelację pomiędzy tymi samymi zmiennymi i niepotrzebnym

⁵ *Codebook: Inclusion Criteria and Variables*, Global Terrorism Database, sierpień 2018 r., <https://www.start.umd.edu/gtd/downloads/Codebook.pdf> [dostęp: 30 V 2022].

skomplikowaniu zbioru danych, co przekłada się na spowolnienie procesu treningu modeli.

	count	unique	top	freq
country_txt	154260	202		Iraq 23407
region_txt	154260	12		Middle East & North Africa 43858
provstate	154260	2380		Baghdad 7563
city	153874	34443		Unknown 7594
summary	112205	109189	09/00/2016: Sometime between September ...	100
attacktype1_txt	154260	9		Bombing/Explosion 79879
targettype1_txt	154260	22		Private Citizens & Property 43145
targsubtype1_txt	144441	112		Unnamed Civilian/Unspecified 11599
corp1	123010	32224		Unknown 18458
target1	153807	73022		Civilians 7489
natlty1_txt	152648	209		Iraq 23077

Rysunek 3. Fragment statystyk zmiennych kategoriycznych.

Źródło: opracowanie własne.

Widoczny jest również problem w postaci wysokiej liczby unikalnych wartości niektórych zmiennych, jak np. *city*, co mogło wpłynąć na wydajność budowanych modeli. Ten problem został rozwiązany podczas przetwarzania danych poprzez usunięcie takich zmiennych ze zbioru danych.


W kolejnym etapie usunięto puste wartości ze zmiennych mających wpływ na liczbę rannych i zabitych. Następnie rozwiązano problem podawania łącznie liczby ofiar zabitych i rannych w wyniku zdarzenia z liczbą zabitych i rannych terrorystów. Odjęto liczbę terrorystów od ogólnej liczby zabitych i rannych w celu uzyskania liczby poszkodowanych niebędących terrorystami.

Po tej operacji utworzono nowe zmienne: *ncasualites* będącą sumą zabitych i rannych oraz *cas_class*, gdzie zerem oznaczono przypadki, w których nie było ofiar, a jedynką te zdarzenia, w których wystąpiły ofiary. Następnie zapisano wstępnie przetworzone dane do nowego pliku.

Trendy w liczbie ataków terrorystycznych i liczbie ofiar

Sporządzono wizualizacje części zmiennych, co pozwoliło na ich dogłębną analizę. Na wykresach przedstawiono liczbę ataków terrorystycznych przeprowadzonych w latach 1970–2019 i ich ofiar.

Od drugiej połowy lat 70. do początku lat 90. XX w. wzrastała liczba ataków (wykres 1), jak również ich ofiar (wykres 2). Wyraźny wzrost w liczbie ofiar w 2001 r. jest spowodowany atakiem na World Trade Center (WTC) z 11 września. Kolejny zauważalny trend wzrostowy w obu przypadkach nastąpił w 2005 r. i utrzymywał się do 2014–2015 r. Przy czym, jak już wspomniano, wzrost ok. 2012 r. jest częściowo spowodowany zmianą metodyki zbierania danych⁶, jednakże ten wzrost rozpoczął się jeszcze przed rokiem 2005. Od 2015 r. widać trend spadkowy w liczbie zarówno ataków, jak i ofiar. Na dzień 4 czerwca 2022 r.⁷ badacze z konsorcjum START nie opublikowali danych z lat 2020–2021, więc nie jest znany wpływ pandemii COVID-19 na dynamikę występowania ataków terrorystycznych.




Wykres 1. Liczba ataków terrorystycznych w latach 1970–2019.

Źródło: opracowanie własne.

⁶ Identyfikacja incydentów terrorystycznych do GTD przed 2012 r. wymagała użycia ok. 300 unikalnych źródeł wiadomości, a po aktualizacji z 2012 r. – ponad 1500. Były to międzynarodowe agencje informacyjne oraz angielskie tłumaczenia lokalnych gazet publikowanych w różnych językach.


⁷ Aktualizacja – na dzień 15 lipca 2023 r. są dostępne dane z pierwszej połowy 2021 r.



Wykres 2. Liczba ofiar ataków terrorystycznych w latach 1970–2019.

Źródło: opracowanie własne.

Następnie dokonano wizualizacji liczby zamachów terrorystycznych i ich ofiar z podziałem na regiony (wykresy 3 i 4).




Wykres 3. Liczba ataków terrorystycznych w latach 1970–2019 z podziałem na regiony.

Źródło: opracowanie własne.

W Europie Zachodniej najwięcej zamachów przeprowadzono w drugiej połowie lat 70., co nie przełożyło się na wzrost liczby ofiar. Podobną sytuację można zaobserwować w Ameryce Południowej w latach 1980–1995, kiedy to dynamicznie wzrosła liczba ataków (co również nie miało przełożenia na liczbę ofiar). W latach 90. nastąpił spadek liczby ataków we wszystkich regionach. Mimo to w Afryce Subsaharyjskiej, na Bliskim

Wschodzie i w Afryce Północnej oraz Azji Południowej i Azji Wschodniej zaobserwowano wzrost liczby ofiar. Widoczny gwałtowny wzrost liczby ofiar w 2001 r. w Ameryce Północnej nie jest efektem błędu we wprowadzaniu danych – wtedy miał miejsce zamach na WTC.

W regionie Bliskiego Wschodu i Afryki Północnej, Azji Południowej oraz w Afryce Subsaharyjskiej zaobserwowano również wzrost liczby ataków i ofiar na początku 2000 r. Szczególnie wyróżnia się krzywa wzrostu na Bliskim Wschodzie, która jest bardziej stroma od krzywych dwóch wcześniej wymienionych regionów. Może to mieć związek z interwencją Stanów Zjednoczonych w Afganistanie oraz Iraku. Na Bliskim Wschodzie w 2000 r. liczba ofiar wyniosła ok. 900, a w 2005 r. było to już prawie 9000. Od 2015 r. jest widoczny trend spadkowy liczby zarówno ataków terrorystycznych, jak i ofiar (wyjątkiem jest Azja Południowa, w której obserwuje się trend wzrostowy pod względem liczby ofiar).



Wykres 4. Liczba ofiar ataków terrorystycznych w latach 1970–2019 z podziałem na regiony.

Źródło: opracowanie własne.

Warto zwrócić uwagę na obszar Europy Zachodniej w tym okresie, ponieważ pomimo kryzysu migracyjnego z 2015 r. nie odnotowano tam wyraźnego wzrostu liczby ataków terrorystycznych (wykres 5).



Wykres 5. Liczba ataków terrorystycznych w Europie Zachodniej latach 1970–2019.

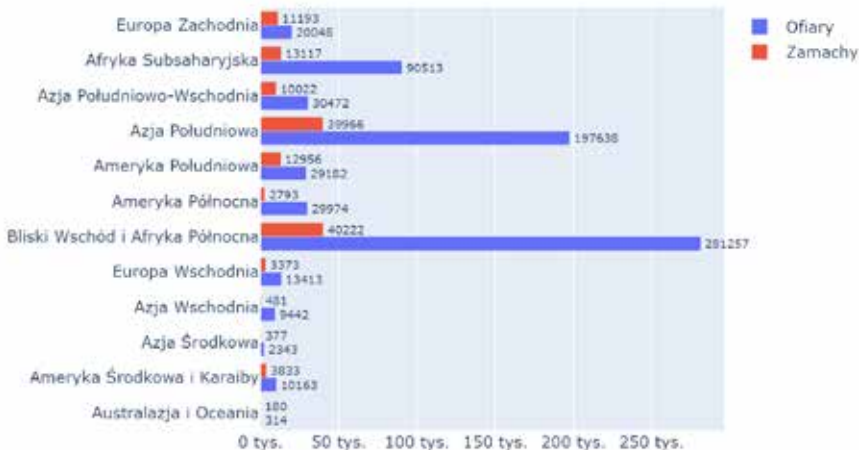
Źródło: opracowanie własne.

W tabeli 1 i na wykresie 6 zawarto informacje na temat stosunku liczby ofiar do liczby zamachów nazywanego dalej współczynnikiem ofiar, co jest bardziej miarodajnym wskaźnikiem niż bezpośrednie porównywanie danych.

Tabela 1. Porównanie współczynnika ofiar ataków terrorystycznych dla poszczególnych regionów.

Region	Współczynnik ofiar
Azja Wschodnia	19,6:1
Ameryka Północna	10,7:1
Bliski Wschód i Afryka Północna	7,0:1
Afryka Subsaharyjska	6,9:1
Azja Środkowa	6,2:1
Azja Południowa	5,0:1
Europa Wschodnia	4,0:1
Azja Południowo-Wschodnia	3,0:1
Ameryka Środkowa i Karaiby	2,7:1
Ameryka Południowa	2,3:1
Europa Zachodnia	1,8:1
Australazja i Oceania	1,7:1

Źródło: opracowanie własne.



Wykres 6. Liczba ataków terrorystycznych oraz liczba ofiar z podziałem na regiony.

Źródło: opracowanie własne.

Zamachy w regionie Bliskiego Wschodu i Afryki Północnej oraz Azji Południowej – pomimo największych liczb bezwzględnych – nie są najbardziej śmiertelne. Najwyższy współczynnik ofiar występuje w Azji Wschodniej i prawie dwukrotnie przewyższa znajdującą się na drugim miejscu Amerykę Północną. Na trzecim miejscu znalazła się Afryka Subsaharyjska. Średnio najniższy współczynnik ofiar mają zamachy przeprowadzone w Australazji i Oceanii oraz w Europie Zachodniej. Z tych statystyk wynika, że w przypadku terroryzmu podział na bogatą północ i biedne południe nie znajduje bezpośredniego przełożenia. Część biedniejszych regionów, takich jak Ameryka Południowa, Azja Południowo-Wschodnia czy też Ameryka Środkowa i Karaiby, nie odnotowuje wyraźnie wyższego współczynnika ofiar niż bogatsze regiony. Może to wskazywać na czynniki pozaekonomiczne, które wpływają na skuteczność działań terrorystów.


Po przeanalizowaniu danych wskazano kolejno dziesięć krajów z największą liczbą ataków terrorystycznych przeprowadzonych w latach 1970–2019 (wykres 7) oraz dziesięć krajów z największą liczbą ofiar tych ataków (wykres 8).

Kraje te (z podziałem na regiony⁸) to:

- Bliski Wschód i Afryka Północna: Irak, Jemen, Syria;
- Azja Południowa: Afganistan, Pakistan, Indie, Sri Lanka;


⁸ Kraje przypisano do regionów zgodnie z *Codebookiem*.

- Azja Południowo-Wschodnia: Filipiny, Tajlandia;
- Ameryka Południowa: Kolumbia, Peru;
- Ameryka Północna: Stany Zjednoczone;
- Afryka Subsaharyjska: Nigeria.



Wykres 7. Liczba ataków terrorystycznych w krajach zajmujących dziesięć pierwszych miejsc pod względem liczby tych ataków.

Źródło: opracowanie własne.



Wykres 8. Liczba ofiar ataków terrorystycznych w krajach zajmujących dziesięć pierwszych miejsc pod względem liczby tych ofiar.

Źródło: opracowanie własne.

Ze względu na relatywnie niewielką liczbę ataków i ofiar w porównaniu z innymi państwami na liście nie ma żadnego kraju z Azji Wschodniej (pomimo wysokiego współczynnika ofiar). Najbardziej dotknięty tym problemem jest Irak, w którym prawie dwa razy częściej niż w Afganistanie

przeprowadzono ataki terrorystyczne, co przekłada się na ponaddwukrotnie większą liczbę ofiar. Pozostałe kraje ujęte w zestawieniu mają już bardziej zbliżone do siebie wartości zarówno pod względem liczby ataków terrorystycznych, jak i ofiar tych zdarzeń.

W tabeli 2 wskazano współczynnik ofiar dla krajów, w których było ich najwięcej. Najwyższe współczynniki mają: Syria (12,8), Stany Zjednoczone (12,0) i Sri Lanka (11,2). Średnio najmniej ofiar zamachu było w Kolumbii i na Filipinach.

Tabela 2. Porównanie współczynnika ofiar ataków terrorystycznych dla dziesięciu krajów z największą liczbą tych ofiar.

Kraj	Współczynnik ofiar
Syria	12,8:1
Stany Zjednoczone	12,0:1
Sri Lanka	11,2:1
Irak	8,2:1
Nigeria	6,6:1
Afganistan	5,6:1
Pakistan	4,7:1
Indie	3,8:1
Kolumbia	2,8:1
Filipiny	2,8:1


Źródło: opracowanie własne.

Można więc wysunąć wnioszek, że czynniki geograficzne mają związek z tym, czy atak terrorystyczny zakończy się ofiarami, czy też nie. Wzięto je więc pod uwagę w trakcie modelowania i został przeanalizowany ich wpływ na wynik predykcji.

Aktywność wybranych grup terrorystycznych

Następnie dokonano analizy aktywności grup odpowiedzialnych za zamachy terrorystyczne. Na wykresie 9 przedstawiono najaktywniejsze grupy terrorystyczne w latach 1970–2019. Dziesięć pierwszych miejsc zajmują grupy powiązane z terroryzmem islamskim: Talibowie (ang. *Taliban*),

Asz-Szabab (ang. *Al-Shabaab*), Boko Haram, Państwo Islamskie (ang. *Islamic State*, ISIS) znane też jako Państwo Islamskie w Iraku i Lewancie (ang. *Islamic State of Iraq and the Levant*, ISIL) oraz z terroryzmem o charakterze skrajnie lewicowym: Baskonia i Wolność (ang. *Basque Fatherland and Freedom*, ETA), Nowa Armia Ludowa (ang. *New People's Army*, NPA), Rewolucyjne Siły Zbrojne Kolumbii (ang. *Revolutionary Armed Forces of Colombia*, FARC), Maoiści (ang. *Maoists*), Świetlisty Szlak (ang. *Shining Path*, hiszp. Sendero Luminoso, SL), Komunistyczna Partia Indii (Maoistowska), ang. *Communist Party of India-Maoist* (CPI-Maoist). Może to wskazywać na pewną korelację pomiędzy motywacją grupy do przeprowadzenia ataku a jej wysoką aktywnością, jednakże w GTD poszczególne grupy nie mają przypisanych charakterystyk. Może to być wskazówka dla badaczy z konsorcjum START, żeby uaktualnić GTD w tym zakresie.



Wykres 9. Liczba ataków terrorystycznych przeprowadzonych w latach 1970–2019 przez dziesięć najbardziej aktywnych grup terrorystycznych.

Źródło: opracowanie własne.

Najstarszą grupą ze wszystkich wyżej wymienionych jest ETA, która w badanym okresie najaktywniej działała w latach 1970–1980, a od początku lat 90. była coraz mniej aktywna. Ostatni odnotowany w GTD zamach został przeprowadzony przez tę grupę w 2011 r. Najprawdopodobniej wiąże się to

z zakończeniem działań zbrojnych tej organizacji w październiku tego samego roku⁹. ETA ostatecznie dokonała samorozwiązania w 2018 r.¹⁰

Aktywny w dosyć wysokim stopniu był również Świetlisty Szlak, którego działalność przypadła przede wszystkim na lata 1980–1990. Później nastąpił wyraźny spadek liczby zamachów przeprowadzanych przez tę grupę. Prawdopodobnie wynikało to z zatrzymania jej kolejnych przywódców w latach 90. oraz w 2012 r.¹¹ Aktywna pozostała jedna z frakcji Świetlistego Szlaku, czyli Zmilitaryzowana Komunistyczna Partia Peru (ang. *Militarized Communist Party of Peru*), która w 2018 r. odzębła się od SL¹².

Kolejną grupą, której wzmożona działalność przypadła na lata 80., jest NPA operująca na Filipinach. Powstała ona w 1969 r. jako zbrojne ramię Komunistycznej Partii Filipin¹³. Spadek aktywności tej grupy po 1990 r. może wynikać z aresztowania postaci kluczowych dla tej organizacji oraz z czystek wewnętrznych¹⁴. Ponadto NPA zrywała, m.in. w 1986 r. i 2010 r., różnego rodzaju zawieszania broni oraz negocjacje¹⁵. Kolejny wzrost aktywności tej grupy odnotowuje się od 2013 r. NPA, w odróżnieniu od SL i ETA, pozostaje aktywna.

Rewolucyjne Siły Zbrojne Kolumbii powstały w 1964 r. Pierwotnie celem tej organizacji było obalenie rządu Kolumbii¹⁶. W latach 2008–2015 nastąpił wzrost aktywności terrorystycznej tej grupy. Pomimo że od 2012 r. rząd podejmował próby negocjacji z FARC, w tym zawierano zawieszania broni, to grupa regularnie je łamała¹⁷. W 2016 r. doszło do porozumienia między rządem a FARC, które przekształciły się w partię polityczną

⁹ *Basque group Eta says armed campaign is over*, BBC News, 20 X 2011 r., <https://www.bbc.com/news/world-europe-15393014> [dostęp: 6 VI 2022].

¹⁰ I. Binnie, *Basque separatist group ETA says it has „completely dissolved”*, Reuters, 2 V 2018 r., <https://www.reuters.com/article/us-spain-eta-idUSKBN1I31TP> [dostęp: 6 VI 2022].

¹¹ S. Saffón, *Peru in Familiar Stalemate With Shining Path Rebels*, InSight Crime, 4 IX 2020 r., <https://insightcrime.org/news/brief/peru-stalemate-shining-path/> [dostęp: 8 VI 2022].

¹² Tamże.

¹³ *Communist Part of the Philippines – New People’s Army*, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/communist-party-philippines-new-peoples-army> [dostęp: 11 VI 2022].

¹⁴ Tamże.

¹⁵ Tamże.

¹⁶ *Revolutionary Armed Forces of Colombia (FARC)*, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/revolutionary-armed-forces-colombia-farc> [dostęp: 8 VI 2022].

¹⁷ Tamże.

i zaprzestały działalności zbrojnej¹⁸. Według danych GTD od 2016 r. ta organizacja nie przeprowadziła ani jednego zamachu.

Komunistyczna Partia Indii (Maoistowska) to grupa zdelegalizowana przez indyjski rząd¹⁹. Wzrost aktywności CPI-Maoist w 2009 r. oraz jej późniejszy spadek może być związany z operacją kontrterrorystyczną „Green Hunt” wymierzoną w tę organizację²⁰. Pomimo podjętych wysiłków nie udało się jej rozbić. Maoiści z kolei to zbiorcza nazwa terrorystycznych grup skrajnie lewicowych niewchodzących w skład CPI-Maoist²¹.

Talibowie powstali jako organizacja w 1994 r. i w latach 1996–2001 rządili w Afganistanie²². Gwałtowny wzrost ich aktywności jest zauważalny po 2001 r., kiedy pokonano ich militarnie, jednak organizacja nie została rozbita. Talibowie powrócili do władzy w 2021 r.

Asz-Szabab jest organizacją wywodzącą się z Somalii, działającą na obszarze wschodniej Afryki oraz Jemenu. Szczyt aktywności grupy przypadł na rok 2014. Rok później odnotowano jednak spadek, który mógł być spowodowany uśmierceniem w 2014 r. przez Stany Zjednoczone jednego z liderów organizacji, co okazało się dla niej dużą stratą²³. Pomimo wysiłków podejmowanych przez rząd somalijski oraz Stany Zjednoczone w celu zwalczania tej organizacji jest ona nadal aktywna.

Boko Haram powstała w Nigerii w 2002 r.²⁴ i rozpoczęła swoją działalność jako organizacja terrorystyczna w 2009 r., kiedy doszło do strzelaniny

¹⁸ Tamże.

¹⁹ *Left Wing Extremism Division*, Ministry of Home Affairs, https://web.archive.org/web/20220707070953/https://www.mha.gov.in/division_of_mha/left-wing-extremism-division [dostęp: 8 VI 2022].

²⁰ A. Sethi, *Green Hunt: the anatomy of an operation*, *The Hindu*, 6 II 2010 r., <https://www.thehindu.com/opinion/op-ed/Green-Hunt-the-anatomy-of-an-operation/article16812797.ece>. [dostęp: 8 VI 2022].

²¹ *Deaths in Maoist attacks down by 21%: Shah at CMs' meeting*, *The Times of India*, 27 IX 2021 r., <https://timesofindia.indiatimes.com/india/deaths-in-naxal-attacks-down-by-21-shah-at-cms-meeting/articleshow/86543018.cms> [dostęp: 8 VI 2022].

²² *The Afghan Taliban*, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/afghan-taliban> [dostęp: 8 VI 2022].

²³ *Pentagon confirms death of Somalia terror leader*, *The Washington Times*, 5 IX 2014 r., <https://www.washingtontimes.com/news/2014/sep/5/pentagon-confirms-death-of-somalia-terror-leader/> [dostęp: 10 VI 2022].

²⁴ H. Matfess, *Boko Haram: History and Context*, w: *Oxford Research Encyclopedia of African History*, Oxford University Press 2017, s. 1.

pomiędzy jej członkami a policją²⁵. Trudno przewidzieć trendy w aktywności tej grupy, gdyż wpływ na to mają działania władz w postaci np. użycia sił zbrojnych, a także odporność Boko Haram na te działania²⁶.

Ostatnią omawianą grupą jest Państwo Islamskie. Organizacja powstała w 1999 r. pod nazwą Dżama'at at-Tauhid wa al-Dżihad (arab. *Jama'at al-Tawhid wal-Jihad*), a po interwencji Stanów Zjednoczonych w Iraku przemianowano ją na Al-Ka'idę w Iraku (ang. *Al Qaeda in Iraq*)²⁷. Grupa wzmocniła się po wycofaniu się Amerykanów z Iraku. Wykorzystując ten fakt oraz wybuch wojny domowej w Syrii, zaczęła sukcesywnie przejmować tereny obu państw w 2013 r. i 2014 r.²⁸ W tym okresie organizacja zmieniła nazwę najpierw na Państwo Islamskie w Iraku i Syrii, następnie w czerwcu 2014 r. ogłosiła utworzenie kalifatu i ostatecznie przyjęła nazwę Państwo Islamskie²⁹. Dynamika zmian w działaniach grupy jest wyraźnie związana z jej postępami w przejmowaniu terytoriów wyżej wymienionych państw. Szczyt osiągnęła w 2014 r. i do 2017 r. była wysoce aktywna, wyprzedzając niekiedy Talibów. Widoczny spadek aktywności w 2018 r. i 2019 r. wynika najpewniej z utraty przez tę grupę większości terytoriów. W 2017 r. ISIS zostało wyparte z kontrolowanych przez siebie ośrodków miejskich, a dwa lata później organizacja utraciła kontrolę nad ostatnimi terytoriami w prowincji Baghuz w Syrii³⁰. Wraz z utratą terytoriów, a co za tym idzie – również środków na prowadzenie operacji, aktywność ISIS sukcesywnie malała. Wyraźny trend spadkowy jest widoczny nadal, jednak pomimo starań sił kurdyjskich, irackich, syryjskich czy też zaangażowania armii Stanów Zjednoczonych grupa pozostaje aktywna.

Warto zwrócić uwagę, że wszystkie najaktywniejsze grupy, pomimo podjęcia różnych działań i środków, w dalszym ciągu prowadzą działalność. Nie dotyczy to tych, które dokonały samorozwiązania na skutek negocjacji podjętych z nimi przez rządy poszczególnych państw.

Dla najbardziej aktywnych grup terrorystycznych obliczono współczynnik ofiar. Jest on przedstawiony w tabeli 3.

²⁵ Tamże, s. 7.

²⁶ Tamże, s. 15.

²⁷ *The Islamic State*, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/islamic-state> [dostęp: 11 VI 2022].

²⁸ Tamże.

²⁹ Tamże.

³⁰ Tamże.

Tabela 3. Współczynnik ofiar dla najaktywniejszych grup terrorystycznych.


Grupa terrorystyczna	Współczynnik ofiar
Państwo Islamskie	11,0:1
Boko Haram	10,0:1
Al-Szabab	5,8:1
Talibowie	5,8:1
Rewolucyjne Siły Zbrojne Kolumbii	3,6:1
Świetlisty Szlak	2,7:1
Komunistyczna Partia Indii (Maoistowska)	1,9:1
Nowa Armia Ludowa	1,8:1
Baskonia i Wolność	1,6:1
Maoiści	1,4:1

Źródło: opracowanie własne.

Można zauważyć, że współczynnik ofiar dla grup islamistycznych jest znacznie wyższy niż dla grup skrajnie lewicowych. Może to stanowić kolejny argument za dodaniem nowej cechy do zbioru danych – wskazującej na przynależność religijną lub polityczną danej grupy i dalsze eksplorowanie tego zagadnienia. Mogłoby to pozytywnie wpłynąć na doskonalenie modeli uczenia maszynowego w zakresie predykcji ofiar zamachów terrorystycznych.

Najczęstsze cele ataków terrorystycznych

Następnie dokonano wizualizacji charakterystyki ataków terrorystycznych w tym ich celów i typów. Na wykresie 10 przedstawiono w kolejności najczęstsze cele ataków terrorystycznych przeprowadzonych w latach 1970–2019. Były to: cywile oraz mienie, policja, instytucje rządowe (ogólne), biznes, transport publiczny, infrastruktura energetyczna, wojsko, przywódcy religijni lub instytucje religijne, szkoły, instytucje rządowe (dyplomaci).




Wykres 10. Najczęstsze cele ataków terrorystycznych z uwzględnieniem liczby przeprowadzonych na nie ataków.

Źródło: opracowanie własne.

Duża liczba ataków skierowanych w cywili oraz mienie może świadczyć o chęci zastraszenia opinii publicznej w danym państwie, a tym samym wpłynięcia na działania jego rządu. Z kolei ataki na policję, wojsko czy też instytucje rządowe mogą sygnalizować motywację polityczną grup terrorystycznych, często uważających władze państw za wroga, którego należy zwalczyć. Ataki na szeroko pojęty sektor prywatny, przeprowadzane np. przez FARC, mogą wskazywać na skrajnie lewicowe motywacje takich grup. Ich celem w dalszej perspektywie może być doprowadzenie do zniesienia własności prywatnej.

Typy ataków terrorystycznych

Sprawdzono również, jaki typ ataku terrorystycznego był przeprowadzany najczęściej (wykres 11). Uwzględniono podział na regiony, co pozwoliło na lepsze uwidocznienie specyfiki ataków dokonywanych w różnych częściach świata.



Wykres 11. Procentowy udział różnych typów ataków terrorystycznych z uwzględnieniem podziału na regiony.

Źródło: opracowanie własne.

Największy odsetek we wszystkich badanych regionach, z wyłączeniem Australazji i Oceanii, stanowiły ataki przeprowadzone przy użyciu materiałów wybuchowych. Ponadto częste były napaść z bronią w ręku i zabójstwo oraz – w niektórych regionach – ataki na infrastrukturę. Może to stanowić wskazówkę dla rządów państw, na jaki typ ataku instytucje państwowe powinny być przygotowane. Wówczas mogą one dokonywać oceny, czy służby właściwe w zakresie zwalczania zagrożenia terrorystycznego mają wypracowane odpowiednie procedury na wypadek danego typu zdarzenia oraz czy służba zdrowia będzie na tyle wydolna, żeby skutecznie opiekować się rannymi (mogłoby to zmniejszyć liczbę ofiar śmiertelnych). Taka ewaluacja obecnych możliwości instytucji państwowych wskazałaby pewne luki w odporności (ang. *resilience*) na tego typu zdarzenia.

Przetwarzanie danych

W kolejnym etapie dokonano przetworzenia danych. W pierwszej kolejności wyselekcjonowano ostateczne zmienne użyte do modelowania. Przedstawiono je w tabeli 4.

Tabela 4. Opis zmiennych użytych do przeprowadzenia badania.

Nazwa zmiennej	Opis zmiennej
<i>Extended</i>	określa, czy czas trwania zdarzenia przekroczył 24 godziny

<i>Country_txt</i>	określa kraj, w którym wystąpiło zdarzenie
<i>Region</i>	określa region, w którym wystąpiło zdarzenie
<i>Latitude</i>	określa szerokość geograficzną miejsca, w którym wystąpiło zdarzenie
<i>Longitude</i>	określa długość geograficzną miejsca, w którym wystąpiło zdarzenie
<i>Specificity</i>	określa rozdzielczość geoprzestrzeni pól szerokości i długości geograficznej. Najbardziej szczegółowa rozdzielczość dostępna w całym zbiorze danych to środek miasta, wsi lub miejscowości, w której nastąpił atak. Współrzędne o większej rozdzielczości, chociaż możliwe, nie są systematycznie umieszczane w bazie danych
<i>Vicinity</i>	określa, czy zdarzenie wystąpiło w bezpośrednim sąsiedztwie danego miasta
<i>Multiple</i>	określa, czy dany atak terrorystyczny jest powiązany z innymi zamachami
<i>Success</i>	sukces zamachu terrorystycznego definiuje się na podstawie jego namacalnych skutków. Sukcesu nie ocenia się w kategoriach szerszych celów sprawców. Na przykład bomba, która eksplodowała w budynku, zostałaby uznana za sukces, nawet gdyby nie udało się zniszczyć budynku ani wywołać represji rządowych
<i>Suicide</i>	określa, czy dany atak był zamachem samobójczym
<i>Attack type1</i>	określa typ ataku terrorystycznego
<i>Targ type1</i>	określa typ celu ataku terrorystycznego
<i>Targ subtype1</i>	określa bardziej szczegółowo kategorię celu
<i>Natlty1</i>	jest to narodowość zaatakowanego celu, niekoniecznie tożsama z krajem, w którym doszło do zdarzenia, choć zazwyczaj tak właśnie jest. W przypadku porwania samolotu rejestruje się jego przynależność państwową, a nie narodowość pasażerów
<i>Gname</i>	zawiera nazwę grupy, która przeprowadziła atak

<i>Guncertain1</i>	określa, czy informacje podawane przez źródła na temat grupy odpowiedzialnej za atak są oparte na spekulacjach lub wątpliwych roszczeniach dotyczących odpowiedzialności
<i>Individual</i>	określa, czy atak został przeprowadzony przez osobę lub kilka osób, o których nie wiadomo, czy są powiązane z grupą lub organizacją terrorystyczną
<i>Nperps</i>	określa łączną liczbę terrorystów uczestniczących w zdarzeniu
<i>Claimed</i>	służy do wskazania, czy grupa lub osoba (-y) przyznała się do ataku
<i>Weaptype1</i>	określa rodzaj użytej broni
<i>Weapsubtype1</i>	określa bardziej szczegółowo kategorię broni
<i>Property</i>	określa, czy w wyniku zdarzenia zostało uszkodzone mienie
<i>Ishostkid</i>	określa, czy podczas zdarzenia ofiary zostały pojmane jako zakładnicy lub porwane
<i>Int_log</i>	wskazuje, czy w celu przeprowadzenia ataku grupa sprawców przekroczyła granicę
<i>Int_misc</i>	wskazuje, czy grupa sprawców zaatakowała cel innej narodowości
<i>Int_any</i>	określa, czy zostały spełnione wszystkie warunki zmiennych z przedrostkiem <i>int</i>
<i>Cas_class</i>	określa, czy zdarzenie spowodowało ofiary

Źródło: opracowanie własne na podstawie: *Codebook: Inclusion Criteria and Variables*, Global Terrorism Database, sierpień 2018 r., <http://www.start-dev.umd.edu/gtd/downloads/Codebook.pdf> [dostęp: 30 V 2022].

Ten zabieg spowodował zmniejszenie liczby kolumn z 60 do 28. Ograniczenie liczby cech przyspieszy modelom uczenia maszynowego proces treningu. Ze względu na to, że część kolumn występuje w formie liczbowej lub tekstowej, jak np. *region* i *region_txt*, zdecydowano się w takim przypadku na wybór tylko jednej kolumny w celu uproszczenia zbioru danych. Zostały usunięte również kolumny zawierające takie metadane, jak unikalny identyfikator zdarzenia czy też pierwotne źródło danych. Nie wzięto pod uwagę zmiennych określających warunki włączenia danego zdarzenia do GTD, ponieważ – jak już wspomniano – zostały odfiltrowane te ataki, które nie

spełniały wszystkich warunków, oraz te, co do których istniały wątpliwości. Tym samym te zmienne nie dostarczają modelom uczenia maszynowego istotnych informacji wpływających na predykcję, a tylko wydłużałyby proces treningu. Ostatnią grupą usuniętych cech są zmienne określające liczbę ofiar lub rannych. Wyeliminowanie ich miało na celu uniknięcie wycieku danych (ang. *data leakage*), przez co wyniki badania byłyby niemiarodajne.

Następnie sprawdzono, jak wiele ataków terrorystycznych zakończyło się ofiarami. W ok. 59% przypadków doszło do zabicia lub ranienia co najmniej jednej osoby niebędącej terrorystą. To oznacza, że występuje niezbalansowanie klas w przewidywanej zmiennej, co może negatywnie wpłynąć na wynik predykcji. Ten problem został rozwiązany podczas budowania modeli uczenia maszynowego poprzez ustawienie parametru *class weight* na wartość *balanced*. Dzięki temu modele zwracają większą uwagę na klasę mniej liczną, co pomaga zrównoważyć wpływ każdej klasy na model, zwiększając tym samym ogólną skuteczność predykcji.

W dalszej kolejności dokonano podziału na zbiór treningowy (80% danych) oraz testowy (pozostałe 20%). Zastosowano przy tym próbkowanie warstwowe (ang. *stratified sampling*), żeby zapewnić podobne rozłożenie klas przewidywanej zmiennej jak w całym zbiorze danych.

W kolejnym kroku utworzono potok (ang. *pipeline*) dokonujący ostatecznych przekształceń na zbiorze danych.

Pierwszym etapem jest transformacja zmiennych *country_txt* oraz *gname* z formy tekstowej na liczbową, ponieważ zbudowane modele uczenia maszynowego mogą pracować wyłącznie na danych w takiej postaci. Z powodu dużej liczby unikalnych wartości w obu kolumnach zdecydowano się na zakodowanie ich na podstawie liczebności występowania. Ta metoda – w przeciwieństwie do metody kodowania 1 z n (ang. *one-hot encoding*), której efektem jest powstanie takiej liczby kolumn, ile jest unikalnych wartości – nie ma efektów ubocznych w postaci zwiększenia wymiarowości danych.


Następnie zamieniono wartości puste na -9. W ten sposób w GTD koduje się wartości, co do których badacze nie mieli wystarczających informacji, aby w sposób jednoznaczny przypisać konkretną wartość do danej cechy zdarzenia³¹.

W ostatnim etapie dokonano normalizacji danych ze względu na to, że część zbudowanych modeli, takich jak np. regresja logistyczna czy maszyny

³¹ *History of the GTD...*

wektorów nośnych, jest wrażliwa na skrajnie różne skale wartości. Ta metoda rozwiązuje problem i może przelożyć się na lepsze wyniki tych modeli oraz przyspieszyć proces uczenia.

Warto wskazać, że obliczanie liczebności występowania danych wartości powinno się odbywać wyłącznie na zbiorze treningowym. Na zbiorze testowym zaś dokonuje się transformacji na podstawie wyliczeń ze zbioru treningowego. Jest to istotne, ponieważ inna procedura prowadzi do wycieku danych, a co za tym idzie – rzutuje na wyniki badania. Z tego też powodu zdecydowano się na zastosowanie potoku dostępnego w bibliotece Scikit-learn, dzięki któremu w prosty sposób można kontrolować etapy przekształceń i zredukować tym samym ryzyko pomyłki (rysunek 4).



Rysunek 4. Potok przeprowadzający przekształcenia na zbiorze danych.

Źródło: opracowanie własne.

Na koniec etapu przetwarzania danych zapisano zbiór treningowy oraz testowy do osobnych plików, żeby zachować przeprowadzone przekształcenia i móc po ich późniejszym wczytaniu przejść bezpośrednio do modelowania.

Proces trenowania modeli uczenia maszynowego

Wszystkie modele były trenowane na komputerze stacjonarnym o parametrach: 16 GB RAM, procesor AMD Ryzen 5 3600. Każdy model trenowano w analogiczny sposób: hiperparametry były wyszukiwane za pomocą frameworka Optuna, a metryki zapisywano za pomocą biblioteki

MLFlow. Aby uniknąć niepotrzebnych powtórzeń, proces trenowania zostanie pokazany tylko na przykładzie drzewa decyzyjnego (rysunek 5).

```

def objective(trial):
    params = {
        "max_depth": trial.suggest_int("max_depth", 15, 50),
        "min_samples_leaf": trial.suggest_int("min_samples_leaf", 1, 40),
        "class_weight": trial.suggest_categorical("class_weight", ["balanced"]),
        "criterion": trial.suggest_categorical("criterion", ["gini", "entropy"])
    }

    model = DecisionTreeClassifier(**params)

    scoring = ["accuracy", "precision", "recall", "f1"]

    preds = cross_validate(model, X_train, y_train, cv=5, n_jobs=-1, scoring=scoring)

    accuracy = np.mean(preds["test_accuracy"])
    precision = np.mean(preds["test_precision"])
    recall = np.mean(preds["test_recall"])
    f1 = np.mean(preds["test_f1"])

    return accuracy, precision, recall, f1

```

Rysunek 5. Fragment kodu odpowiedzialny za wyszukiwanie hiperparametrów.

Źródło: opracowanie własne.

W pierwszej liniжке zdefiniowano funkcję, której nazwa oraz przyjmowane argumenty są zgodne z konwencją przyjętą w Optunie. W liniжkach 2–7 określono przestrzeń hiperparametrów. W późniejszym etapie została ona przeszukana w celu znalezienia jak najlepszej ich kombinacji. Dla liniжek 2–3 oznaczono przedział, w którym wartości tych hiperparametrów mają zostać wyszukiwane, i w tym wypadku będzie to liczba całkowita. Na szczególną uwagę zasługuje liniжка 5. Zaznaczono w niej, że waga klas (ang. *class weight*) powinna być zbalansowana (ang. *balanced*). Jest to jedna z metod rozwiązania wcześniej wspomnianego problemu niezbalansowania klas. W dalszej kolejności dokonano inicjalizacji modelu w liniжке 9, a następnie określono metryki użyte do oceny modeli, czyli kolejno: dokładność (ang. *accuracy*), precyzję (ang. *precision*), czułość (ang. *recall*) oraz F1. Zostaną one szczegółowo omówione w dalszej części artykułu. W liniжке 13 następuje trening modelu na zbiorze treningowym za pomocą walidacji krzyżowej (ang. *cross validation*), a następnie są obliczane wyniki dla poszczególnych zmiennych, które na końcu są zwracane przez tę funkcję.

W kolejnym kroku utworzono tzw. *study*, w którym określa się jego nazwę oraz kierunek optymalizacji metryk. Ze względu na to, że zastosowane metryki dotyczą problemu klasyfikacyjnego, to zostały one

zmaksymalizowane. Następnie dokonuje się przeszukiwania hiperparametrów (rysunek 6), które są zapisywane za pomocą MLFlow (rysunek 7).

```

1 study = optuna.create_study(study_name="decision_tree",
2                             directions=["maximize", "maximize", "maximize", "maximize"])
3 study.optimize(objective, n_trials=100, callbacks=[mlflow_callback])

```

Rysunek 6. Inicjalizacja wyszukiwania hiperparametrów przez Optunę.

Źródło: opracowanie własne.

Metrics <		Parameters <							
<input type="checkbox"/>	accuracy	f1	precision	recall	criterion	max_depth	max_features	min_samples_leaf	min_samples_split
<input type="checkbox"/>	0.849	0.868	0.892	0.845	entropy	21	-	38	-
<input type="checkbox"/>	0.848	0.868	0.887	0.849	entropy	37	-	15	-
<input type="checkbox"/>	0.848	0.868	0.89	0.846	entropy	33	None	20	82
<input type="checkbox"/>	0.848	0.867	0.888	0.848	entropy	25	-	17	-
<input type="checkbox"/>	0.848	0.867	0.89	0.846	entropy	18	None	34	31
<input type="checkbox"/>	0.848	0.867	0.89	0.846	entropy	18	None	34	31

Rysunek 7. Fragment dashboardu z MLFlow z zapisanymi metrykami i parametrami drzewa decyzyjnego.

Źródło: opracowanie własne.

Dla każdego modelu wykonano kilkaset iteracji w celu wyszukania optymalnych hiperparametrów. Następnie wszystkie modele z optymalnymi dla nich hiperparametrami wytrenowano na całym zbiorze treningowym i dokonano walidacji na zbiorze testowym. Do treningu zostały wybrane te modele, które osiągnęły najwyższe wartości metryki F1. Parametry tych modeli oraz ich wyniki zostaną przedstawione później. Wcześniej opisano poszczególne metryki jakości modeli klasyfikacyjnych użytych podczas badania.

Wybrane miary jakości modeli klasyfikacyjnych

Ze względu na wielość różnych miar jakości znajdujących zastosowanie w ocenie modeli klasyfikacyjnych zostały opisane tylko te miary, których użyto podczas badania.

Dokładność klasyfikatora jest miarą określającą, jak wiele przypadków zostało sklasyfikowanych poprawnie³². Można ją przedstawić następującym wzorem:

$$\text{dokładność} = \frac{\text{PP} + \text{PN}}{\text{FP} + \text{FN} + \text{PP} + \text{PN}}$$

gdzie:

- PP, czyli prawdziwie pozytywne (ang. *true positive*, TP) przypadki, kiedy model poprawnie sklasyfikował dane zdarzenie jako powodujące ofiary;
- PN, czyli prawdziwie negatywne (ang. *true negative*, TN) przypadki, kiedy model poprawnie sklasyfikował dane zdarzenie jako niepowodujące ofiar;
- FP, czyli fałszywie pozytywne (ang. *false positive*, FP) przypadki, kiedy model niepoprawnie sklasyfikował dane zdarzenie jako powodujące ofiary;
- FN, czyli fałszywie negatywne (ang. *false negative*, FN) przypadki, kiedy model niepoprawnie sklasyfikował dane zdarzenie jako niepowodujące ofiar³³.

Dwie kolejne miary, czyli precyzja oraz czułość, są ze sobą bezpośrednio związane. Precyzja promuje sytuację, w której klasyfikator jest pewien swoich decyzji i popełnia jak najmniej błędów rodzaju fałszywie pozytywnego, jednakże kosztem tego jest zwiększenie przewidywań fałszywie negatywnych³⁴. Odwrotnie jest w przypadku czułości, ponieważ promuje się tę sytuację, w której klasyfikator dokonuje jak najmniej błędów rodzaju fałszywie negatywnego, jednak kosztem zwiększenia przypadków fałszywie pozytywnych³⁵. Jeśli więc zoptymalizujemy klasyfikator w taki sposób, aby minimalizował szanse niepoprawnego sklasyfikowania danego zdarzenia

³² S. Raschka i in., *Machine Learning with PyTorch and Scikit-Learn: Develop machine learning and deep learning models with Python*, Birmingham 2022, s. 13.

³³ Tamże, s. 195.

³⁴ Tamże, s. 196.

³⁵ Tamże.

jako niepowodującego ofiar, to będzie się on cechował wysoką czułością. Wzór na obliczenie czułości jest następujący:

$$\text{czułość} = \frac{PP}{FN + PP}$$

Odbędzie się to jednak kosztem precyzji, wyrażonej wzorem:

$$\text{precyzja} = \frac{PP}{PP + FP}$$

W celu zrównoważenia precyzji i czułości stosuje się miarę F1, która jest średnią harmoniczną precyzji i czułości³⁶. Oznacza to, że aby osiągnąć wysoką wartość miary F1, klasyfikator musi mieć wysokie wyniki zarówno w precyzji, jak i czułości, ponieważ średnia harmoniczna przywiązuje większą wagę do niskich wartości³⁷. Wartość miary F1 oblicza się następująco:

$$F1 = 2 \frac{\text{precyzja} \times \text{czułość}}{\text{precyzja} + \text{czułość}}$$

Wyniki badania dla poszczególnych modeli

W tabelach 5–8 zaprezentowano hiperparametry dla poszczególnych modeli uczenia maszynowego, a w tabeli 9 – wyniki ich walidacji na zbiorze testowym. Należy zaznaczyć, że przedstawiono tylko te wartości hiperparametrów, które były wcześniej wyszukiwane. Jeśli jakiś hiperparametr nie znajduje się w tabeli, to oznacza, że przyjmuje wartość domyślną zgodną z dokumentacją właściwej biblioteki. Ze względu na to, że klasyfikator

³⁶ A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, Sebastopol 2019, s. 140.

³⁷ Tamże.

głosujący oraz klasyfikator oparty na nakładaniu składają się z innych zbudowanych modeli, to ich hiperparametry są identyczne z tymi przedstawionymi w tabelach.

Tabela 5. Wartości hiperparametrów dla regresji logistycznej.

Nazwa hiperparametru	Wartość
<i>C</i>	9,58649376280703
<i>class_weight</i>	balanced
<i>max_iter</i>	500

Źródło: opracowanie własne.

Tabela 6. Wartości hiperparametrów dla liniowej maszyny wektorów nośnych.

Nazwa hiperparametru	Wartość
<i>C</i>	0,0036775852394361204
<i>class_weight</i>	balanced
<i>dual</i>	false
<i>penalty</i>	L1

Źródło: opracowanie własne.

Tabela 7. Wartości hiperparametrów dla drzewa decyzyjnego.

Nazwa hiperparametru	Wartość
<i>criterion</i>	entropy
<i>class_weight</i>	balanced
<i>max_depth</i>	21
<i>min_samples_leaf</i>	38

Źródło: opracowanie własne.

Tabela 8. Wartości hiperparametrów dla lasu losowego.

Nazwa hiperparametru	Wartość
<i>criterion</i>	entropy
<i>class_weight</i>	balanced

<i>max_depth</i>	42
<i>min_samples_split</i>	6
<i>n_estimators</i>	551
<i>max_features</i>	sqrt

Źródło: opracowanie własne.

Tabela 9. Wartości hiperparametrów dla modelu XGBoost.

Nazwa hiperparametru	Wartość
<i>colsample_bylevel</i>	0,6783261477402747
<i>colsample_bytree</i>	0,23127225599162296
<i>gamma</i>	0,4906870500968865
<i>learning_rate</i>	0,0675784773135259
<i>max_delta_step</i>	5
<i>max_depth</i>	22
<i>min_child_weight</i>	1
<i>n_estimators</i>	1475
<i>reg_alpha</i>	0,12263684424466229
<i>reg_lambda</i>	1,9559489540115411
<i>scale_pos_weight</i>	0,9676022078596858
<i>subsample</i>	0,976706655475712

Źródło: opracowanie własne.

W tabeli 10 znajdują się wyniki poszczególnych modeli wraz z ich czasem treningu. Najlepsze wyniki z danej kategorii zostały wytłuszczone.

Tabela 10. Wyniki poszczególnych modeli uczenia maszynowego.

Nazwa modelu	Czas trwania treningu	Dokładność	Precyzja	Czułość	F1
Regresja logistyczna	2,8 s	0,765	0,823	0,762	0,792
Maszyny wektorów nośnych	10,4 s	0,765	0,824	0,763	0,792

Drzewo decyzyjne	1,0 s	0,845	0,894	0,835	0,864
Las losowy	1,3 min	0,876	0,891	0,898	0,895
XGBoost	1,4 min	0,879	0,890	0,905	0,898
Klasyfikator głosujący	3,6 min	0,870	0,888	0,891	0,889
Klasyfikator oparty na nakładaniu	7,8 min	0,879	0,904	0,889	0,896


Źródło: opracowanie własne.

Najlepszym modelem pod względem wartości miar jakości jest XGBoost. Ewidentnie gorsze wyniki osiągnęły modele liniowe, czyli regresja logistyczna oraz maszyny wektorów nośnych. W związku z tym w dalszych badaniach prawdopodobnie lepiej będzie się skupić na modelach drzewiastych. Warto zwrócić uwagę na to, że różnica w wynikach pomiędzy XGBoost a klasyfikatorem opartym na nakładaniu jest niewielka, jednakże czas treningu XGBoosta jest ponadpięciokrotnie krótszy. Takie wyniki sugerują, że w dalszych badaniach należy skoncentrować się na modelach drzewiastych opartych na wzmacnianiu gradientowym.

Źadnemu modelowi nie udało się przekroczyć progu 90-procentowej skuteczności w metryce F1 pomimo wielu iteracji przy poszukiwaniu hiperparametrów. Prawdopodobnie do osiągnięcia wyników rzędu ok. 95% potrzebne byłoby rozbudowanie zbioru danych o nowe zmienne, takie jak np. przynależność polityczna/religijna danej grupy terrorystycznej, występowanie w danym kraju napięć na tle etnicznym/politycznym/religijnym, odległość miejsca zdarzenia od najbliższego szpitala.

Zdecydowano się również na obliczenie istotności cech (ang. *feature importance*) dla modelu opartego na bibliotece XGBoost, w celu ustalenia, które cechy były najistotniejsze dla tego modelu podczas dokonywania predykcji. Zostało to zaprezentowane na wykresie 12. Na osi y znajdują się opisane wcześniej cechy, a na osi x ukazano wartość danej cechy dla predykcji. Najważniejsze były cele oraz podtyp broni. Podczas ewaluacji planów kryzysowych na wypadek ataku terrorystycznego te dwa czynniki powinny być szczególnie uważnie przeanalizowane. Zbiór czynników geograficznych, takich jak np. region czy długość i szerokość geograficzna, wskazuje

na to, że terroryzm stanowi problem dla niektórych obszarów świata i ma różną charakterystykę.



Wykres 12. Najistotniejsze cechy dla modelu XGBoost.

Źródło: opracowanie własne.

Wnioski

Przeprowadzono badanie zamachów terrorystycznych występujących w latach 1970–2019, w tym dogłębnie przeanalizowano trendy w aktywności wybranych grup terrorystycznych. Zbudowane modele zespołowe osiągnęły zdecydowanie lepsze wyniki od modeli liniowych.

Uzyskane rezultaty wskazują, że w przyszłości należałoby się skupić na modelach opartych na uczeniu zespołowym, ponieważ modele liniowe, takie jak chociażby regresja logistyczna, poradziły sobie wyraźnie gorzej. W szczególności należy się przyjrzeć modelom drzewiastym opartym na wzmacnianiu gradientowym, gdyż XGBoost uzyskał lepsze wyniki przy krótszym czasie treningu w porównaniu z klasyfikatorem głosującym i klasyfikatorem opartym na nakładaniu. W dalszych badaniach można również sprawdzić skuteczność modeli podobnych do XGBoost, jak np. CatBoost,

LightGBM, lub sprawdzić, jak z takim zadaniem poradziłyby sobie głębokie sieci neuronowe.

Po opublikowaniu przez badaczy z konsorcjum START pełnych danych za lata 2020–2021 warto byłoby dokonać analizy, czy zmieniła się aktywność terrorystów, oraz scharakteryzować ich działania podczas pandemii COVID-19. Również uzupełnienie GTD o nowe zmienne, takie jak np. informacje na temat napięć etnicznych czy religijnych, kondycji ekonomicznej danego państwa czy też przynależności religijnej lub politycznej danej grupy terrorystycznej, mogłoby pozytywnie wpłynąć na wyniki klasyfikacji, w tym pomóc przekroczyć barierę 90%.

Niniejszy artykuł wskazuje, że jest możliwe skuteczne wykorzystanie uczenia maszynowego w zakresie bezpieczeństwa. Może to wspomóc odpowiednie organy przy tworzeniu planów zarządzania kryzysowego w przypadku zaistnienia zdarzenia o charakterze terrorystycznym. Państwo może również podjąć działania edukacyjne w postaci kampanii informacyjnych czy też uczenia w szkołach, jak należy się zachowywać podczas zamachu terrorystycznego w zależności od jego rodzaju. Jak wykazano za pomocą wartości istotności zmiennych, to właśnie cel ataku był najważniejszym czynnikiem dla modelu XGBoost, a jak wskazano wcześniej, najczęściej atakowani są cywile. Dzięki działaniom edukacyjnym prawdopodobnie możliwe byłoby zmniejszenie do pewnego stopnia liczby ofiar zamachów terrorystycznych. Drugim ważnym czynnikiem okazał się podtyp broni, zatem po dogłębnym przeanalizowaniu przez odpowiednie służby środków stosowanych przez grupy terrorystyczne na danym terenie można byłoby opracować nowe regulacje prawne utrudniające terrorystom pozyskiwanie broni.

Bibliografia

Géron A., *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, Sebastopol 2019.

Matfess H., *Boko Haram: History and Context*, w: *Oxford Research Encyclopedia of African History*, Oxford University Press 2017.

Raschka S. i in., *Machine Learning with PyTorch and Scikit-Learn: Develop machine learning and deep learning models with Python*, Birmingham 2022.

Źródła internetowe

Basque group Eta says armed campaign is over, BBC News, 20 X 2011 r., <https://www.bbc.com/news/world-europe-15393014> [dostęp: 6 VI 2022].

Binnie I., *Basque separatist group ETA says it has „completely dissolved”*, Reuters, 2 V 2018 r., <https://www.reuters.com/article/us-spain-eta-idUSKBN1I31TP> [dostęp: 6 VI 2022].

Codebook: Inclusion Criteria and Variables, Global Terrorism Database, sierpień 2018 r., <https://www.start.umd.edu/gtd/downloads/Codebook.pdf/> [dostęp: 30 V 2022].

Communist Part of the Philippines – New People’s Army, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/communist-party-philippines-new-peoples-army> [dostęp: 11 VI 2022].

Data Collection Methodology, Global Terrorism Database, <http://www.start-dev.umd.edu/gtd/using-gtd/> [dostęp: 21 V 2022].

Deaths in Maoist attacks down by 21%: Shah at CMs’ meeting, The Times of India, 27 IX 2021 r., <https://timesofindia.indiatimes.com/india/deaths-in-naxal-attacks-down-by-21-shah-at-cms-meeting/articleshow/86543018.cms> [dostęp: 8 VI 2022].

History of the GTD, Global Terrorism Database, <https://start.umd.edu/gtd/about/History.aspx> [dostęp: 11 V 2022].

Left Wing Extremism Division, Ministry of Home Affairs, https://web.archive.org/web/20220707070953/https://www.mha.gov.in/division_of_mha/left-wing-extremism-division [dostęp: 8 VI 2022].

Pentagon confirms death of Somalia terror leader, The Washington Times, 5 IX 2014 r., <https://www.washingtontimes.com/news/2014/sep/5/pentagon-confirms-death-of-somalia-terror-leader/> [dostęp: 10 VI 2022].

Revolutionary Armed Forces of Colombia (FARC), Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/revolutionary-armed-forces-colombia-farc> [dostęp: 8 VI 2022].

Saffón S., *Peru in Familiar Stalemate With Shining Path Rebels*, InSight Crime, 4 IX 2020 r., <https://insightcrime.org/news/brief/peru-stalemate-shining-path/> [dostęp: 8 VI 2022].

Sethi A., *Green Hunt: the anatomy of an operation*, The Hindu, 6 II 2010 r., <https://www.thehindu.com/opinion/op-ed/Green-Hunt-the-anatomy-of-an-operation/article16812797.ece> [dostęp: 8 VI 2022].

The Afghan Taliban, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/afghan-taliban> [dostęp: 8 VI 2022].

The Islamic State, Stanford University, <https://cisac.fsi.stanford.edu/mappingmilitants/profiles/islamic-state> [dostęp: 11 VI 2022].

Jakub Tuszyński

Absolwent studiów magisterskich na Uniwersytecie Warszawskim na kierunku zarządzanie big data.