



**Politechnika
Śląska**

**DYSCYPLINA NAUKOWA
INŻYNIERIA LĄDOWA,
GEODEZJA I TRANSPORT**

ROZPRAWA DOKTORSKA

mgr Michał Bukała

System automatycznej detekcji i klasyfikacji zdarzeń akustycznych związanych z przelotami statków powietrznych

Design of system for automatic detection and classification
of aircraft noise events

Promotor

dr hab. inż. Artur Nowoświat, prof. PŚ

Opiekun

dr inż. Andrzej Chyla

Gliwice, 2024

*Patrycji
Jagdzie
Franciszkowi*

PODZIĘKOWANIA

Składam szczerze i serdeczne podziękowania całemu gronu osób, bez których wsparcia powstanie tej pracy nie byłoby możliwe.

W pierwszym rzędzie podziękowania należą się mojemu promotorowi, dr. hab. inż. Arturowi Nowoświatowi, profesorowi Politechniki Śląskiej, którego wiedza i doświadczenie nawigowały mnie przez wszystkie zawilości, wskazując to, co najistotniejsze i najważniejsze.

Nie sposób nie docenić wkładu i wsparcia udzielonego przez dr. inż. Andrzeja Chylę, którego niezachwiana postawa i okazane wsparcie dały iskrę, od której rozpoczęła się cała rzecz a cenne dyskusje, prowadzone w toku pracy, dawały nieszablonowe i krytyczne spojrzenie na jego przebieg.

Składam serdeczne podziękowania moim współpracownikom i droгим kolegom, z którymi mam szczęście współpracować w Laboratorium Badawczym SVANTEK. Dzięki żmudnej pracy Mariusza i Pawła miałem w dyspozycji unikalną bazę danych, stanowiącą kapitał, leżący u podstaw wszystkich prowadzonych badań.

Dziękuję również nieocenionemu dr. hab. inż. Jackowi Pieprzycy, prof. PŚ, który na comiesięcznych spotkaniach seminaryjnych zdołał przekazać cenne rady, zarówno w zakresie związanym z niniejszą dysertacją, jak i dalece poza ów zakres wykraczające, a także Koleżankom i Kolegom, w których towarzystwie miałem przyjemność spotkania te odbywać. Obserwacja ich postępów w ramach Szkoły Doktorów Politechniki Śląskiej była dla mnie przykładem i źródłem motywacji.

Na koniec chciałbym gorąco podziękować mojej najbliższej rodzinie, a w szczególności drogiej małżonce, której łagodna stanowczość pozwoliła mi przetrwać momenty zwątpienia, a ustępstwa i wyrzeczenia dały czas i przestrzeń, aby niniejsza rozprawa mogła zostać ukończona.

STRESZCZENIE

Wraz ze wzrostem udziału lotnictwa w globalnej strukturze transportu pasażerskiego oraz transportu towarów zyskują na znaczeniu zagadnienia związane ze związanymi z tym emisjami zanieczyszczeń do środowiska. Za takie zanieczyszczenie uznawany jest także hałas, wpływający na komfort i zdrowie społeczności zamieszkujących okolice portów lotniczych. Aby skutecznie zarządzać ruchem lotniczym pod kątem możliwości ograniczenia emisji hałasu na terenach wrażliwych, takich jak obszary gęstej zabudowy mieszkaniowej, niezbędne jest prowadzenie ciągłego monitoringu hałasu.

Podstawowym założeniem obowiązujących metod pomiarów hałasu lotniczego jest potrzeba określenia wartości poziomu ekspozycji na hałas L_{AE} dla każdej operacji statku powietrznego, wykonywanej w zasięgu aparatury pomiarowej. Z kolei kluczowym elementem tego zadania jest precyzyjne wyodrębnienie hałasu statku powietrznego spośród rejestrowanych przez przyrządy sygnałów niepożądanych, czyli tzw. tła akustycznego. Niniejsza praca przedstawia propozycję metody analizy danych pomiarowych, umożliwiającej automatyczną detekcję zdarzeń akustycznych, związanych z operacjami lotniczymi, oraz opisuje sposób jej wdrożenia w rzeczywistym systemie pomiarowym.

W oparciu o prowadzone w latach 2022 – 2023 pomiary poziomu dźwięku hałasu lotniczego, z towarzyszącą 1/3-oktawową analizą widmową, przy wykorzystaniu osiągnięć technik uczenia głębokiego, opracowano architekturę konwolucyjnej sieci neuronowej, zdolnej do efektywnej ekstrakcji kluczowych cech sygnału, przy narzuconej technika pomiarową reprezentacji sygnału wejściowego. Określono także sposób interpretacji wskazań opracowanego modelu, który pozwolił na identyfikację zdarzeń akustycznych ze skutecznością, wynoszącą 97%.

Przeprowadzone badania potwierdziły potencjał rozwiązań opartych o uczenie głębokie w zakresie analizy danych widmowych, w celu identyfikacji źródeł sygnału akustycznego, rejestrowanego przy użyciu relatywnie prostych systemów pomiarowych. Umożliwia to ich szerokie zastosowanie, między innymi w rozwiązaniach typu *smart city*, ułatwiających zarządzanie transportem publicznym pod kątem możliwości zapewnienia komfortu akustycznego mieszkańcom miast, a także w systemach wykrywających obiekty o specyficznej sygnaturze akustycznej, przekraczające granice określonych obszarów.

ABSTRACT

As the aviation sector continues to expand its share in global passenger and cargo transportation, issues related to the environmental impact of associated emissions are gaining increasing importance. Noise pollution, which affects the comfort and health of communities living near airports, is also considered a significant environmental concern. To effectively manage air traffic with the goal of reducing noise emissions in sensitive areas, such as densely populated residential zones, continuous noise monitoring is essential.

The fundamental premise of current methods for measuring aircraft noise is to determine the L_{AE} (Sound Exposure Level) for each aircraft operation within the reach of measurement equipment. A critical component of this task is the precise extraction of aircraft noise events from the unwanted signals recorded by the instruments, known as acoustic background noise. This dissertation proposes a method for analyzing measurement data that enables the automatic detection of acoustic events associated with aircraft operations and describes the implementation of this method in a real measurement system.

Based on sound level measurements of aircraft noise conducted from 2022 to 2023, accompanied by one-third octave band spectral analysis, and leveraging advances in deep learning techniques, a convolutional neural network architecture was developed. This network is capable of efficiently extracting key signal features while adhering to the constraints imposed by the measurement technique on input signal representation. The study also defined a method for interpreting the model's outputs, which allowed for the identification of acoustic events with an accuracy of 97%.

The research confirmed the potential of deep learning-based solutions in the spectral data analysis for identifying sources of acoustic signals recorded using relatively simple measurement systems. This opens up broad applications, including in smart city solutions that facilitate public transport management to ensure acoustic comfort for city residents, as well as in systems detecting objects with specific acoustic signatures that cross the boundaries of designated areas.


SPIS TREŚCI

Podziękowania	iii
Streszczenie	iv
Abstract	v
1 Wprowadzenie	8
1.1 Problematyka hałasu lotniczego	9
1.2 Cel i teza pracy	12
1.3 Zakres rozprawy	13
2 Wybrane zagadnienia akustyki w lotnictwie	15
2.1 Podstawowe pojęcia	15
2.1.1 Poziom ciśnienia akustycznego i poziom dźwięku A	15
2.1.2 Równoważny poziom dźwięku A	17
2.1.3 Poziom ekspozycji na hałas	18
2.1.4 Analiza częstotliwościowa i filtry 1/3-oktawowe	20
2.2 Charakterystyka sygnałów akustycznych generowanych przez przeloty statków powietrznych	21
2.3 Systemy monitoringu hałasu lotniczego	22
2.4 Metody detekcji zdarzeń akustycznych	24
3 Sztuczne sieci neuronowe	29
3.1 Podstawowe założenia sieci neuronowych	29
3.2 Konwolucyjne sieci neuronowe	33
3.3 Rekurencyjne sieci neuronowe	36
3.4 Ocena skuteczności i jakości modelu	37
4 Badania terenowe	41
4.1 Pomiar emisji hałasu lotniczego	41
4.2 Charakterystyka badanych lotnisk	44
4.2.1 Port Lotniczy im. Lecha Wałęsy w Gdańsku	45
4.2.2 Międzynarodowy Port Lotniczy im. Wojciecha Korfańskiego w Pyrzowicach	48
4.3 Punkty pomiaru hałasu	50
4.4 Aparatura pomiarowa	58
4.4.1 Stacje monitoringu hałasu	58
4.4.2 Odbiornik ADS-B Kinetic	60
4.5 Charakterystyka rejestrowanego hałasu	61
4.6 Manualna metoda klasyfikacji	66
4.7 Ocena jakości pozyskanych danych	67
4.7.1 Podstawowe błędy występujące podczas obróbki danych	68
4.7.2 Analiza zdarzeń w dziedzinie czasu	69
4.7.3 Analiza uśrednionych widm 1/3-oktawowych	72
4.8 Podsumowanie	73
5 Koncepcja systemu detekcji	75
5.1 Zestawienie klasycznej i neuronowej metody detekcji	76

5.1.1	Metoda I – wieloprogowa	77
5.1.2	Metoda II – CNN	79
5.1.3	Porównanie metod	80
5.2	Kluczowe założenia	81
5.3	Architektura algorytmu przetwarzania.....	83
5.3.1	Wstępna koncepcja	83
5.3.2	Zrewidowana koncepcja	86
6	Badanie możliwości konwolucyjnych sieci neuronowych w zakresie klasyfikacji hałasu lotniczego.....	88
6.1	Środowisko testowe	88
6.2	Przygotowanie zbiorów danych treningowych i walidacyjnych.....	89
6.2.1	Problem błędów w etykietowaniu danych w otoczeniu innych zdarzeń	92
6.2.2	Problem ramek mieszanych	93
6.2.3	Problem zidentyfikowanych zakłóceń	94
6.2.4	Problem nietypowych zdarzeń.....	96
6.2.5	Podsumowanie	96
6.3	Badane modele konwolucyjnych sieci neuronowych	97
6.4	Eksperyment 1: wybór strategii przetwarzania danych wejściowych	101
6.4.1	Założenia.....	101
6.4.2	Metoda oceny jakości predykcji	102
6.4.3	Wyniki eksperymentu	103
6.5	Eksperyment 2: wybór architektury sieci.....	108
6.5.1	Założenia i metoda oceny	108
6.5.2	Wyniki.....	109
6.6	Podsumowanie	112
7	Badanie możliwości zastosowania sieci neuronowych w systemie detekcji zdarzeń akustycznych.....	114
7.1	Przygotowanie zbiorów danych strojących i testowych	114
7.2	Eksperyment 3: badanie procesu klasyfikacji dla sieci CNN	115
7.2.1	Założenia i metoda oceny	116
7.2.2	Etap treningu.....	119
7.2.3	Etap strojenia	120
7.2.4	Testy końcowe.....	123
7.3	Eksperymenty 4: badanie możliwości zastosowania sieci rekurencyjnych.....	125
8	Zastosowania w systemach pomiarowych	128
9	Podsumowanie	130
	Bibliografia	132
	Spis ilustracji.....	139
	Spis tabel.....	143
	Dodatki.....	144
A.	Szczegóły badanych architektur sieci	144
B.	Szczegółowy opis implementacji systemu detekcji	149

1 WPROWADZENIE

Skokowy rozwój cywilizacyjny i technologiczny, który można obserwować od połowy XX stulecia, łączy się nierozdzielnie z rosnącymi potrzebami w zakresie transportu ludzi i towarów. Zapotrzebowanie takie przekłada się na niemal nieprzerwany od 1945 roku globalny wzrost ruchu lotniczego (Rys. 1.1). Jedyne istotne załamanie tego trendu, związane z czasowymi ograniczeniami spowodowanymi pandemią COVID-19 można uznać za zakończone w roku 2023, kiedy to globalny ruch lotniczy osiągnął 95% wartości sprzed wprowadzenia ograniczeń [80].



Rys. 1.1 Statystyki ruchu lotniczego w latach 1945 – 2021 [84].

Tak istotny wzrost liczby pasażerów łączy się rzecz jasna ze zwiększeniem ilości obsługiwanych statków powietrznych. Flota pasażerska złożona jest w znacznej mierze z samolotów napędzanych silnikami turbowentylatorowymi oraz turbośmigłowymi. Stanowią one istotne źródło emisji zanieczyszczeń powietrza oraz dotykającego coraz większą liczbę zamieszkujących sąsiadujące z portami lotniczymi tereny ludzi hałasu.

Aby skutecznie zarządzać emisjami, w tym hałasem, konieczne są precyzyjne i proste w implementacji metody ich oceny, tak obliczeniowej jak i pomiarowej. Niniejsza praca, poruszając zagadnienia u zbiegu transportu, akustyki oraz technologii informatycznych, stanowi próbę wskazania metody, pozwalającej na szersze niż dotychczas wykorzystanie możliwości nowoczesnych przyrządów, służących do pomiarów akustycznych, wspieranych najnowszymi osiągnięciami technologii informatycznej, aby zautomatyzować coraz trudniejsze w obliczu rosnącej liczby operacji lotniczych procesy, związane z analizami hałasu lotniczego.

1.1 Problematyka hałasu lotniczego

Wstępne rozważania dotyczące natury zjawiska, stanowiącego motywację powstania niniejszej dysertacji, a więc hałasu emitowanego przez statki powietrzne, najlepiej zacząć u źródła; rozpatrując w sposób choćby przybliżony naturę generacji hałasu, którego to detekcji poświęcona jest dalsza część pracy. Pojawia się tu pierwsza trudność, wynikająca z pojemności definicji statku powietrznego¹. Ograniczając jej zasięg do tych statków powietrznych, których eksploatacja powoduje istotną emisję hałasu, międzynarodowa metodyka dotycząca certyfikacji akustycznej statków powietrznych [63] wprowadza szereg kategorii, które diametralnie różnią się między sobą sposobami certyfikacji, co wskazuje na odmienne sposoby jego generacji i propagacji, wynikające zarówno z samej konstrukcji danej klasy statku powietrznego jak i sposobu pilotażu. Kategorie te uwzględniają:

- pasażerskie samoloty z napędem odrzutowym, turboodrzutowym, turbowentylatorowym, śmigłowym i turbośmigłowym,
- samoloty i śmigłowce dyspozycyjne z napędem odrzutowym, i śmigłowym,
- samoloty szkolne z napędem odrzutowym i śmigłowym,
- samoloty ultralekkie ULC,
- śmigłowce z napędem tłokowym i napędem turboodrzutowym,
- wiatrakowce,
- samoloty specjalne, sanitarne i przeciwpożarowe,
- samoloty i śmigłowce wojskowe i policyjne.

Wszystkie wymienione kategorie statków powietrznych użytkowane są w polskiej przestrzeni powietrznej. Każdy z nich generuje hałas o specyficznych charakterystykach parametrach akustycznych takich jak: poziom dźwięku (maksymalny, ekspozycyjny, równoważny), indywidualne widmo generowanego poziomu ciśnienia akustycznego, kierunkowość emisji. Wiele czynników związanych z pełnym opisem hałasu lotniczego związanych jest z konkretną kategorią statku powietrznego oraz elementami jego konstrukcji. Zasadniczą różnicą jest typ zastosowanego napędu (odrzutowy, śmigłowy), sposób wytwarzania siły nośnej (samolot, śmigłowiec, wiatrakowiec), masa i wynikający

¹ Statek powietrzny - urządzenie zdolne do unoszenia się w atmosferze na skutek oddziaływania powietrza innego niż oddziaływanie powietrza odbitego od podłoża [79].

z niej ciąg lub moc zespołu napędowego. Dla wybranych faz lotu elementem wspólnym generowania hałasu jest hałas aerodynamiczny (konfiguracja skrzydła) oraz hałas agregatów (przekładnie, komory spalania, kompresor) i elementów konstrukcyjnych (podwozie, gondole silników).

Parametry trajektorii statku powietrznego w płaszczyźnie pionowej określone są poprzez rozwiązywanie równań różniczkowych [23] w następującej formie:

$$\left\{ \begin{array}{l} \frac{dv}{dt} = \frac{1}{m}(F \cos \varepsilon - D - W \sin \theta), \\ \frac{d\theta}{dt} = \frac{1}{mv}(F \sin \varepsilon + L - W \cos \theta), \\ \frac{dh}{dt} = v \sin \theta, \\ \frac{dx}{dt} = v \cos \theta, \\ \frac{dm}{dt} = -G, \end{array} \right. \quad (1.1)$$

$$\varepsilon = \alpha + \beta \quad (1.2)$$

$$D = c_x \frac{\rho v^2 S}{2} \quad (1.3)$$

$$L = c_y \frac{\rho v^2 S}{2} \quad (1.4)$$

gdzie:

- v częstotliwość [Hz]
- t czas lotu
- m masa samolotu w danej chwili t
- F całkowita siła ciągu zespołu napędowego
- α kąt natarcia
- β kąt zamocowania silników względem cięciwy środkowej części skrzydła,
- D siła oporu aerodynamicznego,
- W waga statku powietrznego,
- θ kąt trajektorii w chwili t ,
- L siła nośna,
- h wysokość,
- x długość rzutu profilu lotu na płaszczyznę poziomą od początku segmentu lotu,

- G całkowite zużycie paliwa w chwili t ,
- c_x współczynnik oporu aerodynamicznego,
- ρ gęstość powietrza,
- S powierzchnia skrzydeł,
- c_y współczynnik siły nośnej.

Parametryzacja fali akustycznej, pochodzącej od tak zróżnicowanych źródeł, w celu odróżnienia jej od zmiennego hałasu tła, jest zadaniem niemal niemożliwym, szczególnie jeśli wziąć pod uwagę ciągły rozwój technologii, za którym podąża także zmiana charakteru emisji poszczególnych elementów.

Umieszczając źródło hałasu w postaci statku powietrznego w rzeczywistym ośrodku, jakim jest powietrze, w którym fala akustyczna propaguje się w kierunku posadzonego nad powierzchnią ziemi odbiornika, takiego jak ucho człowieka, można zaobserwować kolejny zestaw zmiennych, wpływających na parametry tej fali. Propagacja fali akustycznej w atmosferze związany jest głównie z pochłanianiem fali akustycznej, które można traktować jako filtrację dolnoprzepustową. Współczynnik pochłaniania $\alpha(f)$ zależny jest od temperatury, wilgotności i ciśnienia i może być opisany równaniem 1.5 [3]:

$$\alpha(f) = f^2 \left[\left(\frac{1.84 \times 10^{-11}}{\left(\frac{T_0}{T}\right)^{1/2} \frac{p_s}{p_0}} \right) + \left(\frac{T_0}{T}\right)^{2.5} \times \left(\frac{0.10680 e^{-3352/T f_{r,N}}}{f^2 + f_{r,N}^2} + \frac{0.01278 e^{-2239.1/T f_{r,O}}}{f^2 + f_{r,O}^2} \right) \right] \quad (1.5)$$

gdzie:

- f częstotliwość [Hz]
- T temperatura powietrza w Kelvinach
- T_0 temperatura odniesienia (293.15 K)
- $f_{r,N}$ częstotliwość relaksacji związana z drganiami cząstek azotu
- $f_{r,O}$ częstotliwość relaksacji związana z drganiami cząstek tlenu

Powyższe czynniki, z uwzględnieniem zawartości dwutlenku węgla, wpływają także na prędkość fali akustycznej w ośrodku. Ponieważ są one zależne od wysokości, to i prędkość fali akustycznej jest od niej zależna, co wpływa na pojawienie się zjawiska refrakcji, zgodnie z prawem Snell'a. Bardzo istotny wpływ ma również gradient prędkości wiatru, którego prędkość sumuje się wektorowo z prędkością fali akustycznej.

Procedura obliczania hałasu samolotów w okolicy lotnisk, zawarta w normie SAE AIR 1845A [77], pozwala na określenie poziomu ekspozycji na hałas L_{AE} (parametr ten został

szerzej omówiony w Rozdziale 2.1.3). Zakłada ona, że do wyjściowego poziomu $L_{AE}(P, d)$, interpolowanego dodawane są się cztery współczynniki korekcyjne, odzwierciedlają czynniki wpływające na propagację fali akustycznej, istotne z punktu widzenia hałasu statku powietrznego.

$$L_{AE} = L_{AE}(P, d) + \Delta V - \Lambda(B, l) + \Delta L + \Delta\phi \quad (1.6)$$

gdzie:

- $L_{AE}(P, d)$ poziom referencyjny, określony dla mocy silnika P i odległości d,
- ΔV korekta na prędkość, jeśli prędkość względem ziemi różni się od wartości referencyjnej 160 węzłów,
- $\Lambda(\beta, l)$ korekta tłumienia bocznego, zależny od kąta między punktem obserwacji a statkiem powietrznym β oraz odległości pomiędzy punktem obserwacji i statkiem powietrznym l ,
- ΔL korekta wynikająca z kierunkowości emisji hałasu,
- $\Delta\phi$ korekta uwzględniająca różnicę między referencyjnym czasem trwania zdarzenia akustycznego, wynikająca z krzywizn trajektorii

Olbrzymie zróżnicowanie zarówno parametrów źródeł hałasu jak i zmienność wynikająca ze złożonych warunków propagacji już na wstępnym etapie pracy każe przypuszczać, że stosowanie klasycznych metod analizy sygnału do rozwiązania problemu detekcji hałasu lotniczego może być znacznie utrudnione. Należy jednakże przypuszczać, że możliwości, które leżą w rozwijającej się dynamicznie technologii uczenia maszynowego i uczenia głębokiego (ang. *deep learning*) pozwolić mogą na jego rozwiązanie.

1.2 Cel i teza pracy

Podstawowy cel prac opisanych w niniejszej rozprawie stanowi wprowadzenie możliwości automatycznej detekcji i klasyfikacji zdarzeń akustycznych związanych z przelotami statków powietrznych w systemach ciągłego monitoringu hałasu wokół lotnisk. Wstępne analizy i przemyślenia nad zagadnieniem automatyzacji sposobu prowadzenia monitoringu hałasu lotniczego doprowadziły do sformułowania następującej tezy:

Sygnal akustyczny, poddany 1/3-oktawowej analizie widmowej z małą rozdzielczością czasową, zawiera informacje wystarczające do identyfikacji zdarzeń akustycznych związanych z emisją hałasu lotniczego, z precyzją znacznie przekraczającą aktualne wymagania, w przypadku jego analizy przy zastosowaniu sztucznych sieci neuronowych.

Jej udowodnienie wymagało realizacji szeregu celów szczegółowych, do których zaliczają się:

- a) przeprowadzenie badań terenowych, umożliwiających zarejestrowanie wystarczającej do analiz ilości danych akustycznych i danych towarzyszących,
- b) utworzenie oraz weryfikacja etykietowanych zbiorów danych,
- c) opracowanie koncepcji algorytmu detekcji zdarzeń akustycznych,
- d) realizacja koncepcji i badanie własności opracowanej metody,
- e) wdrożenie metody.

1.3 Zakres rozprawy

Niniejsza rozprawa została podzielona na 9 rozdziałów, z których pierwszy stanowi wprowadzenie w tematykę lotnictwa oraz związanej z nim emisji hałasu, a także celu i tezy pracy.

Rozdziały 2 i 3 zawierają wstęp teoretyczny, obejmujący swoim zakresem zagadnienia z dziedzin akustyki oraz sztucznych sieci neuronowych.

W Rozdziale 4 opisane zostały przeprowadzone badania terenowe, z uwzględnieniem metodyki ich realizacji, charakterystyki badanych obiektów – lotnisk, oraz wykorzystanej aparatury pomiarowej. Rozdział ten zawiera także opis wstępnych analiz, które pozwoliły na wstępne scharakteryzowanie zgromadzonych danych.

Rozdział 5 zawiera wyniki przeprowadzonych na początkowym etapie pracy, analiz mających na celu ostateczną weryfikację kierunku prowadzonych badań, w oparciu o obecny stan wiedzy oraz technologii. Opisano w nim także kolejne kroki poprzedzające opracowanie docelowej koncepcji algorytmu.

Rozdziały 6 i 7 przedstawiają eksperymenty przeprowadzone w celu identyfikacji kluczowych parametrów algorytmu detekcji: eksperyment 1 – w zakresie sposobu przetwarzania danych wejściowych, eksperyment 2 – w zakresie wyboru architektury

klasyfikatora, zaś eksperyment 3 – w zakresie interpretacji wyników klasyfikacji. Dodatkowy eksperyment 4 opisuje badanie alternatywnej klasy architektur.

W Rozdziale 8 opisano pokrótce stanowiące element wdrożenia praktyczne zastosowanie opracowanej metody w systemach pomiarowych.

Rozdział 9 stanowi podsumowanie niniejszej dysertacji, z odniesieniem do sformułowanej na wstępie tezy.

Dalsza część pracy odejmuje bibliografię oraz spisy ilustracji i tabel. W dodatkach zawarto szczegółowe informacje dotyczące architektur badanych sieci oraz przykład implementacji metody.

2 WYBRANE ZAGADNIENIA AKUSTYKI W LOTNICTWIE

2.1 Podstawowe pojęcia

Mianem fali akustycznej określane jest rozprzestrzeniające się w ośrodku sprężystym (takim jak powietrze, woda, ciała stałe) zaburzenie mechaniczne, które powoduje oscylacje cząsteczek tego ośrodka wokół ich położenia równowagi. Cząsteczki te poruszają się w kierunku równoległym (fala podłużna) lub prostopadłym (fala poprzeczna) do kierunku rozchodzenia się. Z obecnością fali akustycznej związane jest przenoszenie energii w ośrodku sprężystym o gęstości ρ_a , z prędkością odpowiadającą prędkości propagacji c . Energia ta, będąc w rozpatrywanym przypadku efektem ubocznym, powstającym na skutek użytkowania statku powietrznego, transmitowana jest do organizmów przebywających na jej drodze ludzi, powodując niekorzystne konsekwencje zdrowotne. Podstawowymi wielkościami, charakteryzującymi owo zaburzenie, są: ciśnienie akustyczne p oraz prędkość cząstki akustycznej v , co wynika bezpośrednio z równania Eulera (2.1).

$$\rho_a \frac{\partial v}{\partial t} = -\frac{\partial p}{\partial x} \quad (2.1)$$

2.1.1 Poziom ciśnienia akustycznego i poziom dźwięku A

Najbardziej podstawowym wskaźnikiem, pozwalającym na przybliżone powiązanie, proporcjonalnej do kwadratu ciśnienia akustycznego, energii fali akustycznej z natężeniem wywoływanego przez tę falę wrażenia słuchowego jest, zgodnie z prawem Webera-Fechnera [38], poziom ciśnienia akustycznego L_p (2.2).

$$L_p = 10 \log \left(\frac{\langle p^2 \rangle}{p_0^2} \right) [\text{dB}] \quad (2.2)$$

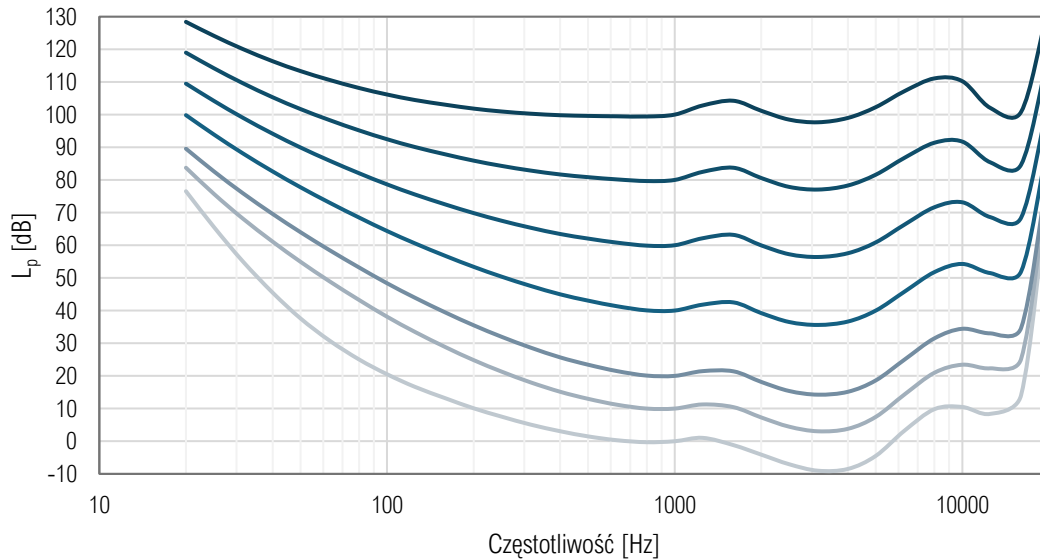
gdzie:

$\langle p^2 \rangle$ uśredniony w czasie kwadrat ciśnienia akustycznego

p_0 ciśnienie odniesienia, $p_0 = 2 \cdot 10^{-5}$ [Pa]

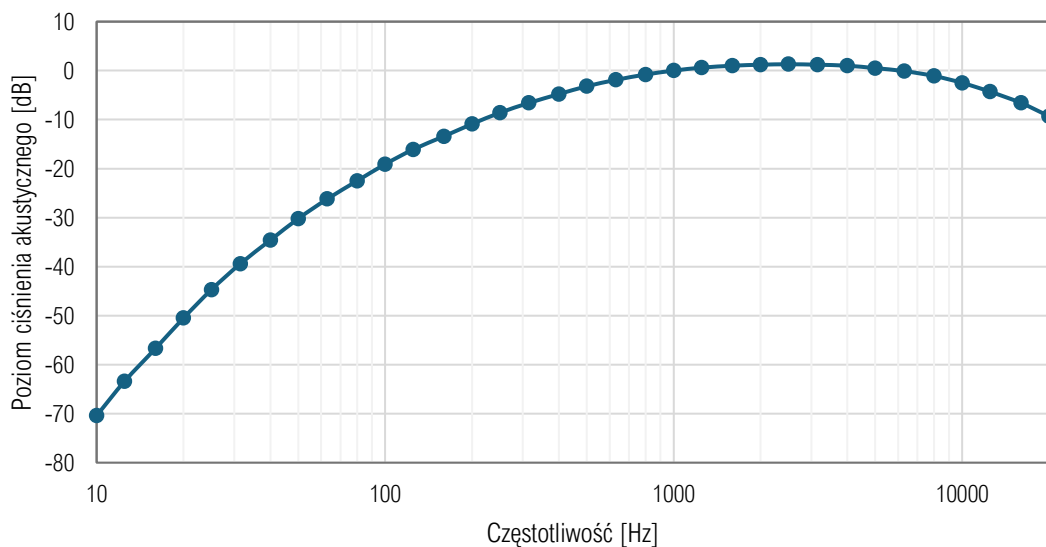
Wspomniane wyżej przybliżenie związku wrażenia głośności wywoływane przez falę akustyczną, charakteryzowaną w danym punkcie ośrodka wartością poziomu ciśnienia akustycznego, związane jest w głównej mierze ze zróznicowaną, z uwagi na budowę układu słuchowego, percepcją dźwięków o różnej częstotliwości [38]. Wpływ ten jest na tyle istotny, że znalazł odzwierciedlenie w międzynarodowej normie ISO 226 [67], która opisuje eksperymentalnie wyznaczone krzywe jednakowej głośności.

Widoczne na Rys. 2.1 krzywe izofoniczne przedstawiają wartości poziomów ciśnienia akustycznego w funkcji częstotliwości, które powodują wrażenie głośności odpowiadające dźwiękowi o częstotliwości 1000 Hz (częstotliwość odniesienia) i poziomie ciśnienia akustycznego 0 dB, 10 dB, 20 dB, 40 dB, 60 dB, 80 dB oraz 100 dB.



Rys. 2.1 Krzywe jednakowej głośności [67].

Aby odzwierciedlić tę właściwość ludzkiego słuchu wprowadzono krzywą korekcyjną A, opartą o odwróconą krzywą izofoniczną dla poziomu głośności 40 fonów (poziom ciśnienia akustycznego 40 dB dla częstotliwości odniesienia 1000 Hz).



Rys. 2.2 Charakterystyka korekcyjna A z zaznaczeniem punktów dla pasm 1/3-oktawowych [71].

Poza krzywą A zdefiniowano także obecnie niestosowaną krzywą B, odpowiadającą izofonie 70 dB oraz wykorzystywaną najczęściej w przypadku pomiarów hałasu na

stanowiskach pracy krzywą C (100 fonów). W latach 70' XX w. wprowadzono także krzywą korekcyjną D², którą stosowano do pomiarów certyfikacyjnych samolotów, wyposażonych w silniki odrzutowe. Wraz ograniczeniem ich stosowania w lotnictwie cywilnym, porzucono także i tę charakterystykę [81].

Wartość skorygowanej charakterystyką częstotliwościową A poziomu ciśnienia akustycznego określa się mianem poziomu dźwięku A. Wczesne mierniki poziomu dźwięku, w których proces uśredniania oraz ważenia częstotliwościowego kwadratu ciśnienia akustycznego realizowano analogowo, wykorzystywały także ważenie czasowe, wynikające z charakterystyki stosowanych wówczas układów uśredniających. W efekcie skorygowany czasowo poziom dźwięku A zyskał postać określoną formułą 2.3 [71]:

$$L_{A\tau} = 10 \log \left[\frac{(1/\tau) \int_{-\infty}^t p_A^2(\xi) e^{-(t-\xi)/\tau} d\xi}{p_0^2} \right] \text{ [dB]} \quad (2.3)$$

gdzie:

- τ stała czasowa funkcji wykładniczej w sekundach (0.125 s dla stałej FAST, 1 s dla stałej SLOW)
- ξ zmienna całkowania względem czasu, które wykonywane było przez pewien czas w przeszłości, co wskazane jest przez dolną granicę całkowania $-\infty$, do chwili t dokonania obserwacji
- $p_A(\xi)$ chwilowe ciśnienie akustyczne, skorygowane częstotliwościowo według charakterystyki A
- p_0 ciśnienie odniesienia, $p_0 = 2 \cdot 10^{-5}$ [Pa]

2.1.2 Równoważny poziom dźwięku A

Poziom dźwięku jest wskaźnikiem opisującym parametry fali akustycznej w krótkim przedziale czasu. Równoważny poziom dźwięku A, stanowiący zlogarytmowany stosunek uśrednionego w czasie kwadratu skorygowanego częstotliwościowo ciśnienia akustycznego sygnału wyznaczonego w ustalonym przedziale czasu T do kwadratu

² Nieobowiązująca już norma IEC 537 z 1.01.1977 r.

wartości odniesienia [71], pozwala na ocenę zmiennego w czasie oddziaływania akustycznego w dłuższym przedziale czasu oceny.

$$L_{Aeq,T} = 10 \log \left[\frac{(1/T) \int_{t-T}^t p_A^2(\xi) d\xi}{p_0^2} \right] [\text{dB}] \quad (2.4)$$

gdzie:

- T przedział czasowy uśredniania
- ξ zmienna całkowania względem czasu, które wykonywane było w przedziale czasowym uśredniania kończącym się w chwili t dokonania obserwacji
- $p_A(\xi)$ chwilowe ciśnienie akustyczne, skorygowane częstotliwościowo według charakterystyki A
- p_0 ciśnienie odniesienia, $p_0 = 2 \cdot 10^{-5}$ [Pa]

Parametr czasu oceny T może przyjmować różne wartości. W założeniu powinny one korespondować z okresami, dla których ekspozycja na hałas o danym poziomie niesie za sobą możliwe do oceny skutki. Równoważny poziom dźwięku A o różnym czasie uśredniania T stanowi obecnie podstawowy wskaźnik oceny hałasu. Jest on szeroko stosowany w normalizacji emisji hałasu [75]. W przypadku czasu oceny wynoszącego rok (średnie długookresowe wskaźniki oceny hałasu) stwierdzono również jego korelację ze skutkami zdrowotnymi na organizm człowieka [89].

2.1.3 Poziom ekspozycji na hałas

Dla źródeł hałasu, które powodują wyraźne lokalne maksima w przebiegu poziomu dźwięku norma ISO 1996-2 zaleca pomiary ekspozycyjnego poziomu dźwięku L_{AE} [66]. Do źródeł powodujących powstawanie pojedynczych zdarzeń akustycznych zaliczają się także operacje wykonywane przez statki powietrzne.

Ekspozycja na hałas definiowana jest zgodnie z formułą 2.5 [71]. Wartość ta pozwala na ocenę energii zdarzenia akustycznego, którego czas trwania wyniósł T .

$$E_{A,T} = \int_{t-T}^t p_A^2(t) dt \quad (2.5)$$

gdzie:

- T przedział odpowiadający czasowi trwania zdarzenia akustycznego

$p_A(t)$ chwilowe ciśnienie akustyczne, skorygowane
 częstotliwościowo według charakterystyki A

Logarytmiczną miarą ekspozycji na hałas jest poziom ekspozycji, określony formułą 2.6.


$$L_{AE} = 10 \log \left[\frac{\int_{t-T}^t p_A^2(t) dt}{p_0^2 T_0} \right] \quad (2.6)$$

gdzie:

T_0 czas odniesienia, $T_0 = 1$ s

p_0 ciśnienie odniesienia, $p_0 = 2 \cdot 10^{-5}$ [Pa]

Korzystając z własności zdefiniowanych powyżej wskaźników łatwo już powiązać wartość równoważnego poziomu dźwięku, określoną dla czasu odniesienia T, ze wartością poziomu ekspozycji na hałas, uśrednioną dla pojedynczych zdarzeń akustycznych w tym samym czasie odniesienia T. Rysunek 2.3 przedstawia przykład obliczenia wspomnianych wyżej wartości. Warto zwrócić uwagę, że równoważny poziom dźwięku wyznaczony na podstawie pojedynczych zdarzeń akustycznych (na rysunku oznaczony jako $L_{Aeq,SEL}$) jest mniejszy od poziomu $L_{Aeq,T}$, wyznaczonego zgodnie z formułą 2.4. Przyczyną takiego stanu jest rzecz jasna odrzucenie z obliczeń występującego pomiędzy zdarzeniami akustycznymi hałasu tła. W ten sposób oceniana jest emisja wybranego źródła hałasu.



Rys. 2.3 Przykład powiązania równoważnego poziomu dźwięku i poziomu ekspozycji na hałas. Opracowanie własne.

W najprostszym przypadku, w którym rozpatrywana jest jedna klasa zdarzeń akustycznych wartość równoważnego poziomu dźwięku można obliczyć zgodnie z poniższą formułą.

$$L_{Aeq,T} = \overline{L_{AE}} + 10 \log \left(\frac{nT_0}{T} \right) [dB] \quad (2.7)$$

gdzie:

$$\overline{L_{AE}} \quad \text{średni poziom ekspozycji, } \overline{L_{AE}} = 10 \log \left[\frac{\frac{1}{n} \sum E_A}{p_0^2 T_0} \right]$$

n liczba zdarzeń akustycznych

T czas oceny

T_0 czas odniesienia, $T_0 = 1 \text{ s}$

p_0 ciśnienie odniesienia, $p_0 = 2 \cdot 10^{-5} \text{ [Pa]}$


Norma ISO 20906 wprowadza także pojęcie skumulowanego poziomu ekspozycji, który należy interpretować zgodnie z formułą:

$$L_{AE,sum} = 10 \log \left[\frac{\sum E_A}{p_0^2 T_0} \right] \quad (2.8)$$

2.1.4 Analiza częstotliwościowa i filtry 1/3-oktawowe

Najprostszym przykładem fali akustycznej jest ton prosty o częstotliwości f , który opisać można pojedynczą funkcją $p(t) = p_{max} \sin 2\pi ft$. Przyjmuje się, że zakres słyszalności człowieka jest zbliżony do 20 Hz od strony małych częstotliwości i do 20 kHz od strony dużych częstotliwości [38]. Występujące w naszym otoczeniu fale akustyczne, pochodzące od rzeczywistych źródeł, składają się z wielu takich tonów, tworzących złożone i zmienne w czasie widmo częstotliwościowe.

Analiza częstotliwościowa jest sposobem na pozyskanie z zarejestrowanej fali akustycznej bardziej szczegółowych informacji odnośnie źródeł generujących hałas. Jednym ze sposobów prowadzenia analizy częstotliwościowej jest, często wykorzystywane w przyrządach pomiarowych, stosowanie banku filtrów pasmowoprzepustowych, o stopniowo rosnących częstotliwościach środkowych i stałej względnej szerokości pasma. Najczęściej stosowane są filtry oktawowe, dla których iloraz górnej i dolnej częstotliwości granicznej pasma przepustowego wynosi 2, oraz filtry 1/3-oktawowe (tercjowe), w których przypadku iloraz ten wynosi $2^{1/3}$. Przykładowe charakterystyki filtrów 1/3-oktawowych przedstawia Rys. 2.7.

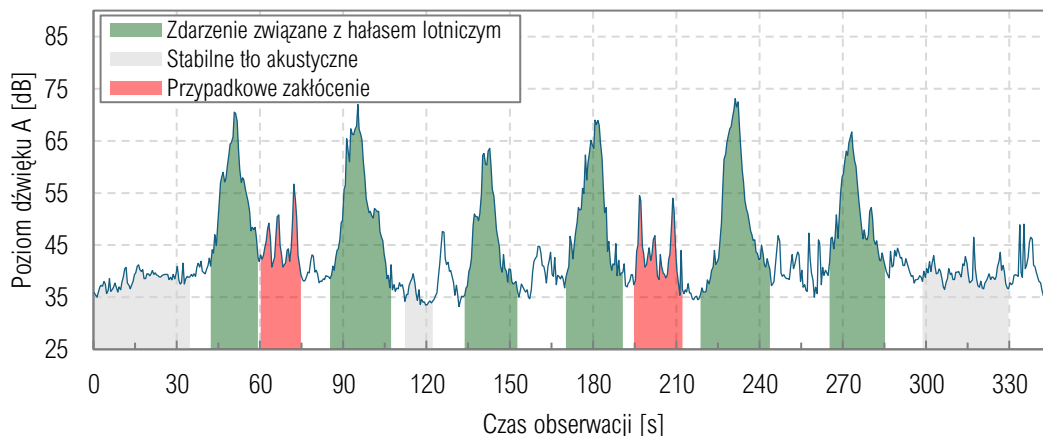


Rys. 2.4 Rzeczywiste charakterystyki filtrów 1/3-oktawowych dla pasma oktawowego 1 kHz dla stacji monitoringu hałasu SVANTEK SV200 [85].

2.2 Charakterystyka sygnałów akustycznych generowanych przez przeloty statków powietrznych

Hałas, określany jako lotniczy, rejestrowany w danym punkcie odbioru, spowodowany jest przelotem statku powietrznego w pobliżu tegoż punktu. Ze względów bezpieczeństwa organy kontroli ruchu bądź piloci zobowiązani są do zachowywania odpowiedniej separacji, czyli odległości w pionie i w poziomie od innych statków powietrznych [74]. Separacja ta w przepisach lotniczych określona jest poprzez minimalny czas pomiędzy startującymi bądź lądującymi statkami powietrznymi i wynosi w zależności od klasy statku powietrznego 2 do 3 minut. Wpływa to na charakter sygnału akustycznego, który możliwy jest do zarejestrowania na terenach położonych w pobliżu lotniska.

Na Rys. 2.5 przedstawiono fragment zarejestrowanej w stałym punkcie monitoringu historii czasowej poziomu dźwięku. Z łatwością można w nim wyróżnić fragmenty, w których zdecydowanie dominuje emisja hałasu lotniczego. W pozostałych momentach można zaobserwować stabilne tło akustyczne oraz przypadkowe zdarzenia zakłócające.



Rys. 2.5 Przykładowy fragment historii czasowej poziomu dźwięku, zawierający zdarzenia akustyczne związane z hałasem lotniczym. Opracowanie własne.

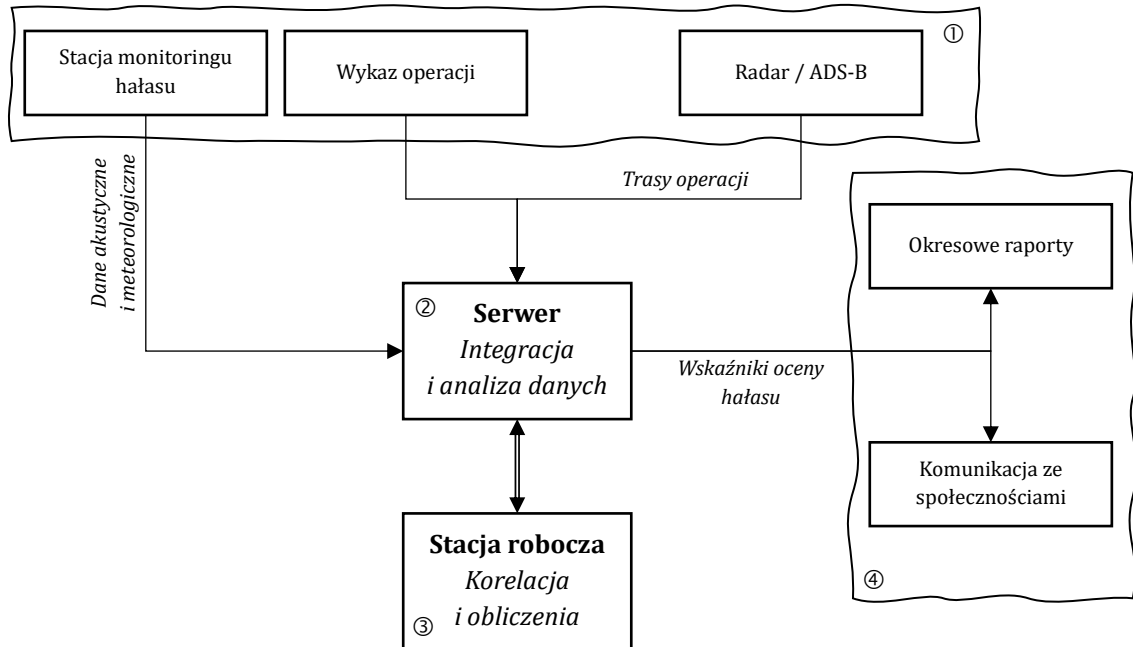
Głównym celem pomiaru jest określenie, wyrażonej odpowiednimi wskaźnikami oceny, wartości poziomu dźwięku emitowanego hałasu. W międzynarodowych normach [3, 6, 7] oraz obowiązujących przepisach krajowych [9] wskazana została metoda pomiaru odpowiednia dla zjawiska, opisanego jako powtarzające się zdarzenia pojedyncze. Jej zastosowanie pozwala na poprawną ocenę hałasu związanego z konkretnym źródłem (w tym przypadku – z operacjami lotniczymi), eliminując istotny wpływ zmiennego w czasie tła akustycznego oraz zdarzeń zakłócających.

2.3 Systemy monitoringu hałasu lotniczego

Istnieje wiele krajowych i międzynarodowych przepisów i wytycznych regulujących instalację systemów monitorowania wokół międzynarodowych lotnisk ([68, 73, 76]).

Systemy monitorowania hałasu, instalowane na lotniskach na całym świecie, obejmują zarówno proste rozwiązania, ograniczające swoją funkcjonalność do pomiaru i raportowania poziomu hałasu poszczególnych lotów, jak i złożone systemy, które gromadzą i analizują dane dotyczące hałasu oraz monitorują trasy lotów samolotów, warunki meteorologiczne, skargi okolicznych mieszkańców oraz automatyzują obliczeniowe oceny zasięgów hałasu lotniczego [8]. Systemy te muszą umożliwiać rzetelne analizy operacji lotniczych i ich skutków dla środowiska, a także dostarczać społeczności lokalnej użytecznych informacji na temat działań podejmowanych w celu kontrolowania hałasu środowiskowego. Dane pomiarowe i wyniki analiz, dostępne dzięki tym systemom, poprawiają planowanie działań związanych z kontrolą hałasu, takich jak eksploatacja samolotów lub ustalanie najlepszych lokalizacji stref mieszkaniowych w sąsiedztwie lotniska.

Typowy system monitoringu hałasu (Rys. 2.6) składa się z czterech głównych części: źródeł danych ①, bazy danych wraz z systemem akwizycji ②, oprogramowania służącego do korelacji danych i prowadzenia obliczeń ③ oraz modułu raportów ④.



Rys. 2.6 Schemat systemu monitoringu hałasu [8].

Odpowiednie użytkowanie systemów monitoringu hałasu lotniczego pozwala na osiągnięcie szeregu celów, związanych z ochroną środowiska oraz zamieszkującej okolice portów lotniczych ludności przed skutkami nadmiernego hałasu [8]. Poprawnie wykorzystywany system monitoringu:

- umożliwia określenie udziału hałasu lotniczego w całkowitym narażeniu na hałas;
- umożliwia wykrywanie przypadków nadmiernych poziomów hałasu, pochodzących od operacji lotniczych;
- umożliwia ocenę skutków wprowadzania procedur operacyjnych i administracyjnych, dotyczących kontroli hałasu oraz ocenę alternatywnych procedur lotniczych pod kątem emisji hałasu;
- wspiera planowanie użytkowania przestrzeni powietrznej;
- zwiększa zaufanie społeczności lokalnych do działalności portów lotniczych w zakresie dbałości o ochronę interesu publicznego;
- umożliwia weryfikację prognoz emisji hałasu oraz technik i metodologii prognozowania hałasu w dłuższym okresie czasu;

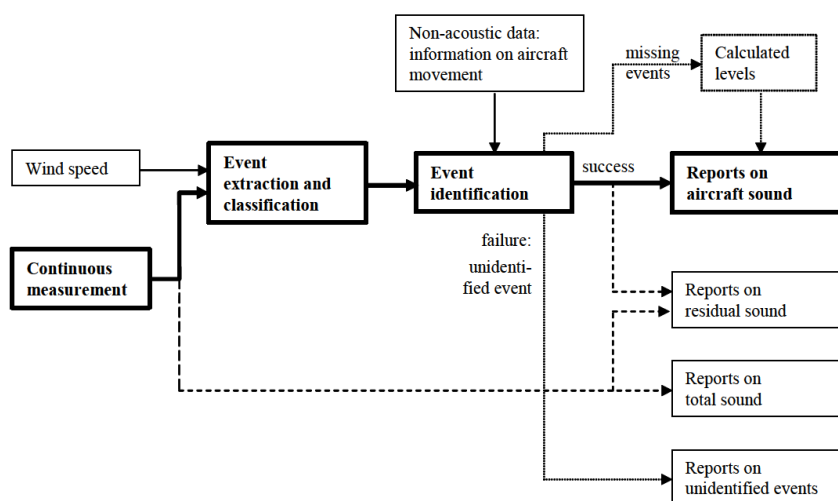
- wspiera odpowiednie władze w planowaniu zagospodarowania przestrzennego terenu w odniesieniu do możliwości rozwoju i wpływu hałasu na obszary w pobliżu lotniska.

2.4 Metody detekcji zdarzeń akustycznych

Stale rosnąca liczba obsługiwanych na lotniskach operacji lotniczych wymusza konieczność automatyzacji procesu wyodrębniania i identyfikacji zdarzeń akustycznych. Międzynarodowa norma ISO 20906 [68] dostarcza pewnych wytycznych odnośnie realizacji takiego procesu. System monitoringu powinien mierzyć wskaźniki: $L_{Aeq,1s}$ oraz dodatkowo $L_{ASmax,1s}$ w sposób ciągły. Na podstawie pomiaru hałasu realizowanego w sposób ciągły (rejestracja wartości wskaźnika $L_{Aeq,1s}$) oraz danych pozaakustycznych (rejestr operacji, dane radarowe) system powinien dokonać detekcji, klasyfikacji i identyfikacji zdarzeń akustycznych w zarejestrowanej historii czasowej. System powinien w efekcie swojego działania dostarczyć listę zdarzeń zidentyfikowanych oraz listę niekompletnych lub uszkodzonych danych.

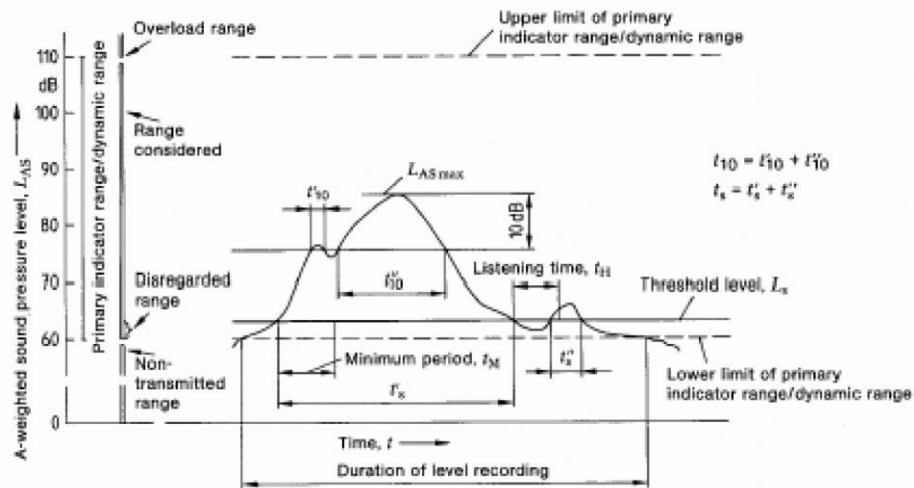
Zdarzenie akustyczne (ogólnie) może być wykrywane na podstawie kryteriów takich jak:

- hałas nie jest stacjonarny, ale również nie jest impulsowy, jego czas trwania zawiera się w określonym limicie;
- poziom dźwięku przekracza wartość odniesienia (próg) co najmniej o zadaną wartość;
- zdarzenie kończy się, jeśli poziom dźwięku nie przekracza ponownie określonej wartości w zadanym czasie.



Rys. 2.7 Schemat algorytmu detekcji [68].

Za przebieg wejściowy norma zaleca przyjmować L_{AS} . Na wyjściu procedury powinny pojawić się wartości $L_{ASmax,i}$, $L_{AE,i}$, czas trwania zdarzenia ΔT_i oraz czas początku zdarzenia.



Rys. 2.8 Definicja zdarzenia akustycznego [68].

Klasyfikacja zdarzenia akustycznego (ogólnego) jako związanego z hałasem lotniczym może następować przy zastosowaniu następujących kryteriów:

- informacji odnośnie prędkości samolotu oraz jego odległości od punktu monitoringu, pozyskanej z systemów śledzenia trajektorii, umożliwiającej określenie czasu trwania zdarzenia;
- relacji pomiędzy $L_{ASmax,i}$ a $L_{AE,i}$;
- danych spektralnych;
- korelacji czasowej ze zdarzeniem zarejestrowanym na innej stacji monitoringu.

Identyfikacja zdarzenia może następować dzięki danym pozaakustycznym, takim jak:

- wykaz operacji zawierający czas, używaną drogę startową, typ statku, trasę;
- dane radarowe lub ADS-B dotyczące danej trajektorii przelotu;
- pozyskiwane z wielomikrofonowych systemów pomiarowych, pozwalających na określenie kierunku nadejścia fali akustycznej.

Te, względnie ogólne, wytyczne zapewniają swego rodzaju ramy, w których z biegiem lat rozwijały się koncepcje algorytmów, opisane w dalszej części pracy.

W artykule Dufournet'a i Rozwadowskiego [16] opisano zasadę działania systemu firmy 01dB, MADRAS. Funkcjonuje on w oparciu o 5 kroków, łączących koncepcję progu adaptacyjnego oraz sieć neuronową:

- a) Detekcja: na tym etapie generowane są pliki audio, jeśli $L_{Aeq,125ms}$ przekroczy próg adaptacyjny $L_{90} + 20$ dB (czas wyznaczania statystyki nie został podany).
- b) Segmentacja: identyfikowane są jednorodne segmenty w nagraniu; metodami morfologii matematycznej (zazwyczaj przetwarzanie obrazu) określone są zawarte w nagraniu wzorce oraz tendencja globalna.
- c) Szeroka klasyfikacja: segmenty są klasyfikowane w oparciu o kryteria stosowane do 50 ms fragmentów sygnału: czas trwania, dynamika, gradienty narastania i zaniku, *surface ratio* (stosunek wartości wskaźnika L_{eq} do L_{max}), „aktywność” (liczba przekroczeń wartości średniej). 5-wymiarowy opis zredukowany przez neuronową, nieliniową wersję Analizy Głównych Składowych (PCA) pozwala na odrzucenie najmniej istotnych czynników.
- d) Specjaliści: sklasyfikowane segmenty są przetwarzane przez wyspecjalizowane sieci neuronowe: wykrywająca izolowane przejazdy (samochodów, ciężarówek itp.), analizator hałasu stacjonarnego (w oparciu o słownik szablonów definiowanych przez użytkownika), analizator hałasu impulsowego (tworzy szablony w oparciu o analizę falkową).
- e) Post-processing: obliczany jest wpływ każdego z wyznaczonych dzięki powyższym krokom źródeł.

Raportowana skuteczność prezentowanego rozwiązania to około 80%. Planowany rozwój obejmuje rozszerzenie algorytmu na analizę spektralną.

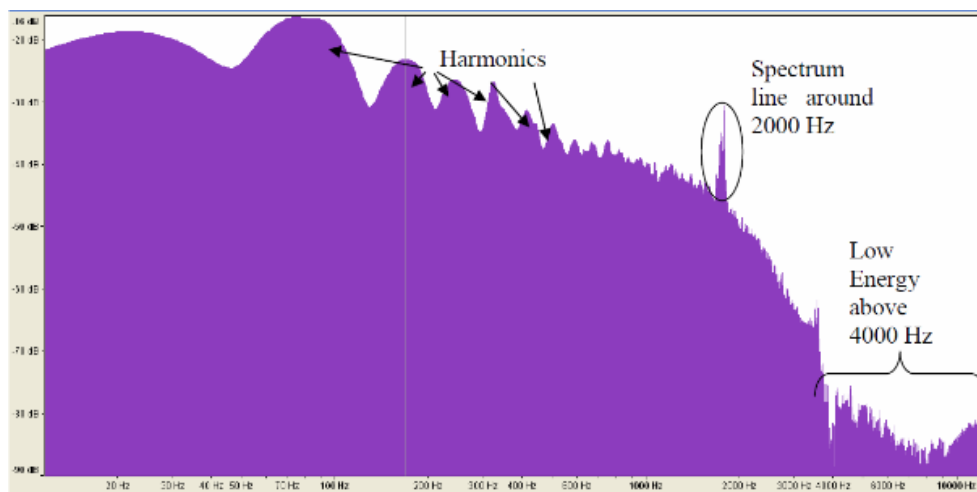
Zintegrowane systemy monitoringu hałasu wykorzystywane przez większość lotnisk oparte są o korelację historii czasowej poziomu dźwięku z informacjami pozaakustycznymi. Zdarzenia identyfikowane są poprzez wykrywanie przekroczenia progu. Problemem jest minimalizacja ilości sytuacji *false-positive*, czyli takich, w których algorytm oznacza zdarzenie zakłócające jako związane z hałasem lotniczym. Rosin i Barbo [47] opisują testy technologii rozpoznawania zdarzeń w oparciu o przetwarzanie sygnału audio na zasadzie rozpoznawania wzorców (ang. *pattern recognition approach*).

W publikacji podkreślono łatwość, z jaką ludzki układ słuchowy wykrywa hałas lotniczy. Naturalnym podejściem jest zatem zastąpienie układu słuchowego sztuczną siecią neuronową, analizującą sygnał audio. Proponowane podejście oparte jest o deskryptory spektralne.

Autorzy szczegółowo opisują charakterystyczne cechy widmowa częstotliwościowego samolotów turboodrzutowych (*jet*):

- składowe harmoniczne poniżej 1 kHz;
- składowa spektralna w okolicy 2 kHz;
- spadek energii powyżej 4 kHz.

Charakterystyki różnią się w zależności od segmentu trajektorii i względnej lokalizacji samolotu. Dzięki zastosowaniu sieci neuronowych możliwe jest adaptacyjne wyznaczenie najbardziej odpowiednich deksyptorów.



Rys. 2.9 Charakterystyki widmowe hałasu samolotu odrzutowego opisane przez Roisina i Barbo [47].

Opisane rezultaty wykazały skuteczność rozwiązania na poziomie 97,6% (166 próbek wykrytych przez system, 170 przez operatora). Wyniki porównano również z danymi dostarczonymi przez system monitoringu, funkcjonującego na badanych lotniskach (Port Lotniczy Paryż-Roissy-Charles de Gaulle oraz Port lotniczy Le Bourget), działającego w oparciu o podstawową metodę przekroczenia progu. Wyniki wskazują na poprawę wykrywalności względem metody klasycznej i skuteczność zbliżoną do ucha ludzkiego.

Interesujące podejście do omawianego problemu przestawili Asensio, Ruiz i Recuero [2], opisując metodę ciągłego śledzenia podobieństwa (oryg. *similarity*) rejestrowanego sygnału do hałasu lotniczego w czasie rzeczywistym. W tym celu zastosowano jednoklasową detekcję przy zastosowaniu logiki rozmytej dla 13 współczynników częstotliwości w skali Mel. Wyniki pracy zostały opatentowane.



Rys. 2.10 Schemat algorytmu, opracowanego przez Asensio i in. [2].

Skuteczność rozwiązania oszacowano na 93%.

Zbliżoną do opisaną wyżej technikę zaproponowali Wszolek i Kłaczyński [57], którzy posługując się wąskopasmowymi multispektrami, uzyskanymi przy zastosowaniu analizy FFT, przekształconymi do spektrogramów mel-cepstralnych zbadali szereg algorytmów detekcji, z których najlepsze wyniki zapewniła sieć neuronowa. Rezultaty przedstawili oddzielnie dla samolotów turbośmigłowych oraz turboodrzutowych, uzyskując poprawność rozpoznawania wynoszącą odpowiednio 95% i 97%.

Prowadzone na przestrzeni lat badania nad zaawansowanymi metodami detekcji hałasu lotniczego wskazują na zastosowanie algorytmów opartych na zastosowaniu sztucznych sieci neuronowych jako najbardziej skutecznych. Szybki rozwój technologii uczenia maszynowego (ang. *machine learning*) i uczenia głębokiego (ang. *deep learning*) oraz wzrost ich dostępności zdecydowanie wspomaga powstawanie nowych, skutecznych technik identyfikacji źródeł hałasu, w tym hałasu lotniczego.

3 SZTUCZNE SIECI NEURONOWE

Sztuczne sieci neuronowe (ANN, ang. *Artificial Neural Networks*) to struktury matematyczne i obliczeniowe inspirowane biologicznymi sieciami neuronowymi, które składają się z wielu połączonych ze sobą węzłów, nazywanych sztucznymi neuronami. Sieci te są podstawowymi narzędziami w dziedzinie sztucznej inteligencji i uczenia maszynowego, wykorzystywanymi do rozpoznawania wzorców, klasyfikacji danych, regresji oraz innych złożonych zadań obliczeniowych.

Sztuczne sieci neuronowe wykorzystywane są w wielu zaawansowanych zastosowaniach, takich jak rozpoznawanie obrazów [24], przetwarzanie języka naturalnego [35], systemy rekomendacyjne [18]. Dzięki zdolności do uczenia się na podstawie prezentowanych danych i generalizowania wzorców, sztuczne sieci neuronowe odgrywają kluczową rolę w nowoczesnej informatyce i badaniach nad sztuczną inteligencją.

Dwa aspekty danego problemu mogą uzasadniać zastosowanie programów, które uczą się i doskonalą na podstawie swojego doświadczenia: złożoność problemu oraz potrzeba adaptacyjności [5].

3.1 Podstawowe założenia sieci neuronowych

Każdy z neuronów oblicza ważoną sumę swoich wejść, mogących pochodzić z warstwy wejściowej lub też z innych neuronów w tzw. warstwach ukrytych. Każde wejście x_i powiązane jest z określoną wagą w_i , określającą jak silny jest wpływ danego wejścia na wynik obliczeń. Etap ten można opisać wyrażeniem (3.1) [53]:

$$z = \sum_{i=1}^n w_i \cdot x_i + b \quad (3.1)$$

gdzie:

- z wynik agregacji
- n liczba wejść
- b wartość przesunięcia (ang. *bias*)

Kluczowym elementem procesu przetwarzania jest zastosowanie nieliniowej funkcji aktywacji $\phi(z)$, która określa zależność pomiędzy wejściami a wyjściem, co pozwala sieci na modelowanie złożonych wzorców. Funkcja ta przyjmować może różne postacie,

dobierane w zależności od oczekiwanych rezultatów. Przykłady najczęściej stosowanych funkcji aktywacji [53] to:

- Sigmoidalna: $\phi(z) = \frac{1}{1+e^{-\beta z}}$,
- ReLU (ang. *Rectified Linear Unit*): $\phi(z) = \max(0, z)$,
- Tangens hiperboliczny: $\phi(z) = \tanh(z)$.

Neurony, zorganizowane w warstwy³, w procesie uczenia aktualizują swoje wagi w_i . Proces nadzorowanego (ang. *supervised*) uczenia (lub treningu) polega na minimalizacji funkcji błędu, obliczanej przez sieć dla określonego zbioru przykładów, o postaci:

$$U = \{\langle \mathbf{X}^{(1)}, z^{(1)} \rangle, \langle \mathbf{X}^{(2)}, z^{(2)} \rangle, \dots, \langle \mathbf{X}^{(N)}, z^{(N)} \rangle\} \quad (3.2)$$

gdzie:

- $\mathbf{X}^{(j)}$ wektor danych wejściowych w j-tym kroku
- $z^{(j)}$ zakładana odpowiedź sieci w j-tym kroku
- N liczba prezentowanych przykładów

Funkcja błędu (kosztu) określa jak bardzo przewidywania sieci różnią się od wyników oczekiwanych. Często przyjmuje postać funkcji błędu średniokwadratowego:

$$Q = \frac{1}{2} \sum_{j=1}^N \left[z^{(j)} - \phi \left(\sum_{i=0}^n w_i^{(j)} x_i^{(j)} \right) \right]^2 \quad (3.3)$$

Traktując wagi wejściowe jako wektor \mathbf{W} , podczas treningu ich wartości modyfikowane są o wektor poprawek, $\Delta \mathbf{W}$ taki, aby minimalizować funkcję błędu. Proces ten określany jest mianem gradientowej minimalizacji funkcji błędu [5].

Błąd jest następnie propagowany wstecz przez sieć, zaczynając od warstwy wyjściowej. Algorytm oblicza gradient funkcji kosztu względem wag każdej warstwy, stosując regułę łańcuchową (ang. *chain rule*) do iteracyjnego różniczkowania funkcji aktywacji i funkcji kosztu. Gradienty obliczane są dla każdej wagi w_{ij} zgodnie z wyrażeniem (3.4):

$$\frac{\partial Q}{\partial w_{ij}} = \delta^{(j)} \cdot a_i \quad (3.4)$$

gdzie:

³ Występując trzy podstawowe typy warstw: wejściowa, wyjściowa oraz warstwy ukryte [53].

$\frac{\partial Q}{\partial w_{ij}}$ pochodna funkcji kosztu Q względem wagi w_{ij}

$\delta^{(j)}$ błąd propagowany wstecz dla neuronu j

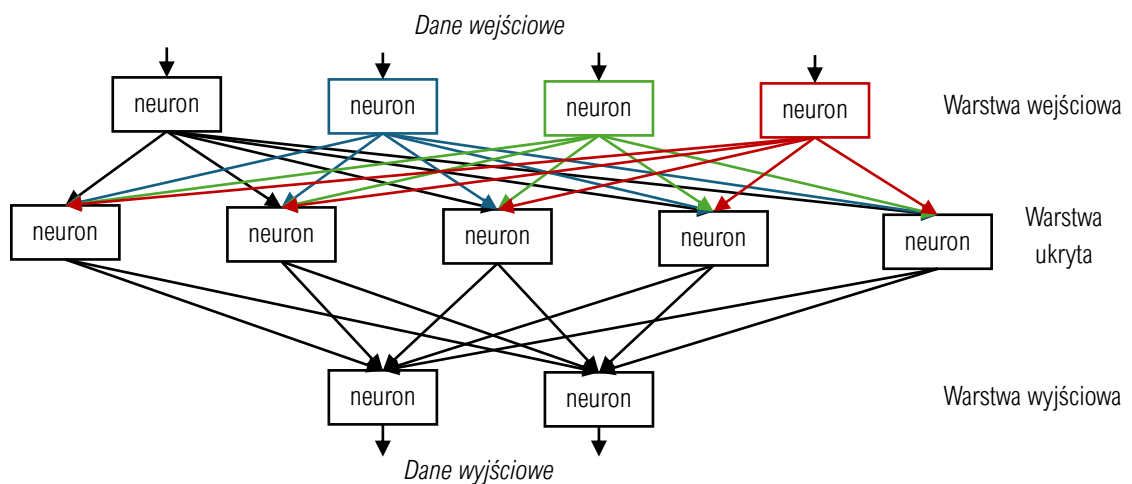
a_i wyjście neuronu i w poprzedniej warstwie

Wagi neuronów są następnie aktualizowane zgodnie z obliczonymi gradientami. Najczęściej stosowana metoda aktualizacji wag to metoda stochastycznego spadku gradientu (SGD, ang. *stochastic gradient descent*), gdzie każda waga w_{ij} jest modyfikowana w kierunku przeciwnym do gradientu, z szybkością określoną przez współczynnik uczenia η (ang. *learning rate*):

$$w_{ij} \leftarrow w_{ij} - \eta \frac{\partial Q}{\partial w_{ij}} \quad (3.5)$$

Dzięki takiej aktualizacji wagi są dostosowywane tak, aby w kolejnych iteracjach sieć lepiej odwzorowywała dane treningowe.

Rysunek 3.1 przedstawia schemat połączeń pomiędzy neuronami w gęstej sieci neuronowej. W sieci takiej każdy neuron z danej warstwy jest połączony z każdym neuronem warstwy kolejnej.



Rys. 3.1 Schemat dwuwarstwowej sieci neuronowej. Opracowanie własne.

Jak wynika z formuły (3.5) bardzo istotnym elementem procesu aktualizacji wag jest dobór wartości η . Zbyt mała jego wartość wydłuża proces treningu, niekiedy do takiego stopnia, że nigdy nie zostanie osiągnięte globalne minimum funkcji kosztu. Z drugiej strony zbyt duża jego wartość może spowodować pojawienie się uniemożliwiającej trening dywergencji. Modyfikacje metody SGD, polegające na wprowadzeniu momentu (ang. *momentum*), który wprowadza swego rodzaju pamięć do procesu optymalizacji wag, uwzględniając poprzednie kroki, a także bardziej złożonych algorytmów takich jak

Adam (ang. *Adaptive Moment Estimation*), który dostosowując współczynnik uczenia dla każdego parametru (wagi) indywidualnie zwiększa tempo i stabilność uczenia [32], są obecnie często stosowane w celu usprawnienia procesu treningu.

Trening sieci powinien w założeniu doprowadzić do sytuacji, w której jest ona w stanie rozwiązywać określony problem na danych innych niż prezentowane podczas treningu. Zjawisko to nazywane jest zdolnością sieci do generalizacji. Aby sieć zyskała tę zdolność konieczne jest uzyskanie wystarczającej „wiedzy” (stanowiącej w istocie dobrane po treningu wagi neuronów). Jeśli będzie ona niewystarczająca, z powodu zbyt małej ilości powtórzeń procesu bądź niereprezentatywności danych treningowych, model będzie dopasowany w zbyt małym stopniu (ang. *underfitting*). Z kolei zbyt długi trening da rezultat w postaci nadmiernego dopasowania do danych treningowych – przeuczenia (ang. *overfitting*). Nadmiernie dopasowany model traci zdolność do generalizacji prezentowanego mu problemu. W obu przypadkach najprostszym i najbardziej intuicyjnym rozwiązaniem jest zastosowanie większej ilości danych treningowych [13], choć przy zbyt małej zmienności ich cech czasem i ono może być niewystarczające. Uzyskanie najlepszego możliwego dopasowania do danych treningowych przy jednoczesnym zachowaniu wysokiej zdolności do generalizacji stanowi podstawowy cel treningu sieci. Jego osiągnięcie realizowane jest na różne sposoby, zależne zarówno od postaci danych wejściowych jak i stosowanych architektur sieci. Jedną z nich jest nałożenie ograniczeń na złożoność sieci, zmuszając jej wagi do przyjmowania tylko małych wartości, co sprawia, że rozkład wartości wag staje się bardziej regularny. Technika ta określana jest mianem regularyzacji wag i polega na dodaniu do funkcji straty sieci kosztu związanego z posiadaniem dużych wag [13]. Regularyzacja ta może przyjmować postać L1, w której dodawany koszt jest proporcjonalny do wartości bezwzględnej wag, bądź L2, gdzie koszt ten jest proporcjonalny do kwadratu wartości wagi. Inne popularne techniki uwzględniają *dropout* (losowe zerowanie aktywacji neuronów podczas uczenia [52]), *batch normalization*⁴ (polegającą na normalizowaniu danych wejściowych do każdej kolejnej warstwy [28]), *early stopping* (wcześniejsze

⁴ Technika ta stosowana jest głównie w celu ograniczeniu zanikania lub eksplozji gradientu, ale jej skutkiem ubocznym jest także ograniczenie ryzyka przeuczenia.

zatrzymanie procesu treningu, w momencie, gdy zaczyna występować przeuczenie [59]) i wiele innych.

3.2 Konwolucyjne sieci neuronowe

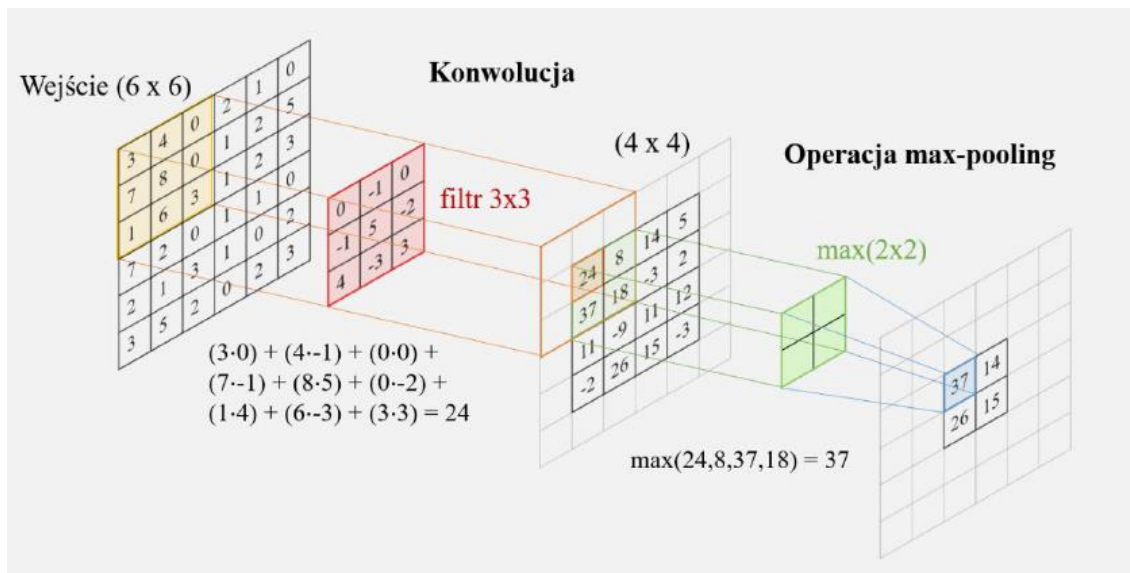
Wbudowanie właściwości niezmienniczości w strukturę sieci neuronowej powoduje, że staje się ona odporna na pewne transformacje danych wejściowych. Jest to założenie leżące u podstaw rozwiązania, określonego mianem konwolucyjnej sieci neuronowej (CNN, ang. *convolutional neural network*) [34], które znalazło szerokie zastosowanie w przetwarzaniu danych dwuwymiarowych.

W zadaniach, takich jak rozpoznawanie ręcznie pisanych cyfr, celem jest zidentyfikowanie pewnych wzorców, wspólnych dla poszczególnych znaków, mogących przy tym różnić się szczegółami. Jednym z możliwych rozwiązań problemu jest zastosowanie opisanej wyżej sieci gęstej, w której każdy z neuronów danej warstwy łączy się z każdym neuronem z warstwy po niej następującej. Dysponując zestawem danych treningowych o odpowiednio dużej liczebności, taka sieć mogłaby pozwolić na rozwiązanie problemu i nauczyłaby się odpowiednich niezmienniczości na podstawie zaprezentowanych przykładów. Podejście takie jednakże pomija kluczową cechę obrazów, polegającą na silniejszej korelacji dla punktów pobliskich niż oddalonych od siebie [50].

Sieci konwolucyjne, poprzez wykorzystanie trzech kluczowych mechanizmów, wyodrębniają lokalne cechy, obecne w niewielkich podobszarach obrazu; cechy te są scalane na późniejszych etapach przetwarzania, co pozwala z kolei na identyfikację cech wyższego rzędu, co pozwala ostatecznie na uzyskanie informacji o obrazie jako całości.

Na wspomniane mechanizmy składają się: lokalne pola recepcyjne (ang. *receptive fields*), współdzielenie wag oraz podpróbkiowanie (ang. *subsampling*). Przykładowa struktura sieci konwolucyjnej, przedstawiona na Rys. 3.3, składa się przede wszystkim z warstw konwolucyjnych, w których poszczególne filtry zorganizowane są w płaszczyzny, z których każda nazywana jest mapą cech (ang. *feature map*). Filtry w mapie cech pobierają dane wejściowe tylko z małego podobszaru obrazu. Są także ograniczone do współdzielenia tych samych wartości wag. Mapa cech może składać się ze 100 filtrów rozmieszczonych w siatce 10×10 , gdzie każda jednostka pobiera dane wejściowe z fragmentu obrazu o rozmiarze 5×5 pikseli. Cała mapa cech ma więc 25 regulowanych parametrów wag oraz jeden regulowany parametr biasu. Wartości wejściowe


z analizowanego fragmentu są liniowo łączone przy użyciu wag i biasu, a wynik jest transformowany przez nieliniową funkcję sigmoidalną. Jeśli myślimy o jednostkach jako detektorach cech, to wszystkie jednostki w mapie cech wykrywają ten sam wzorec, ale w różnych lokalizacjach obrazu wejściowego. Sposób działania filtrów przedstawiono na Rys. 3.2.



Rys. 3.2 Schemat obrazujący zasadę działania warstwy konwolucyjnej oraz warstwy zbierającej na przykładzie max-poolingu. Konwolucja ze skokiem o wielkości 1 (ang. stride), warstwa zbiorcza ze skokiem o wielkości 2, bez paddingu [42].

Drugim elementem sieci konwolucyjnej są warstwy agregacyjne (ang. *pooling layers*), realizujące operację redukcji wymiarowości danych (ang. *subsampling*), zwykle przez uśrednianie (ang. *average pooling*) lub wybieranie wartości maksymalnych (ang. *max pooling*).

Sieć konwolucyjna zakończona jest warstwami gęstymi, które pełnią rolę decyzyjną. Przetwarzają wyodrębnione przez warstwy konwolucyjne cechy macierzy wejściowej na końcowy rezultat predykcji modelu. W zadaniach klasyfikacyjnych ostatnia warstwa gęsta często zawiera tyle neuronów, ile jest klas do rozpoznania. Najczęściej stosowana jest w jej przypadku aktywacja *softmax*, która przekształca wyjścia w prawdopodobieństwa, na podstawie których podejmowana jest decyzja o przynależności do konkretnej klasy. W zadaniach opartych na regresji ostatnia warstwa gęsta może zawierać jeden neuron lub kilka neuronów bez funkcji *softmax*, które zwracają wartości liczbowe jako przewidywane wyniki.




Rys. 3.3 Architektura sieci LeNet-5 [34]. Opracowanie własne.

Parametry neuronów, zorganizowanych w końcowe warstwy gęste, służą do ważenia cech na wyjściu warstw konwolucyjnych, w ten sposób decydując, które z nich najlepiej odzwierciedlają postawione przed siecią zadanie.

Sieci konwolucyjne, mimo zdecydowanej przewagi nad klasycznymi sieciami gęstymi w przypadku analizy danych dwuwymiarowych, nie są wolne od problemów. Dwoma podstawowymi są: zjawisko zanikającego gradientu (ang. *vanishing gradient*) oraz problem „wąskiego gardła” (ang. *bottleneck*), pojawiający się, jeśli jedna z warstw posiada zbyt mało filtrów [13]. Występują one w szczególności w przypadku głębokich sieci, tzn. sieci o wielu warstwach. Szczególnie istotny jest tu pierwszy wymienionych problemów, który utrudnia, a czasem wręcz uniemożliwia wsteczne propagowanie sygnału zwrotnego, co sprawia, że sieć staje się niemożliwa do wytrenowania.

W 2015 r. He i in. [24] zaproponowali interesującą, pozwalającą na ograniczenie występowania wspomnianych problemów technikę, polegającą na wprowadzeniu w architekturze sieci połączeń rezydualnych (Rys. 3.4), wprowadzających dodatkowe połączenia, omijające warstwy głównej ścieżki przetwarzania i przekazujące dane wejściowe bezpośrednio do wyjścia bloku. W efekcie, wyjście bloku rezydualnego jest sumą przetworzonych danych z głównej ścieżki i oryginalnych danych wejściowych, co pozwala na swobodny przepływ gradientu, łagodząc problem jego zanikania.



Rys. 3.4 Struktura bloku rezydualnego [24].

Dzięki zachowaniu przepływu danych w przypadku zbyt mało wydajnej ścieżki głównej bloki rezydualne ograniczają też skutki występowania problemu *bottleneck*.

3.3 Rekurencyjne sieci neuronowe

W latach 80. XX w. rozpoczęły się prace, które zaowocowały powstaniem koncepcji rekurencyjnych sieci neuronowych. Posiadają one wewnętrzne sprzężenie zwrotne, polegające na przekazywaniu wyjścia z kroku $t-1$ jako część wejścia do kroku t (3.6) [22].

$$h_t = f(W_h \cdot h_{t-1} + W_x \cdot x_t + b_h) \quad (3.6)$$

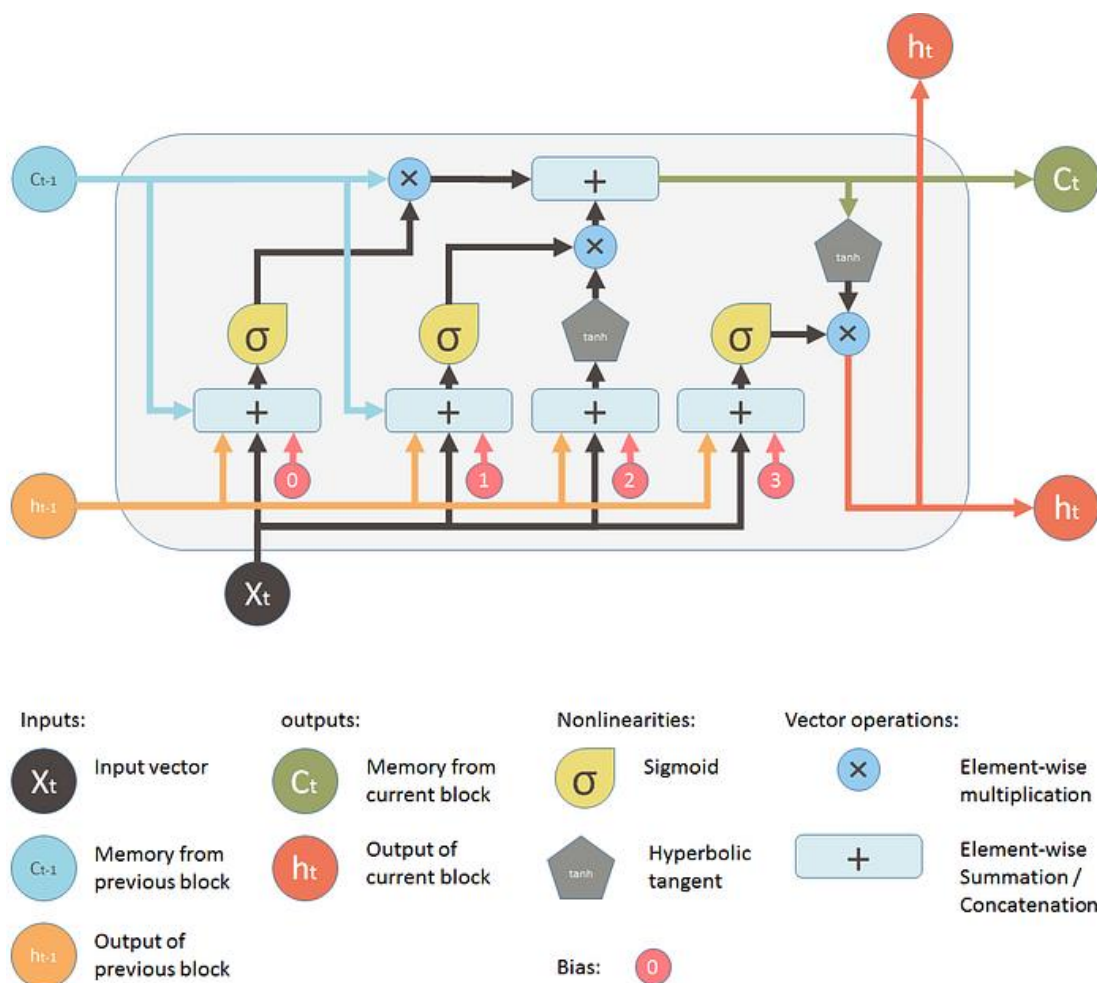
gdzie:

- h_t stan ukryty w czasie t
- h_{t-1} stan ukryty z poprzedniego kroku czasowego
- x_t wejście w czasie t
- W_h macierz wag sprzężenia zwrotnego
- W_x macierz wag na wejściu
- b_h wektor przesunięcia (bias)
- f funkcja aktywacji

Sieci te sprawdziły się w analizie danych sekwencyjnych, takich jak sygnały dźwiękowe, dane tekstowe, serie czasowe [13]. Ze względu na zastosowane sprzężenie, sieci rekurencyjne w swojej podstawowej formie napotykały na problemy zanikającego i eksplodującego gradientu, spowodowane propagowaniem gradientów przez wiele kroków czasowych. Rozwiązaniem okazała się modyfikacja w postaci wyposażonej w jednostki pamięci architektury LSTM (ang. *Long Short-Term Memory*) [27].

Zastosowano w niej trzy bramki: *input*, *output* oraz *forget*, kontrolujące przepływ informacji przez jednostkę pamięci. Model LSTM zorganizowany jest formie struktury łańcuchowej, złożonej z pojedynczych komórek (Rys. 3.5).

Kolejną architekturą, uproszczoną względem LSTM, była GRU (ang. *Gated Recurrent Unit*), w której zastosowano bramki: *reset* i *update*.



Rys. 3.5 Schemat pojedynczej komórki sieci LSTM [58].

3.4 Ocena skuteczności i jakości modelu

Detekcja wybranego źródła hałasu w zarejestrowanym sygnale, a zatem przypisanie każdej próbce wartości pozytywnej (obecność wybranego źródła) bądź negatywnej (brak owego źródła) można określić mianem klasyfikacji binarnej. Każdej próbce I można przypisać rzeczywistą przynależność do jednej z klas $\{P; N\}$. Ta sama próbka I , sklasyfikowana przez określony model, otrzymuje etykietę $\{\hat{P}; \hat{N}\}$, stanowiącą wynik predykcji.

Rezultat klasyfikacji \hat{P} dla próbki o rzeczywistej klasie P określany jest mianem prawdziwie pozytywnego (ang. *true positive*). W przypadku, w którym klasyfikator zwraca wynik \hat{P} dla próbki o rzeczywistej klasie N , uzyskany rezultat to wynik fałszywie pozytywny (ang. *false positive*). Odpowiednio, rezultat prawdziwie negatywny (ang. *true negative*) oznacza zgodność predykcji \hat{N} z rzeczywistą klasą N , zaś wynik predykcji \hat{N} dla próbki o klasie P to wynik fałszywie negatywny (ang. *false negative*) [17]. Te cztery

możliwe przypadki formują macierz pomyłek (ang. *confusion matrix*), stanowiącą punkt wyjścia w ocenie jakości klasyfikacji binarnej (Rys. 3.6).

W oparciu o macierz pomyłek można określić służące do oceny jakości predykcji miary, takie jak: czułość (ang. *sensitivity* lub *recall*), precyzję (ang. *precision*) oraz swoistość (ang. *specificity*), opisane formułami 3.7 - 3.9.

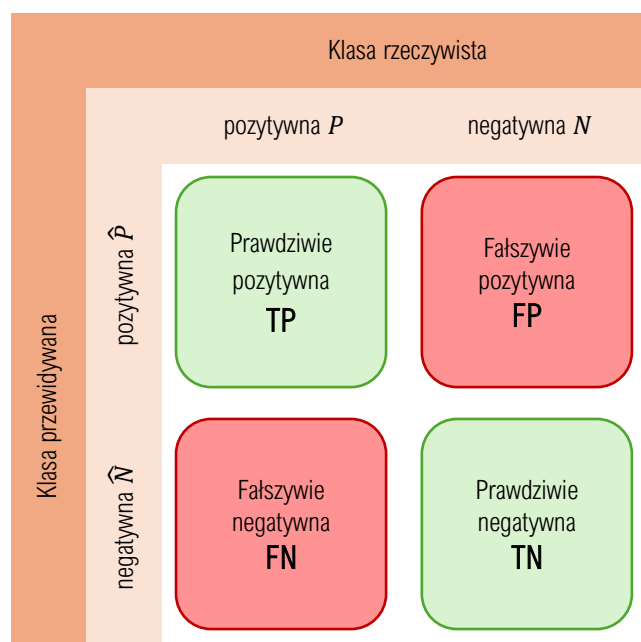
$$\text{czułość (TPR)} = \frac{TP}{TP + FN} \quad (3.7)$$

$$\text{precyzja} = \frac{TP}{TP + FP} \quad (3.8)$$

$$1 - \text{swoistość (FPR)} = \frac{FN}{TN + FN} \quad (3.9)$$

Popularną, z uwagi na swoją intuicyjność, miarą jest także dokładność (ang. *accuracy*):

$$\text{dokładność} = \frac{TP + TN}{TP + FP + TP + TN} \quad (3.10)$$



Rys. 3.6 Macierz pomyłek dla klasyfikacji binarnej. Opracowanie własne za [17].

Przedstawione powyżej wskaźniki są określane mianem niezbalansowanych [49]. W przypadku, gdy liczebność próbek poszczególnych klas nie jest zbliżona (dane niezbalansowane) stosowanie tych wskaźników często prowadzi do błędnych wniosków. Wykazują one bowiem tendencję do pomijania oceny zdolności predykcyjnych w odniesieniu do mniej licznej klasy. Niech zbiór danych zawiera 95% próbek, należących do klasy negatywnej, a 5% do klasy pozytywnej. Jeśli klasyfikator zawsze

przewiduje klasę negatywną, jego dokładność wyniesie 95%, co wydaje się bardzo dobrym wynikiem. Jednakże w rzeczywistości model całkowicie ignoruje klasę pozytywną, co oznacza, że nie jest skuteczny w odniesieniu do najważniejszej części problemu. W problemach, w których dane są niezbalansowane, zasadnym jest stosowanie bardziej zrównoważonych wskaźników, które lepiej odzwierciedlają rzeczywistą skuteczność modelu.

Pierwszy z nich stanowi F-score (formuła 3.11), którego szczególny przypadek, F_1 , stanowi średnią harmoniczną precyzji i czułości.

$$F_{\beta} = \frac{(\beta^2 + 1) \cdot \text{precyzja} \cdot \text{czułość}}{\beta^2 \cdot \text{precyzja} + \text{czułość}} \quad (3.11)$$

Miara ta pozwala na równoczesne uwzględnienie precyzji i czułości, zaś zastosowanie współczynnika β umożliwia zwiększenie wpływu jednego z tych wskaźników na wynik oceny.

Kolejnym wskaźnikiem jest MCC (ang. *Matthews Correlation Coefficient*) [40]. Współczynnik ten uwzględnia prawdziwe i fałszywe pozytywne oraz negatywne przewidywania. Uznawany jest za zrównoważoną miarę, którą można stosować także wtedy, gdy klasy mają zróżnicowaną liczebność [6]. Może zostać wyznaczony bezpośrednio z macierzy pomyłek zgodnie z formułą (3.12).

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (3.12)$$

Warto zwrócić uwagę, że omówione wskaźniki F_1 oraz MCC wymagają jednoznacznego przypisania próbki do jednej z dwóch klas. Efekt działania sieci neuronowej, zakończonej sigmoidalną funkcją aktywacji (patrz Rozdział 3.1), ma jednakże postać liczby rzeczywistej z przedziału $\langle 0; 1 \rangle$. Aby porównać jakość predykcji modeli przy użyciu wskaźników F_1 bądź MCC konieczna jest odpowiednia interpretacja wartości wyjściowej. Konieczne jest zatem określenie pewnej wartości progowej, powyżej której klasyfikator zwróci klasę pozytywną, poniżej zaś – negatywną. Proste zaokrąglenie do najbliższej liczby całkowitej stanowi w istocie ukryte przypisanie wartości progowej, wynoszącej 0,5. Wartość progu może być jednak dostrojona do charakterystyki modelu. Operacji tej można dokonać iteracyjnie, dobierając wartość progu tak, aby uzyskać najwyższe wartości danego wskaźnika. Można także posłużyć się krzywymi ROC (ang. *Receiver Operating Characteristic*) i PR (ang. *precision-recall*).

Pierwsza z nich, ROC, pokazuje związek między czułością (*True Positive Rate*, TPR) a 1-swoistością (*False Positive Rate*, FPR) dla różnych progów decyzyjnych modelu [17]. Punkt (0, 1) odpowiada idealnemu modelowi, który ma czułość 1 (wykrywa wszystkie pozytywne przypadki) i FPR 0 (nie generuje fałszywych pozytywnych przypadków). W praktyce, im bliżej krzywa ROC znajduje się tego punktu, tym lepszy jest model [11]. Korzystając z tej cechy krzywej ROC można wyznaczyć próg odcięcia najbliższy idealnemu klasyfikatorowi [56].

Często stosowaną miarą jest także pole powierzchni pod krzywą ROC, oznaczana jako AUC ROC (ang. *area under curve*). Im wyższa wartość tej miary, tym model wyższa jakość klasyfikacji modelu. $AUC\ ROC = 1$ oznacza model idealny, zaś $AUC\ ROC = 0,5$ wskazuje, że model swoje predykcje generuje losowo. W pewnych warunkach, w szczególności przy dużym niezrównoważeniu danych, krzywa ROC, oparta o niezbalansowany wskaźnik FPR, może dawać zbyt optymistyczne rezultaty [17].

Drugą, zbliżoną miarą, jest krzywa PR, która jest istotnie mniej podatna na fałszywie pozytywne wyniki [17]. Czyni ją to bardziej odpowiednią w przypadkach, gdy występowanie próbek klasy pozytywnej jest względnie rzadkie. Krzywa PR jest otrzymywana poprzez wyznaczenie punktów dla różnych progów odcięcia, co pokazuje, jak zmieniają się precyzja i czułość w zależności od tego progu. Wartość pola powierzchni pod krzywą, AUC PR, może być podobnie jak w przypadku AUC ROC stosowana do porównywania jakości predykcji modeli.

4 BADANIA TERENOWE

Podstawowy problem przy klasyfikacji metodami uczenia maszynowego stanowi zapewnienie zbioru danych treningowych, walidacyjnych i testowych w wystarczającej ilości i jakości. Ze względu na nieczęsto rozpatrywaną specyfikę klasyfikacji zdarzeń akustycznych związanych z hałasem lotniczym zbiory danych dostępne publicznie, takie jak AudioSet [20] czy ESC-50 [44], nie znalazły zastosowania w niniejszej pracy. Zbiory te zawierają pięcio- lub dziesięciosekundowe fragmenty nieskalibrowanych nagrań w formacie *wav* (czysty sygnał audio). Ich zastosowanie wymagałoby doprowadzenia do postaci analogicznej do zapisywanej przez przyrządy pomiarowe, co stanowiło jedno z podstawowych założeń pracy, nie dając gwarancji powodzenia.

Z tego względu do dalszych analiz wykorzystano udostępnione dzięki uprzejmości przedstawicieli Portu Lotniczego im. Lecha Wałęsy w Gdańsku oraz Międzynarodowego Portu Lotniczego Katowice im. Wojciecha Korfańskiego w Pyrzowicach dane rejestrowane przez systemy ciągłego monitoringu hałasu lotniczego, obsługiwane przez Laboratorium Badawcze SVANTEK. W niniejszym rozdziale omówiono charakterystykę wybranych lotnisk oraz metodę prowadzenia pomiarów hałasu w ramach systemu monitoringu, wraz ze stosowaną aparaturą i lokalizacją punktów pomiarowych. Przedstawiono także stosowaną metodę manualnej klasyfikacji i jej wpływ na jakość pozyskiwanych danych.

4.1 Pomiar emisji hałasu lotniczego

Zgodnie z artykułem 175 ustawy Prawo Ochrony Środowiska [78], Zarządzający leżącym w granicach aglomeracji miejskiej lotniskiem, obsługującym powyżej 10 000 operacji startów i lądowań, jest zobowiązany do prowadzenia monitoringu hałasu w sposób ciągły. Sposób realizacji pomiaru monitoringowego określa *Referencyjna metodyka wykonywania ciągłych pomiarów poziomów hałasu wprowadzanego do środowiska przez starty, lądowania i przeloty statków powietrznych w związku z eksploatacją lotnisk oraz kryteria lokalizacji punktów pomiarowych* zawarta w Załączniku 1 do Rozporządzenia Ministra Środowiska z dnia 16 czerwca 2011 r. w sprawie wymagań w zakresie prowadzenia pomiarów poziomów substancji lub energii w środowisku przez zarządzającego drogą, linią kolejową, linią tramwajową, lotniskiem lub portem (Dz. U. 2011 nr 140 poz. 824, Dz. U. 2011 nr 288 poz. 1697) [76]. Zapisy Rozporządzenia określają metodę realizacji pomiarów, parametry aparatury pomiarowej, lokalizację punktów pomiarowych oraz wykorzystywane wskaźniki oceny hałasu. Warto zauważyć,

że polskie regulacje w pewnym zakresie różnią się od przepisów międzynarodowych [68]. Ponieważ jednak różnice te nie będą mieć bezpośredniego wpływu na wybór metody detekcji sygnału, nie zostaną szczegółowo omówione w niniejszej pracy.

Podstawowym założeniem pomiaru prowadzonego metodą ciągłą przy wykorzystaniu pojedynczych zdarzeń akustycznych jest rejestracja danych akustycznych (równoważnego poziomu dźwięku A) z krokiem nie mniejszym niż 1 s oraz towarzyszących danych meteorologicznych, w celu kontroli warunków pomiaru. Ponadto na podstawie rejestru wykonywanych lotów pozyskiwane informacje dodatkowe, konieczne do klasyfikacji zdarzeń akustycznych: typ statku powietrznego, typ operacji lotniczej (start, przelot, lądowanie) oraz symbol prognozy drogi startowej.

Kluczowy element metody stanowi wyodrębnienie z zarejestrowanych danych fragmentów, zawierających zdarzenia związane z ocenianym źródłem hałasu oraz powiązanie ich z konkretnymi statkami powietrznymi. O wystąpieniu takiego zdarzenia można mówić, pod warunkiem spełnienia kryterium, określonego formułą (4.1), stanowiącego zarazem warunek dla czasu trwania wyznaczanego zdarzenia akustycznego [76]:

$$L_{A,max} - 10 \leq L_A(t) \leq L_{A,max} \quad (4.1)$$

Dla każdego z wyodrębnionych zdarzeń obliczana jest wartość poziomu ekspozycji na hałas, opisanego poniższą formułą [72]:

$$L_E = 10 \log \left(\frac{E}{E_0} \right) \text{ [dB]} \quad (4.2)$$

gdzie:

$$E = \int_T p(t)^2 dt \quad (4.3)$$

Uwzględniając z kolei fakt, że polskie przepisy wymagają przy ocenie hałasu w środowisku stosowania krzywej częstotliwościowej charakterystyki korekcyjnej A, otrzymujemy dla przedziału czasu trwania zdarzenia $(t_0; t_1)$:

$$L_{AE} = 10 \log \left[\frac{\int_{t_0}^{t_1} p_A(t)^2 dt}{p_0^2} \right] \text{ [dB]} \quad (4.4)$$

gdzie:

$p_A(t)$ chwilowe ciśnienie akustyczne, zmodyfikowane charakterystyką częstotliwościową A, w chwili t ;

p_0 akustyczne ciśnienie odniesienia (20 μ Pa).

Dysponując zestawem danych, na które składa się wartość ekspozycyjnego poziomu dźwięku, klasa zdarzenia akustycznego oraz moment jego wystąpienia, a także towarzyszące mu warunki meteorologiczne można wyznaczyć długo- lub krótkookresowe poziomy dźwięku A, wyrażone odpowiednio wskaźnikami L_{DWN} i L_N lub $L_{Aeq D}$ i $L_{Aeq N}$ [19]. Pierwszy krok stanowi określenie średniej poziomu ekspozycji dla danej klasy zdarzeń akustycznych, $L_{AE,k}$.

$$L_{AE,k} = 10 \log \left[\frac{1}{n} \sum_{i=1}^n 10^{0,1L_{AE,ki}} \right] [\text{dB}] \quad (4.5)$$

gdzie:

n liczba pojedynczych zdarzeń akustycznych należących do klasy oznaczonej „k”, pozbawionych wpływu zakłóceń akustycznych i spełniających wymagania dotyczące warunków meteorologicznych

$L_{AE,ki}$ wartość poziomu ekspozycyjnego dla pojedynczych zdarzeń akustycznych zakwalifikowanych do klasy oznaczonej „k”, spełniających powyższe kryteria

Wartości wskaźników oceny hałasu wyznaczane są następnie, w zależności od potrzeb, wynikających z celu prowadzenia pomiaru, zgodnie z formułą 4.6. W Polsce, na potrzeby opracowań strategicznych, stosowane są długookresowe, średnie poziomy dźwięku L_D dla pory dnia (06:00 – 18:00), L_W dla pory wieczoru (18:00 – 22:00) oraz L_N dla pory nocy (22:00 – 06:00). Są one obliczane w odniesieniu do jednego roku [78].

$$L_X = 10 \log \left[\frac{1}{T} \sum_{k=1}^m N_k 10^{0,1L_{AE,k}} \right] [\text{dB}] \quad (4.6)$$

gdzie:

X przyjmuje wartość D , W lub N dla pory dnia, wieczoru lub nocy przy wyznaczaniu wskaźników długookresowych bądź $Aeq D$ lub $Aeq N$ dla pory dnia lub nocy przy wyznaczaniu wskaźników krótkookresowych

T czas odniesienia w sekundach [s], odpowiadający okresowi oceny

N_k liczba pojedynczych zdarzeń akustycznych zaobserwowanych w czasie odniesienia T, należących do klasy oznaczonej „k”


$L_{AE,k}$ wartość poziomu ekspozycyjnego klasy oznaczonej „k” [dB], uśredniona dla czasu trwania pomiarów

m liczba klas pojedynczych zdarzeń akustycznych

4.2 Charakterystyka badanych lotnisk

Do badań wytypowano dwa polskie lotniska komunikacyjne: Port Lotniczy im. Lecha Wałęsy w Gdańsku (kod ICAO: EPGD) oraz Międzynarodowy Port Lotniczy im. Wojciecha Korfańskiego w Pyrzowicach (kod ICAO: EPKT). Oba lotniska przyjmują w głównej mierze turboodrzutowe samoloty wąskokadłubowe (Rys. 4.1), obsługujące połączenia lokalne.

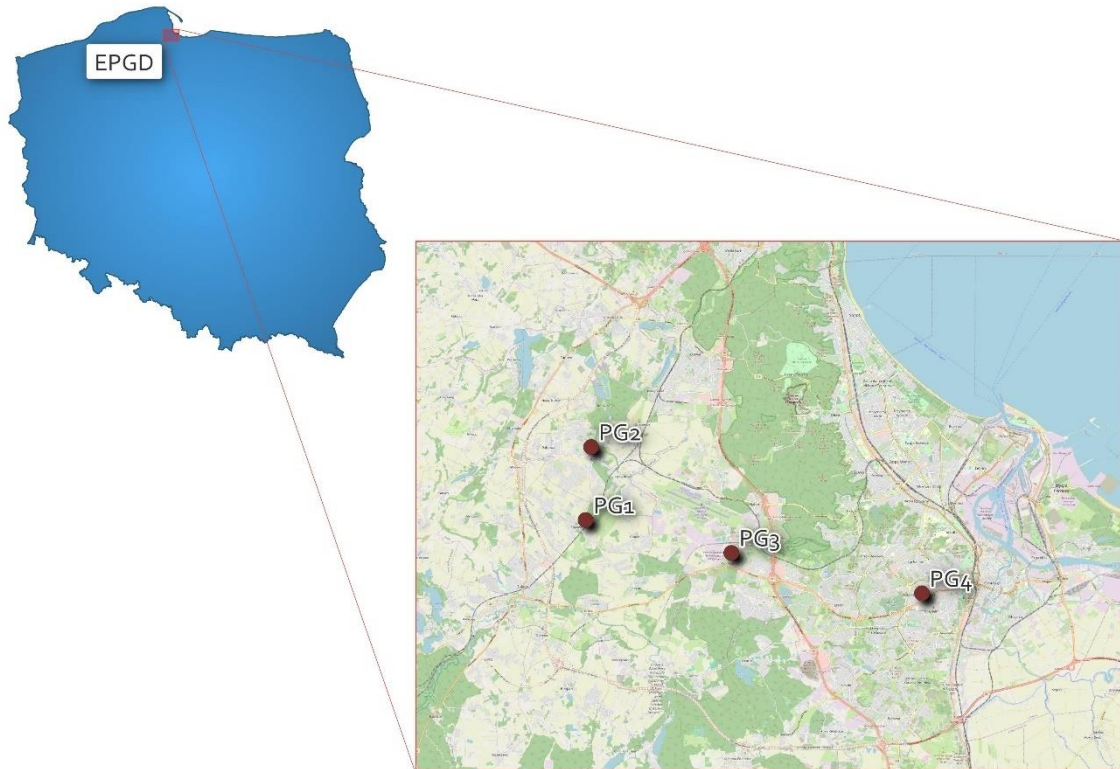
Lotniska zostały wytypowane przede wszystkim ze względu na charakterystyki obsługiwanych statków powietrznych a także na dobrze zdefiniowane trasy startów i lądowań. Czynniki te mają istotny wpływ na charakterystykę widmową hałasu, rejestrowanego przez punkty monitoringu hałasu lotniczego, co zostanie szczegółowo omówione w rozdziale 4.5.



Rys. 4.1 Procentowy udział w ruchu lotniczym w roku 2022 na lotniskach objętych pomiarami. Opracowanie własne na podstawie danych z systemu monitoringu.

4.2.1 Port Lotniczy im. Lecha Wałęsy w Gdańsku

Lotnisko położone jest w północnej części Polski, w województwie pomorskim, na terenie gminy Gdańsk, około 10 km na południowy zachód od centrum Gdańska (Rys. 4.2). W jego sąsiedztwie znajduje się Obwodnica Trójmiasta oraz drogi krajowe nr S6, 7, 20 i 91, autostrada A1 oraz linia Pomorskiej Kolei Metropolitalnej.



Rys. 4.2 Lokalizacja Portu Lotniczego im. Lecha Wałęsy w Gdańsku wraz z miejscem instalacji punktów monitoringu hałasu [88].

Lotnisko posiada jedną utwardzoną drogę startową o długości 2 800 m. Podstawowe dane oraz punkty charakterystyczne przedstawiono w Tab. 4.1.

Tab. 4.1 Podstawowe dane lotniska EPGD [82].

Nazwa lotniska	EPGD - GDAŃSK im. Lecha Wałęsy
Współrzędne ARP	54°22'39"N 018°27'58"E
Lokalizacja ARP	Centralna linia RWY, 1800 m od THR 29
Wzniesienie lotniska	489 ft
Liczba dróg startowych	1
Długość i szerokość drogi startowej	2800 m x 45 m
Progi dróg startowych	11, 29
Lokalizacja progu drogi startowej 11	54°22'51.84"N 018°27'07.38"E
Lokalizacja progu drogi startowej 29	54°22'16.56"N 018°29'30.18"E

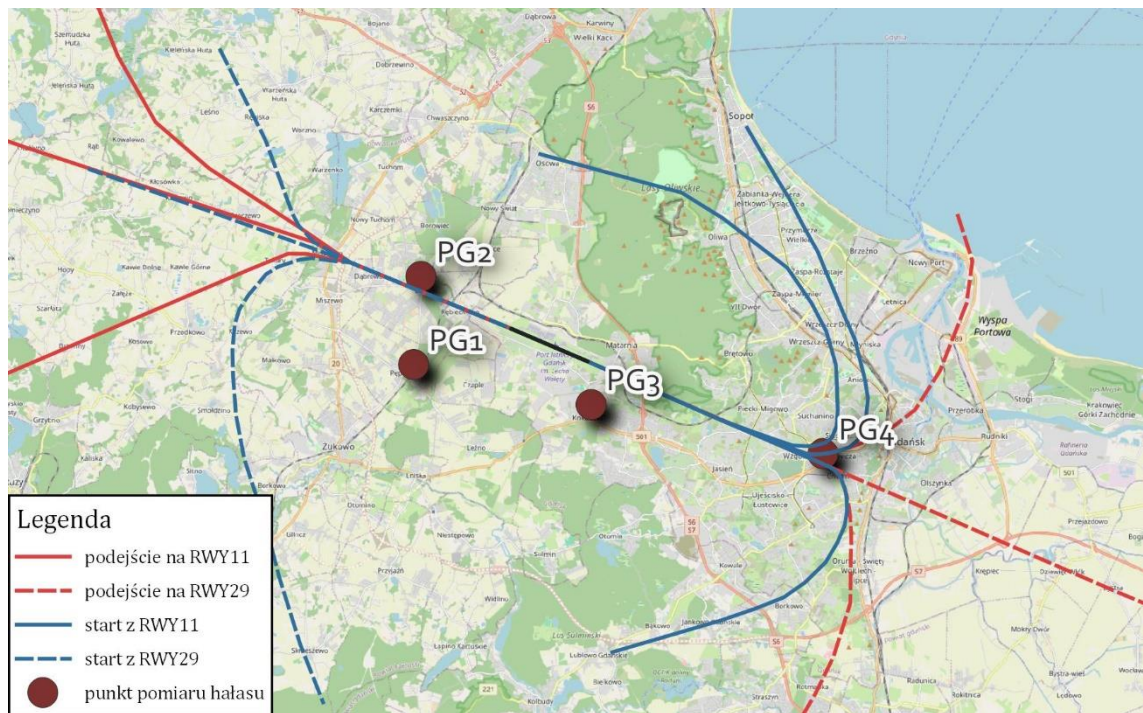
Na podstawie danych, przekazywanych przez służby operacyjne portu w celu umożliwienia funkcjonowania systemu ciągłego monitoringu hałasu, określono najczęściej obsługiwane na lotnisku typy statków powietrznych (Tab. 4.2). Analizę ograniczono do statków powietrznych o udziale w łącznym ruchu przekraczającym 1%.

Tab. 4.2 Procentowy udział w ruchu lotniczym w roku 2022 w Porcie Lotniczym im. L. Wałęsy w Gdańsku. Opracowanie własne na podstawie danych z systemu monitoringu.

Typ statku powietrznego	Udział w ruchu [%]	Opis
B738	30,70	turbowentylatorowy samolot średniego zasięgu
A320	12,42	turbowentylatorowy samolot średniego zasięgu
A321	8,52	turbowentylatorowy samolot średniego zasięgu
DH8D	6,65	turbośmigłowy samolot regionalny
A21N	5,69	turbowentylatorowy samolot średniego zasięgu
CRJ9	5,65	turbowentylatorowy samolot regionalny
E190	4,29	turbowentylatorowy samolot średniego zasięgu
EC35	2,88	śmigłowiec ratunkowy z silnikiem turbowałowym
A20N	1,91	turbowentylatorowy samolot średniego zasięgu
E175	1,86	turbowentylatorowy samolot średniego zasięgu
B38M	1,73	turbowentylatorowy samolot średniego zasięgu
B752	1,39	turbowentylatorowy samolot średniego zasięgu
SF34	1,20	turbośmigłowy samolot krótkiego zasięgu
AT75	1,13	turbośmigłowy samolot regionalny

W roku 2022 70% obsłużonych na lotnisku statków powietrznych stanowiły pasażerskie samoloty średniego zasięgu, z napędem turbowentylatorowym. Samoloty pasażerskie z napędem turbośmigłowym miały 10% udziały w łącznym ruchu, zaś 4% - śmigłowce, głównie ratunkowe. Pozostałe 16% stanowiły małe samoloty turboodrzutowe oraz lekkie samoloty pasażerskie z napędem tłokowym.

Na podstawie indywidualnych tras przelotów statków powietrznych, zarejestrowanych w roku 2022 przy użyciu odbiornika ADS-B (ang. *Automatic Dependent Surveillance–Broadcast*), wyodrębniono 12 uśrednionych tras startów i lądowań (Rys. 4.3). W roku 2022 77% startów z lotniska odbyło się w kierunku zachodnim (z progu RWY 29), zaś 74% lądowań odbyło się z kierunku wschodniego (na próg RWY 29).

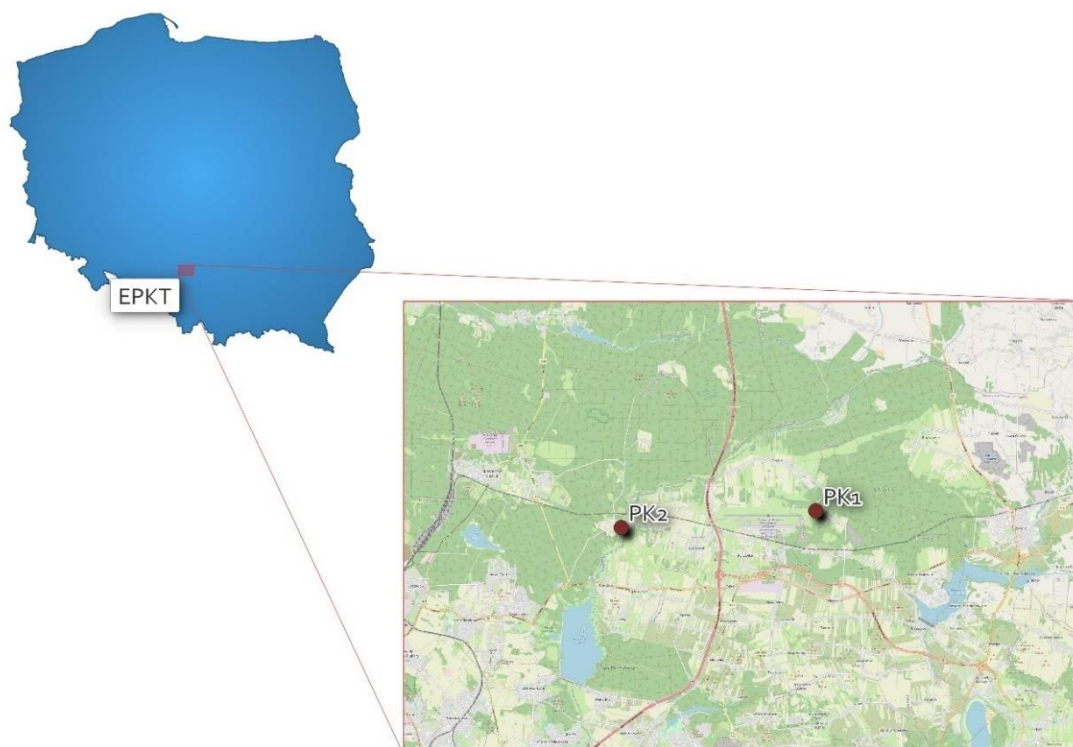


Rys. 4.3 Przebieg tras startów i lądowań w roku 2022 [88].

Lotnisko wyposażone jest w czteropunktowy system monitoringu hałasu, obsługiwany w roku 2022 przy użyciu stacji ciągłego monitoringu hałasu SV 210C firmy SVANTEK. Rejestracja trajektorii realizowana była przy użyciu odbiornika KINETIC SBS3. Szczegółowy opis przyrządów pomiarowych przedstawiono w rozdziale 4.3. System monitoringu na lotnisku funkcjonuje nieprzerwanie od roku 2010.

4.2.2 Międzynarodowy Port Lotniczy im. Wojciecha Korfanego w Pyrzowicach

Lotnisko położone jest w południowej części Polski, w województwie śląskim, na terenie gminy Ożarówice, około 33 km od centrum Katowic (Rys. 4.4). Dojazd zapewniają autostrada A1 oraz droga ekspresowa S1 a także linia Kolei Śląskich.



Rys. 4.4 Lokalizacja Międzynarodowego Portu Lotniczego im. Wojciecha Korfanego w Pyrzowicach wraz z miejscem instalacji punktów monitoringu hałasu [88].

Lotnisko posiada jedną utwardzoną drogę startową o długości 3 200 m, oddaną do użytku w roku 2015. Podstawowe dane oraz punkty charakterystyczne przedstawiono w Tab. 4.3.

Tab. 4.3 Podstawowe dane lotniska EPKT [82].

Nazwa lotniska	EPKT – Katowice – Pyrzowice
Współrzędne ARP	50°28'27"N 019°04'48"E
Lokalizacja ARP	Na TWY H4
Wzniesienie lotniska	1007 ft
Liczba dróg startowych	1
Długość i szerokość drogi startowej	3200 m x 45 m
Progi dróg startowych	08, 26
Lokalizacja progu drogi startowej 08	50°28'33.78"N 019°03'34.45"E
Lokalizacja progu drogi startowej 26	50°28'33.46"N 019°06'00.50"E

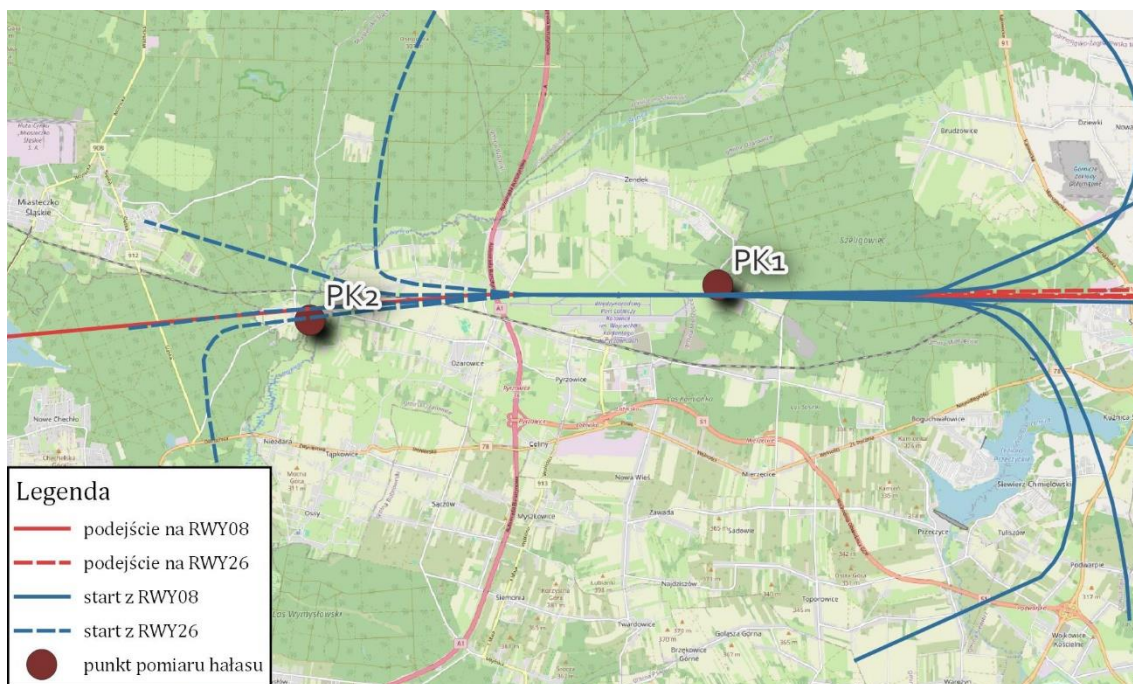
W roku 2022 86% obsłużonych na lotnisku statków powietrznych stanowiły pasażerskie samoloty średniego zasięgu, z napędem turbowentylatorowym. Samoloty pasażerskie z napędem turbośmigłowym miały 8% udziały w łącznym ruchu, zaś 2% - śmigłowce, głównie ratunkowe. Pozostałe 4% stanowiły małe samoloty turboodrzutowe oraz lekkie samoloty pasażerskie z napędem tłokowym.

Tab. 4.4 Procentowy udział w ruchu lotniczym w roku 2022 w Międzynarodowym Porcie Lotniczym im. Wojciecha Korfańskiego w Pyrzowicach. Opracowanie własne na podstawie danych z systemu monitoringu.

Typ statku powietrznego	Udział w ruchu [%]	Opis
B738	39,46	turbowentylatorowy samolot średniego zasięgu
A320	12,53	turbowentylatorowy samolot średniego zasięgu
32Q	8,08	turbowentylatorowy samolot średniego zasięgu
B38M	5,75	turbowentylatorowy samolot średniego zasięgu
B734	5,41	turbowentylatorowy samolot średniego zasięgu
A321	4,68	turbowentylatorowy samolot średniego zasięgu
E170	3,51	turbowentylatorowy samolot średniego zasięgu
AT72	1,29	turbośmigłowy samolot regionalny
E190	1,27	turbowentylatorowy samolot średniego zasięgu

Na podstawie indywidualnych tras przelotów statków powietrznych, zarejestrowanych w roku 2022 przy użyciu odbiornika ADS-B, wyodrębniono 17 uśrednionych tras startów i lądowań (Rys. 4.5).

W roku 2022 77% startów z lotniska odbyło się w kierunku zachodnim (z progu RWY 27), zaś 74% lądowań odbyło się z kierunku wschodniego (na próg RWY 27).



Rys. 4.5 Przebieg tras startów i lądowań w roku 2022 [88].


Lotnisko wyposażone jest w dwupunktowy system monitoringu hałasu, obsługiwany w roku 2022 przy użyciu stacji ciągłego monitoringu hałasu SV 200 firmy SVANTEK. Rejestracja trajektorii realizowana była przy użyciu odbiornika KINETIC SBS3. Szczegółowy opis przyrządów pomiarowych przedstawiono w rozdziale 4.3. System monitoringu na lotnisku funkcjonuje nieprzerwanie od roku 2014.

4.3 Punkty pomiaru hałasu

Metodyka referencyjna [76], zgodnie z którą prowadzone są ciągłe pomiary hałasu lotniczego, określa wymagania dotyczące lokalizacji i otoczenia punktów pomiarowych.

Rozlokowanie punktów pomiarowych na terenach otaczających lotnisko w przypadku pomiaru ciągłego nie może być przypadkowe. Celem pomiarów jest przede wszystkim monitorowanie charakterystyk akustycznych źródła hałasu. Z tego względu wprowadzono wymagania uwzględnienia rzutów tras operacji lotniczych (startów, lądowań, lotów po kręgu i przelotów) podczas wyboru lokalizacji punktów. Nie mniej istotny wymóg stanowi konieczność uwzględnienia charakteru i poziomu tła akustycznego w rejonie punktu. Spełnienie powyższych wymagań pozwala na zapewnienie stosunku sygnału hałasu lotniczego do szumu (tła akustycznego) wystarczającego do identyfikacji hałasu pochodzącego od statków powietrznych i wyodrębnienia poprawnych, z punktu widzenia kryteriów przedstawionych w rozdziale 4.1, zdarzeń akustycznych.

Drugi zestaw kryteriów dotyczy zasad lokalizacji mikrofonu pomiarowego w otoczeniu. Oś mikrofonu powinna być kierowana pionowo. Jego wysokość nad powierzchnią terenu nie może być mniejsza niż 4 m, zaś wewnątrz stożka o kącie wierzchołkowym 160° i osi pokrywającej się z osią mikrofonu nie mogą znajdować się żadne przeszkody wpływające na propagację fali akustycznej (Rys. 4.6).



Rys. 4.6 Przykładowe usytuowanie mikrofonu pomiarowego z zaznaczeniem kryteriów metodyki referencyjnej [76]. Kolorem czerwonym oznaczono fragmenty obiektów znajdujące się poza dozwoloną strefą. Opracowanie własne.

Spełnienie powyższych kryteriów zapewnia odpowiednie warunki pola akustycznego w otoczeniu punktu. Wpływ odbić fali akustycznej jest pomijalny, zaś ekranowanie wynikające z obecności sąsiadujących obiektów nie ma wpływu na bezpośrednią falę akustyczną w przedziale dynamiki rejestrowanego sygnału $\langle L_{A,S,max}; L_{A,S,max} - 10 \text{ dB} \rangle$ [68].

Punkty monitoringowe, z których dane wykorzystane będą do dalszych analiz dobrano w sposób zapewniający różnorodne warunki akustyczne, zarówno pod kątem charakterystyk widmowych sygnału źródła i tła akustycznego jak i szerokopasmowego stosunku sygnału do szumu. Szczegółowy opis różnic w rejestrowanym sygnale znajduje się w rozdziale 4.5.

Poniżej przedstawiono szczegółowy opis lokalizacji i otoczenia punktów ciągłego pomiaru hałasu, z których dane wykorzystane zostały do dalszych badań.


a) Punkt pomiarowy **PG1**

Punkt ten położony jest w odległości 140 m od najbliższego istotnego źródła zakłóceń akustycznych (jednojezdniowa droga lokalna o nawierzchni bitumicznej), ekranowanego zabudową jednorodzinną.

Podstawowym celem punktu było monitorowanie wpływu jednej z południowych tras wznoszenia po starcie na pobliską zabudowę jednorodzinną. Po zmianach procedur startowych, które miały miejsce w roku 2021, trasa została zlikwidowana, co istotnie zmniejszyło stosunek sygnału do szumu w tym rejonie. Utrudnia to wyodrębnianie zdarzeń akustycznych z rejestrowanych historii czasowych poziomu dźwięku.

Tab. 4.5 Charakterystyka punktu pomiarowego PG1.

Nazwa punktu pomiarowego	PG1
Oznaczenie lotniska (ICAO)	EPGD
Współrzędne geograficzne w układzie WGS 84	54°22'12,6"N 18°24'10,3"E
Względna wysokość [m]	4
Odległość od najbliższego progu drogi startowej [m]	3 470
Odległość od rzutu najbliższej średniej trasy startu [m]	2 325
Odległość od rzutu najbliższej średniej trasy lądowania [m]	2 325



Rys. 4.7 Lokalizacja punktu pomiarowego PG1 [88] wraz z dokumentacją fotograficzną.


b) Punkt pomiarowy **PG2**

Punkt ten położony jest w odległości 400 m od najbliższego istotnego źródła zakłóceń akustycznych (jednojezdniowa droga główna o nawierzchni bitumicznej), ekranowanego zabudową jednorodzinną. Zapewnia to niskie poziomy tła akustycznego.

W sąsiedztwie punktu przebiega preferowana trasa wznoszenia po starcie, użytkowana przez samoloty komunikacyjne. W połączeniu z niskim tłem akustycznym zapewnia to wysoki stosunek sygnału do szumu, ułatwiając identyfikację zdarzeń akustycznych.

Tab. 4.6 Charakterystyka punktu pomiarowego PG2.

Nazwa punktu pomiarowego	PG2
Oznaczenie lotniska (ICAO)	EPGD
Współrzędne geograficzne w układzie WGS 84	54°23'46,9"N 18°24'22,2"E
Względna wysokość [m]	4
Odległość od najbliższego progu drogi startowej [m]	3 500
Odległość od rzutu najbliższej średniej trasy startu [m]	450
Odległość od rzutu najbliższej średniej trasy lądowania [m]	450



Rys. 4.8 Lokalizacja punktu pomiarowego PG2 [88] wraz z dokumentacją fotograficzną.


c) Punkt pomiarowy **PG3**

Punkt ten położony jest w odległości 120 m od najbliższego istotnego źródła zakłóceń akustycznych (jednojezdniowa droga zbiorcza o nawierzchni bitumicznej), ekranowanego zabudową jednorodzinną oraz wpływem wzniesienia terenu.

Punkt znajduje się w sąsiedztwie głównej trasy podejścia do lądowania. Niewielka wysokość samolotów w tak małej odległości od progu drogi startowej powoduje powstawanie odbić i ekranowania, utrudniając identyfikację zdarzeń. Jednakże przy wykorzystaniu trasy wznoszenia po starcie, źródło hałasu znajduje się na większej wysokości, co istotnie redukuje wspomniane efekty.

Tab. 4.7 Charakterystyka punktu pomiarowego PG3.

Nazwa punktu pomiarowego	PG3
Oznaczenie lotniska (ICAO)	EPGD
Współrzędne geograficzne w układzie WGS 84	54°21'31,2"N 18°29'35,5"E
Względna wysokość [m]	4
Odległość od najbliższego progu drogi startowej [m]	1 450
Odległość od rzutu najbliższej średniej trasy startu [m]	1 260
Odległość od rzutu najbliższej średniej trasy lądowania [m]	1 260



Rys. 4.9 Lokalizacja punktu pomiarowego PG3 [88] wraz z dokumentacją fotograficzną.

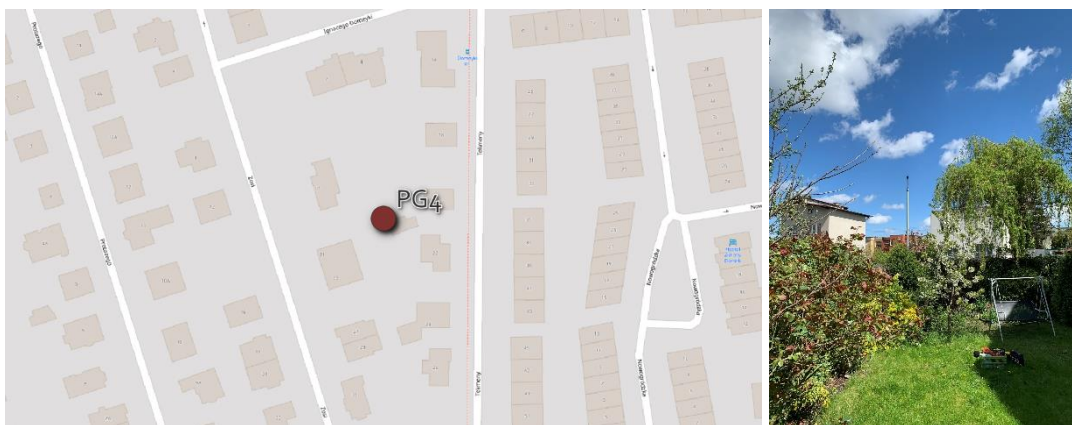
d) Punkt pomiarowy **PG4**

Punkt ten położony jest w odległości 290 m od najbliższego istotnego źródła zakłóceń akustycznych (dwujezdniowa droga zbiorcza o nawierzchni bitumicznej i dużym natężeniu ruchu pojazdów), ekranowanego zabudową jednorodzinną oraz wpływem wzniesienia terenu.

Punkt znajduje się bezpośrednio pod trasą podejścia do lądowania z kierunku wschodniego oraz wznoszenia po starcie, na terenie zwartej zabudowy mieszkaniowej jednorodzinnej. Znaczny wpływ ekranowania od źródeł hałasu komunikacyjnego powoduje niskie poziomy tła, co w połączeniu z położeniem bezpośrednio pod trasami operacji lotniczych zapewnia wysoki stosunek sygnału do szumu, ułatwiając identyfikację zdarzeń akustycznych.

Tab. 4.8 Charakterystyka punktu pomiarowego PG4.

Nazwa punktu pomiarowego	PG4
Oznaczenie lotniska (ICAO)	EPGD
Współrzędne geograficzne w układzie WGS 84	54°20'40,3"N 18°36'40,0"E
Względna wysokość [m]	4
Odległość od najbliższego progu drogi startowej [m]	8 300
Odległość od rzutu najbliższej średniej trasy startu [m]	0
Odległość od rzutu najbliższej średniej trasy lądowania [m]	0



Rys. 4.10 Lokalizacja punktu pomiarowego PG4 [88] wraz z dokumentacją fotograficzną.


e) Punkt pomiarowy **PK1**

Punkt PK1 znajduje się w odległości około 20 m od drogi zbiorczej o nawierzchni bitumicznej, w zasięgu bezpośredniej fali akustycznej. Droga ta stanowi źródło zakłóceń akustycznych, zazwyczaj w postaci pojedynczych zdarzeń związanych z przejazdami pojazdów lekkich i ciężkich oraz autobusów.

Punkt ten oddalony jest jedynie o 900 m od progu drogi startowej lotniska i 200 m od rzutów tras startów i lądowań. Z tego względu pomimo podwyższonych wartości tła akustycznego identyfikacja zdarzeń akustycznych jest ułatwiona. Bliskość punktu do progu drogi startowej powoduje jednocześnie, że wpływ na rejestrowane przez niego sygnały mają także operacje kołowań przed startem i po lądowaniu.

Tab. 4.9 Charakterystyka punktu pomiarowego PG2.

Nazwa punktu pomiarowego	PK1
Oznaczenie lotniska (ICAO)	EPKT
Współrzędne geograficzne w układzie WGS 84	50°28'39,8"N 19°6'46,0"E
Względna wysokość [m]	4
Odległość od najbliższego progu drogi startowej [m]	900
Odległość od rzutu najbliższej średniej trasy startu [m]	200
Odległość od rzutu najbliższej średniej trasy lądowania [m]	200




Rys. 4.11 Lokalizacja punktu pomiarowego PK1[88] wraz z dokumentacją fotograficzną.

f) Punkt pomiarowy **PK2**

Punkt PK2 zlokalizowano w odległości około 100 m od drogi lokalnej, w otoczeniu ekranującej zabudowy o charakterze zagrodowym.

Tab. 4.10 Charakterystyka punktu pomiarowego PG2.

Nazwa punktu pomiarowego	PK2
Oznaczenie lotniska (ICAO)	EPGD
Współrzędne geograficzne w układzie WGS 84	50°28'17,4"N 18°59'55,7"E
Względna wysokość [m]	5
Odległość od najbliższego progu drogi startowej [m]	4 300
Odległość od rzutu najbliższej średniej trasy startu [m]	50
Odległość od rzutu najbliższej średniej trasy lądowania [m]	220



Rys. 4.12 Lokalizacja punktu pomiarowego PK2 [88] wraz z dokumentacją fotograficzną.

4.4 Aparatura pomiarowa

4.4.1 Stacje monitoringu hałasu

Przyrządy pomiarowe, przy użyciu których dokonywana jest ocena hałasu emitowanego do środowiska w związku z eksploatacją portu lotniczego, powinny spełniać wymagania obowiązujących w Polsce przepisów prawnych, w szczególności metodyki referencyjnej [76]. Wytypowane do badań lotniska wyposażone są w stacje ciągłego monitoringu hałasu firmy SVANTEK.

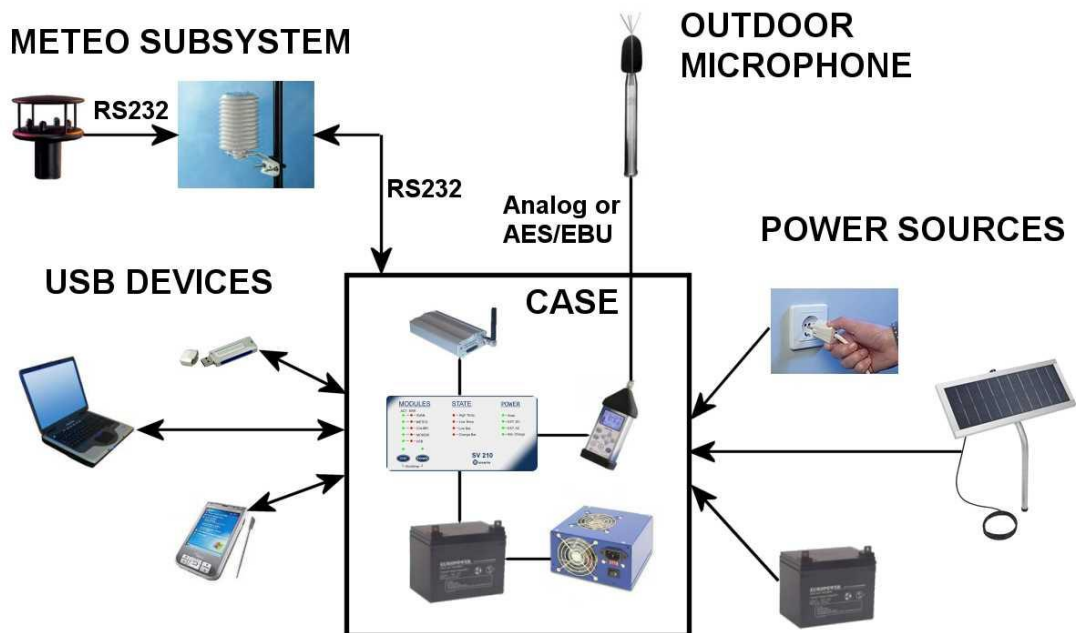
W skład stacji monitoringu wchodzi układ pomiarowy, spełniający wymagania określone dla miernika poziomu dźwięku klasy 1 [65], mikrofon w osłonie umożliwiającej pracę podczas niekorzystnych warunków meteorologicznych oraz moduł komunikacji. Stacja umożliwia również podłączenie urządzeń peryferyjnych, takich jak moduł meteorologiczny.

W Porcie Lotniczym im. Lecha Wałęsy w Gdańsku w okresie zbierania danych pomiarowych wykorzystywano stacje monitoringu SV210C z miernikiem klasy 1 SVAN 959, współpracującym z mikrofonem GRAS 41AM, dedykowanym do ciągłych pomiarów hałasu lotniczego. Mikrofon wyposażono w aktuator elektrostatyczny, pozwalający na realizację zdalnych sprawdzeń stabilności toru pomiarowego oraz grzałkę, redukującą wpływ kondensacji pary wodnej na membranie mikrofonu. Urządzenie umożliwia podłączenie stacji meteorologicznej SV205 firmy SVANTEK.



Rys. 4.13 Wnętrze stacji SV210C [86] oraz mikrofon GRAS 41AM [87].

Dostęp do danych, rejestrowanych przez urządzenia pomiarowe, zapewnia modem 3G firmy Siemens. Stacja wyposażona jest w kontroler, pozwalający na komunikację pomiędzy poszczególnymi jej komponentami. Urządzenie zasilane jest z sieci energetycznej o napięciu 230V oraz wyposażone w akumulator, pozwalający na 48 godzin pracy w warunkach braku zasilania zewnętrznego. Ideowy schemat urządzenia przedstawiono na Rys. 4.14.



Rys. 4.14 Schemat ideowy stacji SV210C [86].

Międzynarodowy Port Lotniczy im. Wojciecha Korfanteo w Pyrzowicach posiada system monitoringu oparty o zintegrowane stacje monitoringu hałasu nowej generacji typu SV200 firmy SVANTEK. Korzystają one z półcalowych mikrofonów MK 250 firmy Microtech Gefell. Stacja łączy w zwartej obudowie układ pomiarowy, kontrolny (oparty o aktuator elektrostatyczny), zasilania oraz komunikacji zdalnej (Rys. 4.15).



Rys. 4.15 Fotografia stacji monitoringu hałasu SV200 [85].

Oba typy przyrządów umożliwiają dokonywanie analizy 1/3-oktawowej (tercjowej) rejestrowanego sygnału w czasie rzeczywistym.


4.4.2 Odbiornik ADS-B Kinetic

Nieodłącznym elementem systemów monitoringu hałasu są układy rejestrujące trajektorie operacji lotniczych. Pozwalają one na korelację wyodrębnionych zdarzeń akustycznych z konkretnymi statkami powietrznymi i umożliwiają weryfikację danych przekazywanych przez Zarządzających lotniskami.

W systemach monitoringu hałasu, eksploatowanych na wytypowanych do badań lotniskach, wykorzystywane są w tym celu odbiorniki ADS-B (ang. *Automatic Dependent Surveillance–Broadcast*) firmy Kinetic. Są to urządzenia stosowane w transporcie lotniczym do odbierania i przetwarzania sygnałów nadawanych przez statki powietrzne wyposażone w transpondery ADS-B. System ADS-B jest częścią nowoczesnego systemu monitorowania ruchu lotniczego, umożliwiającego efektywne śledzenie i zarządzanie lotami.

Odbiornik ADS-B działa na zasadzie odbierania sygnałów radiowych o częstotliwości nośnej 1090 MHz, nadawanych przez statki powietrzne, które są wyposażone w transpondery ADS-B. Transpondery te emitują informacje o położeniu, prędkości, wysokości i innych istotnych parametrach lotu. Te dane są następnie przekazywane przez odbiornik ADS-B do systemu monitorowania ruchu lotniczego, co umożliwia dostarczenie dokładnych informacji na temat lokalizacji i ruchu statków powietrznych [61].

Na rysunku Rys. 4.16 przedstawiono przykład wizualizacji przestrzennej rejestrowanych danych oraz wykorzystywane urządzenie SBS3.




Rys. 4.16 Wizualizacja przykładowych tras rejestrowanych przez odbiornik ADS-B (a) oraz wykorzystywane urządzenie SBS3 (b).

4.5 Charakterystyka rejestrowanego hałasu

Rejestrowane przez przyrządy pomiarowe dane miały charakter tzw. multispektrow, czyli widm 1/3-oktawowych, w przedziale częstotliwości środkowych od 20 Hz do 20 kHz, zapisywanych z krokiem 0,5 s. Przyrządy rejestrowały również wartość poziomu dźwięku A. Oznacza to, że każda z półsekundowych próbek składała się z 32 wartości. Dla zachowania przejrzystości prezentowanych przykładów, w porównaniach w domenie czasu ograniczę się do przedstawienia wartości szerokopasmowej poziomu dźwięku A, zaś w domenie częstotliwości – do widma uzyskanego w momencie wystąpienia najwyższej wartości szerokopasmowego poziomu dźwięku A.

Przedstawione w niniejszym rozdziale wykresy historii czasowej sporządzono przyjmując numer próbki, dla której pojawiła się najwyższa wartość poziomu dźwięku za 0. Ich wartości zostały również znormalizowane do wartości maksymalnej. Podobną normalizację zastosowano dla wykresów przedstawiających widma 1/3-oktawowe. Normalizacja wartości poziomów ciśnienia akustycznego w sposób oczywisty uniemożliwia porównanie samych wartości (te zostaną szerzej omówione w rozdziale 4.6), uwydatniając jednakże tendencje lokalne.

Liczba parametrów źródła hałasu, tak złożonego jak statek powietrzny, wpływających na charakterystyki rejestrowanego w nierzadko bardzo odległych od niego punktach hałasu jest bardzo duża i sama w sobie stanowić by mogła temat obszernego opracowania. Z tego powodu, celem niniejszego rozdziału jest omówienie wybranych czynników, istotnych z punktu widzenia tematu pracy.




Rys. 4.17 Lokalizacja punktów pomiarowych w lokalnym układzie współrzędnych z początkiem w najbliższym progu drogi startowej. Opracowanie własne.

Na Rys. 4.17 przedstawiono lokalizację punktów pomiarowych względem najbliższego progu drogi startowej. Różnice w lokalizacji punktów pomiarowych względem progu

drogi startowej powodują, że statek powietrzny znajduje się w rejonie objętym pomiarem w innym czasie od początku operacji lotniczej. Powoduje to, że w rzeczywistości rejestrowane dane dotyczą odmiennych faz lotu statku powietrzego. Zmienia się także jego orientacja względem punktu pomiarowego, wpływając na kierunkowość docierającego do punktu hałasu. Czynniki te powodują istotne różnice pomiędzy charakterystykami widmowymi rejestrowanych w każdym z punktu sygnałów [10].


Wykres widoczny na Rys. 4.18 przedstawia widmo uśrednione oraz obwiednię maksymalną i minimalną widm zarejestrowanych na poszczególnych punktach pomiarowych, w momencie maksymalnej wartości poziomu dźwięku A, dla operacji startu samolotu turboodrutowego B738⁵.



Rys. 4.18 Analiza widm 1/3-oktawowych zarejestrowanych w analizowanych punktach pomiarowych dla operacji startu turboodrutowego samolotu pasażerskiego B738. Opracowanie własne.

Rozpiętości przedziału zmienności widm są istotnie większe niż w przypadku kolejnych operacji startu w wybranym punkcie pomiarowym (Rys. 4.19).

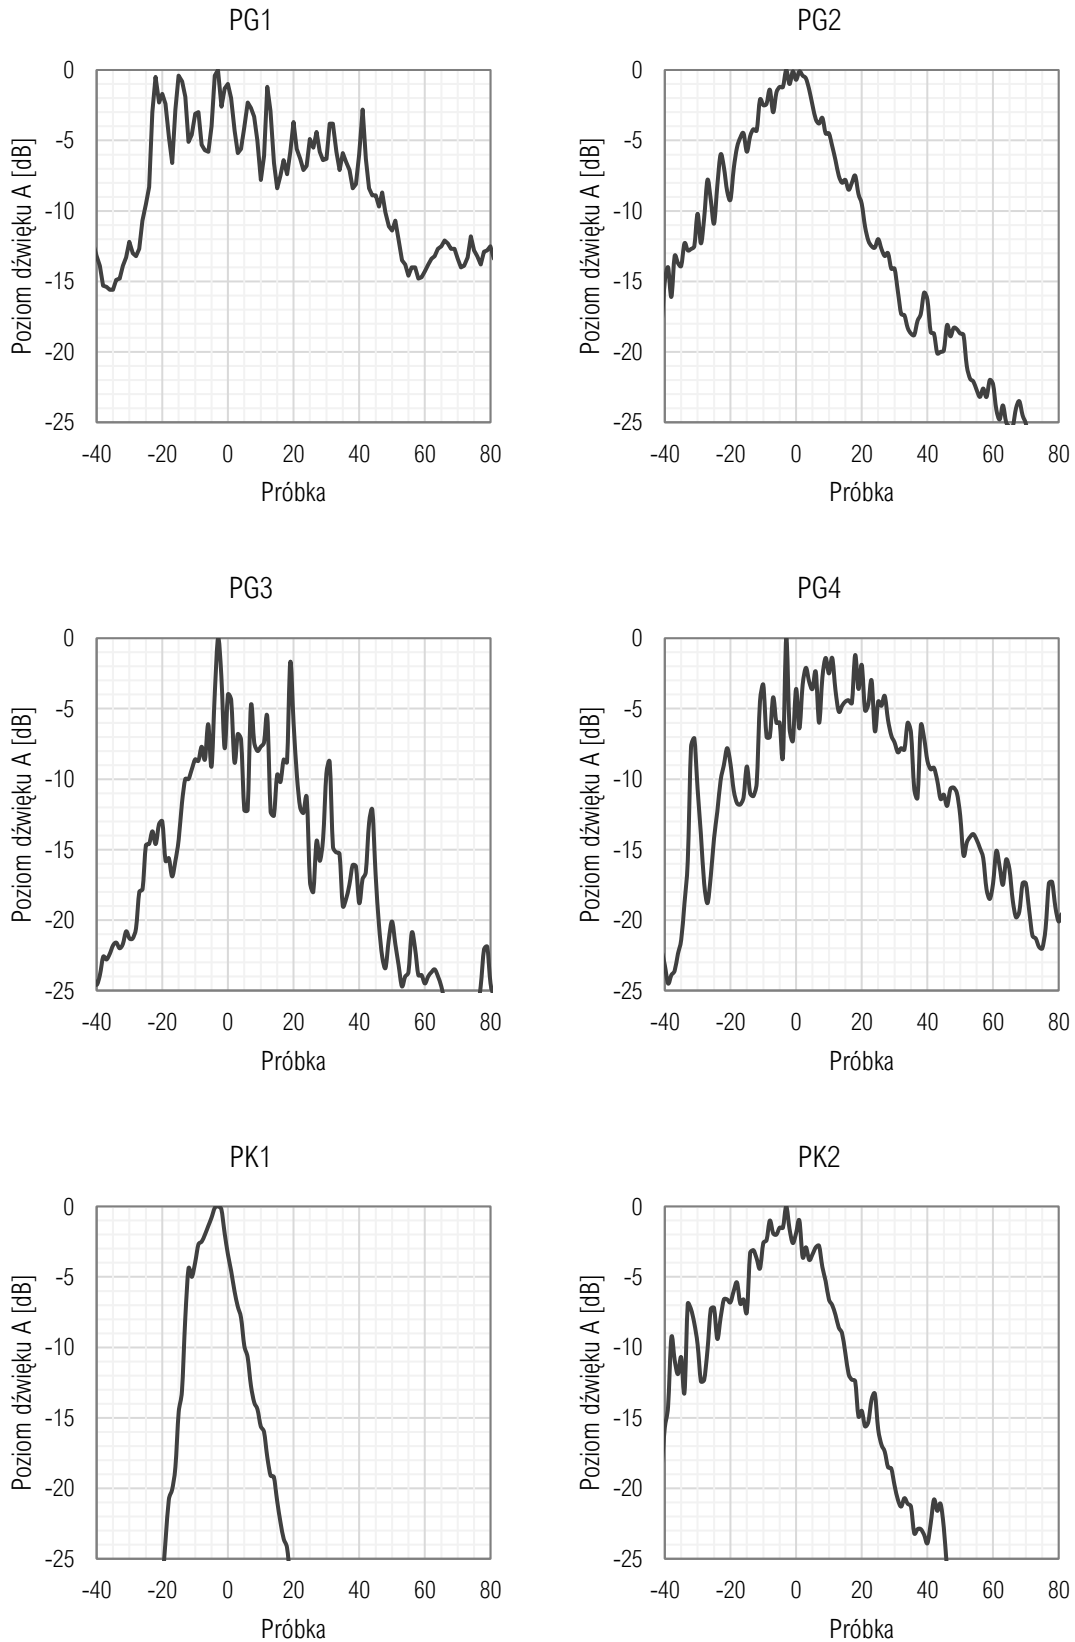
⁵ W niniejszej pracy posłużono się konwencją nazewnictwa typów statków powietrznych na podstawie DOC 8643 ICAO [64]. Bardziej szczegółowe dane dotyczące typów statków powietrznych nie były dostępne w pozyskanych od Zarządzających lotniskami danych.



Rys. 4.19 Analiza trzech widm 1/3-oktawowych zarejestrowanych w punkcie pomiarowym PG2 dla operacji startu turboodrzutowego samolotu pasażerskiego B738. Opracowanie własne.

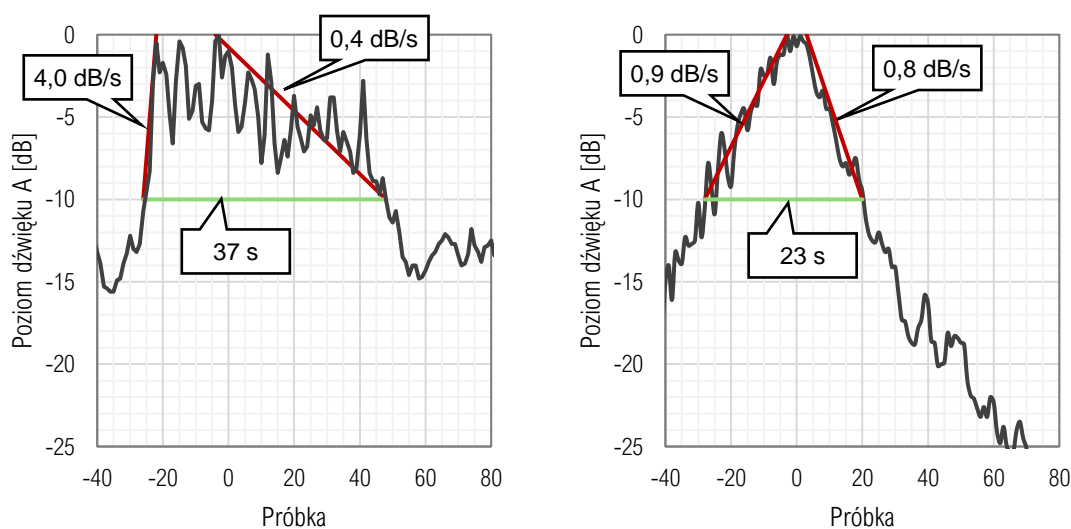
Rozrzut parametrów widmowych pomiędzy poszczególnymi realizacjami, wyrażony jako pierwiastek sumy kwadratów różnic pomiędzy maksymalną i minimalną obwiednią w poszczególnych pasmach częstotliwości, jest trzykrotnie większy w przypadku widm rejestrowanych dla tego samego typu operacji lotniczej w różnych punktach pomiarowych niż w jednym punkcie.

Równie istotne różnice zaobserwować można analizując historie czasowe poziomu dźwięku A zarejestrowane w poszczególnych punktach (Rys. 4.20).



Rys. 4.20 Zestawienie zarejestrowanych w punktach pomiarowych historii czasowych poziomu dźwięku A dla operacji startu turboodrzutowego samolotu pasażerskiego B738. Opracowanie własne.

Czasy trwania zdarzeń, określone na poziomie -10 dB, gradienty narastania i zaniku sygnału dla wybranego startu samolotu B738 w każdym z punktów pomiarowych przedstawia Tab. 4.11. Parametry zostały wyznaczone w sposób przedstawiony na Rys. 4.21 i Rys. 4.22.



Rys. 4.21 Przykład wyznaczania czasu trwania zdarzenia oraz gradientów. Opracowanie własne.

Analiza danych wykazała obecność pewnych wzorców: zbliżone wartości wyznaczonych dla punktów PK2 i PG2, korespondują z podobieństwem ich lokalizacji względem progu drogi startowej a także charakterem tła akustycznego występującego w ich otoczeniu. Ilość czynników wpływających na charakter czasowy sygnału jest jednak na tyle duża i podatna na losowe zmiany, że w przypadku pozostałych punktów trudno zaobserwować prawidłowości.


Tab. 4.11 Szerokości zdarzenia akustycznego związanego ze startem turboodrzutowego samolotu B738 w poszczególnych punktach pomiarowych. Opracowanie własne.

Punkt pomiarowy	Czas trwania zdarzenia na poziomie -10 dB [s]	Gradient narastania sygnału [dB/s]	Gradient zaniku sygnału [dB/s]
PG1	37	4,0	0,4
PG2	23	0,9	0,8
PG3	16,5	2,0	0,8
PG4	24	2,0	0,5
PK1	9,5	1,8	2,2
PK2	21	0,8	1,1

Przedstawione powyżej przykłady dotyczą jednej realizacji zdarzenia akustycznego, gdzie stały był zarówno typ operacji, typ statku powietrznego oraz próg drogi startowej w relacji do punktu pomiarowego. Wystarczy jednak zmiana jednego z tych czynników

a zarówno parametry widmowe jak i czasowe analizowanych sygnałów zmieniają się diametralnie.

Porównanie widm i historii czasowych dla turbodrzutowego samolotu B738 oraz turbośmigłowego ATR72 przedstawia Rys. 4.22. Pomędzy krzywymi widać zdecydowane różnice – w widmie ATR72 pojawiają się składowe związane z różnicą w zespole napędowym, zaś czas trwania zdarzenia jest wydłużony ze względu na mniejszą prędkość startową.



Rys. 4.22 Porównanie widm 1/3-oktawowych oraz historii czasowych poziomu dźwięku A samolotu turbodrzutowego B738 i samolotu turbośmigłowego ATR72 w punkcie pomiarowym PK1. Opracowanie własne.

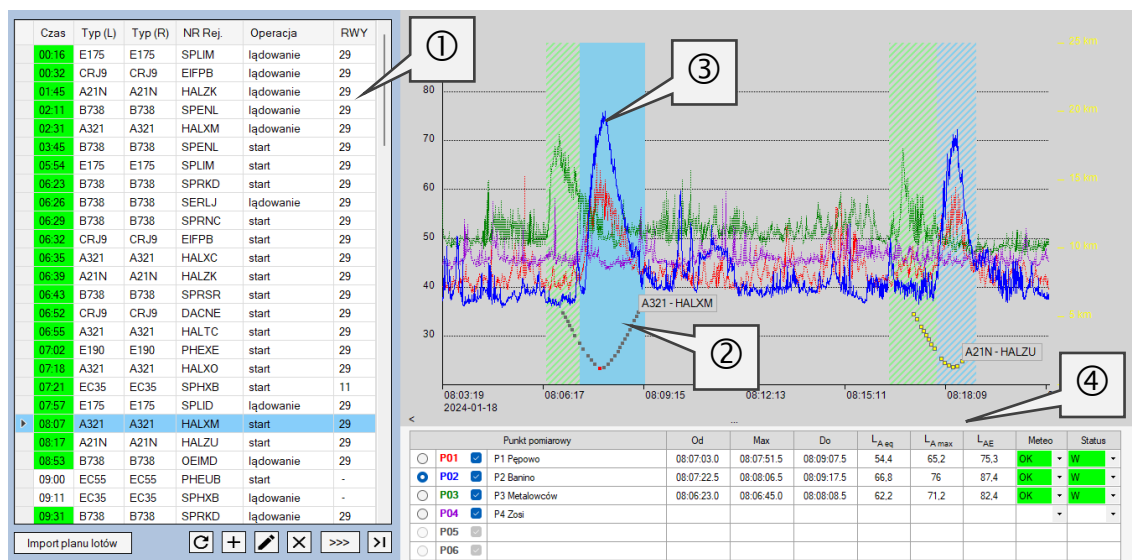
Przedstawione przykłady zdarzeń akustycznych wskazują na znaczną zmienność sygnałów, które związane są ze startami, lądowaniami i przelotami statków powietrznych różnych typów. Utrudnia to dobór zestawu takich parametrów sygnału, który w sposób uniwersalny i niewymagający pracochłonnego strojenia dla odmiennych lokalizacji punktów pomiarowych pozwoliłby na ich efektywną kategoryzację.

4.6 Manualna metoda klasyfikacji

W celu wyznaczenia odpowiednich wskaźników oceny hałasu konieczne jest wyodrębnienie z ciągłych przebiegów zdarzeń akustycznych i wyznaczenie odpowiadających im wartości wskaźników L_{AE} oraz $L_{AF,max}$ oraz przypisanie tych wartości do konkretnej operacji lotniczej, wykazanej przez lotnisko [68, 76]. Obecnie, systemy monitorujące opisane wcześniej lotniska, obsługiwane są ręcznie, przy użyciu dedykowanego oprogramowania, wspierającego ten proces.

Dokładność działania ludzkich operatorów systemu rzutować będzie na jakość danych dostępnych do dalszych analiz.

Interfejs użytkownika oprogramowania korelującego przedstawia Rys. 4.23. Punkt wyjścia w procesie korelacji stanowi wykaz operacji przekazany przez Zarządzającego lotniskiem. Wykaz ten zawiera czas wykonania operacji na płycie lotniska, jej typ (start lub lądowanie), typ statku powietrznego oraz jego znaki boczne ①. System wyznacza odległość aktualnie analizowanego statku powietrznego od aktywnego punktu pomiarowego ②, której minimum wskazuje na moment, w którym statek ten znajdował się nad punktem – jeśli dany statek powietrzny wyposażony jest w odpowiedni transponder ADS-B i informacja o jego lokalizacji jest dostępna. Zadaniem operatora jest wyodrębnienie zdarzenia akustycznego z historii czasowej poziomu dźwięku A ③, pochodzącej z danego punktu.



Rys. 4.23 Ekran korelacji zdarzeń dostępny dla operatorów.

Aplikacja wyświetla równocześnie przebiegi ze wszystkich punktów pomiarowych, rozmieszczonych wokół danego lotniska. Bazując na zależnościach czasowych pomiędzy lokalnymi maksimum przebiegów czasowych poziomu dźwięku, doświadczony operator jest w stanie z większym prawdopodobieństwem wskazać właściwe zdarzenia. Po skorelowaniu zdarzenia system wyznacza wskaźniki L_{Aeq} , L_{Amax} oraz L_{AE} ④.

4.7 Ocena jakości pozyskanych danych

Przeprowadzone na potrzeby pracy pomiary hałasu lotniczego dostarczyły ponad 4,4 GB danych w binarnym formacie *svl*, obejmujących łącznie zakres 362 dni, z których stosując manualne metody detekcji i korelacji z danymi operacyjnymi wyodrębniono 15 268

zdarzeń akustycznych odpowiadających operacjom lotniczym. Zestawienie zarejestrowanych danych, w podziale na punkty pomiarowe oraz przeznaczenie uzyskanych zbiorów, przedstawia tabela Tab. 4.12.

Tab. 4.12 Podsumowanie zarejestrowanych danych.

Punkt pomiarowy	Przeznaczenie zbioru	Czas trwania obserwacji (dni)	Ilość zdarzeń
PG1	treningowy	50	1551
PG1	walidacyjny	6	238
PG2	treningowy	50	2223
PG2	walidacyjny	6	299
PG3	treningowy	50	1730
PG3	walidacyjny	6	110
PG4	treningowy	50	1912
PG4	walidacyjny	6	306
PK1	treningowy	61	3370
PK1	walidacyjny	7	350
PK2	treningowy	61	2882
PK2	walidacyjny	7	297
	treningowy	324	13668
	walidacyjny	38	1600
	łącznie	362	15268

Zbiór walidacyjny i testowy został oddzielony już na etapie pozyskiwania danych, tak aby uniknąć fałszywych wniosków co do skuteczności algorytmu detekcji. Przyczyną takich błędów może być przypadkowe i często nieświadome połączenie danych treningowych i walidacyjnych. W efekcie, ocena skuteczności klasyfikacji prowadzona jest na znanych wcześniej danych, które rzecz jasna klasyfikowane są o wiele lepiej niż dane uprzednio nie prezentowane [7].

Kluczowym elementem, wpływającym na możliwość realizacji dalszych etapów pracy, jest ocena jakości i przydatności pozyskanych danych. Zapoznanie się z zawartymi w nich informacjami oraz potencjalnymi błędami i nieścisłościami pozwoli na odpowiednie ich przetworzenie w celu przygotowania zestawów, przeznaczonych do treningu sieci.

4.7.1 Podstawowe błędy występujące podczas obróbki danych

Wyrywkowe analizy poszczególnych próbek, przeprowadzone na początkowym etapie pracy wykazały najczęściej występujące błędy. Każdy z nich wynikać może z trywialnej pomyłki operatora, jednakże przyczyny części z nich są również systemowe.

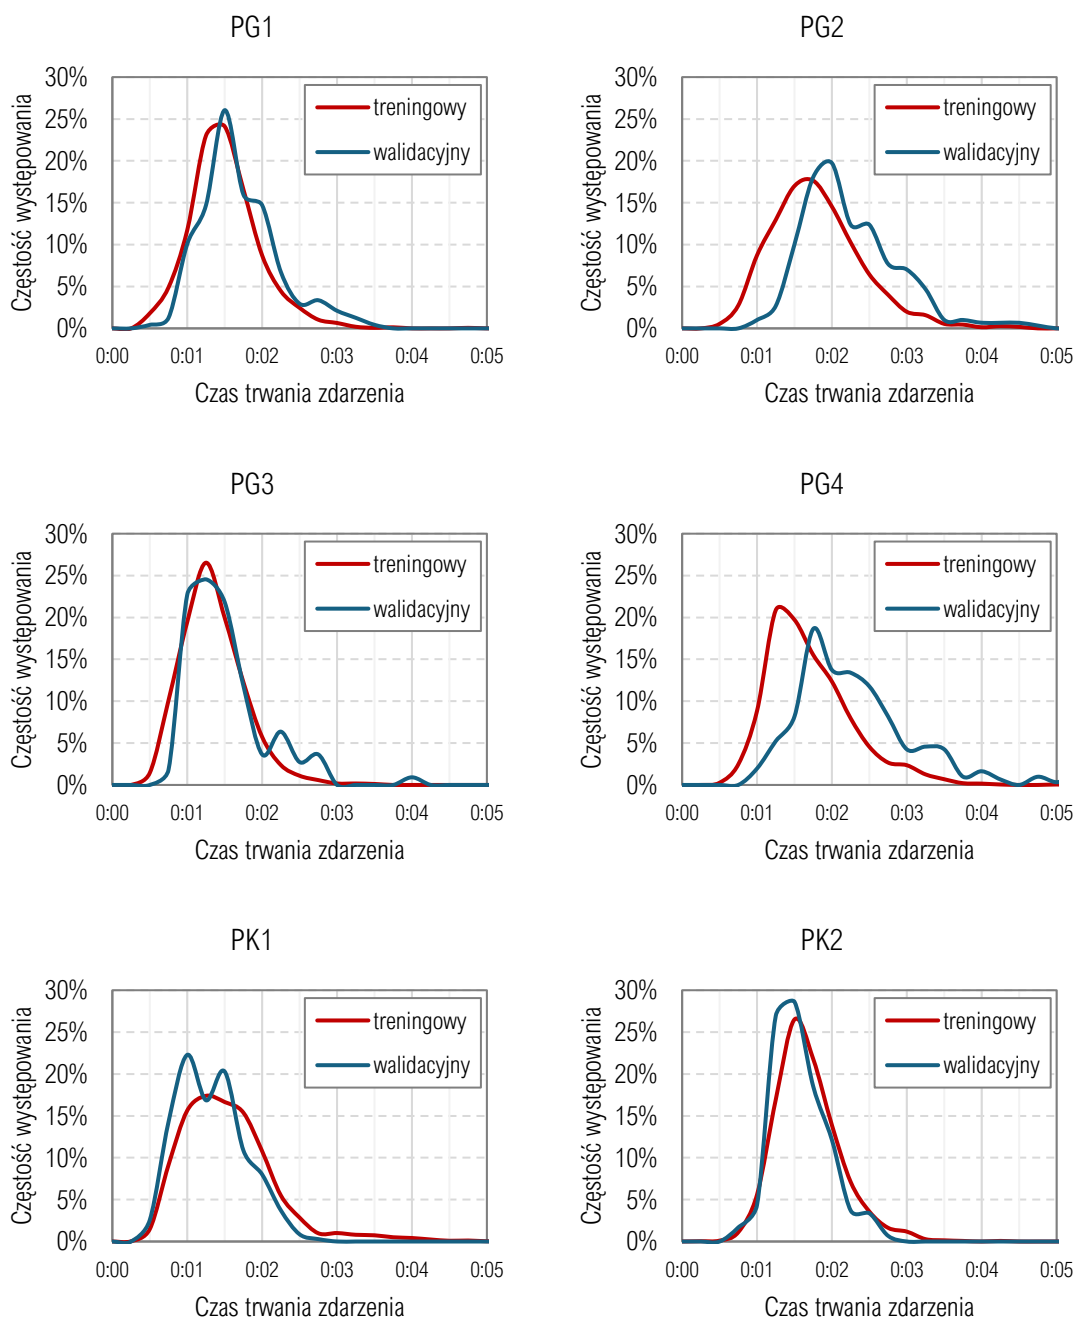
Pierwszą grupę błędów stanowiły fragmenty sygnału związane z hałasem lotniczym, niezaklasyfikowane jako taki (ang. *false negative*). Problemy tej klasy wynikać mogą z nieścisłości wykazów operacji oraz nieuwzględnienia w nich przelotów *de facto* nieobsłużonych na lotnisku. Samoloty wojskowe bądź należące do innych podmiotów (np. Polska Agencja Żeglugi Powietrznej), niejednokrotnie realizujące wielokrotne przeloty w rejonie punktów pomiarowych, pomimo emisji hałasu o pożądanej charakterystyce, nie były identyfikowane właśnie ze względu na brak ich powiązania formalnego z danym lotniskiem. Błędy tego rodzaju w zasadzie nie mogły być skorygowane. Inną przyczyną może być niepoprawna klasyfikacja w otoczeniu zaburzających percepcję operatora zdarzeń z pozostałych punktów pomiarowych. Propozycja eliminacji wpływu tego typu problemów zostanie omówiona w Rozdziale 6.1.

Zdarzenia niepoprawnie zaklasyfikowane jako hałas lotniczy (ang. *false positive*) wynikały z obecności zakłóceń akustycznych o obwiedni poziomu dźwięku A zbliżonej do obwiedni hałasu lotniczego. Te błędy występowały zazwyczaj dla przelotów mniejszych statków powietrznych, nieemitujących danych o swoim położeniu.

Zdarzenia o niepoprawnie wyznaczonym czasie rozpoczęcia lub zakończenia wynikają najczęściej z nieuwagi operatora, czasem także z chwilowego braku, uzupełnianych później danych. W takim jednak wypadku są one oznaczone w systemie jako zdarzenia zakłócone, podobnie jak zdarzenia, w trakcie których wystąpiły losowe zakłócenia akustyczne. Niekiedy jednak pojawiają się próbki, które pomimo błędów czasowych i obecności zakłóceń nie zostały oznaczone poprawnie.

4.7.2 Analiza zdarzeń w dziedzinie czasu

W ramach badania oznaczonych przez operatorów zdarzeń akustycznych przeprowadzono globalną analizę czasów trwania zdarzeń dla poszczególnych punktów pomiarowych. Częstość występowania zdarzeń o różnych czasach przedstawiono na wykresach, widocznych na Rys. 4.24. Uzyskane rozkłady wykazały różnice czasów trwania pomiędzy najkrótszymi a najdłuższymi zdarzeniami sięgające do 8 minut, co stanowi wartość dość zaskakującą. Wskazuje również na zasadność weryfikacji możliwości odrzucenia skrajnych wartości jako potencjalnie obciążonych istotnym błędem, co zostanie omówione szerzej w rozdziale 6.1.



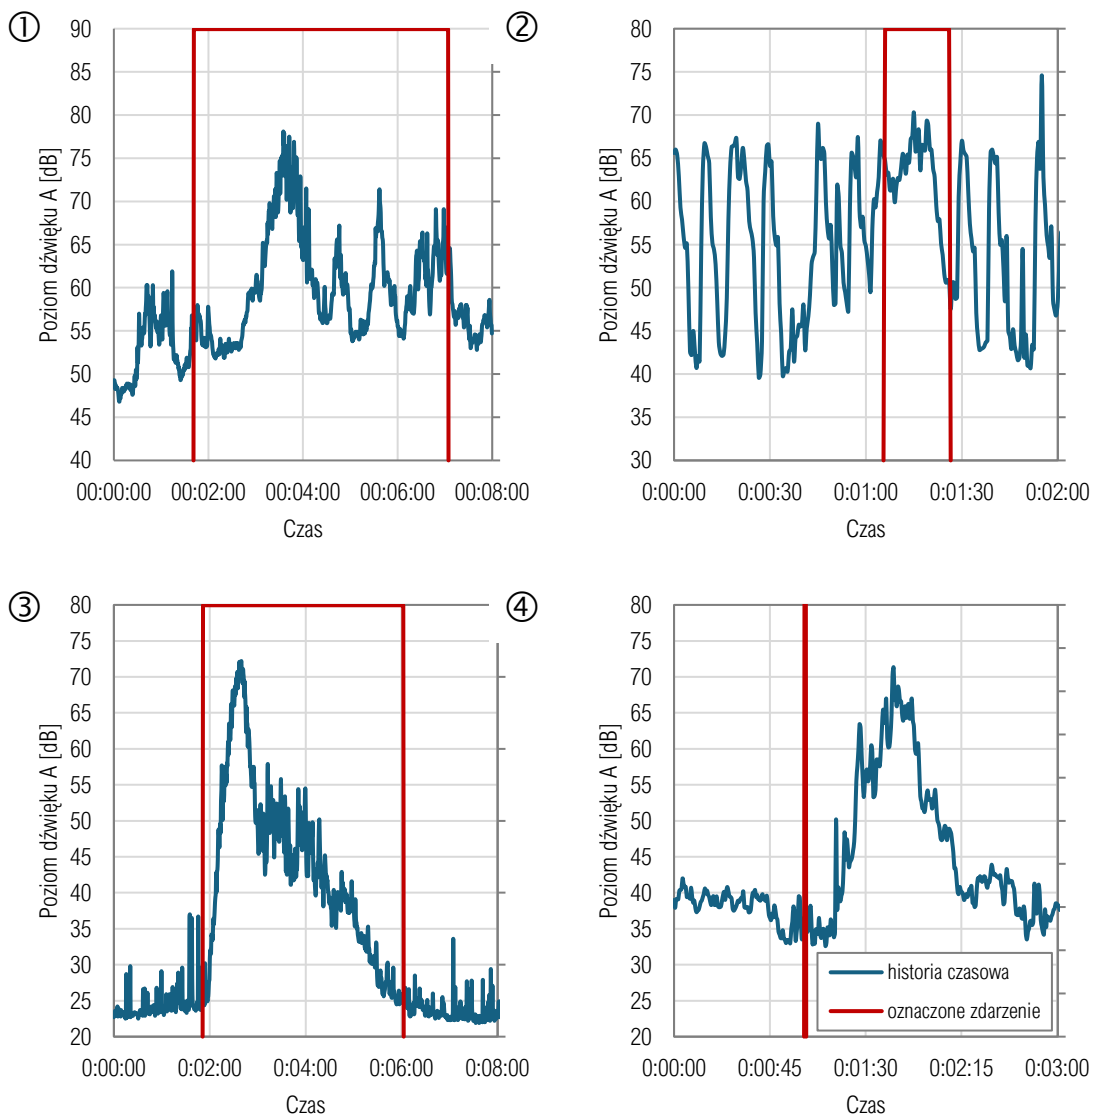
Rys. 4.24 Histogramy czasów zdarzeń akustycznych w wybranych punktach pomiarowych. Opracowanie własne.

Na Rys. 4.25 przedstawiono przykłady zdarzeń o skrajnych czasach trwania.

Czas trwania zdarzenia ①, zarejestrowanego w punkcie pomiarowym PG2 i związanego ze startem samolotu B738 wynosi 00:05:23. W bazie danych oznaczono je jako zakłócone, co najprawdopodobniej spowodowane jest późniejszym uzupełnieniem danych pomiarowych.

Trwające 00:00:20 zdarzenie ②, również zarejestrowane w punkcie PG2 i związane ze startem samolotu B738 oznaczono jako niespełniające warunków meteorologicznych ze względu na występowanie silnych podmuchów wiatru.

Zdarzenie ③, zarejestrowane w punkcie PK2 i związane ze startem samolotu B738 pomimo wyjątkowo długiego czasu trwania wynoszącego 00:04:11 jest pod każdym względem prawidłowe, w przeciwieństwie do trwającego zaledwie 1 s zdarzenia ④. Jest ono oznaczone jako poprawne i stanowi ewidentną omyłkę operatora systemu.

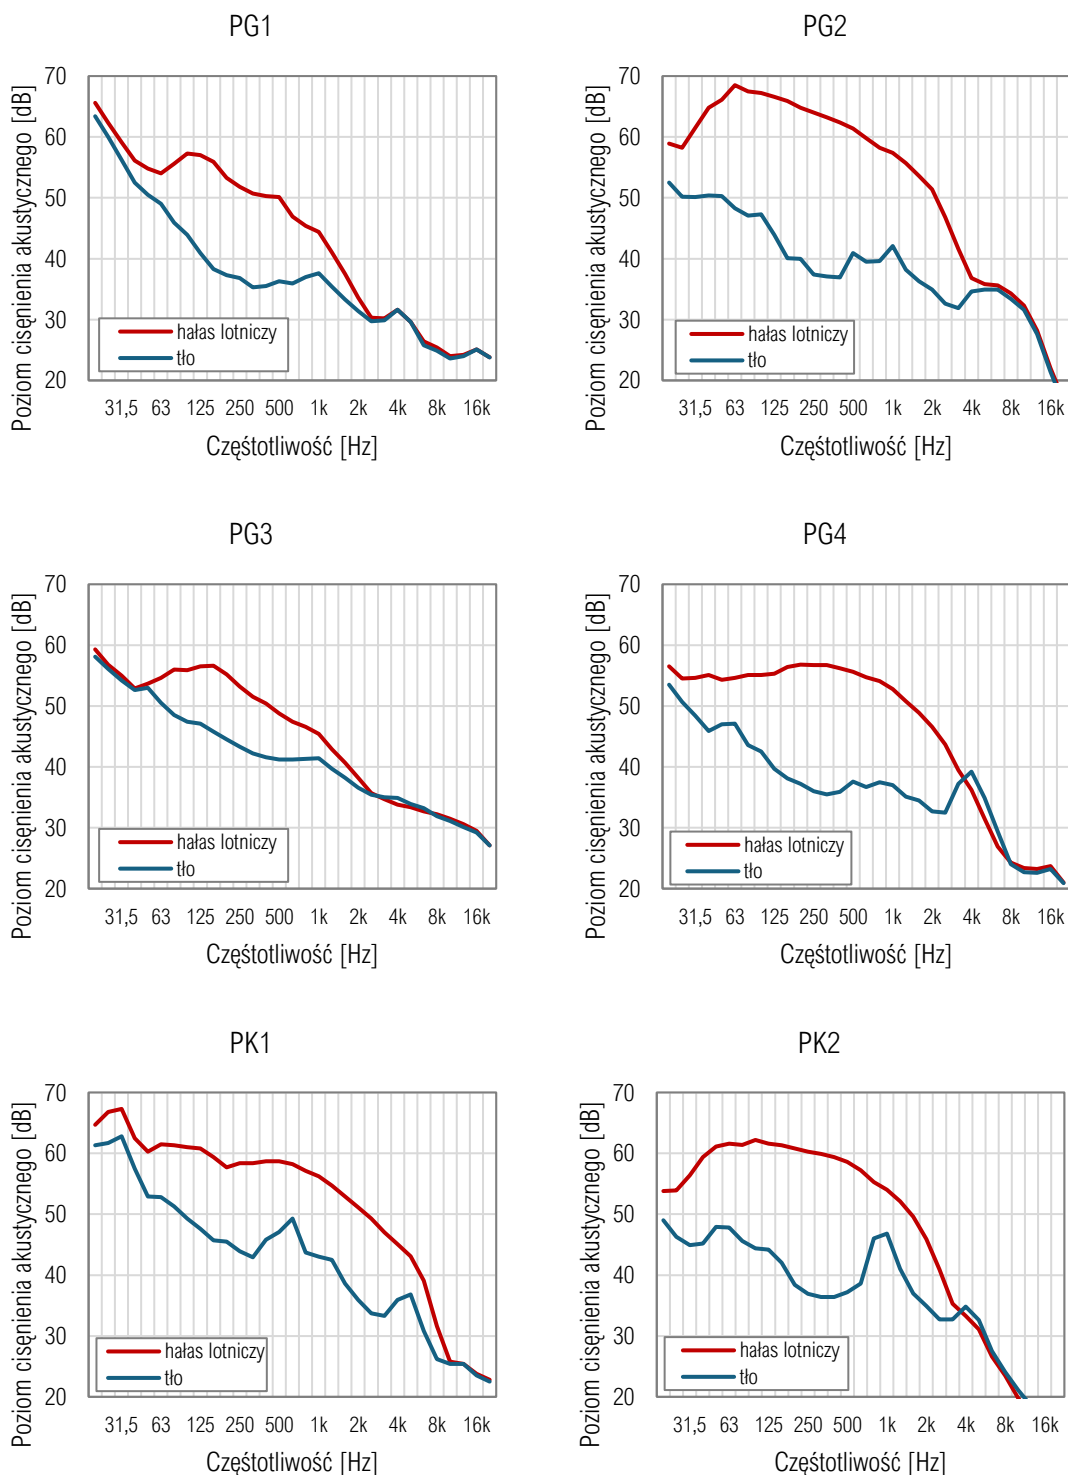


Rys. 4.25 Przykłady zdarzeń akustycznych o różnych czasach trwania, występujące w zbiorze danych wejściowych. Opracowanie własne.

W wyniku przeprowadzonych analiz powstała koncepcja filtracji pozyskanych z systemu danych, która zostanie opisana szczegółowo w rozdziale 6.1.

4.7.3 Analiza uśrednionych widm 1/3-oktawowych

Jednym z podstawowych założeń, determinujących kierunek prowadzonych badań, jest występowanie różnic w 1/3-oktawowym widmie hałasu lotniczego oraz tła akustycznego, wystarczających do odróżnienia tych dwóch zjawisk.




Rys. 4.26 Zestawienie widm hałasu lotniczego i tła akustycznego zarejestrowanych w wybranych punktach pomiarowych. Opracowanie własne.

Wstępna analiza została przeprowadzona dla wybranego 24-godzinnego fragmentu z zarejestrowanych danych. Na Rys. 4.26 zestawiono uśrednione widma ze wszystkich zidentyfikowanych przez operatorów systemu monitoringu zdarzeń, z widmami uśrednionymi dla przedziałów czasu nieoznaczonych jako hałas lotniczy.

W większości punktów pomiarowych największe różnice pomiędzy widmami przypadają na częstotliwości w zakresie 125 – 500 Hz. Jedynie w przypadku zlokalizowanego w małej odległości od progu drogi startowej punktu PK1 i jednocześnie w bezpośrednim sąsiedztwie stanowiącej źródło hałasu tła ulicy porównywalne różnice można dostrzec także w paśmie 2 kHz. Różnice pomiędzy uśrednionymi widmami w pasmach częstotliwości powyżej 4 kHz stają się nieistotne. Oznacza to, że prawdopodobnie nie niosą ze sobą istotnych dla problemu dyskryminacji przesłanek.

4.8 Podsumowanie

Wstępne analizy wykazały istnienie zauważalnych różnic pomiędzy charakterystyką widmową sygnałów związanych z hałasem lotniczym oraz pozostałego hałasu tła. Rozpatrywanie dostępnych widm 1/3-oktawowych, bez ograniczania się do szerokopasmowego poziomu dźwięku A (Rys. 4.27), wydaje się istotnie poprawiać możliwość odróżnienia interesujących zdarzeń akustycznych od pozostałych zakłóceń.



Rys. 4.27 Przykład zakłóconego zdarzenia akustycznego w postaci historii poziomu dźwięku A (po lewej) oraz spektrogramu (po prawej). Opracowanie własne.

Zależności czasowe w zakresie szerokopasmowego dźwięku A są uwarunkowane wieloma czynnikami, których identyfikacja oraz określenie wpływu na wynikowe wartości nie leży w zakresie niniejszej pracy. Można oczekiwać, że stopień komplikacji zagadnienia istotnie wzrośnie, w przypadku analizy tych zależności w pasmach częstotliwościowych.


W takiej sytuacji obiecujące rezultaty może przynieść zastosowanie sztucznych sieci neuronowych [15], które zdolność do wykrywania złożonych relacji pod warunkiem

dysponowania odpowiednią ilością danych do treningu. Dostępna baza danych skorelowanych zdarzeń akustycznych, wraz z towarzyszącymi im źródłowymi danymi w postaci widm 1/3-oktawowych liczy sobie 15268 fragmentów o przeciętnym czasie trwania między 1 a 2 minuty. Efektywność sztucznych sieci neuronowych istotnie spada, jeśli w danych treningowych występują błędy (*outliers*) [30, 33]. Biorąc pod uwagę występowanie błędów w sklasyfikowanych danych konieczne będzie utworzenie strategii ich wstępnego przetwarzania, pozwalającego na możliwie największe ograniczenie ich ilości.

Kolejne próbki, zawierających widmo akustyczne, można przedstawić w postaci, odzwierciedlającej spektrogram, dwuwymiarowej macierzy. Taka reprezentacja danych umożliwi z kolei posłużenie się jedną z bardziej zaawansowanych i aktywnie rozwijanych odmian sieci neuronowych, czyli sieć konwolucyjną (CNN) [51], o którą oparto koncepcję systemu detekcji, omówioną szczegółowo w Rozdziale 5 niniejszej pracy.

5 KONCEPCJA SYSTEMU DETEKCJI

Jednym z najbardziej podstawowych zadań, stojącym przed systemem monitoringu hałasu lotniczego jest wyodrębnienie zdarzeń akustycznych, związanych z przelotami statków powietrznych. Problem ten można sformułować jako wyznaczenie czasu rozpoczęcia i zakończenia zdarzenia akustycznego (Rys. 5.1), jeśli zdarzenie to związane jest z przelotem statku powietrznego.



Rys. 5.1 Przykład wyznaczania czasu rozpoczęcia (t_1) oraz czasu zakończenia (t_2) zdarzenia akustycznego. Opracowanie własne.

Klasyczne, dwuetapowe podejście [68] realizowane jest zazwyczaj na zasadzie klasyfikacji wyodrębnionych uprzednio zdarzeń akustycznych. Rozwijane obecnie metody korzystają przy tym z rozpoznawania wzorców [47, 39, 48] czy też technik opartych o sieci neuronowe [57]. Dane wejściowe do analiz stanowią najczęściej różnego rodzaju widma częstotliwościowe, wąskopasmowe FFT czy też mel-cepstralne MFCC, najczęściej wyznaczone w oparciu o nagrania sygnału audio towarzyszące wykrytym zdarzeniom. Mimo zróżnicowanych metod i wskaźników wydajności, opisywana w literaturze efektywność tych podejść jest na ogół wysoka, znacznie przewyższająca prostą, szerokopasmową klasyfikację [9]. Należy jednak zwrócić uwagę, że ostateczna efektywność funkcjonowania systemu zależy od algorytmu wyodrębniania zdarzeń, najczęściej działającego na zasadzie prostego przekroczenia progu wyzwolenia z dodatkiem warunków czasowych. Wyklucza to możliwość identyfikacji zdarzeń, których wartość poziomu dźwięku nie przekroczy zadanego progu.

Inne podejście wykorzystują prace dotyczące quasi-ciągłych funkcji wskazujących możliwość wystąpienia hałasu lotniczego [2, 21], łącząc zarówno detekcję zdarzeń, jak

i klasyfikację w jeden proces. Jedynym bezwzględnym ograniczeniem jest w tej sytuacji odstęp sygnału od szumu, co potencjalnie pozwala na detekcję większej ilości zdarzeń akustycznych. Metoda została zastosowana do jedno- i wielokanałowych nagrań audio. Pomimo obiecujących perspektyw, kosztowne obliczenia i duża ilość rejestrowanych danych sprawiają, że pełne jej wykorzystanie nie jest możliwe w praktyce wielopunktowych systemów ciągłego monitoringu hałasu.

Rozwój sztucznych sieci neuronowych, jaki obserwować można w ostatnich latach umożliwia wysoką dokładność klasyfikacji bez polegania na złożonych i kosztownych analizach FFT lub MFCC. Korzystając z konwolucyjnej sieci neuronowej (CNN) z dwoma warstwami, analizującej multispektra 1/3-oktawowe, Heller i in. osiągnęli znaczną dokładność klasyfikacji, wynoszącą 97% [25].

Podstawowym założeniem od początku powstawania niniejszej pracy było wykorzystanie wskaźnika identyfikacji hałasu lotniczego występowania hałasu lotniczego. Podejście to, poza swoją prostotą i elegancją, odpowiada filozofii funkcjonowania stacji monitoringu hałasu, rejestrujących parametry w kolejno następujących próbkach. Wykorzystanie konwolucyjnej bądź rekurencyjnej sieci neuronowej, operującej na 1/3-oktawowych widmach częstotliwościowych stanowiło naturalną konsekwencję dostępnych danych i technologii w kontekście tendencji obserwowanych w pracach badawczych, dotyczących omawianego zagadnienia.

5.1 Zestawienie klasycznej i neuronowej metody detekcji

Przedstawione w rozdziale 4 rozważania dotyczące trudności w efektywnym zastosowaniu klasycznych sposobów detekcji zdarzeń akustycznych zostały zweryfikowane poprzez porównanie skuteczności działania opisanej przez Osses Vecchi metody opartej o analizę zmienności historii czasowej poziomu dźwięku [41] oraz testowanej na lotnisku Minneapolis St. Paul International Airport, opartej o konwolucyjną sieć neuronową, metody klasyfikacji wykrytych prostym algorytmem zdarzeń akustycznych [25].

Przeprowadzone na początkowym etapie testy umożliwiły jednocześnie zapoznanie się z językiem *Python* oraz biblioteką *TensorFlow*. Na potrzeby badania stworzona została aplikacja z interfejsem umożliwiającym wczytanie i wyświetlenie danych akustycznych, a także wyświetlenie i eksport wykrytych przy użyciu wybranych metod zdarzeń

akustycznych. Badanie obejmowało dane zarejestrowane przez okres miesiąca i zawierające 1138 zdarzeń związanych z przelotem statku powietrznego.

5.1.1 Metoda I – wieloprogowa

Metoda wieloprogowa oparta jest o badanie zmienności przebiegu historii czasowej poziomu dźwięku A, przy użyciu ilorazu różnicowego, określonego formułą (5.1).

$$V_a = \frac{a(t) - a(t - h)}{h} \quad (5.1)$$

gdzie:

$a(t)$ wartość próbki sygnału w chwili t

h ilość próbek, dla której określana jest różnica


Wyznaczony przebieg jest następnie wygładzany przy użyciu filtra dolnoprzepustowego pierwszego rzędu:

$$y_n = \alpha x_{n-1} + (1 - \alpha)y_{n-1} \quad (5.2)$$

Początek i koniec zdarzenia akustycznego, zdefiniowanego jako wzrost poziomu dźwięku ponad stabilne tło akustyczne, wyznaczany jest następnie w oparciu o zestaw trzech progów T_h , T_{L1} , T_{L2} , o wartościach dobranych empirycznie do charakterystyki rejestrowanego sygnału. Ilustracja funkcjonowania algorytmu została przedstawiona w formie zrzutu ekranu z opracowanej aplikacji (Rys. 5.2).


Metoda zakłada, że zdarzenie wykryte na podstawie tak sformułowanych kryteriów związane jest z przelotem statku powietrznego. Przeprowadzone testy wykazały, że założenie to w określonych warunkach jest poprawne i pozwala na odróżnienie zdarzeń lotniczych od pozostałych, które cechują się zazwyczaj odmiennymi gradientami narastania i zaniku.

Bardziej szczegółowe analizy wskazują jednak na istotne ograniczenia w zastosowaniu takiego algorytmu. Na dokładność wyznaczania charakterystycznych punktów zdarzenia wpływa odstęp od tła akustycznego – metoda daje gorsze wyniki przy sygnałach o małej dynamice. Wartości progowe są odpowiednie dla stabilnej sytuacji akustycznej (próg drogi startowej, typ operacji lotniczej, trasa). Modyfikacja tych parametrów powoduje zmianę charakterystyki czasowej sygnału. Wartości progów powinny być korygowane po każdej modyfikacji.



Rys. 5.2 Fragment interfejsu użytkownika aplikacji testowej.

Dokładniej weryfikując istnienie zależności pomiędzy gradientami narastania i zaniku dla dużej liczby zdarzeń (Rys. 5.3) można dostrzec różnice w rozkładach tych parametrów pomiędzy poszczególnymi punktami pomiarowymi, co wyjaśnia pogorszenie skuteczności detekcji.



Rys. 5.3 Analiza gradientów narastania i zaniku dla zbioru treningowego na przykładzie lotniska EPGD. Opracowanie własne.


Dokładność detekcji spada także w obecności sygnałów zakłócających o zbliżonej charakterystyce czasowej, takich jak przejazdy samochodów ciężarowych.

5.1.2 Metoda II – CNN

Podejście opisane przez Hellera i in. [25] wymaga dwóch etapów przetwarzania sygnału. W pierwszym etapie algorytm identyfikuje wszystkie zdarzenia akustyczne, określone jako fragmenty sygnału, dla których wartość poziomu dźwięku A przekroczyła ustaloną wartość progową T_1 oraz nie spada poniżej wartości progu T_2 przez czas większy niż τ . W opisanej przez autorów wersji wartości progów T_1 i T_2 wynosiły odpowiednio: 65 dB i 63 dB zaś kryterium czasu trwania zdarzenia ustalono na 8 s.

W kolejnym etapie analizy zdarzenia takie, w formie znormalizowanych czasowo i amplitudowo spektrogramów, z towarzyszącą informacją o rzeczywistym czasie trwania zdarzenia, były klasyfikowane przez konwolucyjną sieć neuronową, wytrenowaną na około 2000 zdarzeń akustycznych.

Na potrzeby eksperymentu wykorzystana została aplikacja testowa (Rys. 5.2), w której zrealizowano badanie metod detekcji zdarzeń. Zapisane multispektra wykorzystano do przeprowadzenia treningu i oceny jakości działania sieci neuronowej, bazując na kodzie źródłowym udostępnionym przez autorów [25]. Poniższy wykres przedstawia rezultat treningu sieci dla danych zawierających 1138 zdarzeń hałasu lotniczego oraz około 1000 zdarzeń zakłócających.



Rys. 5.4 Wyniki treningu sieci CNN [25] na własnych danych wejściowych.

Wyniki uzyskane podczas treningu sieci (Rys. 5.3) wykazały bardzo wysoką dokładność klasyfikacji dla wykrytych zdarzeń. Konsekwencją proponowanego dwuetapowego

podejścia jest brak możliwości prawidłowej klasyfikacji operacji lotniczych, niespełniających założonych kryteriów zdarzenia akustycznego. W przypadku zastosowania tej techniki do obróbki danych z punktów monitoringowych usytuowanych zgodnie z normą ISO 20906 nie stanowi to istotnego problemu. Można jednak dostrzec potencjalne trudności w przypadku prób uogólnienia algorytmu dla potrzeb klasyfikacji innych źródeł hałasu, których charakter nie wiąże się z występowaniem tak charakterystycznych maksimów lokalnych.

5.1.3 Porównanie metod

Wyniki detekcji, przeprowadzonej obiema metodami na opisanych wyżej danych testowych, odniesiono do rezultatów uzyskanych na drodze manualnej korelacji, przedstawionej w Rozdziale 4.6. Liczba zdarzeń hałasu lotniczego wykrytych metodą manualną wynosiła 1138, zaś skumulowana ekspozycja na hałas (opisana formułą 2.8) – 112,6 dB. W przypadku metody wieloproęgowej przetestowano kilka różnych zestawów wartości progowych, spośród których zaprezentowane zostały trzy, zapewniające najlepsze rezultaty detekcji. Parametry etapu wstępnego wykrywania zdarzeń dla metody CNN zostały również zmodyfikowane tak, aby dostosować je do charakteru zarejestrowanego sygnału.

Dla każdego wariantu zestawiono wynikową precyzję, czułość oraz wartość wskaźnika F_1 . Ponadto odniesiono się do przedstawionych w normie ISO 20906 kryteriów: bezwzględnej wartości różnicy skumulowanych ekspozycji ΔL , względem metody manualnej, oraz różnicy w liczbie wykrytych zdarzeń Δn . Wyniki porównania przedstawia tabela Tab. 5.1.

Tab. 5.1 Porównanie jakości detekcji dla dwóch badanych metod.

Metoda	Precyzja	Czułość	F_1	$ \Delta L $ [dB]	$ \Delta n $
wieloproęgowa [0.25, -0.19, -0.13]	65%	60%	0.62	0,2	8%
wieloproęgowa [0.22, -0.16, -0.11]	47%	75%	0.58	1,6	59%
wieloproęgowa [0.25, -0.17, -0.13]	62%	62%	0.62	0,3	1%
CNN	97%	91%	0.94	0,4	5%

Analiza została przeprowadzona na dość wczesnym etapie pracy, stąd zastosowanie najprostszych wskaźników oceny jakości klasyfikacji. Ponadto wyniki dla sieci CNN mogą być nieco zawyżone ze względu na przeprowadzenie testu na potencjalnie znanych sieci próbkach.

Wyniki porównania są dość intrygujące i wymagają komentarza. Normowe kryterium dopuszczalnej różnicy poziomów (3 dB) skumulowanych zostało spełnione we wszystkich przypadkach. Różnica liczby wykrytych zdarzeń przekracza kryteria normowe jedynie w przypadku drugiego zestawu parametrów wieloprogowej metody detekcji. Wartości wskaźnika F_1 nie są już tak optymistyczne i nie przekraczają 0.62, co wskazuje na bardzo małą dokładność. Oznacza to, że algorytm klasyfikował zdarzenia zakłócające jako lotnicze a ich liczba i poziom ekspozycji są przypadkowo zbliżone z wartościami odniesienia. W przypadku metody konwolucyjnej wartość F_1 wynosi 0.94, co wskazuje na bardzo wysoką jakość klasyfikatora. Normowe kryteria ΔL i Δn również zostały spełnione.

Metoda wieloprogowa, pozbawiona informacji widmowych dostępnych dla sieci neuronowej a także możliwości automatycznej adaptacji progów w zależności od parametrów sygnału wejściowego, wykazała zdecydowanie gorszą zdolność do klasyfikacji hałasu lotniczego o zmiennych parametrach. Wyniki wstępnego eksperymentu pozwalają zakładać, że zastosowanie konwolucyjnej sieci neuronowej pozwoli na stworzenie efektywnego algorytmu klasyfikacji hałasu lotniczego, dysponującego potencjałem do uogólnienia na inne źródła hałasu.


5.2 Kluczowe założenia

Podstawowym celem projektu opisywanego w ramach niniejszej pracy jest uzyskanie gotowego do wdrożenia w infrastrukturze informatycznej firmy SVANTEK algorytmu, realizującego proces detekcji zdarzeń akustycznych związanych z wykonywaniem operacji lotniczych, rejestrowanych przez przyrządy pomiarowe produkowane przez firmę. Koncepcja, rozwijana w ramach niniejszej pracy, oparta jest o połączenie quasi-ciągłego wskaźnika identyfikacji hałasu lotniczego uzyskiwanej na podstawie klasyfikacji kolejnych ramek o stałej długości przez sieć neuronową, operującą na danych spektralnych o rozdzielczości 1/3 oktawy, rejestrowanych przez urządzenia pomiarowe z rozdzielczością czasową 500 ms.

Przyjęta we wstępnych założeniach rozdzielczość czasowa wynika z ustalonego, wewnętrznego standardu rejestracji sygnału, który zaadaptowany został z metodyk pomiarowych dotyczących certyfikacji akustycznej statków powietrznych [69]. Modyfikacja rozdzielczości czasowej z pewnością wpływa na skuteczność detekcji, w przypadku korzystania z rozwiązań opartych o sieci neuronowe [54]. Zweryfikowanie tego czynnika byłoby naturalnym krokiem w pracy badawczej, jednakże ze względu na względy praktyczne tu musiał zostać pominięty. Zmiana konfiguracji przyrządów pomiarowych w żywym systemie monitoringu niesie ze sobą poważne konsekwencje dla pozostałych elementów systemu i – ze względu na poczynione niegdyś założenia projektowe – prowadzi do znacznego zwiększenia nakładu pracy w codziennej eksploatacji. Z uwagi na opisane konsekwencje podjęto decyzję o przyjęciu stałej wartości tego parametru, ze świadomością, że wszelkie jego modyfikacje, szczególnie przy próbach uogólnienia wyników dla źródeł hałasu o odmiennych charakterystykach czasowych, mogą istotnie wpłynąć na możliwości detekcji.

Dostępne stacje monitoringu są w stanie dokonywać analizy w pasmach 1/3 oktawowych w czasie rzeczywistym a jej wyniki zapisywać bezpośrednio do plików binarnych, pobieranych następnie przez sieć komórkową. Przedstawione w Rozdziale 4.7 porównanie średniego widma tercjowego sygnału hałasu lotniczego oraz pozostałych sygnałów, umownie nazywanych tłem akustycznym, już na etapie koncepcji rozwiązania daje podstawy, by przypuszczać, że właśnie widmo stanowić będzie źródło danych wystarczające do skutecznej dyskryminacji. Ze względu na możliwości aparatury pomiarowej oraz ograniczenia transmisji i przechowywania danych bardziej złożone analizy nie były rozpatrywane. Ich zastosowanie wymaga obecnie rejestracji i transmisji plików audio w formacie *wave*, bądź też modyfikacji oprogramowania wewnętrznego przyrządów, co z kolei wiąże się z szeregiem konsekwencji, zarówno ekonomicznych jak i formalnych.

Wstępna koncepcja sposobu funkcjonowania algorytmu, przedstawiona na Rys. 5.5, zakłada, że będzie możliwe wyznaczenie takiego wskaźnika identyfikacji hałasu lotniczego, że w oparciu o analizę jego przebiegu możliwe będzie precyzyjne wyznaczenie początku i końca zdarzenia akustycznego związanego z operacją statku powietrznego, w dziedzinie poziomu dźwięku A, który to poziom stanowi podstawę do wyznaczenia opisanych w Rozdziale 2.1 wskaźników oceny hałasu.



Rys. 5.5 Oczekiwany sposób funkcjonowania algorytmu detekcji hałasu lotniczego. Opracowanie własne.

Powyższe podejście, odróżniające proponowaną koncepcję zastosowania sieci neuronowej od opisanej przez Hellera i in. [25], w założeniu pozwolić powinno na wykrycie zdarzeń o małych czasach trwania, zdarzeń o małej wartości maksymalnej poziomu dźwięku A, a także na potencjalne zastosowanie metody do klasyfikacji innych od lotniczych źródeł hałasu.

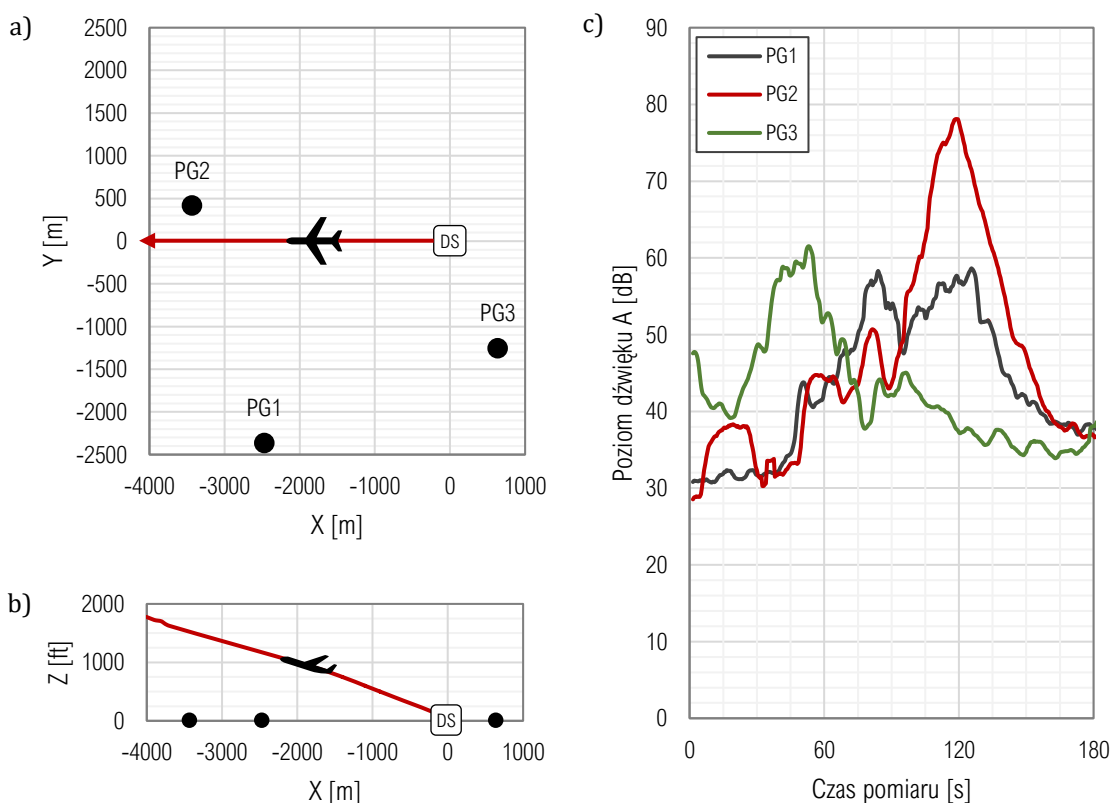
5.3 Architektura algorytmu przetwarzania

5.3.1 Wstępna koncepcja

Początkowe założenia przyjęte w pracy [9] opierały się na próbie wykorzystania do detekcji sygnału hałasu lotniczego zarówno danych zawartych w widmie poziomu ciśnienia akustycznego, rejestrowanego w poszczególnych punktach pomiarowych w obrębie jednego lotniska, jak również informacji przejawiającej się w relacjach czasów wystąpienia zdarzenia w tych punktach. Proponowana architektura, w założeniu, pozwalać miała na uwzględnienie w samym procesie detekcji sygnału hałasu lotniczego rejestrowanego w punkcie R_i wyników rejestrowanych w punktach $R_{k \neq i}$, pracujących w ramach sieci stacji monitoringowych zlokalizowanych w sąsiedztwie danego portu lotniczego.

Przykład takiej relacji czasowej przedstawia Rys. 5.6. W zobrazowanej sytuacji hałas pochodzący od operacji startu zaobserwować można początkowo w punkcie PG3 – sygnał związany jest z kołowaniem oraz rozpoczęciem rozbiegu ze startowym ciągiem silników. Następnie emitowany hałas pojawia się w zlokalizowanym w odległości

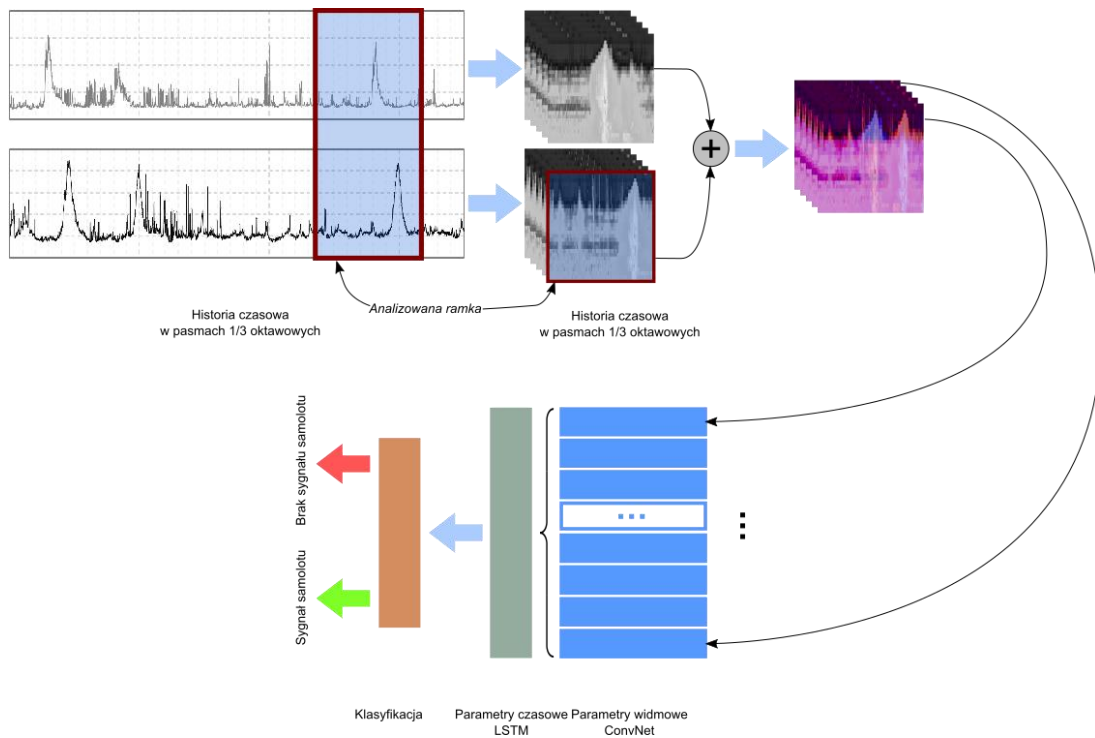
1 252 m punkcie PG1. 36 sekund później obserwujemy maksimum emisji hałasu w punkcie PG2. Po kolejnych 4 sekundach odnajdujemy drugie lokalne maksimum poziomu hałasu w punkcie PG1, co związane jest z kierunkowością zespołów napędowych.



Rys. 5.6 Trasa startu (a) oraz jego profil wysokościowy (b) i odpowiadające jej zdarzenia akustyczne rejestrowane w poszczególnych punktach pomiarowych (c). Opracowanie własne.

Obserwowane zależności będą rzecz jasna w pewnych granicach zmienne, co wynika ze zróżnicowanych prędkości startowych V_2 , wahających się w przedziale od 55 węzłów (dla małych samolotów turbośmigłowych) do 170 węzłów (w przypadku samolotów o napędzie turboodrzutowym) [55].

Proponowany sposób funkcjonowania algorytmu przedstawiono schematycznie na Rys. 5.7. Dane wejściowe w postaci multispektrów rejestrowanych przez stacje monitoringu hałasu są przetwarzane do postaci trójwymiarowych macierzy (ramek), o wymiarach $T \times B \times R$, gdzie T jest założonym czasem trwania okna analizy, zaś B ilością wektorów danych akustycznych (31 pasm tercjowych + wektor L_{Aeq}), a R stanowi liczbę punktów monitoringowych uwzględnionych w analizie. Punkt pomiarowy, dla którego prowadzona jest detekcja będzie znajdować się zawsze w pierwszej warstwie ramki.



Rys. 5.7 Pierwotna wersja architektury systemu detekcji. Opracowanie własne.

Ze zbioru wybierane są z ustalonym krokiem kolejne ramki podstawowe, dla których tworzone jest okno analizy. Czas trwania okna jest zależny od konkretnego lotniska; przewidywana długość nie będzie przekraczała 5 minut.

Każda z ramek okna analizowana jest przez sieć konwolucyjną, której wstępna architektura, oparta została o koncepcję sieci rezydualnej [24]. Sieci konwolucyjne pozwalają na uzyskanie bardzo obiecujących rezultatów przy zadaniu rozpoznawania i klasyfikacji obrazów [22]; w taki właśnie sposób interpretować można widmowe ramki danych akustycznych. W przedstawionej architekturze przewidziano podstawowe mechanizmy przeciwdziałające zjawisku *overfittingu*, czyli nadmiernego dopasowania modelu do danych treningowych: redukcję przesunięcia współzmiennego (ang. *covariate shift*) poprzez zastosowanie warstw *batch normalization* [28] oraz *dropout* [52]. Inne mechanizmy będą wdrażane w zależności od potrzeb wraz z testami modelu.

W celu wykorzystania zależności czasowych z rejestrowanych sygnałów w drugim kroku zastosowano sieć rekurencyjną RNN, realizowaną przez warstwę *Long-Short Term Memory* (LSTM) [26], zakończoną warstwą decyzyjną. Tego typu architektury są z powodzeniem wykorzystywane są przy rozwiązywaniu problemów łączących dane czasowe i przestrzenne, takie jak analiza wielokanałowych sygnałów EEG [4].

Przyjęte w koncepcji założenia, choć obiecujące, okazały się być trudne do realizacji w praktyce. Podstawowy problem stanowiła dostępność danych z wielopunktowych systemów monitoringu: tylko jedno z obsługiwanych lotnisk posiadało punkty pomiarowe zdolne do zapewnienia wymaganych danych. W połączeniu ze znaczącym spadkiem ruchu lotniczego, który wystąpił w związku z ograniczeniami wprowadzonymi po wybuchu pandemii COVID-19 istniało ryzyko, że nie uda się zgromadzić wystarczającej do efektywnego treningu, walidacji oraz kalibracji trenowanych sieci neuronowych ilości danych treningowych. Doprowadziło to do konieczności znacznego uproszczenia koncepcji, polegającego na odstąpieniu od drugiego stopnia przetwarzania a zatem od rozpatrywania zależności czasowych pomiędzy danymi rejestrowanymi na poszczególnych punktach pomiarowych przy użyciu sieci rekurencyjnej. Wraz ze wzrostem ruchu lotniczego oraz wynikającą z niego rozbudową systemów monitoringowych pojawi się prawdopodobnie możliwość powrotu do oryginalnych założeń w późniejszych badaniach.

5.3.2 Zrewidowana koncepcja

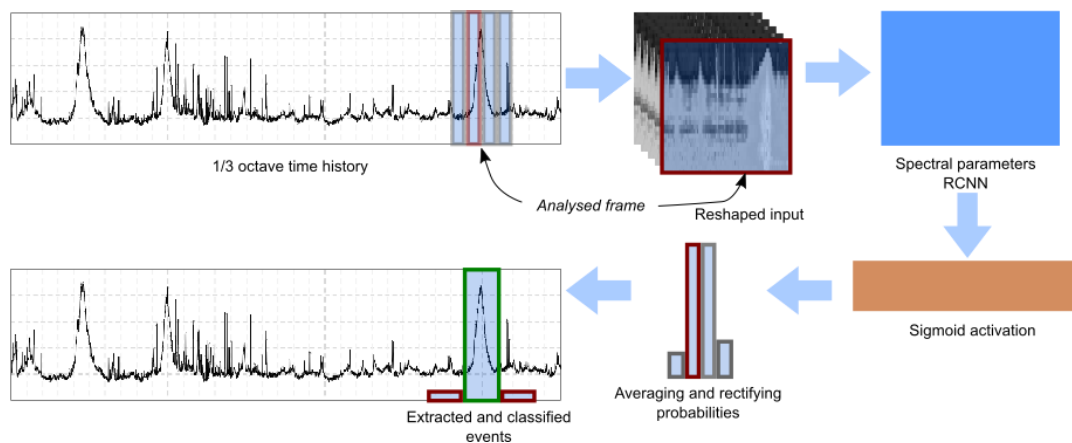
Konieczność uproszczenia założeń, dotycząca drugiego stopnia przetwarzania, nie wpłynęła istotnie na założenia dotyczące sposobu funkcjonowania sieci analizującej widma poziomu ciśnienia akustycznego. Po wstępnych rozważaniach i testach zostały one jednak istotnie doprecyzowane, także w zakresie planowanych badań.

Na proponowaną koncepcję procesu detekcji i klasyfikacji (Rys. 5.8) składają się następujące etapy przetwarzania. Początkowo wejściowe widma 1/3-oktawowe, rejestrowane z krokiem 500 ms, dzielone są na nakładające się ramki, w formie macierzy o wymiarach $T \times S$, gdzie T stanowi długość ramki w próbkach, zaś S ilość wektorów akustycznych danych widmowych wraz z dodatkowym wektorem szerokopasmowego poziomu dźwięku A , analogicznie do wstępnej propozycji.

Tak przygotowane ramki wejściowe są następnie klasyfikowane przy użyciu sieci neuronowej, której wyjście interpretowane jest jako nieskalibrowana miara, opisująca występowanie sygnału lotniczego w danej ramce. Dostępne dla sieci dane wejściowe stanowią w istocie serie czasowe. Najbardziej zaawansowanym i wysoce efektywnym narzędziem do ich klasyfikacji są obecnie rekurencyjne sieci neuronowe [13] typu LSTM lub GRU. Jak wynika z poprzednio omówionych prac, w przypadku multispektrów, które można przedstawić także w formie spektrogramu, bardzo dobre wyniki przy mniejszym

koszcie obliczeniowym zapewniają także sieci konwolucyjne, przewidywane do zastosowania w pierwotnej koncepcji algorytmu. Te dwie klasy rozwiązań zostaną zweryfikowane w trakcie badań.

Efektom klasyfikacji poszczególnych ramek jest tablica nakładających się wartości wskaźnika identyfikacji hałasu lotniczego o wymiarach $N \times T$, gdzie N stanowi ilość próbek sygnału wejściowego, zaś T odpowiada długości ramki. Tablica jest następnie uśredniana w wymiarze T , co pozwala na uzyskanie pojedynczego wektora \mathbf{u} o długości N , zawierającego uśrednione wartości wskaźnika oceny hałasu lotniczego.



Rys. 5.8 Docelowa wersja architektury systemu detekcji. Opracowanie własne.

Uzyskany wektor wartości wskaźnika identyfikacji \mathbf{u} , zawierających się w przedziale $\langle 0; 1 \rangle$ jest następnie interpretowany za pomocą wartości progowej t , w taki sposób, że wartościom $p \geq t$ przypisywana jest wartość 1, zaś wartościom $p < t$ – wartość 0. Otrzymane wartości odpowiadają obecności lub brakowi sygnału hałasu lotniczego w konkretnej próbie danych wejściowych.

Zaproponowane podejście kryje w sobie potencjalny kompromis dotyczący długości ramki (T). Kompromis dotyczy najlepszej wartości T , która równoważy dwie kluczowe kwestie: rozdzielczość czasową i dokładność klasyfikacji pojedynczej ramki.

Z jednej strony, zastosowanie ramki o mniejszej długości może poprawić rozdzielczość czasową metody. Oznacza to, że nawet krótkotrwałe zdarzenia hałasu lotniczego mogą być wykrywane z większą precyzją. Jednakże, mniejsza wartość T skutkuje mniejszą liczbą punktów danych dostępnych dla klasyfikatora neuronowego, co potencjalnie prowadzić może do obniżonej dokładności klasyfikacji.

Weryfikacja efektywności działania algorytmu dla różnych wartości T stanowić będzie jedno z kluczowych badań przeprowadzonych w ramach niniejszej pracy.

6 BADANIE MOŻLIWOŚCI KONWOLUCYJNYCH SIECI NEURONOWYCH W ZAKRESIE KLASYFIKACJI HAŁASU LOTNICZEGO

Niniejszy rozdział zawiera opis przygotowania i przebiegu eksperymentów, mających celu zweryfikować możliwości sieci neuronowych, w celu realizacji założonego zadania. Przeprowadzono dwa eksperymenty, składające się z szeregu etapów, w ramach których przeprowadzono trening i ocenę skuteczności działania 300 modeli sieci neuronowych. Badania przeprowadzone w ramach eksperymentu 1 miały na celu wybór najlepszej spośród sześciu wytypowanych strategii przygotowania danych wejściowych do treningu konwolucyjnej sieci neuronowej w wariacie bazowym. W eksperymencie 2, mającym na celu wytypowanie najbardziej skutecznej architektury sieci, badaniu podlegało sześć wariantów architektury sieci konwolucyjnej, z których pięć opartych było o koncepcję sieci rezydualnej.

Opisane niżej eksperymenty mają strukturę zbliżoną do metody *Grid Search* [14]. Jednakże ze względu na zachowanie pełnej kontroli nad procesem badawczym nie zdecydowano się za zastosowanie gotowych rozwiązań ją implementujących, zamiast tego realizując proces treningu i wyboru zestawu wstępnie przyjętych jako najbardziej istotne hiperparametrów, na które składały się: długość ramki w dziedzinie czasu, poziom filtracji danych oraz architektura sieci, w sposób bezpośredni. Rozwiązanie to zwiększyło czas przeprowadzenia badań oraz analizy ich wyników, pozwalając jednak na dogłębne zapoznanie się z ograniczeniami trenowanych modeli sieci neuronowych.

6.1 Środowisko testowe

Proces treningu sieci neuronowej polega na wielokrotnej aktualizacji wag poszczególnych neuronów, co samo w sobie stanowi bardzo prostą operację matematyczną, jednak ze względu na ilość aktualizowanych przy każdym przebiegu wag, sięgającą w przypadku niektórych z badanych modeli setek tysięcy, wymaga znacznych mocy obliczeniowych. Aby uniknąć konieczności zakupu wysokiej klasy stacji roboczej, wyposażonej w dedykowany układ GPU, wielokrotnie przyspieszający prowadzenie obliczeń, zdecydowano się na wykorzystanie środowiska *Colab PRO*, korzystającego z bibliotek *Keras* i *TensorFlow* oraz języka *Python*. Środowisko *Colab* wykorzystuje strukturę Jupyter Notebook, pozwalającą na łączenie fragmentów sformatowanego

tekstu, kodu języka Python oraz efektów jego działania w postaci tekstowej lub graficznej.

W eksperymencie 1 wykorzystano dostępny sprzętowy akcelerator TPU v2, co pozwoliło na osiągnięcie średniego czasu treningu modelu, wynoszącego 4 min 8 sek. W eksperymencie 2, w którym trenowane były bardziej złożone sieci o większej ilości wag, czasy treningu sięgały 50 minut. Po zmianie akceleratora sprzętowego na T4 GPU średni czas treningu zredukowano do 15 min 32 s. Łączny czas treningu sieci w ramach dwóch omawianych w niniejszym rozdziale eksperymentów wyniósł 39 h 56 min 18 s.


Skrypt treningowy korzystał z danych testowych, w formie umieszczonych na wirtualnym dysku *Google Drive* plików *npy*, zawierających przygotowane uprzednio próbki wejściowe, stanowiące macierze biblioteki *Numpy*. Pliki te zostały uprzednio przygotowane przy użyciu zewnętrznej stacji roboczej, wyposażonej w 64 GB pamięci RAM. Pliki wejściowe utworzone zostały przy pomocy skryptów *generate_frames.py* oraz *generate_pure_frames.py*. Szczegółowy opis sposobu przetwarzania akustycznych danych wejściowych przedstawiono w Rozdziale 6.2.

Aby umożliwić wygodną analizę rezultatów treningu sieci, skrypt treningowy zapisywał wytrenowane modele w strukturze katalogów, na której kolejne poziomy składały się: (1) numer eksperymentu, (2) wariant danych treningowych i architektura sieci, (3) kolejna runda treningu. Dla każdej rundy zapisywane były: wagi modelu, parametry eksperymentu, historia treningu (w formie źródłowej i graficznej) oraz wyniki testów (w formie źródłowej i graficznej). Dodatkowo w katalogu eksperymentu tworzony był plik tekstowy, w którym dla każdej rundy treningu zapisywane były podstawowe dane identyfikacyjne (architektura sieci, wariant danych treningowych i numer rundy) oraz wyniki testu sieci, w postaci wartości parametrów: dokładności (*accuracy*), wskaźnika F_1 , powierzchni pod krzywą ROC (*Receiver Operating Characteristic*) oraz powierzchni pod krzywą PR (*Precision-Recall*).

6.2 Przygotowanie zbiorów danych treningowych i walidacyjnych

Konsekwencją przyjętej w pracy koncepcji klasyfikacji kolejnych fragmentów sygnału akustycznego jest konieczność przetworzenia zarejestrowanych przez stacje monitoringu hałasu danych w postaci widm 1/3 oktaowych, rejestrowanych z krokiem 500 ms do postaci ramek. Aby umożliwić trening i testy sieci, każdej z tych ramek przypisano jedną

z dwóch klas: 1 – zawiera sygnał hałasu lotniczego (klasa pozytywna) oraz 0 – nie zawiera sygnału hałasu lotniczego (klasa negatywna).



Rys. 6.1 Przykład ramki przedstawionej w formie spektrogramu 1/3-oktawowego przedstawiający a) sygnał klasy negatywnej, b) sygnał klasy pozytywnej. Opracowanie własne.


Skrypt generujący wybierał fragment zarejestrowanej historii czasowej o zadanej długości. Następnie weryfikował, czy część lub całość tego fragmentu przypada na zakres czasu, odpowiadający zidentyfikowanemu w systemie monitoringu lotniczemu zdarzeniu akustycznemu. Ramka zapisywana była w tablicy odpowiedniej klasy a okno analizy przesuwane było o 30 próbek (15 sekund). Kroki były powtarzane do momentu wyczerpania próbek w zbiorze danych.

Rozważając sposób funkcjonowania splotowych sieci neuronowych w połączeniu z charakterystyką dostępnych danych sformułowano trzy robocze hipotezy:

1. wraz ze wzrostem długości ramki wzrośnie jakość predykcji;
2. ze względu na uśrednianie wyników predykcji mniejsze długości mogą dać ostatecznie lepsze rezultaty;
3. zbyt duża długość ramki ograniczy zbiór dostępnych danych.

Aby dokonać weryfikacji powyższych hipotez do dalszych badań wytypowano sześć długości ramek, rozumianych jako czas trwania okna analizy: 2,5 s, 5 s, 10 s, 15 s, 30 s oraz 45 s. Najmniejsza wartość wynika z konieczności zapewnienia wystarczających danych do przeprowadzenia operacji splotu, realizowanej przez sieć. Największa wartość odpowiada w przybliżeniu średniemu czasowi trwania zdarzenia akustycznego, a dalszy

wzrost długości okna analizy istotnie redukował reprezentację klasy pozytywnej w wynikowym zbiorze danych. Liczebność uzyskanych dla poszczególnych długości ramek zbiorów danych przedstawia Rys. 6.2.



Rys. 6.2 Liczba ramek poszczególnych klas dla treningowego zbioru danych.


Z pewnością jednym z pierwszych spostrzeżeń dotyczących powyższego wykresu może być zdecydowana nadreprezentacja klasy negatywnej 0. W istocie, udział próbek klasy 1 w uzyskanych zbiorach waha się od 4,6% dla ramki 2,5 s do 2,6% dla ramki 45 s. Trening sieci na tak silnie niezbalansowanych danych może dawać trudne do interpretacji rezultaty. Ograniczenie tego efektu jest możliwe poprzez augmentację, czyli zwiększenie liczebności klasy pozytywnej, poprzez wygenerowanie dodatkowych przykładów w oparciu o istniejące dane i zestaw reguł, odpowiadający charakterystyce danych, bądź też podpróbki, stanowiące w istocie losowe, bądź oparte na określonych regułach odrzucenie nadmiarowych przykładów z klasy negatywnej. Stosowane obecnie metody augmentacji spektrogramów, takie jak *SpecAugment* opisane przez Parka [43], nie były rozpatrywane w toku niniejszej pracy przede wszystkim ze względu na ze względu na wystarczającą ilość oryginalnych danych, zarejestrowanych na potrzeby niniejszych badań. Strategie podpróbki zostały szczegółowo opisane w dalszej części niniejszego rozdziału.

Jakość danych wejściowych stanowi istotny czynnik wpływający na trening sieci neuronowej. Jeżeli zbiory treningowy lub walidacyjny zawierają błędnie sklasyfikowane próbki, to dokładność predykcji wytrenowanego modelu pogarsza się [33, 30]. Wpływ błędnych danych wejściowych wzrasta wraz z ich liczebnością w zbiorze danych

treningowych i walidacyjnych. Ze względu na rozmiar zbioru danych precyzyjne zidentyfikowanie błędnych próbek nie było w praktyce możliwe. Jednakże dzięki analizie danych, opisanej w Rozdziale 4.7, możliwe było sformułowanie określonych reguł ich filtracji, opisanych szczegółowo w kolejnych podrozdziałach. Zbiory danych, poddane oczyszczaniu zgodnie z kolejnymi regułami, stanowiły podstawę do badań przeprowadzonych w ramach Eksperymentu 1, opisanego w Rozdziale 6.4.

6.2.1 Problem błędów w etykietowaniu danych w otoczeniu innych zdarzeń

Pierwsza kategoria błędów, które zostały zaobserwowane w pozyskanych zbiorach, wynika z przyjętego w oprogramowaniu korelacyjnym sposobu prezentacji wyników pomiarów: nałożenia na jednym wykresie wyników ze wszystkich punktów pomiarowych w obrębie danego lotniska. Z jednej strony podejście takie pozwala operatorowi na łatwe spostrzeżenie zależności czasowych pomiędzy wynikami, z drugiej jednak może utrudniać dostrzeżenie mniej prominentnych lokalnych maksimów przebiegu historii czasowej.



Rys. 6.3 Przykład dwóch zdarzeń zachodzących w jednym czasie. Opracowanie własne.

Sytuacje takie zdarzają się w momencie, kiedy przelot nad jednym z punktów pomiarowych spowodował wysoki poziom emitowanego hałasu, na kolejnym zaś – istotnie niższy. Ilustrację dwóch zdarzeń, które wystąpiły w zbliżonym momencie przedstawia Rys. 6.4. Na widocznym przykładzie zdarzenie, które zarejestrował przyrząd pomiarowy w punkcie PG1 mogło zostać pominięte przez operatora po zidentyfikowaniu zdarzenia w punkcie PG2. Percepcję dodatkowo utrudnia historia czasowa punktu PG3.

Efektem tego błędu, który przekładał się bezpośrednio na zbiór danych było oznaczenie jako klasa negatywna fragmentu sygnału, który w istocie zawiera klasę pozytywną. Zaproponowany sposób zmniejszenia liczby błędnie klasyfikowanych ramek klasy negatywnej dla n punktów pomiarowych w obrębie jednego portu lotniczego zakłada, że podczas generacji ramek dla i -tego punktu z obróbki wykluczane są fragmenty sygnału, zawierające się w przedziale opisanym formułą 6.1, jeśli znajdujące się w nich próbki zostały przypisane do klasy negatywnej.

$$\langle t_1^{p \neq i} - 180 \text{ s}; t_2^{p \neq i} + 180 \text{ s} \rangle \quad (6.1)$$

gdzie:


- p numer punktu pomiarowego
- t_1^p czas początku dowolnego zidentyfikowanego zdarzenia akustycznego w punkcie pomiarowym p
- t_2^p czas końca dowolnego zidentyfikowanego zdarzenia akustycznego w punkcie pomiarowym p

6.2.2 Problem ramek mieszanych

Już na wczesnym etapie wstępnego przetwarzania danych wejściowych zaobserwowano występowanie ramek przejściowych, które zawierają zarówno część zidentyfikowaną jako klasa pozytywna oraz część klasy negatywnej. Rysunek 6.4 ilustruje powyższe zagadnienie, przedstawiając trzy przykładowe ramki o stałej długości 20 s: negatywną – 0, pozytywną – 1 oraz mieszaną – mix, która obejmuje fragment tła akustycznego oraz początkowy gradient narastania hałasu związanego z przelotem statku powietrznego. Podczas przygotowania danych do treningu nie sposób przypisać takiej ramce wartość odpowiadającą jednej z dwóch klas.

Aby określić możliwy wpływ sposobu uwzględnienia ramek mieszanych w zbiorze treningowym i walidacyjnym na jakość predykcji trenowanego modelu w zestawach wejściowych do eksperymentu 1 zawarto:

- zbiór, w którym wszystkie ramki przejściowe traktowane były jako negatywne,
- zbiór, w którym wszystkie ramki przejściowe traktowane były jako pozytywne,
- zbiór, w którym ramki te zostały wykluczone.




Rys. 6.4 Liczba ramek poszczególnych klas dla treningowego zbioru danych. Opracowanie własne.

Ostatni z trzech wariantów jest wstępnie typowany jako pozwalający na zapewnienie najlepszych wyników. Przypisanie próbce mieszanej *a priori* przynależność do jednej z klas zawsze wiązać się będzie z błędem, dając rezultat w postaci niewłaściwie sklasyfikowanej próbki (*outlier*). Wydaje się zatem, że zdolność konwolucyjnej sieci neuronowej do generalizacji swoich predykcji [37] pozwoli na uzyskanie lepszych wyników dla nieprezentowanych podczas treningu ramek mieszanych.

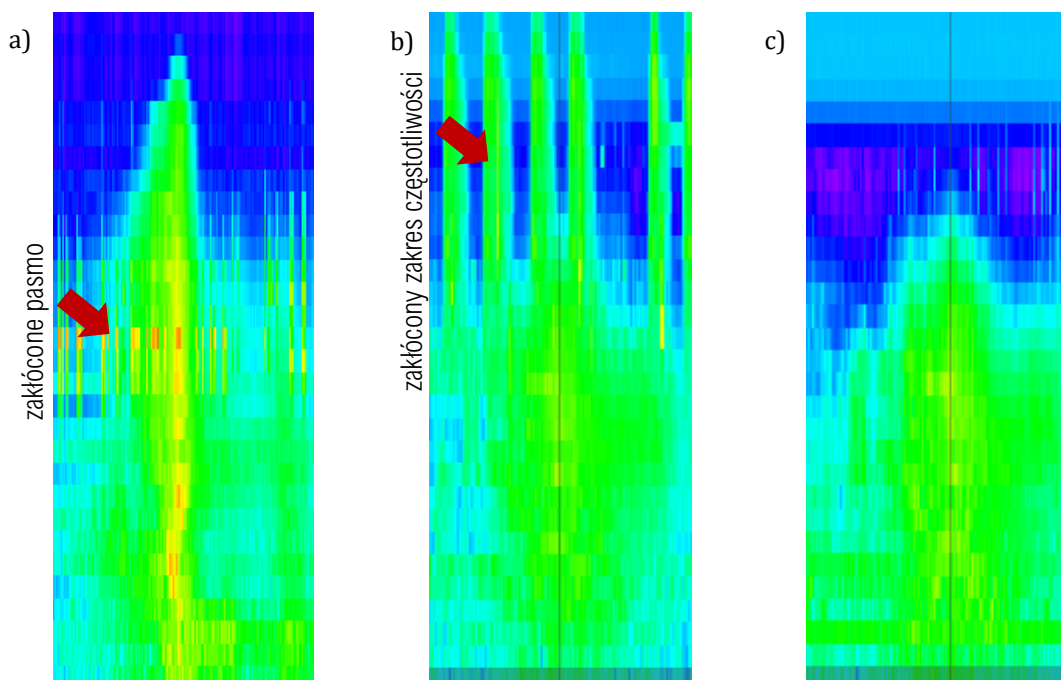
6.2.3 Problem zidentyfikowanych zakłóceń

Podczas manualnej korelacji zdarzeń akustycznych dla każdego z nich system zapisuje informację o występowaniu zakłóceń akustycznych a także o fakcie spełnienia bądź niespełnienia kryterialnych warunków meteorologicznych [76] w czasie trwania danego zdarzenia. Przykłady zdarzeń, podczas których wystąpiły losowe zakłócenia akustyczne przedstawia Rys. 6.5.



Rys. 6.5 Przykłady zakłóconych zdarzeń akustycznych, związanych z przelotami statku powietrznego. Opracowanie własne.

Niektóre z tych zakłóceń nie wpływają istotnie na charakter spektrogramu. Rys. 6.6 a) przedstawia operację startu samolotu B738, podczas którego wystąpiły wyraźne zakłócenia w zakresie szerokopasmowego poziomu dźwięku A. Można dostrzec na nim, że zakłócenie obejmuje jedno pasmo częstotliwości. Na Rys. 6.6 b) i c) widoczna jest z kolei operacja lądowania samolotu CRJ9 odpowiednio z zakłóceniami i bez zakłóceń. W tym przypadku emisja sygnału zakłócającego obejmuje wiele pasm, istotnie zaburzając charakter spektrogramu.



Rys. 6.6 Spektrograficzne reprezentacje zdarzenia a) zakłóconego, bez widocznego wpływu na charakter spektrogramu, b) zakłóconego z widocznym wpływem na charakter spektrogramu, c) niezakłóconego. Opracowanie własne.

Na etapie wstępnego przetwarzania danych nie sposób przewidzieć, czy większą korzyść z punktu widzenia jakości predykcji przyniesie prezentacja sieci bardziej zróżnicowanych danych treningowych czy też lepszym rozwiązaniem okaże się wykorzystanie jej zdolności do generalizacji już na etapie predykcji.

Kolejny etap filtracji sygnału wejściowego, przewidziany w eksperymencie 1 zakłada odrzucanie danych oznaczonych w systemie jako zakłócone oraz niespełniające kryteriów meteorologicznych. Warto zauważyć, że ten typ filtracji wpłynie na redukcję liczebności klasy pozytywnej w zbiorach treningowym i testowym, ograniczając tym samym całkowitą liczbę dostępnych do treningu próbek. Ograniczenie ilości prezentowanych podczas treningu danych może z kolei stanowić czynnik decydujący o pogorszeniu jakości predykcji [36].

6.2.4 Problem nietypowych zdarzeń

Opisana w Rozdziale 4.7.2 analiza rozkładów czasu trwania zapisanych w bazie danych systemu monitoringu hałasu wykazała, że w czterech z sześciu punktów są one zbliżone do rozkładu normalnego. W przypadku dwóch wyróżniających się punktów monitoringu (PG4 i PK2) rozkłady są zaburzone z uwagi na lokalizację punktu względem tras przelotów, co powoduje powstanie drugiego lokalnego maksimum w rozkładzie. Wskazuje to na zróżnicowanie czasu trwania zdarzeń związanych z operacjami wykonywanymi z różnych progów drogi startowej.

Analiza wykazała także, że część zdarzeń o czasach trwania z krańców rozkładu może być efektem błędów klasyfikacji. Może to w efekcie wpłynąć na pogorszenie jakości predykcji, podobnie jak w przypadku zdarzeń świadomie oznaczonych jako zakłócone. Proponowanym sposobem wykluczenia tego typu błędów jest ograniczenia uwzględnianych w zbiorach treningowym i walidacyjnym zdarzeń do tych, których czas trwania zawiera się w przedziale $\langle -\sigma_p; \sigma_p \rangle$ dla danego punktu pomiarowego, gdzie σ_p jest odchyleniem standardowym czasu trwania zdarzenia, wyznaczonym dla punktu pomiarowego p .

6.2.5 Podsumowanie

Po przeprowadzeniu analiz, ukierunkowanych na możliwość określenia sposobu filtracji danych wejściowych pozwalającej na uzyskanie największej dokładności predykcji wytrenowanej sieci, wytypowano do dalszych badań następujące zestawy:

1. brak filtracji,
2. filtracja otoczenia zdarzeń, ramkom mieszanym przypisywana klasa negatywna,
3. filtracja otoczenia zdarzeń, ramkom mieszanym przypisywana klasa pozytywna,
4. filtracja ramek przejściowych,
5. filtracja zdarzeń zakłóconych i niespełniających kryteriów meteorologicznych,
6. filtracja zdarzeń o niewłaściwym czasie trwania.

W tabelach 6.1 i 6.2 przedstawiono liczebność zbiorów treningowego i walidacyjnego, uzyskanych po kolejnych etapach filtracji. Kolorem czerwonym oznaczono warianty danych, które zawierały mniej próbek, niż wstępnie założona do treningu ilość: 100 000 dla zbioru treningowego oraz 10 000 dla zbioru walidacyjnego.

Tab. 6.1 Liczebność zbiorów danych treningowych dla poszczególnych długości ramki.

Zestaw danych	Długość ramki					
	2,5 s	5 s	10 s	15 s	30 s	45 s
zestaw 1	187274	181480	190554	199360	226080	251602
zestawy 2 i 3	176861	181375	190482	199306	226019	251503
zestaw 4	164418	159827	150813	141932	114692	88143
zestaw 5	154299	150046	141585	133319	107955	83087
zestaw 6	113428	110188	103750	97537	78299	59036


Tab. 6.2 Liczebność zbiorów danych treningowych dla poszczególnych długości ramki.

Zestaw danych	Długość ramki					
	2,5 s	5 s	10 s	15 s	30 s	45 s
zestaw 1	21288	21807	22765	23760	26704	29602
zestawy 2 i 3	21289	21801	22766	23754	26709	29601
zestaw 4	19445	19497	18376	17407	14404	11434
zestaw 5	19694	19232	18153	17204	14240	11313
zestaw 6	14784	14431	13621	12868	10603	8317

Powyższe zestawy danych zostały wykorzystane w procesie treningu sieci we wszystkich prowadzonych w ramach pracy eksperymentach. Wybrane losowo ramki zostały zapisane w plikach *.npy*, które w przypadku danych treningowych zawierały po 10 000 ramek każdy, zaś w przypadku danych walidacyjnych – po 2 500 ramek.

6.3 Badane modele konwolucyjnych sieci neuronowych


W ramach pracy przeanalizowano szereg wariantów konwolucyjnych sieci neuronowych. Badania rozpoczęto od architektury bazowej, stanowiącej jedną z najprostszych, klasycznych sieci (Rys. 6.7). Sieć o tej architekturze zastosowana została także w pracy Hellera i in. [25]. W dalszej części pracy wariant ten oznaczono jako *base_cnn*.



Rys. 6.7 Podstawowy wariant architektury konwolucyjnej sieci neuronowej.

Składa się ona z dwóch warstw konwolucyjnych. Po każdej z nich stosowana jest podpróbkująca warstwa *max pooling*. Ze względu na zbyt mały wymiar ramki 2,5 s drugi blok konwolucyjno-podpróbkujący nie mógł być wykorzystany w jej przypadku. Sieć zakończona jest klasycznym blokiem decyzyjnym, złożonych z dwóch warstw gęstych, zakończonych sigmoidalną funkcją aktywacji. Badanie tej właśnie najprostszej architektury zostało przeprowadzone w ramach Eksperymentu 1.

Eksperyment 2, którego celem była weryfikacja wpływu głębokości sieci na wyniki predykcji, obejmował poza wariantem *base_cnn* bardziej złożone architektury, wykorzystujące blok rezydualny (Rys. 6.8), opisany w pracy He i in. [24]. Blok ten wprowadzono w rozpoznającej obrazu sieci ResNet. Funkcjonuje on na zasadzie sumowania wyjścia pojedynczej warstwy konwolucyjnej z wyjściem głębszego fragmentu sieci, składającego się w przypadku stosowanych w pracy architektur z dwóch warstw konwolucyjnych, poprzedzonych warstwą *batch normalization*.



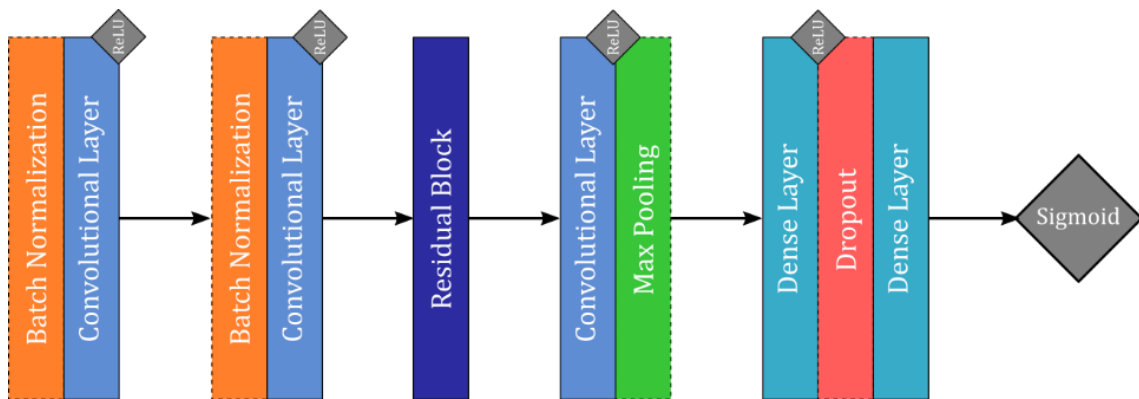
Rys. 6.8 Blok rezydualny, wykorzystany w architekturach *resnet_1*, *resnet_2* i *resnet_3*.

Badane warianty architektur stanowiły:

- Sieć bazowa, stosowana w eksperymencie 1
- Sieć z jednym blokiem rezydualnym
- Sieć z dwoma blokami rezydualnymi w trzech podwariantach, różniących się zastosowaniem warstw maksymalizujących w miejsce uśredniających oraz wielkością parametru *dropout*, pozwalającego sieci na „zapominanie” części wag
- Sieć z trzema blokami rezydualnymi

Podstawową różnicą pomiędzy badanymi sieciami jest więc przede wszystkim głębokość, czyli liczba wykorzystanych warstw konwolucyjnych.

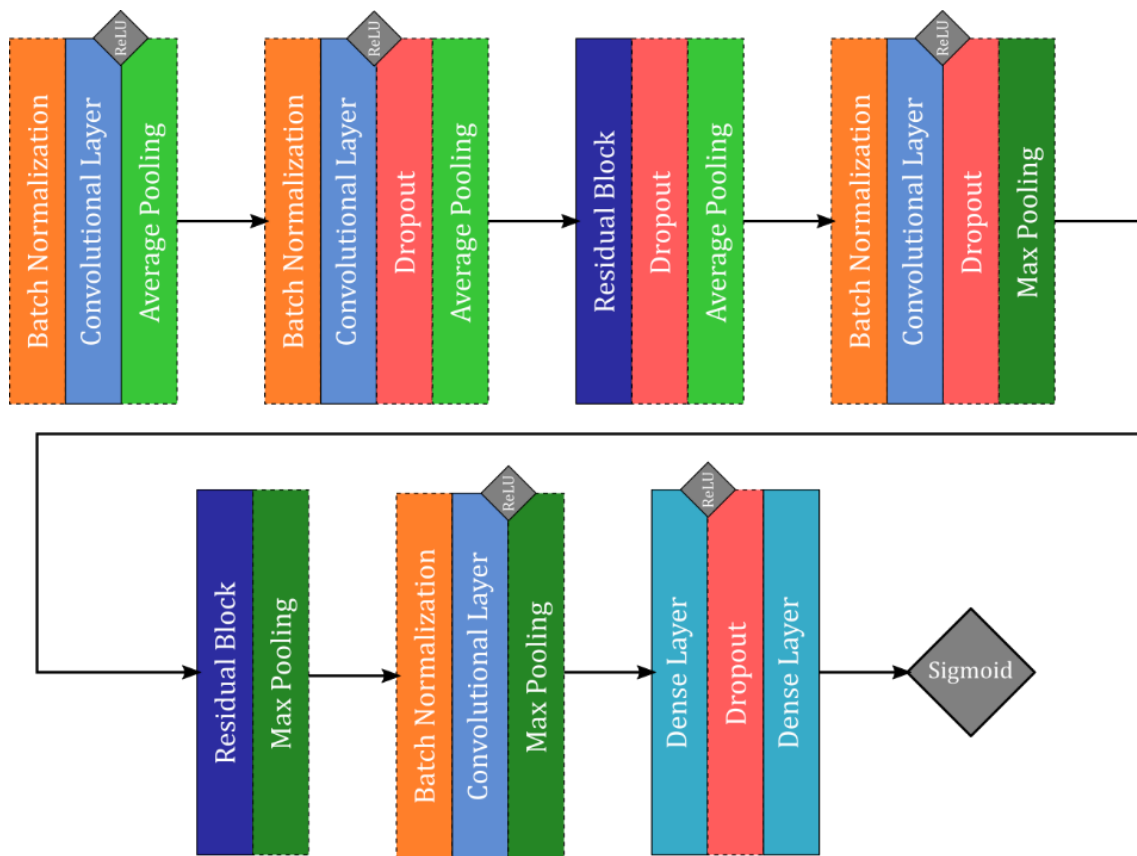
Mała, w porównaniu do tradycyjnych zastosowań sieci konwolucyjnych, rozdzielczość analizowanych spektrogramów, istotnie ogranicza możliwość zastosowania rozwiązań o dużej liczbie warstw. Niewystarczająca ilość informacji, docierająca do dalszych skutkuje zanikiem gradientu, co w efekcie zmniejsza zdolność sieci do uczenia się [27]. Na rysunkach 6.9 – 6.11 przedstawiono rozpatrywane w pracy architektury sieci rezydualnych. Pierwsza z nich, określona jako *resnet_1* (Rys. 6.9) stanowi uzupełnienie architektury bazowej o jeden blok rezydualny, oraz następującą po nim dodatkową warstwę konwolucyjną.



Rys. 6.9 Schemat sieci *resnet_1*.

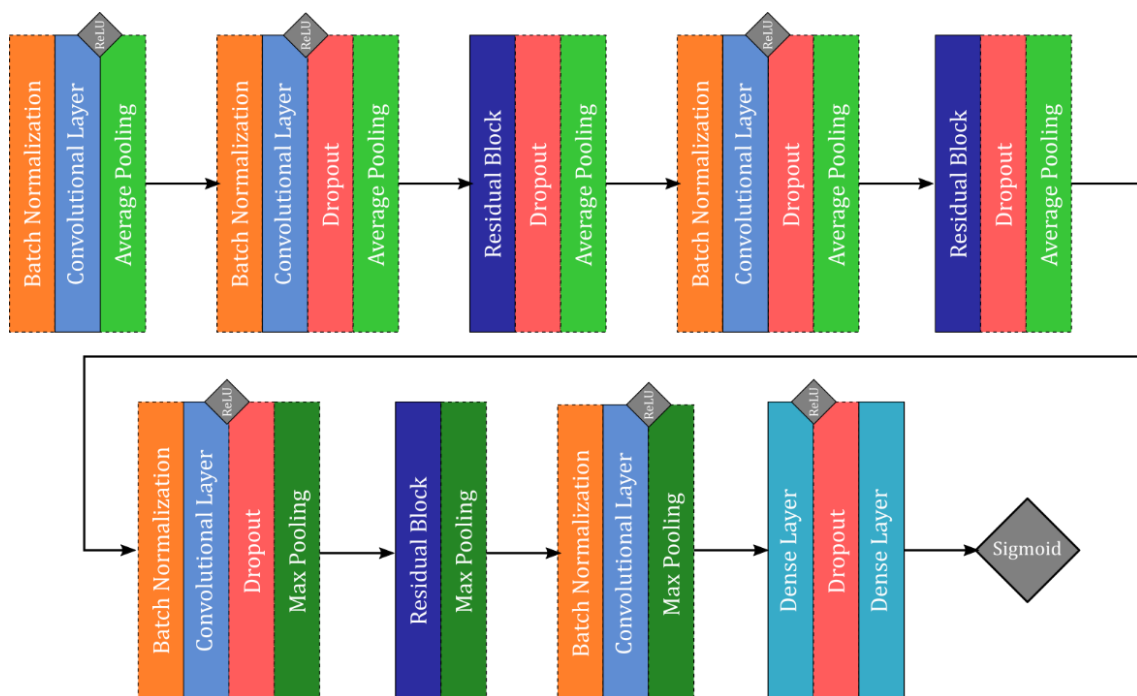
Druga z architektur, *resnet_2*, oparta jest o dwa zestawy bloków rezydualnych z warstwą konwolucyjną. Dodatkowo, w celu ograniczenia zjawiska *overfittingu*, posłużono się warstwami *dropout*. Ponieważ koncepcja sieci zakłada, że zadaniem jej jest określenie bardziej ogólnych zależności w prezentowanych danych, etap podpróbki początkowo zrealizowano przy użyciu warstwy *average pooling*.

W przeciwieństwie do najpowszechniej stosowanej w zagadnieniach identyfikacji obrazów warstwy *max pooling*, której efekt działania można opisać jako identyfikację krawędzi w analizowanych obrazach [13], warstwa *average pooling* pozwala sieci na przetwarzanie bardziej subtelnych zmian, których występowania można spodziewać się w wejściowych ramkach spektralnych. Weryfikacja tej hipotezy została przeprowadzona poprzez stworzenie wariantów sieci *resnet_2*, dalej określanych jako *resnet_2a* i *resnet_2b*. Szczegółowe wizualizacje architektury tych sieci przedstawiono w dodatku do pracy.



Rys. 6.10 Schemat sieci resnet_2.

Ostatnią z badanych sieci jest wykorzystująca trzy bloki rezydualne resnet_3 (Rys. 6.11).



Rys. 6.11 Schemat sieci resnet_3.

6.4 Eksperyment 1: wybór strategii przetwarzania danych wejściowych

Podstawowy cel opisanego w niniejszym rozdziale eksperymentu stanowiła weryfikacja strategii przetwarzania danych wejściowych do postaci ramek spektralnych. Po przygotowaniu środowiska testowego (Rozdział 6.1), zestawów danych treningowych i walidacyjnych, koniecznych do przeprowadzenia treningu sieci (Rozdział 6.2) oraz bazowej architektury sieci (Rozdział 6.3) opracowano plan eksperymentu, który pozwoliłby na możliwie najlepsze wykorzystanie posiadanych danych.

6.4.1 Założenia

Ocena jakości wytrenowanych modeli jest często dokonywana przy użyciu technik walidacji krzyżowej (ang. *cross-validation*), które zakładają wielokrotne powtarzanie treningu na zbiorach danych, które są automatycznie dzielone na części. Większa z tych części służy następnie do treningu, mniejsza zaś – do walidacji modelu, czyli oceny jego jakości predykcji po każdej epoce treningu. Założony na etapie koncepcji badań sposób przygotowania danych wejściowych niósłby w takim przypadku ryzyko wycieku danych. Z tego względu jednym z kluczowych elementów pracy był rozdział zbiorów treningowego i walidacyjnego już na etapie akwizycji (Rozdział 4.7). W konsekwencji nie było możliwym zastosowanie klasycznej walidacji krzyżowej. Aby jednak zredukować możliwy negatywny wpływ pojedynczego treningu na wyniki dalszych eksperymentów zaadaptowano procedurę k -krotnej walidacji krzyżowej (ang. *k-fold cross-validation*) do posiadanych danych.

Przyjęta w tym i dalszych eksperymentach procedura zakładała, że liczebność zbioru treningowego wynosić powinna 100 000 próbek, zaś walidacyjnego – 10 000⁶. Dla każdego treningu (technicznie określanego jako próba – *run*) spośród dostępnych plików *npy* losowano odpowiednią liczbę (10 dla zbioru treningowego, 4 dla walidacyjnego). Na Rys. 6.12 przedstawiono przykład wyboru plików do zbioru treningowego dla k prób.

⁶ Założenie to nie było możliwe do spełnienia dla każdego zbioru danych ze względu na malejącą liczbę próbek dla wariantów o dużym poziomie filtracji.

W eksperymencie 1 liczba prób została ustalona na 5, zaś liczba epok w każdej próbie na 15. Trening przeprowadzono na ramkach o długościach: 2,5 s, 5 s, 10 s, 20 s, 30 s i 45 s, przetwarzanych w wariantach 0, 1a, 1b, 2, 3, 4, opisanych w tabeli 6.3.

n=1	8	4	3	1	12	5	7	6	11	2
n=2	10	13	5	9	1	8	14	2	6	14
⋮										
n=k	3	8	4	7	9	11	2	1	10	15

Rys. 6.12 Przykład wyboru plików z danymi treningowymi. Opracowanie własne.

Łącznie, w ramach eksperymentu 1, wytrenowano 180 modeli, zaś czas trwania treningu przy użyciu opisanego wyżej środowiska przekroczył 12 godzin.

Tab. 6.3 Zestawienie wariantów danych do treningu.

Wariant	Oznaczenie
Brak filtracji	0
Filtracja otoczenia zdarzeń, ramki przejściowe – 0	1a
Filtracja otoczenia zdarzeń, ramki przejściowe – 1	1b
Filtracja ramek przejściowych	2
Filtracja zdarzeń zakłóconych	3
Filtracja zdarzeń o niewłaściwym czasie trwania	4

6.4.2 Metoda oceny jakości predykcji

Każdy z wytrenowanych modeli testowano na jednym, nie biorącym udziału w procesie treningu, pliku *npy*, pochodzącym ze zbioru danych walidacyjnych. Stanowił on zbiór testowy dla eksperymentu 1. Zawierał on 2 500 etykietowanych ramek spektralnych. W efekcie poziom filtracji danych testowych odpowiadał poziomowi filtracji danych treningowych i walidacyjnych. Podejście takie pozwoliło na ocenę jakości predykcji modelu odniesienia dla danego wariantu danych testowych a w rezultacie ocenę wpływu poziomu filtracji danych.

Bazowa architektura sieci (a także wszystkie kolejne) zakończona jest aktywacją sigmoidalną. Wynika z tego, że wyjście sieci stanowi wartość z przedziału $\langle 0; 1 \rangle$, nie zaś konkretna klasa, przypisana danej ramce. Z tego względu, w celu porównania jakości predykcji posłużono się wartościami powierzchni pod krzywymi ROC (ang. *receiver operating characteristic*) oraz PR (ang. *precision recall*).

6.4.3 Wyniki eksperymentu

Wartości powierzchni pod krzywymi ROC i PR, oznaczane zwyczajowo jako AUC(ROC) i AUR(PR) zostały uśrednione dla wszystkich prób, wytrenowanych w ramach jednego wariantu danych. Uzyskane wyniki przedstawiają tabele 6.4 i 6.5. Rezultaty zestawiono w formie wykresów na Rys. 6.13.


Tab. 6.4 Wartości powierzchni pod krzywą ROC – eksperyment 1.

Długość ramki	Wariant danych treningowych					
	0	1a	1b	2	3	4
2.5 s	0,886	0,908	0,908	0,910	0,954	0,914
5 s	0,890	0,910	0,908	0,918	0,962	0,936
10 s	0,900	0,924	0,916	0,934	0,968	0,950
20 s	0,902	0,916	0,914	0,942	0,966	0,956
30 s	0,918	0,926	0,924	0,970	0,980	0,978
45 s	0,932	0,930	0,928	0,982	0,980	0,990

Tab. 6.5 Wartości powierzchni pod krzywą PR – eksperyment 1.

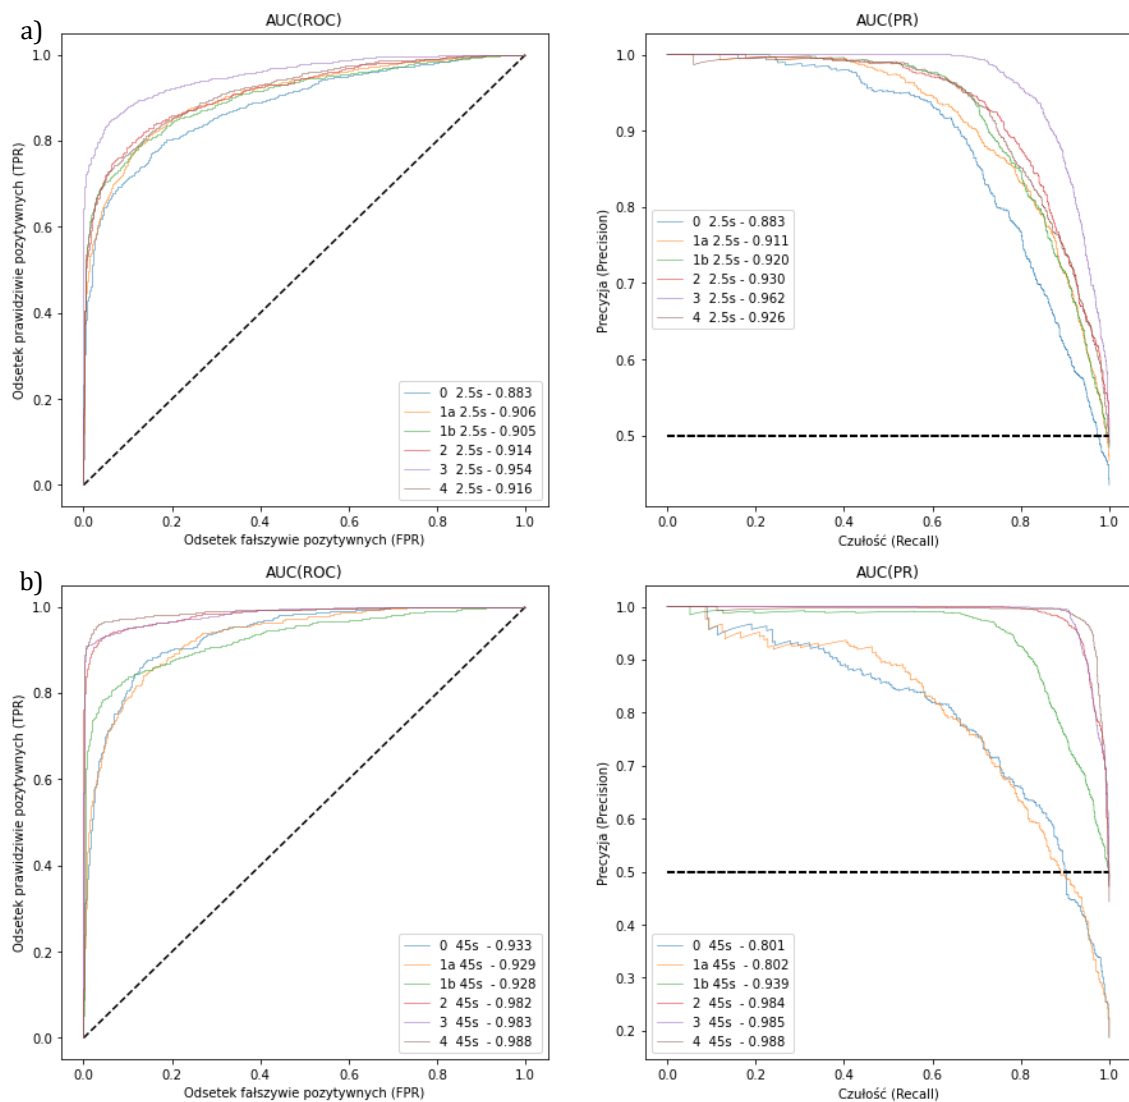
Długość ramki	Wariant danych treningowych					
	0	1a	1b	2	3	4
2.5 s	0,884	0,912	0,922	0,922	0,960	0,922
5 s	0,880	0,910	0,920	0,934	0,966	0,944
10 s	0,880	0,918	0,920	0,940	0,972	0,956
20 s	0,868	0,884	0,930	0,952	0,974	0,960
30 s	0,844	0,856	0,934	0,970	0,982	0,980
45 s	0,804	0,802	0,938	0,984	0,988	0,988

Uzyskane rezultaty wskazują na wzrost jakości predykcji przy rosnącym czasie trwania ramki dla wariantów danych 2, 3 i 4, pozbawionych ramek przejściowych. Interesującym zjawiskiem jest spadek powierzchni pod krzywą PR wraz ze wzrostem długości ramki w wariantach, w których ramki przejściowe zostały potraktowane jako negatywne.



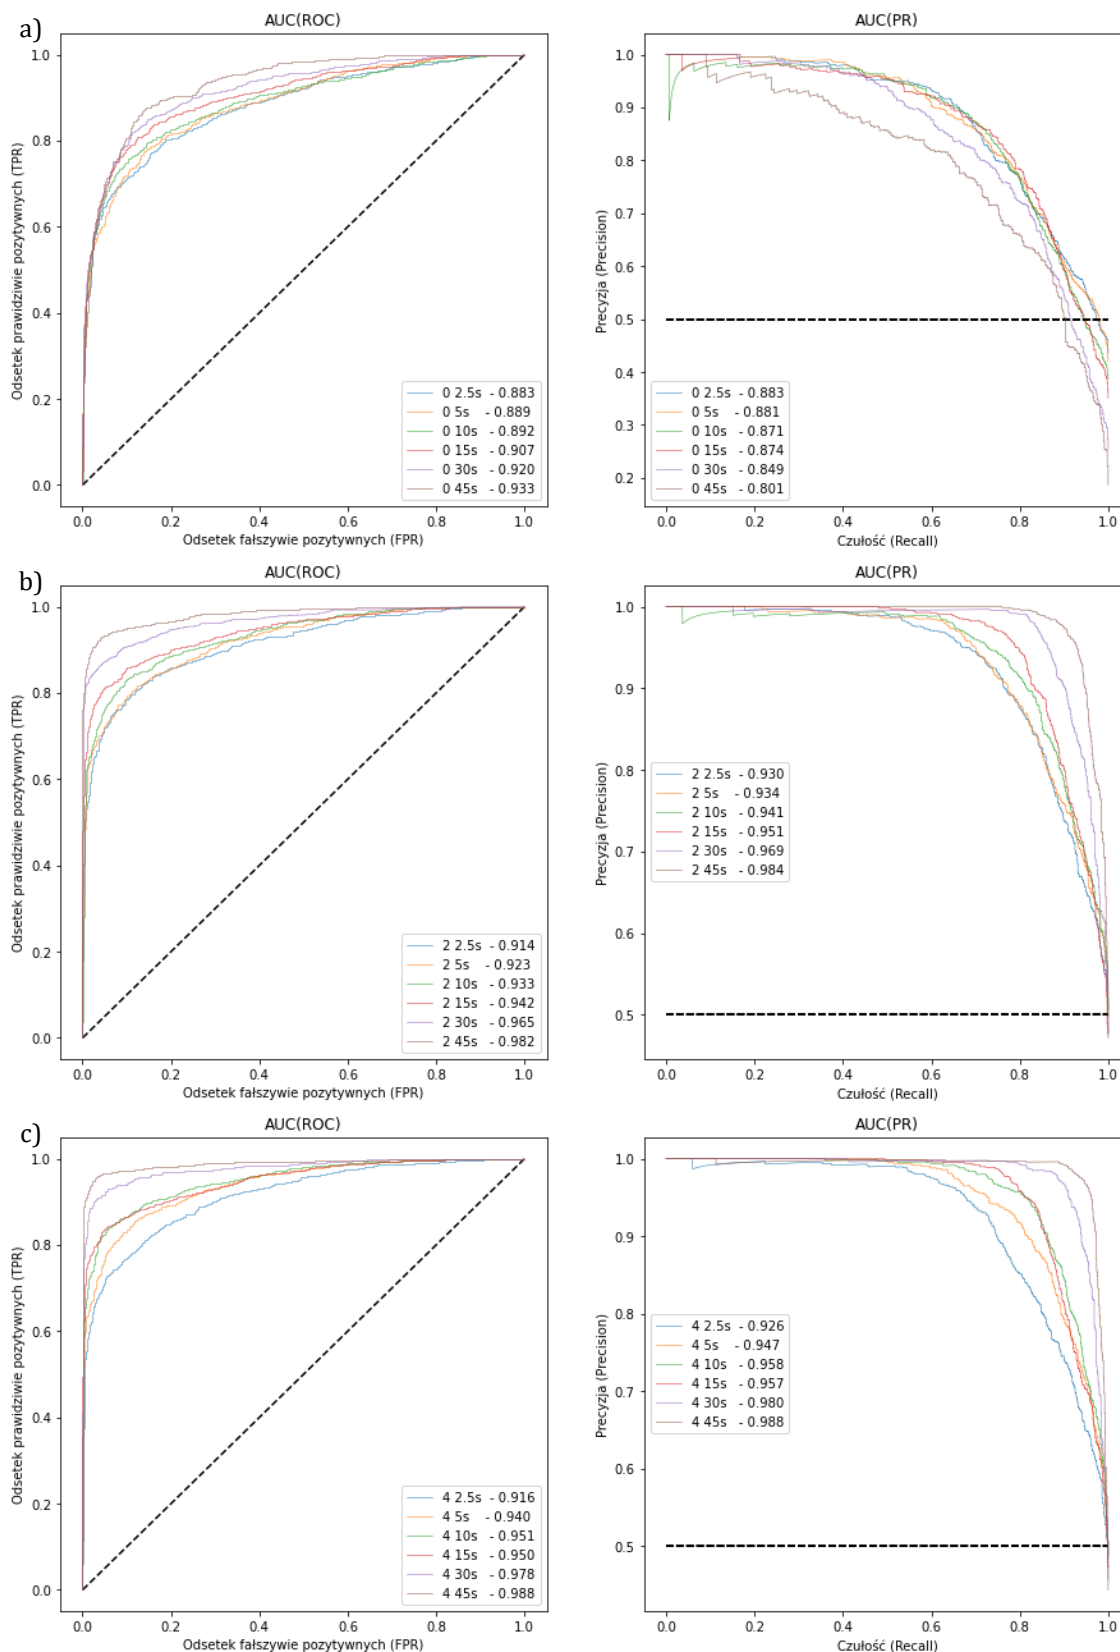
Rys. 6.13 Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 1.

Analizując uzyskane charakterystyki można stwierdzić, że poziom filtracji danych ma istotny wpływ na jakość predykcji modelu. Największy wpływ można zaobserwować dla zróżnicowanego podejścia do ramek przejściowych. Szczególnie interesujący jest spadek wartości AUC(PR) wraz z długością ramki dla wariantów, w których ramkom przejściowym przypisano klasę negatywną.



Rys. 6.14 Krzywe ROC (lewa strona) oraz PR (prawa strona) dla badanych poziomów filtracji przy ramce o długości a) 2.5 s, b) 45 s. W legendzie zawarto wartości pól pod krzywą.

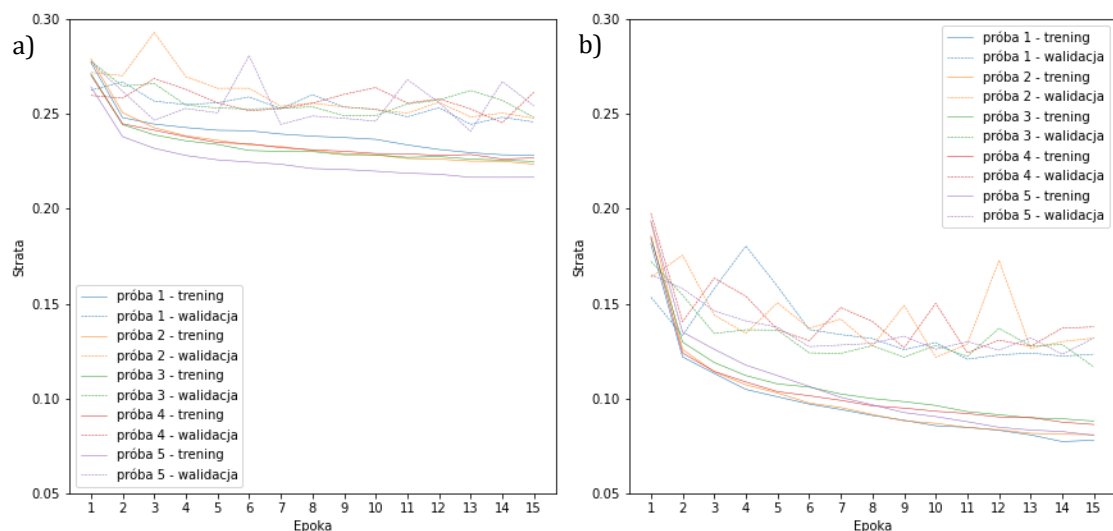
Na rysunkach 6.14 i 6.15 przedstawiono rodziny krzywych ROC i PR dla wybranej próby, szczególnie ilustrujące wpływ poziomu filtracji danych oraz długości ramki na jakość predykcji modelu bazowego.



Rys. 6.15 Krzywe ROC (lewa strona) oraz PR (prawa strona) dla badanych długości ramki przy poziomej filtracji a) brak filtracji, b) filtracja ramek przejściowych, c) filtracja zdarzeń o niewłaściwym czasie trwania. W legendzie zawarto wartości pól pod krzywą.

Uzyskane charakterystyki przedstawiają wzrost jakości predykcji wraz ze wzrostem długości w obrębie danego poziomu filtracji. Wyjątek stanowi wspomniany już spadek wartości powierzchni pod krzywą PR dla wariantów 0 i 1a, w których ramki przejściowe traktowane są jako negatywne. Przypisanie klasy 1 powoduje zatrzymanie wartości AUC(PR) na jednym poziomie, niezależnie od długości ramki. Istotną poprawę uzyskano w wariancie 2, gdzie ramki przejściowe zostały odfiltrowane. Filtracja potencjalnych błędów w klasyfikacji manualnej w otoczeniu prominentnych zdarzeń ma zdecydowanie mniejszy wpływ na wyniki, podobnie jak odrzucanie próbek zakłóconych i o nietypowym czasie trwania. Tym niemniej trening i testy przeprowadzone na danych po ostatnim poziomie filtracji w połączeniu z największą dostępną długością ramki pozwoliły na uzyskanie najlepszej możliwej jakości predykcji. Uzyskana wartość dotyczy rzecz jasna pojedynczej ramki i jest jak najbardziej zgodna z intuicją: wzrost ilości danych oraz ich jednorodności ułatwia klasyfikację.

Dokonano także analizy przebiegu treningu dla modelu cechującego się najmniejszą i największą wartością powierzchni pod krzywą PR, którą przyjęto za podstawowe kryterium oceny jakości modelu, poprzez wykreślenie obliczonej wartości straty treningu i walidacji dla każdej epoki treningu modelu (Rys. 6.16).



Rys. 6.16 Wartość funkcji straty treningu i walidacji w funkcji epoki dla długości ramki 45 s i poziomu filtracji a) 1a, b) 4.

Uzyskane wykresy wskazują na to, że oba modele zyskują docelową wiedzę w ciągu dwóch pierwszych epok treningu. Model wytrenowany na wariancie 1a cechuje się rzecz jasna zdecydowanie większymi od trenowanego na wariancie 4 stratami, jednak w obu przypadkach występuje szybka stabilizacja straty walidacyjnej przy dalszym,

stopniowym spadku straty treningowej. Wskazuje to na zbyt małą pojemność bazowego modelu sieci a zatem konieczność weryfikacji głębszych sieci, wykorzystujących mechanizmy, które umożliwiają ograniczenie zaobserwowanego *overfittingu*.

Już po zakończeniu niniejszego eksperymentu należy postawić pytanie: czy i w jakim stopniu taki rezultat ma wpływ na jakość predykcji dla całego procesu klasyfikacji? Odpowiedzi powinien dostarczyć eksperyment 3, opisany szerzej w Rozdziale 7.

6.5 Eksperyment 2: wybór architektury sieci

Obserwacje poczynione po przeprowadzeniu eksperymentu 1 potwierdzają wstępne założenia dotyczące eksperymentu 2, dotyczące konieczności określenia architektury lepszej od bazowej sieci konwolucyjnej.

6.5.1 Założenia i metoda oceny

Podstawowe założenia dotyczące sposobu doboru danych wejściowych i metod oceny przyjęto analogicznie do eksperymentu 1.

W eksperymencie 2 liczba prób została zredukowana do 3, ze względu na niewielkie różnice pomiędzy rezultatami dla kolejnych prób, zaobserwowane w eksperymencie 1. Liczbę epok w każdej próbie ustalono na 25, aby możliwa była obserwacja tendencji występujących w treningu. Trening, podobnie jak w eksperymencie 1, przeprowadzono na ramkach o długościach: 2,5 s, 5 s, 10 s, 20 s, 30 s i 45 s. Wykorzystano dane z odfiltrowanymi ramkami z otoczenia zdarzeń oraz ramkami mieszanymi, tj. na poziomie filtracji 2.

Badane architektury przedstawiono szczegółowo w Rozdziale 6.3, ich zestawienie wraz z przypisanymi oznaczeniami znajduje się zaś w tabeli 6.6.

Tab. 6.6 Zestawienie trenowanych architektur.

Architektura	Oznaczenie
base_cnn	0
resnet_1	1
resnet_2	2
resnet_2a	2a
resnet_2b	2b
resnet_3	3

Łącznie, w ramach eksperymentu 2, wytrenowano 120 modeli, zaś czas trwania treningu przy użyciu opisanego wyżej środowiska przekroczył 28 godzin.

6.5.2 Wyniki

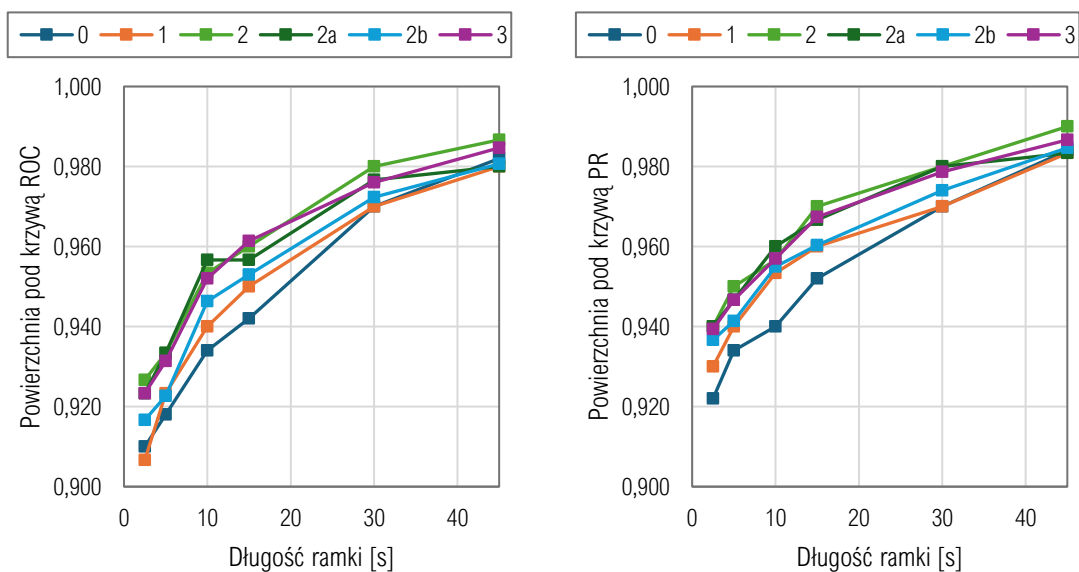
Do oceny jakości predykcji modelu, aby umożliwić porównanie z rezultatami eksperymentu 1, wykorzystano ponownie wartości powierzchni pod krzywymi ROC i PR. Usrednione wartości przedstawiają tabele 6.7 i 6.8. Rezultaty zestawiono w formie wykresów na Rys. 6.17.

Tab. 6.7 Wartości powierzchni pod krzywą ROC – eksperyment 2/.

Długość ramki	Badana architektura sieci					
	0	1	2	2a	2b	3
2.5 s	0,910	0,907	0,927	0,923	0,917	0,923
5 s	0,918	0,923	0,933	0,933	0,923	0,931
10 s	0,934	0,940	0,953	0,957	0,946	0,952
20 s	0,942	0,950	0,960	0,957	0,953	0,961
30 s	0,970	0,970	0,980	0,977	0,972	0,976
45 s	0,982	0,980	0,987	0,980	0,981	0,985

Tab. 6.8 Wartości powierzchni pod krzywą PR – eksperyment 2.

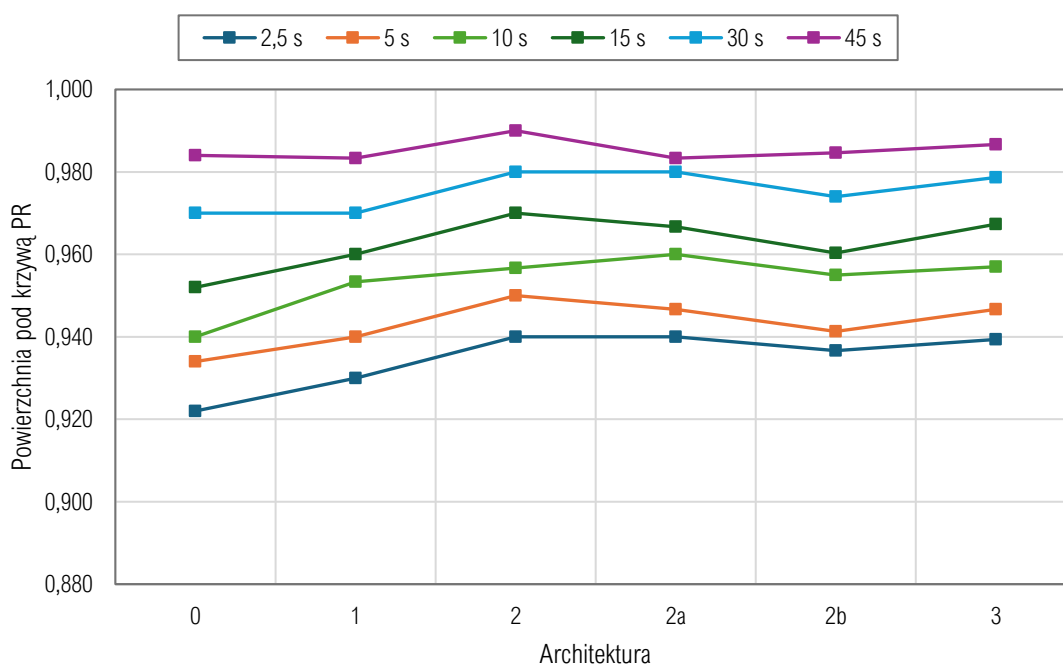
Długość ramki	Badana architektura sieci					
	0	1	2	2a	2b	3
2.5 s	0,922	0,930	0,940	0,940	0,937	0,939
5 s	0,934	0,940	0,950	0,947	0,941	0,947
10 s	0,940	0,953	0,957	0,960	0,955	0,957
20 s	0,952	0,960	0,970	0,967	0,960	0,967
30 s	0,970	0,970	0,980	0,980	0,974	0,979
45 s	0,984	0,983	0,990	0,983	0,985	0,987



Rys. 6.17 Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 2.

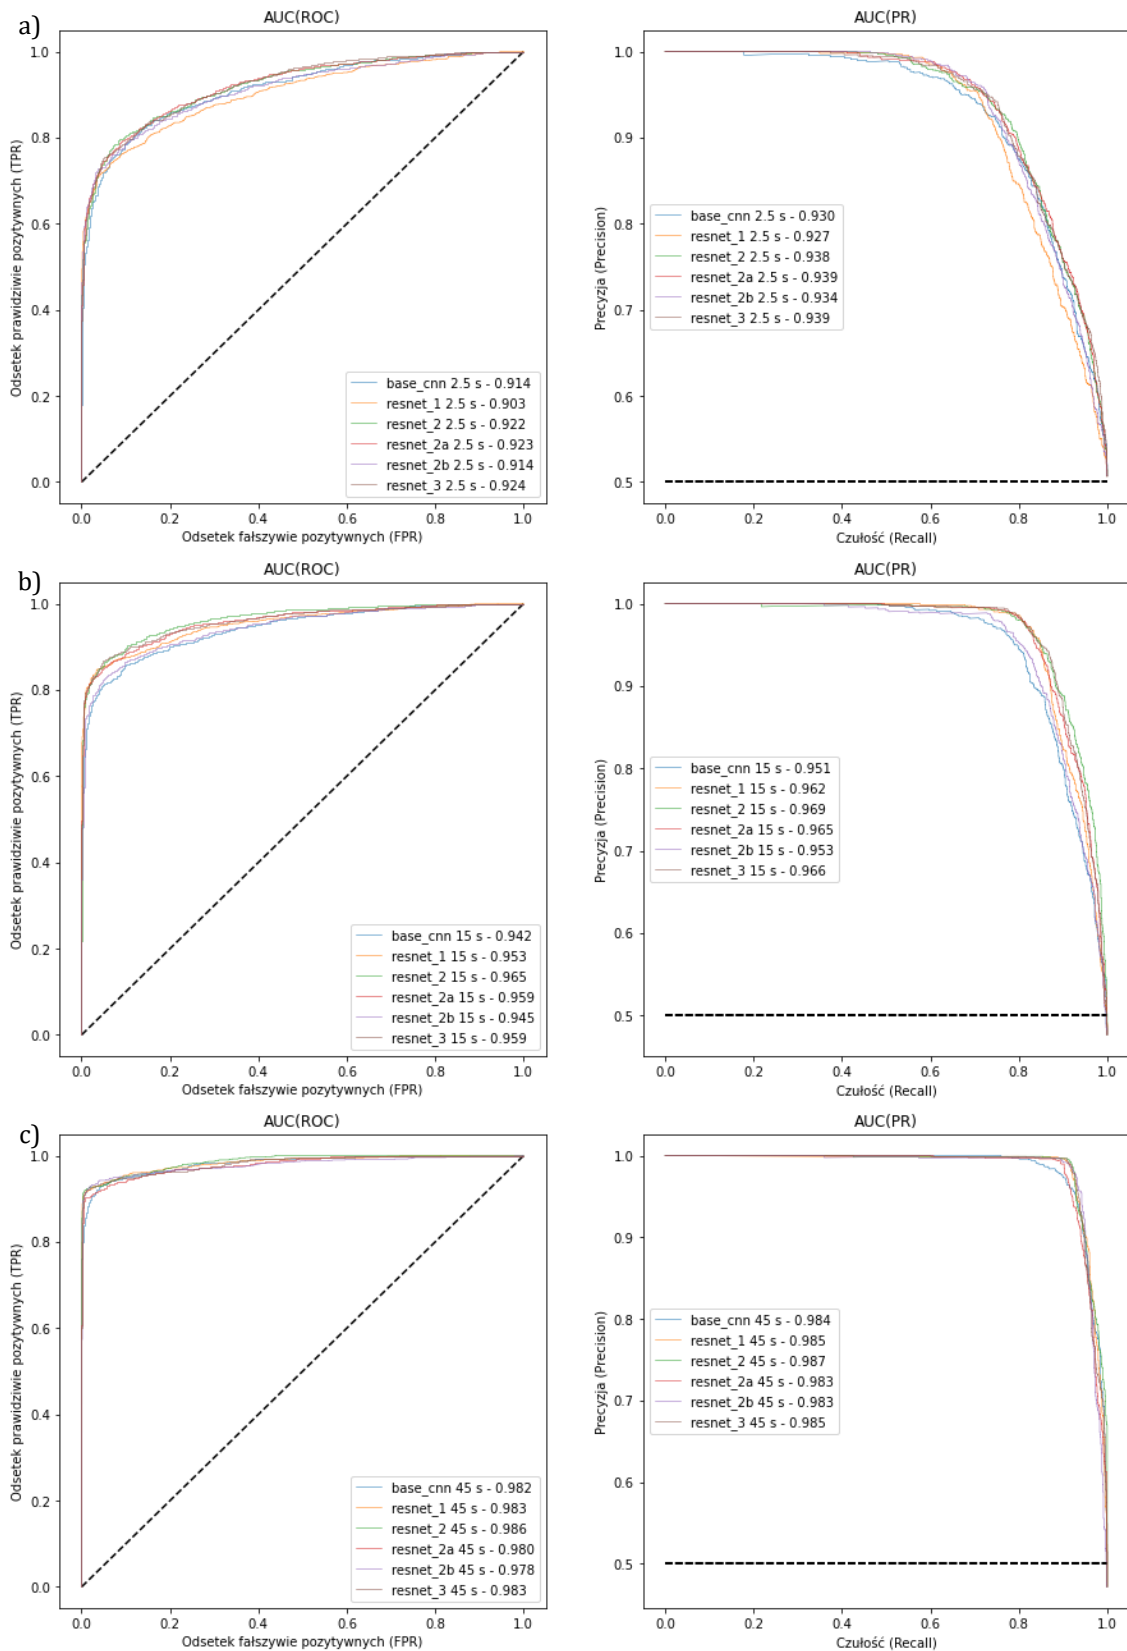
Tendencje w zakresie jakości klasyfikacji dla rosnących czasów ramki, które wykazała sieć bazowa utrzymują się w przypadku pozostałych architektur.

Uzyskane wyniki wskazują na to, że wzrost głębokości sieci zapewnia lepszą predykcję tylko do pewnego stopnia (Rys. 6.18). Dalszy wzrost powoduje pogorszenie wyników. Zjawisko to spowodowane jest zanikaniem gradientu. Końcowe najgłębszej sieci nie dysponują wystarczającą ilością informacji do przetwarzania, wprowadzając jedynie zniekształcenia.



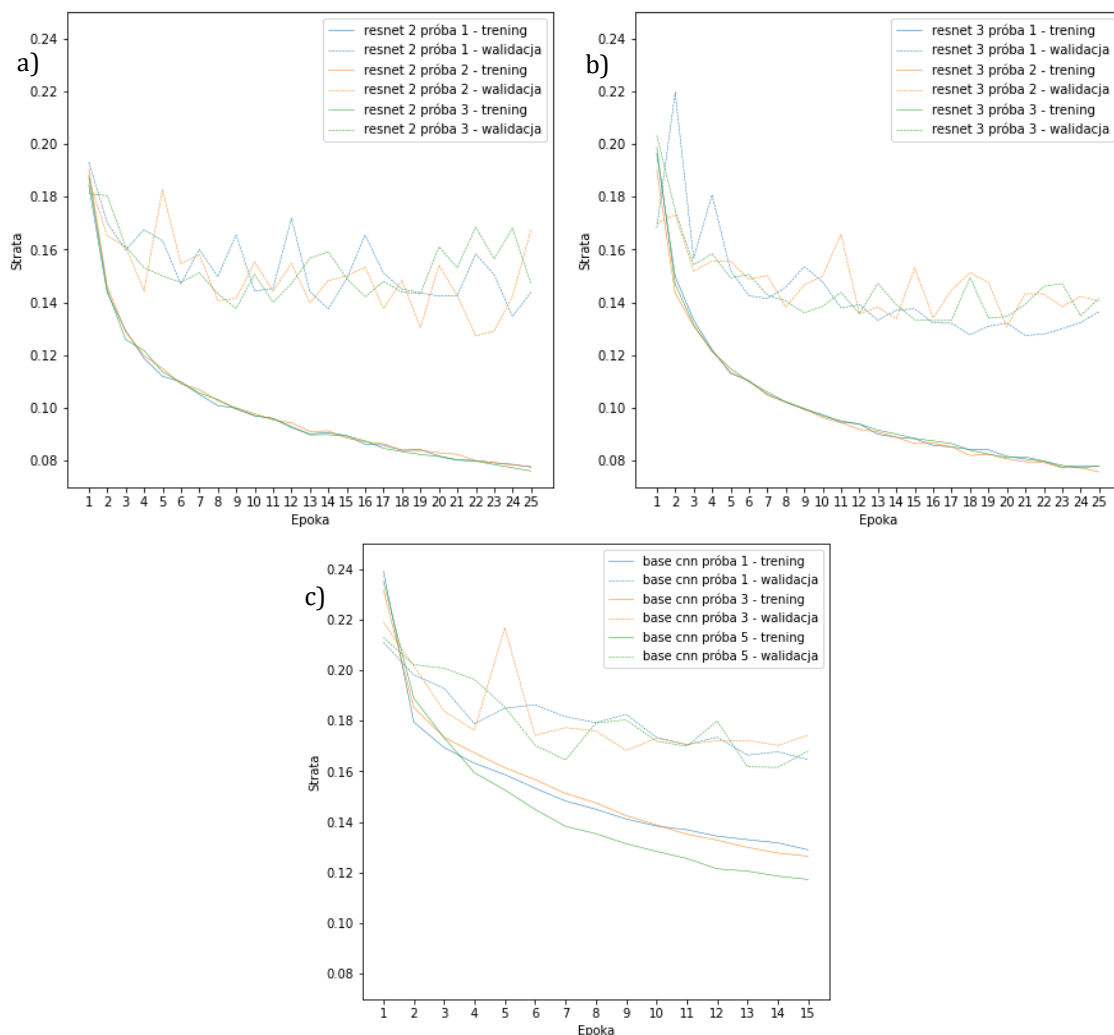
Rys. 6.18 Wartości powierzchni pod krzywą PR w zależności od architektury sieci.

Przebiegi krzywych ROC i PR uzyskane w toku eksperymentu 2, przedstawione na Rys. 6.19, wskazują na istotnie większy wpływ długości analizowanej przez sieć ramki, niż nawet istotnych zmian w samej architekturze. Dynamika zmian powierzchni pod krzywą PR, uzyskana w eksperymencie 1 wynosi 0,186 zaś w eksperymencie 2 jedynie 0,068.



Rys. 6.19 Krzywe ROC (lewa strona) oraz PR (prawa strona) dla wybranych długości ramki a) 2,5 s, b) 15 s, c) 45 s. W legendzie zawarto wartości pól pod krzywą.

Analogiczna do przeprowadzonej dla wyników eksperymentu 1 analiza historii treningu (Rys. 6.20) wskazuje przede wszystkim na zdecydowanie lepsze dopasowanie modelu do danych treningowych w przypadku bardziej złożonych architektur *resnet_2* i *resnet_3*. Poszczególne próby cechują się także mniejszym rozrzutem wartości straty. Zakładane przesunięcie punktu pojawienia się *overfittingu* zostało potwierdzone, szczególnie dla sieci *resnet 3*, dla której zaczyna on występować od 12 epoki treningu.



Rys. 6.20 Wartość funkcji straty treningu i walidacji w funkcji epoki dla długości ramki 45 s i architektury sieci a) *resnet 2*, b) *resnet 3*, c) *base cnn*.

6.6 Podsumowanie

Przeprowadzone eksperymenty pozwoliły na rozpoznanie ograniczeń sieci konwolucyjnych, stosowanych w klasyfikacji ramek spektralnych. Z przeprowadzonych badań wynika, że jakość klasyfikacji pojedynczej ramki zależy przede wszystkim od stopnia filtracji danych wejściowych na etapie wstępnego ich przetwarzania (ang. *preprocessing*), oraz długości ramki w domenie czasu. Różnice, wynikające ze

złożoności architektury sieci dotyczą w głównej mierze poprawy stabilności procesu treningu, w nieco mniejszym stopniu wpływając na końcową jakość klasyfikatora.

Pierwsze obserwacje po ukończeniu opisanego w Rozdziale 6 etapu pracy pozwalają na wytypowanie zestawu hiperparametrów: długość ramki – stopień filtracji – architektura sieci, który pozwala na najbardziej efektywną klasyfikację pojedynczej ramki sygnału. Zestaw ten to ramka o długości 45 s, na 4, najwyższym poziomie filtracji, podczas której z zestawu danych treningowych odrzucono: potencjalnie błędnie oznaczone próbki negatywne (otoczenie zidentyfikowanych zdarzeń lotniczych), ramki mieszane (zawierające część sygnału związanego z hałasem lotniczym oraz część sygnału tła), zdarzenia oznaczone jako zakłócone lub niespełniające kryteriów meteorologicznych oraz zdarzenia o nietypowym czasie trwania. Największą jakość predykcji, wyrażoną powierzchniami pod krzywymi ROC i PR, uzyskała architektura *resnet 2*, wykorzystująca bloki rezydualne, warstwy normalizujące (*batch normalization*) oraz warstwy *dropout*.

Wyniki pozostałych architektur oraz poziomów filtracji danych 2 i 3 pozwoliły na uzyskanie nieznacznie tylko gorszych wyników. Z tego względu opisane w kolejnym rozdziale badania możliwości wykorzystania sieci konwolucyjnych w kompleksowym procesie klasyfikacji, opisanym w Rozdziale 5, obejmować będzie większą liczbę zestawów.

7 BADANIE MOŻLIWOŚCI ZASTOSOWANIA SIECI NEURONOWYCH W SYSTEMIE DETEKCJI ZDARZEŃ AKUSTYCZNYCH

Badania, opisane w niniejszym rozdziale pracy, obejmują realizację całego procesu klasyfikacji, opisanego w Rozdziale 5. Mają na celu określenie sposobu interpretacji wartości zwracanych przez sieć neuronową, który umożliwi przypisanie danemu fragmentowi analizowanego sygnału klasy pozytywnej, odpowiadającej hałasowi emitowanemu przez operację lotniczą, bądź też negatywnej.

Poniżej opisano przebieg dwóch eksperymentów, oznaczonych jako eksperyment 3 i 4. Eksperyment 3 rozszerza rezultaty uzyskane w eksperymentach 1 i 2. Wytrenowano ponownie wybraną grupę modeli a następnie, w oparciu o dodatkowe zestawy danych, przeprowadzono strojenie wartości progowej, która umożliwiła jednoznaczną interpretację wyniku predykcji danego modelu. Następnie przeprowadzono końcowe testy i porównania z manualnie wyznaczonymi zdarzeniami, opierając się o kolejny zestaw danych.

W dodatkowym eksperymencie 4 przeprowadzono badania możliwości zastąpienia badanych dotychczas sieci konwolucyjnych sieciami rekurencyjnymi oraz mieszanymi, korzystającymi zarówno z warstw rekurencyjnych jak i konwolucyjnych.

7.1 Przygotowanie zbiorów danych strojących i testowych

Dzięki dużej dostępności skorelowanych z operacjami lotniczymi danych akustycznych na etapie strojenia i testów procesu klasyfikacji możliwe było posłużenie się kolejnym, do tej pory niewykorzystywanym zestawem. Etap strojenia klasyfikatora, opisany został szczegółowo w Rozdziale 7.2. Przeprowadzono go korzystając z 24-godzinnej rejestracji w każdym z sześciu dotychczas wykorzystywanych punktów pomiarowych, co pozwoliło na wykorzystanie 144 godzin spektrogramów. W uzyskanych przebiegach zidentyfikowano 476 zdarzeń akustycznych związanych ze startem, lądowaniem lub przelotem statku powietrznego. Dane, wykorzystywane do strojenia nie były filtrowane, nie balansowano również liczby ramek pozytywnych i negatywnych.

Dane do końcowych testów jakości klasyfikacji zarejestrowano w punkcie pomiarowym G2. Poza standardowym zapisem 1/3 oktawowego multispektrum przyrząd pomiarowy rejestrował także sygnał audio, w celu umożliwienia odsłuchowej weryfikacji zdarzeń,

zarówno podczas manualnej jak i automatycznej klasyfikacji. Tak zarejestrowane dane, ze względu na ograniczenia transmisji bezprzewodowej w rejonie uwzględnionych w pracy punktów pomiarowych, obejmowały 17 godzin i 20 minut sygnału, co pozwoliło na identyfikację 56 zdarzeń związanych z operacjami statków powietrznych.

7.2 Eksperyment 3: badanie procesu klasyfikacji dla sieci CNN

Na wyjściu sieci neuronowej, zakończonej aktywacją sigmoidalną, uzyskiwana jest wartość x_i w postaci liczby rzeczywistej z przedziału $\langle 0; 1 \rangle$, przypisana do każdej i -tej ramki sygnału, której szerokość w próbkach oznaczyć można jako τ , zaś czas początku i końca odpowiednio jako $t_{i,1}$ oraz $t_{i,2} = t_{i,1} + \tau$. Wynik predykcji x_i przypisywany jest poszczególnym próbkom sygnału wejściowego o sygnaturze czasu ξ , gdzie $\xi \in \langle t_{i,1}; t_{i,2} \rangle$. Po wykonaniu przypisania wartości dla wszystkich ramek określana jest wartość wskaźnika identyfikacji hałasu lotniczego dla danej próbki sygnału, zgodnie z formułą (7.1).


$$v(\xi) = \frac{\sum x_i(\xi)}{\tau} \quad (7.1)$$

Ilustrację powyższego procesu przedstawiono na Rys. 7.1, który przedstawia schematycznie podział sygnału wejściowego, dla uproszczenia reprezentowanego na rysunku w postaci historii czasowej poziomego dźwięku A. Sygnał dzielony jest na kolejne ramki. Ich wysokość, przedstawiona na rysunku, koresponduje z wyznaczoną przez sieć neuronową wartością x_i . Przebieg wskaźnika identyfikacji $v(\xi)$ pozwala na odrzucenie w procesie analizy zdarzeń zakłócających, odzwierciedlając rejestrowany hałas lotniczy.

Aby możliwe było wyznaczenie początku i końca fragmentu sygnału związanego z przelotem statku powietrznego, przyjęta w pracy koncepcja zakłada wprowadzenie wartości progowej ϑ takiej, że:

$$\begin{cases} v(\xi) \geq \vartheta \Rightarrow \textit{klasa pozytywna} \\ v(\xi) < \vartheta \Rightarrow \textit{klasa negatywna} \end{cases}$$

□ Analizowany przebieg ■ Wynik predykcji x_i ■ Wskaźnik identyfikacji hałasu lotniczego



Rys. 7.1 Ilustracja złożenia wartości x_i dla poszczególnych ramek sygnału w uśredniony wskaźnik identyfikacji hałasu lotniczego. Opracowanie własne.

7.2.1 Założenia i metoda oceny

Eksperyment składał się z trzech etapów. W pierwszym przeprowadzono ponowny trening wytypowanych modeli, korzystając z procedury *early stopping*, która polega na zatrzymaniu procesu treningu po ustalonej w parametrze *patience* liczbie epok, w trakcie których nie zachodzi poprawa jakości predykcji modelu. Pozostałe założenia procesu treningu sieci, dotyczące w szczególności doboru i podziału danych wejściowych oraz trenowanych architektur, były analogiczne jak w eksperymentach 1 i 2.

Drugi etap obejmował optymalizację progowej wartości ϑ . Ponieważ na tym etapie problem uzyskał formę klasyfikacji binarnej, przydzielając konkretnym fragmentom sygnału jedną z dwóch wartości (0 lub 1), pierwsze kryterium optymalizacji stanowiło uzyskanie największej możliwej wartości wskaźnika *F1*, drugie zaś – wskaźnika *MCC* (ang. *Matthews Correlation Coefficient*). Procedura optymalizacji polegała na iteracyjnej zmianie wartości progu odcięcia ϑ , w zakresie (0; 1), z krokiem 0,01. Dla każdej wartości ϑ , na podstawie sklasyfikowanych danych odniesienia, obliczana była wartość wskaźników kryterialnych. Ponieważ liczebność klas pozytywnej i negatywnej była silnie zróżnicowana (dane niezbalansowane), podstawowe kryterium stanowił wskaźnik

MCC [12]. Proces strojenia powtarzany był odrębnie dla każdego z sześciu zestawów danych strojących.

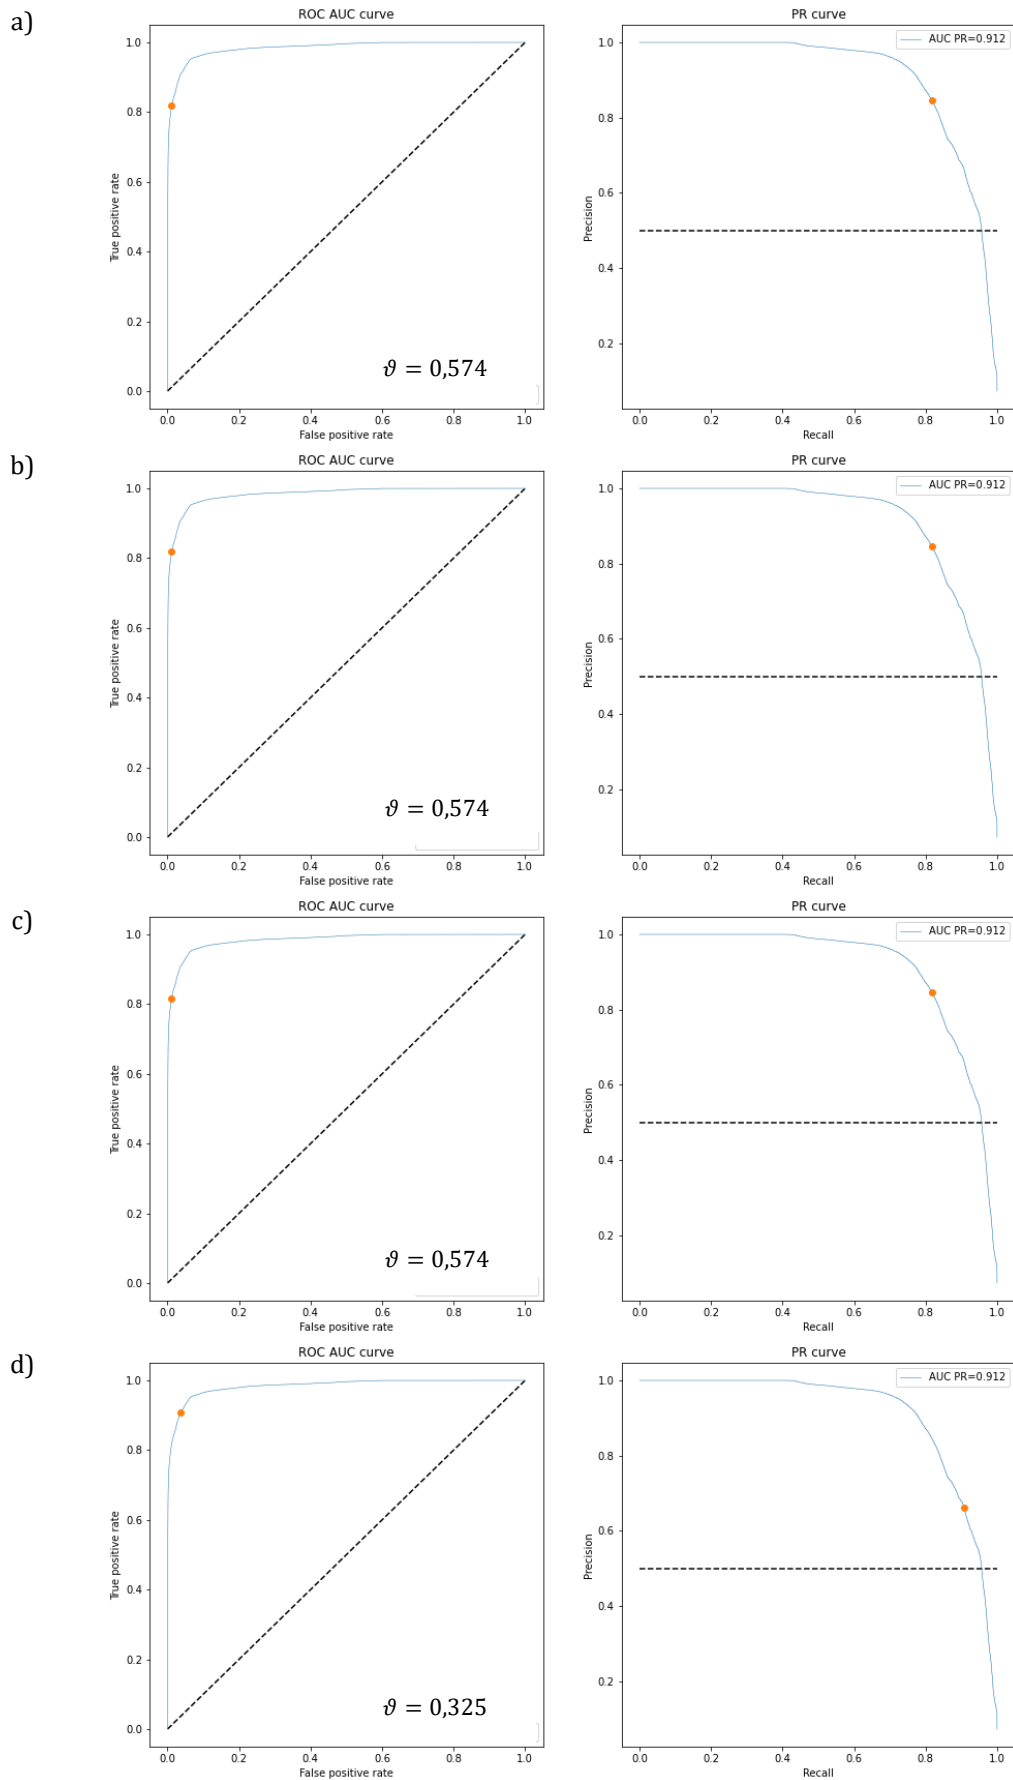
Dodatkowo wykorzystano także alternatywne metody doboru wartości progowej, wykorzystujące krzywe ROC i PR. Ponieważ każdy z punktów na wspomnianych krzywych stanowi w istocie wartość progu odcięcia, można wykorzystać je do wyboru wartości optymalnej pod kątem wybranego wskaźnika oceny. Do analizy krzywej ROC wykorzystano metodę indeksu *j*-Yourdena [60] oraz opracowaną przez Unala [56] metodę opartą o wskaźnik IU. Strojenie progu w oparciu o krzywą PR w większości przypadków pozwala na uzyskanie wartości progowych zbliżonych do strojenia metodą wyboru wskaźnika F_1 , jednak w przypadku krzywych zawierających lokalne minima uzyskiwano błędne rezultaty. Stąd, choć wyniki uzyskane w oparciu o te metody są zawarte w prezentowanych w niniejszym rozdziale zestawieniach, to w praktyce nie wzięły udziału w ostatecznym wyborze modelu. Przykłady progów wyznaczonych różnymi metodami przedstawia Rys. 7.2

Następnie przeprowadzono proces klasyfikacji przy wyznaczonej wartości progu odcięcia ϑ na zbiorze danych testowych. Wynik testu, stanowiący podstawę do porównania wyników dla poszczególnych poddanych badaniu wariantów, przyjmował postać pary wskaźników F_1 i *MCC*. Badania przeprowadzono dla architektur i wariantów danych wejściowych, przedstawionych w Tab. 7.1.

Tab. 7.1 Zestawienie wariantów danych do treningu.

Czas trwania ramki [s]	Poziom filtracji danych wejściowych	Architektura sieci
2,5; 5; 10; 15; 30; 45	2	base_cnn
2,5; 5; 10; 15; 30; 45	2	resnet_2
15; 30; 45	3	resnet_2
15; 30; 45	4	resnet_2
2,5; 5; 10; 15; 30; 45	2	resnet_3
15; 30; 45	3	resnet_3
15; 30; 45	4	resnet_3

Łącznie, w ramach eksperymentu 3, wytrenowano 90 modeli, zaś czas trwania treningu przekroczył 10 godzin. Proces strojenia i testów obejmował wielokrotną realizację predykcji. Jego realizacja na komputerze osobistym trwała w związku z tym około 96 godzin.



Rys. 7.2 Strojenie progu odcięcia metodą a) doboru wskaźnika F1, b) doboru wskaźnika MCC, c) wyznaczenia z krzywej PR, d) wyznaczenia z krzywej ROC metodą Yourdena.

7.2.2 Etap treningu

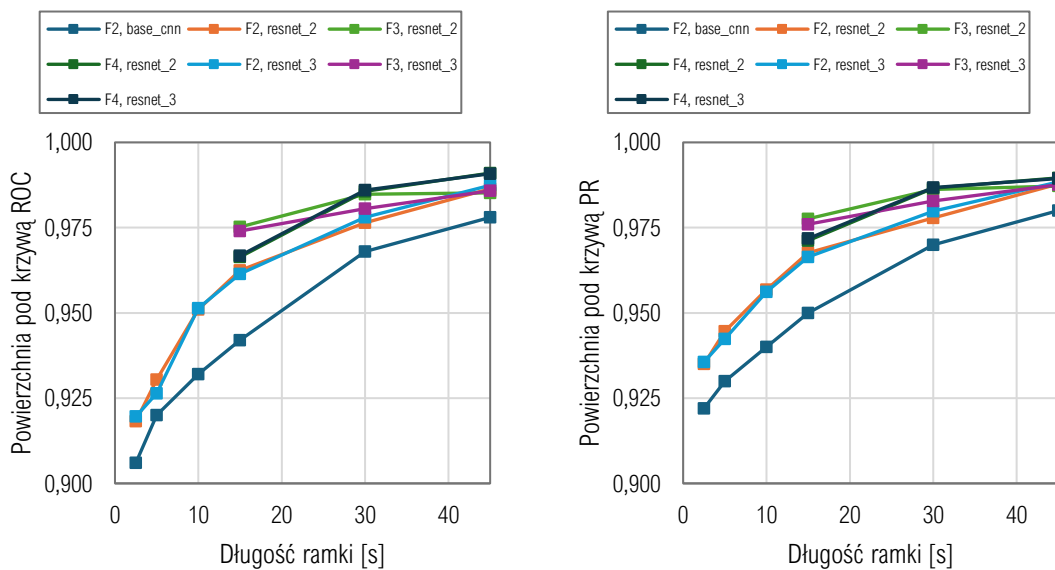
Ponowny trening wytypowanych architektur, z wykorzystaniem procedury *early stopping*, zapewnił nieznaczną poprawę wartości powierzchni pod krzywymi ROC i PR, przedstawionych w tabelach 7.2 i 7.3. Architektury *resnet_2* i *resnet_3* trenowane na danych o 4-tym poziomie filtracji pozwoliły na uzyskanie najwyższych wartości wskaźników oceny.

Tab. 7.2 Wartości powierzchni pod krzywą ROC – eksperyment 3.

Długość ramki	Wariant danych treningowych i architektura sieci						
	F2 base_cnn	F2 resnet_2	F3 resnet_2	F4 resnet_2	F2 resnet_3	F3 resnet_3	F4 resnet_3
2.5 s	0,906	0,918	-	-	0,920	-	-
5 s	0,920	0,930	-	-	0,926	-	-
10 s	0,932	0,951	-	-	0,951	-	-
20 s	0,942	0,962	0,975	0,966	0,961	0,974	0,967
30 s	0,968	0,976	0,985	0,986	0,978	0,981	0,986
45 s	0,978	0,986	0,985	0,991	0,987	0,986	0,991

Tab. 7.3 Wartości powierzchni pod krzywą PR – eksperyment 3.

Długość ramki	Wariant danych treningowych i architektura sieci						
	F2 base_cnn	F2 resnet_2	F3 resnet_2	F4 resnet_2	F2 resnet_3	F3 resnet_3	F4 resnet_3
2.5 s	0,922	0,935	-	-	0,936	-	-
5 s	0,930	0,945	-	-	0,942	-	-
10 s	0,940	0,957	-	-	0,956	-	-
20 s	0,950	0,968	0,978	0,971	0,966	0,976	0,972
30 s	0,970	0,978	0,986	0,987	0,980	0,983	0,987
45 s	0,980	0,988	0,987	0,990	0,988	0,988	0,989




Rys. 7.3 Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 3.

7.2.3 Etap strojenia

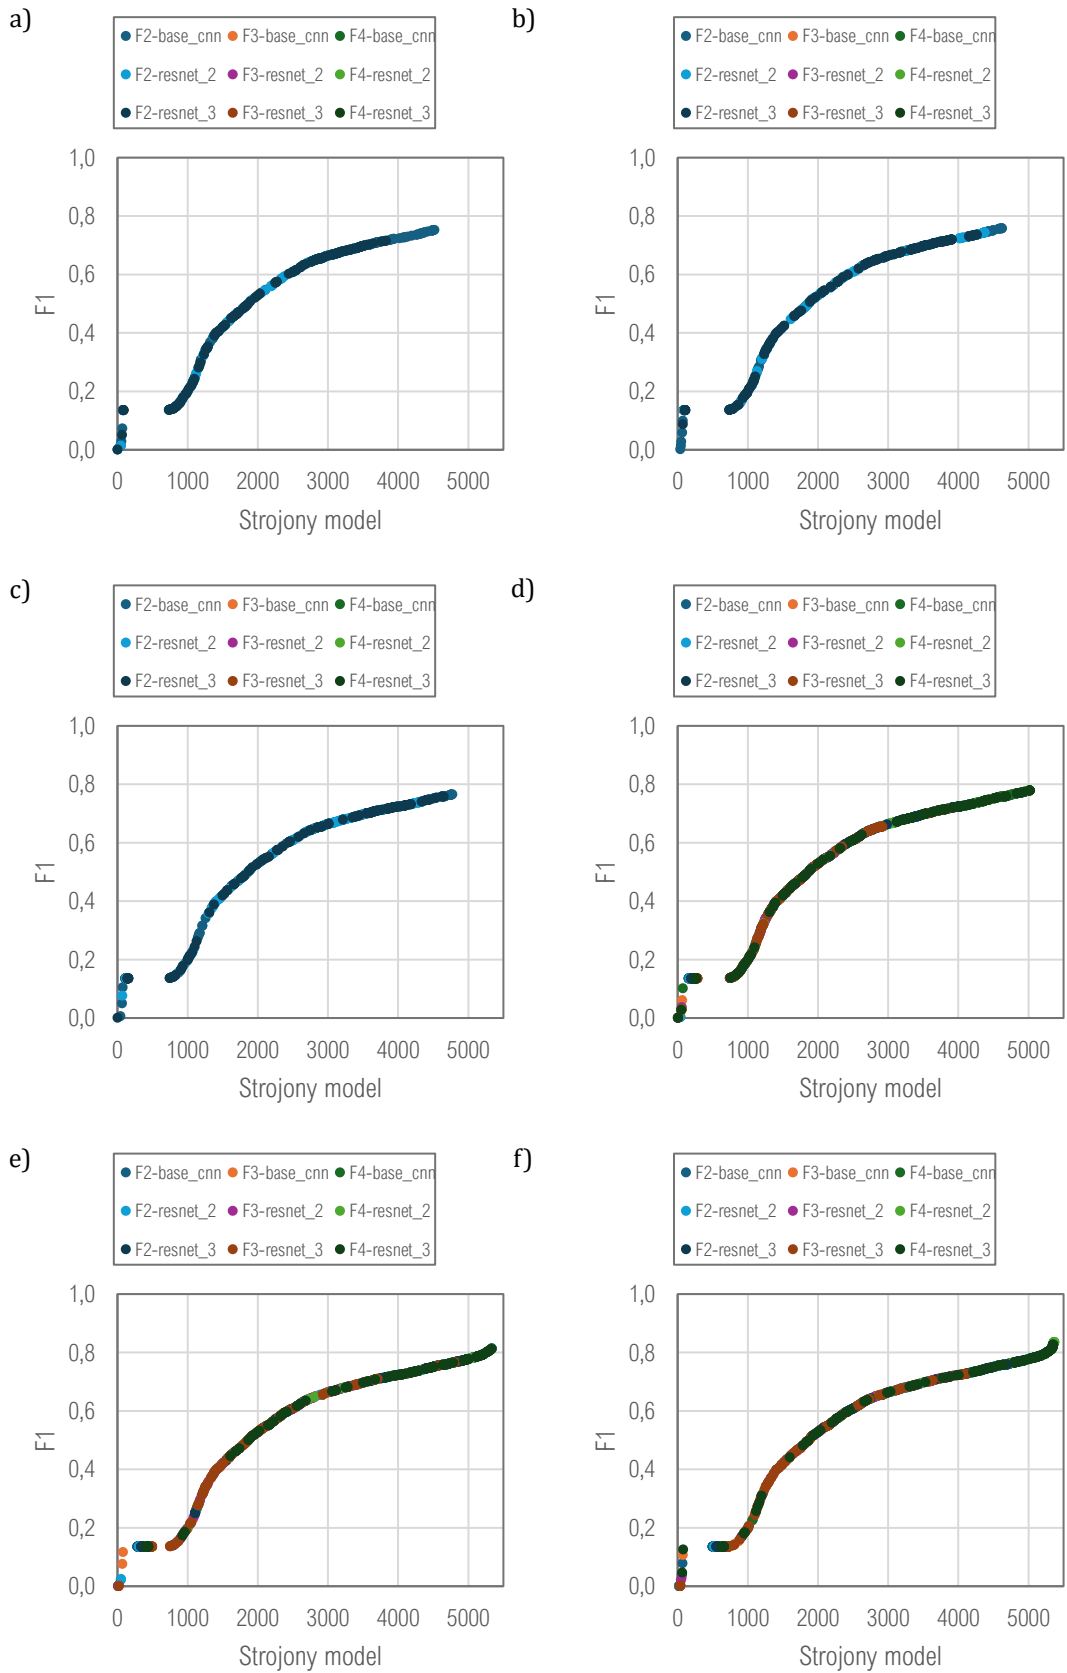
Drugi etap eksperymentu, przeprowadzony na rzeczywistych, nieprzetwarzanych danych, pozwolił na powiązanie dotychczasowych wyników, dotyczących efektywności działania modelu w odniesieniu do pojedynczej ramki, z możliwością jego wykorzystania w charakterze elementu całego procesu detekcji zdarzeń.

Przedstawione na Rys. 7.4 wyniki dla najlepiej dostrojonego modelu w funkcji długości ramki wskazują, że monotoniczna zależność jakości klasyfikacji od długości ramki, obserwowana w eksperymentach 1 i 2, przekłada się na całościowy proces klasyfikacji. Oznacza to, że zwiększenie długości ramki nie pogarsza rozdzielczości czasowej klasyfikatora bądź też, że pogorszenie to jest kompensowane znacznie lepszą zdolnością modelu do dyskryminacji pozytywnych i negatywnych próbek sygnału.



Rys. 7.4 Wartości wskaźników F_1 i MCC dla najlepszych modeli, w funkcji długości ramki.

Dystrybucje wartości wskaźnika F_1 , przedstawione na Rys. 7.5, wskazują, że dla długości ramki 30 s i 45 s istnieje niewielka grupa modeli, których jakość predykcji w połączeniu z odpowiednio dobranym progiem wyróżnia się pozytywnie na tle ogólnego trendu. Część z 5370 realizacji cechuje się wyjątkowo niskimi wartościami wskaźnika F_1 . Są one najczęściej wynikiem błędnego doboru progu odcięcia, spowodowanego niestabilnością krzywej PR, bądź też zastosowaniem nieodpowiedniej metody strojenia, opartej o wskaźnik IU.



Rys. 7.5 Rozkład wartości wskaźnika F1 strojonych modeli dla długości ramki a) 2,5 s, b) 5 s, c) 10 s, d) 15 s, e) 30 s, f) 45 s.

Tabela 7.4 przedstawia wartości wskaźników $F1$ i MCC wyznaczone dla 20 najlepszych realizacji procesu strojenia.

Tab. 7.4 Wyniki po strojeniu dla 20 najlepszych realizacji.

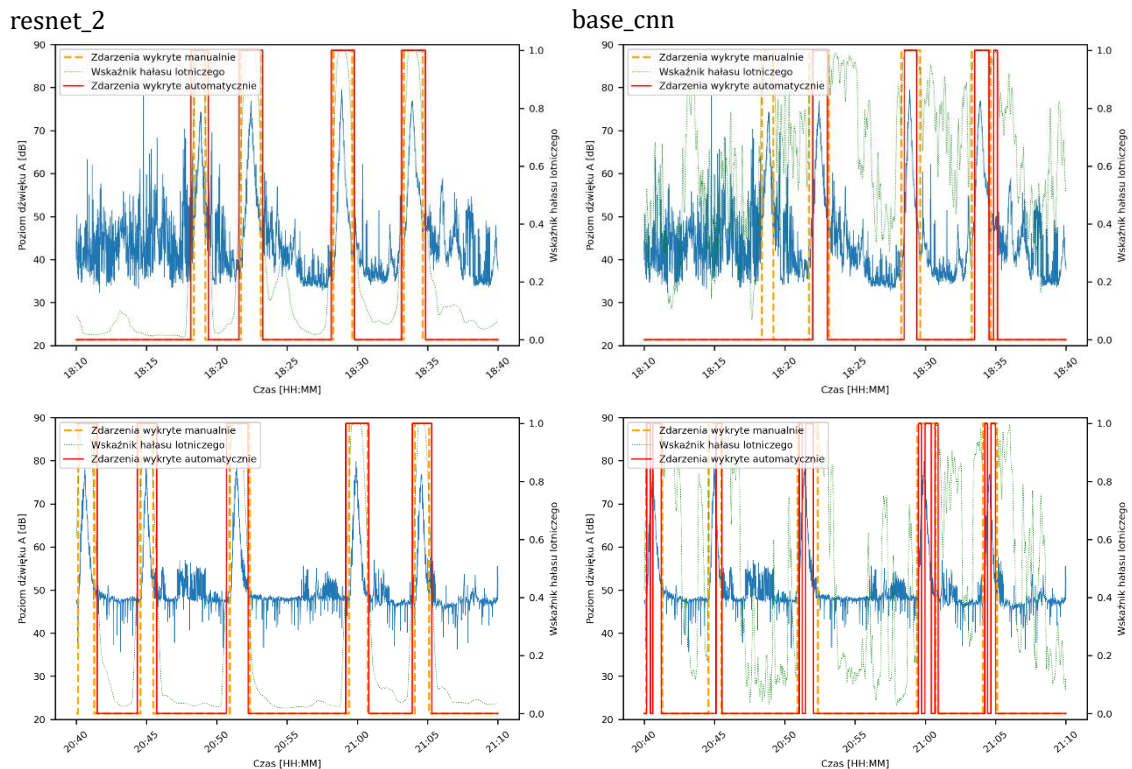
Wariant danych	Architektura	Próba	Punkt strojący	Metoda strojenia	Dobry próg ϑ	F1	MCC
45 s, F4	resnet_3	1	PG2	mcc	0,748	0,825	0,813
45 s, F4	resnet_3	1	PG3	fscore	0,755	0,825	0,813
45 s, F4	resnet_3	1	PK1	auc_pr	0,752	0,825	0,813
45 s, F4	resnet_3	1	PG2	auc_pr	0,733	0,826	0,814
45 s, F4	resnet_3	1	PG3	mcc	0,746	0,826	0,814
45 s, F4	resnet_2	3	PG2	fscore	0,574	0,832	0,819
45 s, F4	resnet_2	3	PG2	mcc	0,574	0,832	0,819
45 s, F4	resnet_2	3	PG2	auc_pr	0,574	0,832	0,819
45 s, F4	resnet_2	3	PK1	mcc	0,580	0,832	0,820
45 s, F4	resnet_2	3	PG4	fscore	0,586	0,833	0,821
45 s, F4	resnet_2	3	PG4	auc_pr	0,586	0,833	0,821
45 s, F4	resnet_2	3	PG3	fscore	0,598	0,834	0,822
45 s, F4	resnet_2	3	PG3	mcc	0,598	0,834	0,822
45 s, F4	resnet_2	3	PG3	auc_pr	0,598	0,834	0,822
45 s, F4	resnet_2	3	PG4	mcc	0,596	0,834	0,823
45 s, F4	resnet_2	3	PK1	fscore	0,597	0,834	0,822
45 s, F4	resnet_2	3	PK1	auc_pr	0,597	0,834	0,822
45 s, F4	resnet_2	3	PK2	fscore	0,616	0,835	0,824
45 s, F4	resnet_2	3	PK2	mcc	0,616	0,835	0,824
45 s, F4	resnet_2	3	PK2	auc_pr	0,616	0,835	0,824

Można dostrzec, że 15 spośród wybranych 20 rezultatów zostało uzyskanych przy użyciu trzeciej próby treningu modelu *resnet_2* dla ramek o długości 45 s na 4-tym poziomie filtracji. Ta długość ramki i poziom filtracji utrzymują się dla wszystkich rezultatów, co jednoznacznie pokrywa się z wynikami eksperymentów 1 i 2. Dobrane na podstawie danych z odmiennych punktów pomiarowych wartości progu ϑ różnią się nieznacznie. Punkt pomiarowy ma zdecydowanie większy wpływ na wartość progu odcięcia niż metoda strojenia, która w większości prezentowanych przypadków nie wpływała na wartość progu. Zaobserwować można skokową zmianę wyznaczonego progu dla modelu *resnet_3*. Analiza większej próby danych wskazuje jednak, że za zmianę tę odpowiada w większym stopniu proces treningu niż sama architektura sieci.

Wskaźniki $F1$ i MCC są często stosowane w ocenie i porównaniach klasyfikatorów binarnych. Jak jednak uzyskane wartości przekładają się na rzeczywistą zdolność badanej metody do identyfikacji zdarzeń akustycznych? I czy zdolność ta odpowiada kryteriom normowym?

7.2.4 Testy końcowe

Odpowiedzi na postawione w poprzednim rozdziale pytanie nie sposób udzielić nie przyglądając się z bliska procesowi klasyfikacji. Rysunek 7.6 przedstawia sposób funkcjonowania dwóch wybranych klasyfikatorów na dwóch rzeczywistych fragmentach sygnału, zarejestrowanego w punkcie PG2. Na rysunku widoczny jest wejściowy przebieg historii czasowej, w postaci rejestrowanego z krokiem 0,5 s równoważnego poziomu dźwięku A, oraz zidentyfikowane przez człowieka zdarzenia akustyczne. Zielona linia odzwierciedla przebieg wyznaczonego przez klasyfikator wskaźnika identyfikacji hałasu lotniczego, zaś czerwona – zidentyfikowane na jego podstawie zdarzenia akustyczne.




Rys. 7.6 Rezultaty klasyfikacji w dziedzinie czasu: po lewej sieć *resnet_2*, próba 3, strojenie w punkcie PK2 metodą *fscore*, po prawej sieć *base_cnn*, próba 4, strojenie w punkcie PG3 metodą *MCC*.

Na wykresach dostrzec można zdecydowanie większą stabilność wyznaczonego wskaźnika identyfikacji hałasu lotniczego dla sieci *resnet_2*. Wiąże się ona z lepszą zdolnością sieci do dyskryminacji pojedynczej ramki oraz do generalizacji posiadanej wiedzy. Różnica ta przekłada się na dostępny zakres użytecznych wartości progowych, który w przypadku sieci *base_cnn* jest zdecydowanie mniejszy. Tak niestabilny wskaźnik daje rezultaty w postaci fragmentarycznych, pominiętych lub błędnie wykrytych zdarzeń akustycznych, obniżając wartości wskaźników F_1 i *MCC*.

Analizując dokładniej przebieg klasyfikacji sieci *resnet_2* dostrzec można, że punkty początkowe i końcowe wykrytych zdarzeń różnią się nieznacznie od przyjętego odniesienia. Różnice te pozostają bez wpływu na ostateczny wynik, który w przypadku hałasu lotniczego stanowić będzie wyznaczona dla czasu trwania zdarzenia wartość ekspozycyjnego poziomu dźwięku A, L_{AE} , jednakże ograniczają wartości wskaźników oceny jakości klasyfikacji F_1 i MCC .

Przechodząc z jednoliczbowych wskaźników oceny stosowanych w dziedzinie czasu do analizy poszczególnych zdarzeń akustycznych (Rys. 7.7) zaobserwować można, że badany algorytm poprawnie oznaczył 94,6% zdarzeń, co plasuje go zdecydowanie powyżej normowego kryterium [68], wynoszącego 50%. Różnica skumulowanych poziomów ekspozycji wyniosła przy tym 0,0 dB, przy wartości kryterialnej 3 dB. Co interesujące, system oznaczył także zdarzenia niewystępujące w zestawie odniesienia, który etykietowano jedynie w oparciu o odsłuch sygnału. Ponowna weryfikacja wsparta zestawieniem wyników z danymi operacyjnymi wykazała jednak, że istotnie, w tych momentach znajdowały się zdarzenia akustyczne. Podobnie jak w przypadku oryginalnej sieci ResNet podczas konkursu ImageNet model okazał się być „lepszy” od człowieka.



Rys. 7.7 Porównanie czasów początku zdarzeń odniesienia oraz zdarzeń wykrytych automatycznie.


Wracając już po raz ostatni do wartości wskaźnika F_1 , wyznaczonego dla wykrytych przez wytypowany w trakcie prowadzonych badań model sieci konwolucyjnej zdarzeń akustycznych związanych z przelotami statków powietrznych w wybranym przebiegu testowym, stwierdzono, że wynosi ona 0,97. Opisanie powyżej wartości kryterialne czynią opisaną metodę odpowiednią do stawianego zadania.

Na podstawie przeprowadzonych badań stwierdzono, że duża długość ramki wpływa pozytywnie na jakość klasyfikacji, nie redukując rozdzielczości czasowej algorytmu.


Nie udało się uzyskać potwierdzenia płynącego z eksperymentu 2 wniosku; zwiększanie głębokości sieci do trzech bloków rezydualnych nie spowodowało istotnego zmniejszenia jakości klasyfikacji. Nie odnotowano, jednakże poprawy jakości klasyfikacji dla głębszej sieci. Ze względu na mniejszy czas obliczeń, co w zastosowaniach praktycznych stanowi istotny czynnik wpływający na wybór algorytmu, jako docelowe rozwiązanie do wdrożenia wytypowano sieć o dwóch blokach rezydualnych.

7.3 Eksperymenty 4: badanie możliwości zastosowania sieci rekurencyjnych

Ponieważ spektralna ramka wejściowa może być interpretowana jako sekwencja czasowa wektorów, zawierających widmo 1/3-oktawowe, może pojawić się pytanie, czy przy takim przedstawieniu problemu sieci rekurencyjne, stosowane z powodzeniem do analizy sekwencji [4, 26], nie pozwoliłyby na uzyskanie lepszej od sieci konwolucyjnych jakości predykcji. Aby zbadać taką możliwość przeprowadzono dodatkowy eksperyment 4, którego celem było przeprowadzenie badania sieci rekurencyjnej w sposób analogiczny do eksperymentu 3. Ponieważ sieci rekurencyjne działają najlepiej na sekwencjach, do badań wytypowano wariant danych wejściowych z ramkami o długości 45 s, na czwartym, najwyższym poziomie filtracji, który zapewnił najlepsze wyniki dla sieci konwolucyjnych. Badanie przeprowadzono dla czterech dodatkowych architektur, których schematy przedstawiono na rysunkach 7.8 i 7.9. Zastosowano w nich rekurencyjne warstwy *LSTM*.



Rys. 7.8 Schemat sieci lstm_1 (po lewej) i lstm_2 (po prawej).




Rys. 7.9 Schemat sieci *mixed_1* (po lewej) i *mixed_2* (po prawej).

Architektura *lstm_1* stanowiła prosty, dwuwarstwowy wariant, w którym pierwsza warstwa *LSTM* zwracała sekwencję, dostępną dla drugiej. Wyjście drugiej warstwy było interpretowane bezpośrednio przez warstwę *Dense*, zwracającą jak w przypadku badanych w poprzednich eksperymentach wartość z przedziału $\langle 0; 1 \rangle$. Architektura *lstm_2* została zdefiniowana w sposób analogiczny do *lstm_1*. Klasyczne warstwy *LSTM* zastąpiono warstwami dwukierunkowymi.

Architektury *mixed_1* i *mixed_2* analizowały ramkę wejściową dwutorowo: przy użyciu sieci *resnet_2* (z pominięciem bloku decyzyjnego) oraz sieci *lstm_1*. Wyniki przetwarzania były łączone poprzez konkatencję dwóch wektorów, z których pierwszy, uzyskany z sieci rezydualnej liczył 384 elementy, drugi zaś, stanowiący efekt pracy sieci rekurencyjnej – 32 elementy. Sieci zakończono blokami decyzyjnymi o dwóch (*mixed_1*) bądź trzech (*mixed_2*) warstwach *Dense*.

Wyniki klasyfikacji ocenione na zbiorze danych testowych, po ukończonym strojeniu, przeprowadzonym w sposób odpowiadający eksperymentowi 3, przedstawiono na Rys. 7.10. Do porównania przyjęto najlepszy dla każdej z architektur wariant.

Dla wytypowanego wariantu danych wejściowych sieci rekurencyjne osiągnęły nieznacznie gorsze od sieci rezydualnych rezultaty. Architektury mieszane, w których udział sieci rekurencyjnej wynosił 7,7%, uzyskały zbliżone do sieci rezydualnych rezultaty, co wskazuje na zasadność stosowania oryginalnie rozwijanego rozwiązania.



Rys. 7.10 Wyniki badania sieci rekurencyjnych, zestawione w rezultatach dla sieci rezydualnych resnet_2 i resnet_3.


Uzyskane wartości wskaźników *F1* i *MCC* dla poszczególnych architektur przedstawiono w Tab. 7.5.

Tab. 7.5 Wyniki klasyfikacji najlepiej dostrojonych modeli.

Architektura	F1	MCC
lstm_1	0,799	0,786
lstm_2	0,794	0,779
mixed_1	0,822	0,808
mixed_2	0,814	0,805
resnet_2	0,835	0,824
resnet_3	0,826	0,814

8 ZASTOSOWANIA W SYSTEMACH POMIAROWYCH

Stworzone w efekcie opisanych wyżej badań rozwiązanie zostało wdrożone w dwóch, należących do firmy SVANTEK, systemach. Pierwszy z nich, to stosowane w dziale Laboratorium Badawczego oprogramowanie SMHL, stosowane do identyfikacji i korelacji zdarzeń akustycznych związanych z operacjami lotniczymi na potrzeby obsługiwanych przez Laboratorium systemów monitoringu hałasu lotniczego na pięciu lotniskach w Polsce. Element interfejsu, widoczny dla użytkownika, został opisany w Rozdziale 4.6. Korzysta on z danych gromadzonych w bazie MS SQL. Wiersze w tabeli zawierającej dane akustyczne (poziom dźwięku A zapisywany z krokiem 0,5 s) są oznaczane przez badany algorytm jako zawierające sygnał hałasu lotniczego (flaga 1). Interfejs użytkownika (Rys. 8.1) został rozbudowany o możliwość automatycznego oznaczania wskazanych fragmentów w oparciu o tak oznaczone wiersze, istotnie przyspieszając proces manualnej korelacji danych.



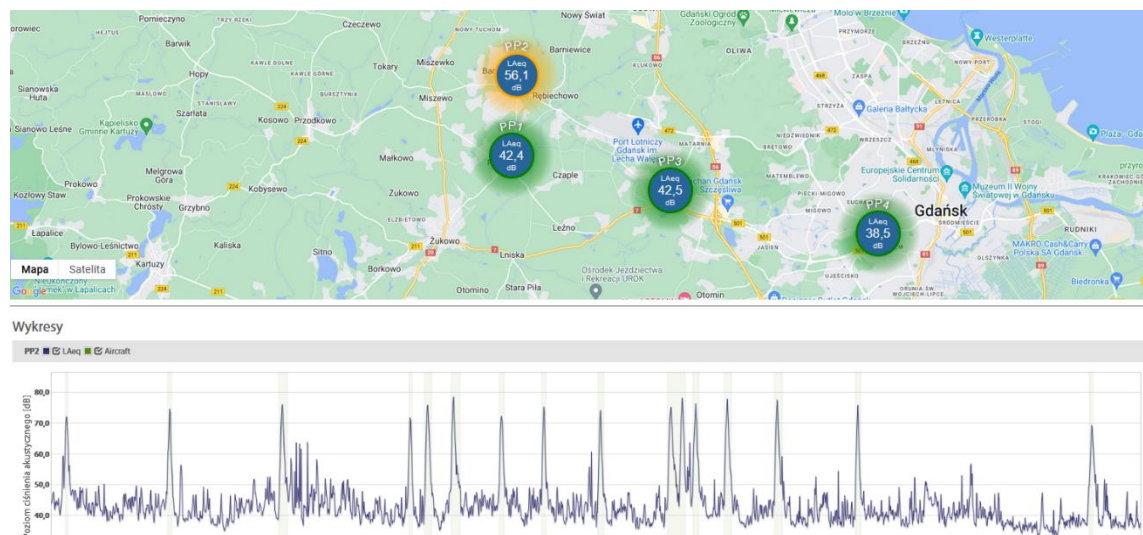
Rys. 8.1 Widok ekranu użytkownika oprogramowania SMHL. Wyróżniony fragment sygnału został oznaczony przez badany algorytm jako hałas lotniczy.

Dalsze prace rozwojowe uwzględniać będą automatyzację procesu korelacji wykrytych zdarzeń z wykazywanymi przez porty lotnicze statkami powietrznymi. Etap ten jednak, biorąc pod uwagę konieczność zapewnienia najwyższej możliwej dokładności korelacji, wymaga dalszych prac, nie wchodzących w zakres opisanych badań.

Prowadzone od momentu wdrożenia testy wykazały, że poza oczywistym przyspieszeniem procesu algorytm poprawia także dokładność korelacji zdarzeń, analizując dane widmowe, co ze względu na ilość danych nie byłoby możliwe do realizacji dla człowieka.

Drugim systemem, w którym zastosowano badany algorytm, jest dostępna dla klientów firmy platforma SvanNET. Wdrożenie rozwiązania rozszerzyło jej możliwości o wskazywanie na dostępnych dla użytkowników wykresach historii czasowych fragmentów sygnału, w których dominuje hałas lotniczy.

System umożliwia także obliczanie wskaźników oceny hałasu, takich jak ekspozycyjny poziom dźwięku L_{AE} . W przypadku przekroczenia ustalonego limitu generowane są alarmy, informujące użytkowników, takich jak porty lotnicze, o wykonaniu operacji lotniczej w sposób powodujący generację zbyt dużego poziomu hałasu. Takie bieżące alarmowanie pozwala na podejmowanie efektywnych działań, mających na celu takie wpłynięcie na przewoźników i operatorów, aby eliminować tego typu sytuacje. Są one najczęściej powiązane z niedotrzymaniem procedur startu bądź lądowania. Automatyczne wykrywanie takich incydentów może mieć wpływ także na poprawę bezpieczeństwa lotu.



Rys. 8.2 Widok wykresu historii czasowej na platformie SvanNET, z zaznaczeniem wykrytych przez algorytm zdarzeń związanych z przelotami statków powietrznych.

9 PODSUMOWANIE

W niniejszej rozprawie przedstawiono przebieg badań związanych z monitoringiem hałasu emitowanego do środowiska w związku ze startami, lądowaniami i przelotami statków powietrznych. Podstawowe osiągnięcie, poczynione w ramach pracy, stanowi opracowany, przetestowany i wdrożony skuteczny algorytm identyfikujący związane z hałasem lotniczym zdarzenia akustyczne, co stanowi niezbędny element wspomnianego monitoringu.

W toku badań potwierdzono jednoznacznie następującą tezę pracy badawczej:

Sygnal akustyczny, poddany 1/3-oktawowej analizie widmowej z małą rozdzielczością czasową, zawiera informacje wystarczające do identyfikacji zdarzeń akustycznych związanych z emisją hałasu lotniczego, z precyzją znacznie przekraczającą aktualne wymagania, w przypadku jego analizy przy zastosowaniu sztucznych sieci neuronowych.

W trakcie badań zgromadzono oraz dokonano etykietowania blisko 9 000 godzin sygnału akustycznego w formie próbek widma 1/3-oktawowego, zapisywanych z krokiem 0,5 s, pochodzących z sześciu punktów ciągłego pomiaru hałasu, zlokalizowanych w otoczeniu dwóch regionalnych portów lotniczych. Dane te podzielone zostały na 4 zestawy: treningowy, walidacyjny, strojący oraz testowy. Następnie przetworzono je do postaci zbiorów ramek wejściowych, zawierających równą liczbę przykładów oznaczonych jako „zawierający widmo hałasu lotniczego” (klasa pozytywna) oraz „niezawierający widma hałasu lotniczego” (klasa negatywna) o różnych czasach trwania pojedynczej ramki. Po wstępnej analizie zarejestrowanych danych, zbiory treningowy i walidacyjny zostały poddane kolejnym etapom filtracji, w celu pozbawienia ich przykładów mogących negatywnie wpłynąć na proces treningu sieci. Korzystając z tak przygotowanych zbiorów danych dokonano treningu sześciu architektur konwolucyjnych oraz dwóch architektur rekurencyjnych sieci neuronowych. Na kolejnym etapie badań określono wartość progową, pozwalającą na interpretację odpowiedzi sieci funkcjonującej w ramach stworzonego algorytmu, w efekcie uzyskując rozwiązanie, zdolne do precyzyjnej identyfikacji występowania hałasu lotniczego w analizowanym sygnale. Przeprowadzone testy opracowanego rozwiązania wykazały 97% skuteczność detekcji sygnału hałasu lotniczego.

Stworzony algorytm umożliwia wyznaczenie początku i końca lotniczego zdarzenia akustycznego jedynie w oparciu o wyznaczone dla poszczególnych ramek podobieństwo do hałasu lotniczego, z dokładnością spełniającą założenia z wymagań normowych. Dzięki podejściu, opierającemu się na obliczaniu wartości wskaźnika identyfikacji hałasu lotniczego w analizowanej serii pomiarowej w perspektywie jest możliwe rozszerzenie stworzonego rozwiązania o możliwość klasyfikacji większej liczby źródeł hałasu, takich jak zdarzenia związane z przejazdami składów kolejowych, a potencjalnie także źródeł hałasu nie powodujących powstawania możliwych do wyodrębnienia zdarzeń akustycznych, takich jak hałas drogowy.

Opracowana metoda cechuje się możliwością prostej implementacji w istniejących systemach. Jej zastosowanie w monitoringu hałasu lotniczego może znacząco poprawić możliwości systemów, ułatwiając i przyspieszając zarządzanie nim poprzez precyzyjne wykrywanie operacji lotniczych, wykonywanych w sposób powodujący nadmierną emisję hałasu. Rozwiązanie takie zostało wdrożone w systemie firmy Svantek, wspierając polskie lotniska we wspomnianym wyżej zakresie.

BIBLIOGRAFIA

1. Antoine N, Kroo I. Optimizing Aircraft and Operations for Minimum Noise. AIAA's Aircraft Technology, Integration, and Operations (ATIO) 2002 Technical Forum 2002. <https://doi.org/10.2514/6.2002-5868>
2. Asensio C., Ruiz M., Recuero M.; Real-time aircraft noise likeness detector, *Applied Acoustics* (2009), 71(6), 539–545, DOI 10.1016/j.apacoust.2009.12.005.
3. Attenborough, K. Sound propagation in the atmosphere. In *Springer Handbook of Acoustics*; Springer: Berlin/Heidelberg, Germany, 2014; pp. 117–155.
4. Bashivan P, Rish I, Yeasin M, Codella N. Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks 2015. <https://doi.org/10.48550/ARXIV.1511.06448>
5. Bishop C. M.; *Pattern recognition and machine learning*; Springer, 2006
6. Boughorbel S, Jarray F, El-Anbari M. Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric. *PLoS ONE* 2017;12:e0177678. <https://doi.org/10.1371/journal.pone.0177678>
7. Bouke MA, Abdullah A. An empirical study of pattern leakage impact during data preprocessing on machine learning-based intrusion detection models reliability. *Expert Systems with Applications* 2023; 230:120715. <https://doi.org/10.1016/j.eswa.2023.120715>.
8. Bukala M, Zaporozhets O, Dobrzańska M, Isaienko V, Chyla A, i in. Noise monitoring for improvement of operational performances of the aircraft in vicinity of airports. *Selected Aspects of Providing the Chemmotological Reliability of the Engineering* 2019:271–9. <https://doi.org/10.18372/38211>
9. Bukala M., Nowoświat A., Chyla A.; Initial Assumptions for the System of Automatic Detection and Classification of Aircraft Noise Events.; *Vibrations in Physical Systems*, 2022, 33(2), 2022208; <https://doi.org/10.21008/J.0860-6897.2022.2.08>.
10. Bukala M.; Zastosowanie wskaźników oceny izolacyjności akustycznej ścian zewnętrznych budynków ze względu na hałas lotniczy; In: *Współczesne zagadnienia z inżynierii lądowej: prace naukowe doktorantów: praca zbiorowa*; Gliwice, Poland, 2020; I. Pokorska-Silva, K. Gromysz; Wydawnictwo Politechniki Śląskiej
11. Carrington AM, Manuel DG, Fieguth PW, Ramsay T, Osmani V, Wernly B, i in. Deep ROC Analysis and AUC as Balanced Average Accuracy to Improve Model Selection, Understanding and Interpretation. *arXiv* 2021. <https://doi.org/10.48550/ARXIV.2103.11357>

12. Chicco D, Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics* 2020;21. <https://doi.org/10.1186/s12864-019-6413-7>
13. Chollet F; *Deep Learning with Python*; Manning Publications Co., 2017
14. Claesen M, De Moor B. *Hyperparameter Search in Machine Learning* 2015. <https://doi.org/10.48550/ARXIV.1502.02127>
15. Cottrell M, Olteanu M, Rossi F, Rynkiewicz J, Villa-Vialaneix N. *Neural Networks for Complex Data*. arXiv 2012. <https://doi.org/10.48550/ARXIV.1210.6511>
16. Dufournet D, Rozwadowski A. *Automatic noise source recognition*, 1997
17. Fawcett T. An introduction to ROC analysis. *Pattern Recognition Letters* 2006;27:861–74. <https://doi.org/10.1016/j.patrec.2005.10.010>
18. Fessahaye F, Perez L, Zhan T, Zhang R, Fossier C, Markarian R, i in. *T-RECSYS: A Novel Music Recommendation System Using Deep Learning*. 2019 IEEE International Conference on Consumer Electronics (ICCE) 2019. <https://doi.org/10.1109/icce.2019.8662028>.
19. Gałuszka, M.; Krótco- i długookresowe wskaźniki oceny hałasu lotniczego. *Rozprawa doktorska*. Promotor: prof. dr hab. inż. Rufin Makarewicz; Poznań 2014
20. Gemmeke JF, Ellis DPW, Freedman D, Jansen A, Lawrence W, Moore RC, i in. *Audio Set: An ontology and human-labeled dataset for audio events*. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) 2017. <https://doi.org/10.1109/icassp.2017.7952261>.
21. Genescà M., Romeu J., Pàmies T., Sánchez A.; *Real time aircraft fly-over noise discrimination*; *Journal of Sound and Vibration*,2009;323:112–29. <https://doi.org/10.1016/j.jsv.2008.12.030>
22. Goodfellow I., Bengio Y., Courville A.; *Deep Learning*; MIT Press; 2016.
23. Gudmundsson S., *General aviation aircraft design*. Woburn, MA: Butterworth-Heinemann, 2013. <https://doi.org/10.1016/C2011-0-06824-2>
24. He K, Zhang X, Ren S, Sun J. *Deep Residual Learning for Image Recognition*. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) 2016. <httpsdoi.org10.1109cvpr.2016.90>
25. Heller N., Anderson D., Baker M., B. Juffer, Papanikolopoulos N.; *Convolutional Neural Networks for Aircraft Noise Monitoring*; 2018; <https://doi.org/10.48550/ARXIV.1806.04779>
26. Hochreiter S, Schmidhuber J. *Long Short-Term Memory*. *Neural Computation* 1997;9:1735–80. <https://doi.org/10.1162/neco.1997.9.8.1735>

27. Hochreiter S. The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions. *Int J Unc Fuzz Knowl Based Syst* 1998;06:107–16. <https://doi.org/10.1142/s0218488598000094>
28. Ioffe S., Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift 2015. <https://doi.org/10.48550/ARXIV.1502.03167>
29. Kapoor R, Kloet N, Gardi A, Mohamed A, Sabatini R. Sound Propagation Modelling for Manned and Unmanned Aircraft Noise Assessment and Mitigation: A Review. *Atmosphere* 2021;12:1424. <https://doi.org/10.3390/atmos12111424>
30. Khamis A, . ZI, . KH, . ATM. The Effects of Outliers Data on Neural Network Performance. *J of Applied Sciences* 2005;5:1394–8. <https://doi.org/10.3923/jas.2005.1394.1398>
31. Kil, J. i Podciborski, T. (2008). Wpływ hałasu lotniczego na sposób zagospodarowania przestrzeni . Dźwięk w krajobrazie jako przedmiot badań interdyscyplinarnych Prace komisji krajobrazu kulturowego T. XI.
32. Kingma DP, Ba J. Adam: A Method for Stochastic Optimization 2014. <https://doi.org/10.48550/ARXIV.1412.6980>
33. Klein BD, Rossin DF. Data quality in neural network models: effect of error rate and magnitude of error on predictive accuracy. *Omega* 1999;27:569–82. [https://doi.org/10.1016/s0305-0483\(99\)00019-5](https://doi.org/10.1016/s0305-0483(99)00019-5)
34. Lecun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. *Proc IEEE* 1998;86:2278–324. <https://doi.org/10.1109/5.726791>
35. Liu P, Qiu X, Huang X. Recurrent Neural Network for Text Classification with Multi-Task Learning 2016. <https://doi.org/10.48550/ARXIV.1605.05101>
36. Luo C, Li X, Wang L, He J, Li D, Zhou J. How Does the Data set Affect CNN-based Image Classification Performance? 2018 5th International Conference on Systems and Informatics (ICSAI) 2018. <https://doi.org/10.1109/icsai.2018.8599448>.
37. Madan, S., Henry, T., Dozier, J. et al. When and how convolutional neural networks generalize to out-of-distribution category–viewpoint combinations. *Nat Mach Intell* 4, 146–153 (2022). <https://doi.org/10.1038/s42256-021-00437-5>
38. Makarewicz R, Dźwięki i fale, Wydawnictwo Naukowe Uniwersytetu im. Adama Mickiewicza w Poznaniu, 2004
39. Márquez-Molina M., Sánchez Fernández L. P., Suárez-Guerra S., Sánchez-Pérez L. A.; Aircraft take-off noises classification based on human auditory's matched features extraction; *Applied Acoustics* 2014, 84:83–90; <https://doi.org/10.1016/j.apacoust.2013.12.003>.

40. Matthews BW. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. *Biochimica et Biophysica Acta (BBA) - Protein Structure* 1975;405:442–51. [https://doi.org/10.1016/0005-2795\(75\)90109-9](https://doi.org/10.1016/0005-2795(75)90109-9)
41. Osses Vecchi A., Glisser Donoso M., C. Büchi G., Guzmán López R.; Comparison of methodologies for continuous noise monitoring and aircraft detection in the vicinity of airports; Proceedings of the 18th International Congress on Sound & Vibration, Rio de Janeiro, Brazil, 10-14 July 2011
42. Pamuła H.; Nowe metody akustycznej identyfikacji ptaków migrujących nocą; Rozprawa doktorska; Kraków, 2022
43. Park DS, Chan W, Zhang Y, Chiu C-C, Zoph B, Cubuk ED, i in. SpecAugment: A Simple Data Augmentation Method for Automatic Speech Recognition. *Interspeech* 2019 2019. <https://doi.org/10.21437/interspeech.2019-2680>
44. Piczak KJ. ESC. Proceedings of the 23rd ACM International Conference on Multimedia 2015. <https://doi.org/10.1145/2733373.2806390>.
45. Raghavan V, Bollmann P, Jung GS. A critical investigation of recall and precision as measures of retrieval system performance. *ACM Trans Inf Syst* 1989;7:205–29. <https://doi.org/10.1145/65943.65945>
46. Rajpert T.; Hałas lotniczy i sposoby jego zwalczania; WKŁ; Warszawa 1980
47. Rosin C., Barbo B.; Aircraft Noise Monitoring: Noise Level Shape and Spectrum Pattern Recognition Applied to Aircraft Noise Detection; Proceedings of the Internoise 2010, Lisbon, Portugal, 13-16 June 2010
48. Sánchez Fernández L. P., Sánchez Pérez L. A., Carbajal Hernández J. J.; Monitoring System of Environment Noise and Pattern Recognition; *International Journal of Energy and Environment* 2021,15:10–7; <https://doi.org/10.46300/91012.2021.15.2>
49. Santafe G, Inza I, Lozano JA. Dealing with the evaluation of supervised classification algorithms. *Artif Intell Rev* 2015;44:467–508. <https://doi.org/10.1007/s10462-015-9433-y>
50. Shalev-Shwartz S., Ben-David S., *Understanding Machine Learning: From Theory to Algorithms*, Cambridge University Press, 2014
51. Sharma A, Kumar D.; Classification with 2-D Convolutional Neural Networks for breast cancer diagnosis. *arXiv* 2020. <https://doi.org/10.48550/ARXIV.2007.03218>
52. Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., Dropout: A Simple Way to Prevent Neural Networks from Overfitting, *Journal of Machine Learning Research*, 15(56):1929–1958, 2014
53. Tadeusiewicz R.; Wprowadzenie do sieci neuronowych; Materiały Seminarium NeuroMet'97, AGH, Kraków 1997

54. Thambawita V, Strümke I, Hicks SA, Halvorsen P, Parasa S, Riegler MA. Impact of Image Resolution on Deep Learning Performance in Endoscopy Image Classification: An Experimental Study Using a Large Dataset of Endoscopic Images. *Diagnostics* 2021;11:2183. <https://doi.org/10.3390/diagnostics11122183>
55. The Science Behind Takeoff Speeds: How Fast Do A Plane Go at Takeoff?, online: <https://defensebridge.com/article/the-science-behind-takeoff-speeds-how-fast-do-a-plane-go-at-takeoff.html>, dostęp: 23.03.2024
56. Unal I. Defining an Optimal Cut-Point Value in ROC Analysis: An Alternative Approach. *Computational and Mathematical Methods in Medicine* 2017;2017:1–14. <https://doi.org/10.1155/2017/3762651>
57. Wszolek W., Kłaczyński M.; Recognition of aircraft noise in long-term environmental monitoring; *Mechanics and Control*, 2010, 29(4), 192-197
58. Yan, S., Understanding LSTM and Its Diagrams, <https://medium.com/mlreview/understanding-lstm-and-its-diagrams-37e2f46f1714>, dostęp 18 sierpnia 2024
59. Yao Y, Rosasco L, Caponnetto A. On Early Stopping in Gradient Descent Learning. *Constr Approx* 2007;26:289–315. <https://doi.org/10.1007/s00365-006-0663-2>
60. Youden WJ. Index for rating diagnostic tests. *Cancer* 1950;3:32–5. [https://doi.org/10.1002/1097-0142\(1950\)3:1<32::aid-cncr2820030106>3.0.co;2-3](https://doi.org/10.1002/1097-0142(1950)3:1<32::aid-cncr2820030106>3.0.co;2-3)
61. Yun D, Yong Y, Kaijun X, Zhaoyu X. Progress of ADS-B IN technology in civil aviation applications. 2022 7th International Conference on Communication, Image and Signal Processing (CCISP) 2022. <https://doi.org/10.1109/ccisp55629.2022.9974442>

Normy i akty normatywne

62. Guide to the expression of uncertainty in measurement – Part 6: Developing and using measurement models, CGM GUM-6:2020, JCGM 2020
63. ICAO, Załącznik 16 do Konwencji o międzynarodowym lotnictwie cywilnym. Ochrona środowiska. Tom I Hałas statków powietrznych. Lipiec 2014 r.
64. ICAO, DOC 8643, Aircraft Type Designators
65. IEC 61672-1:2013 Electroacoustics - Sound level meters - Part 1: Specifications
66. ISO 1996-2:2017 Acoustics. Description, measurement and assessment of environmental noise. Part 2: Determination of sound pressure levels
67. ISO 226:2003, Acoustics - Normal equal-loudness-level contours
68. ISO, International Standard ISO 20906:2009/Amd 1:2013 (E): Acoustics – Unattended monitoring of Aircraft sound in the vicinity of airports, Geneva, 2013

69. Konwencja o międzynarodowym lotnictwie cywilnym, podpisana w Chicago dnia 7 grudnia 1944 r. (Dz.U. 2012 poz. 370), Załącznik 16, Tom I – Hałas statków powietrznych
70. PN-EN 61260-1:2015-01 Elektroakustyka - Filtry pasmowe o szerokości oktawy i części oktawy - Część 1: Wymagania
71. PN-EN 61672-1:2014-03, Elektroakustyka - Mierniki poziomu dźwięku - Część 1: Wymagania
72. PN-ISO 1996-1:2006 Akustyka. Opis, pomiary i ocena hałasu środowiskowego. Część 1: Wielkości podstawowe i procedury oceny
73. PN-ISO 1996-2:1999 Akustyka. Opis i pomiary hałasu środowiskowego. Zbieranie danych dotyczących sposobu zagospodarowania terenu
74. Procedury Służb Żeglugi Powietrznej. Zarządzanie Ruchem Lotniczym (PL-4444). Załącznik do wytycznych Nr 13 Prezesa Urzędu Lotnictwa Cywilnego z dnia 8 września 2014 r.
75. Rozporządzenie Ministra Środowiska z dnia 14 czerwca 2007 r. w sprawie dopuszczalnych poziomów hałasu w środowisku (Dz.U. 2014 poz. 112)
76. Rozporządzenie Ministra Środowiska z dnia 16 czerwca 2011 r. w sprawie wymagań w zakresie prowadzenia pomiarów poziomów substancji lub energii w środowisku przez zarządzającego drogą, linią kolejową, linią tramwajową, lotniskiem lub portem (Dz. U. 2011 nr 140 poz. 824, Dz. U. 2011 nr 288 poz. 1697)
77. SAE AIR 1845A:2012-08-16 Procedure for the Calculation of Airplane Noise in the Vicinity of Airports (Stabilized: Aug 2012)
78. Ustawa z dnia 27 kwietnia 2001 r. Prawo ochrony środowiska. (Dz. U. 2022 poz. 2556, Dz. U. 2023 poz. 2029)
79. Ustawa z dnia 3 lipca 2002 r. Prawo lotnicze. (Dz.U. 2023 poz. 2110)

Inne źródła

80. ACI, Analiza ruchu lotniczego w roku 2023, <https://www.aci-europe.org/media-room/477-passenger-traffic-reaches-nearly-95-of-pre-pandemic-levels-in-2023.html>, dostęp: lipiec 2024
81. Acoustic Glossary, Sound Level Frequency Weightings : A, B, C, D, Lin, Z: <https://www.acoustic-glossary.co.uk/frequency-weighting.htm>, dostęp: 15.09.2024
82. AIP Polska – AIP VFR, Służba Informacji Lotniczej, online: <https://www.ais.pansa.pl/publikacje/aip-vfr/>, dostęp: 26.12.2023
83. Dane katalogowe firmy RION, Aircraft Noise Monitoring System: https://rion-sv.com/download/catalog/p38veq00000039j0-att/NA-39A_DataSheet.pdf, dostęp: 15.09.2024

- 84.** ICAO, Effects of Novel Coronavirus (COVID-19) on Civil Aviation: Economic Impact Analysis, Mottréal, 2021
- 85.** Instrukcja obsługi stacji monitoringu hałasu SV200, SVANTEK
- 86.** Instrukcja obsługi stacji monitoringu hałasu SV210C, SVANTEK
- 87.** Katalog produktów firmy GRAS,
https://www.grasacoustics.com/files/GRASProductCatalogue_WEB.pdf, dostęp: 27.01.2024 r.
- 88.** Podkład kartograficzny: OpenStreetMap
- 89.** WHO, Environmental noise guidelines for the European Region:
<https://iris.who.int/bitstream/handle/10665/279952/9789289053563-eng.pdf?sequence=1>, dostęp 07.08.2024

SPIS ILUSTRACJI

Rys. 1.1	Statystyki ruchu lotniczego w latach 1945 – 2021 [84].	8
Rys. 2.1	Krzywe jednakowej głośności [67].	16
Rys. 2.2	Charakterystyka korekcyjna A z zaznaczeniem punktów dla pasm 1/3-oktawowych [71].	16
Rys. 2.3	Przykład powiązania równoważnego poziomu dźwięku i poziomu ekspozycji na hałas. Opracowanie własne.	19
Rys. 2.4	Rzeczywiste charakterystyki filtrów 1/3-oktawowych dla pasma oktawowego 1 kHz dla stacji monitoringu hałasu SVANTEK SV200 [85].	21
Rys. 2.5	Przykładowy fragment historii czasowej poziomu dźwięku, zawierający zdarzenia akustyczne związane z hałasem lotniczym. Opracowanie własne.	22
Rys. 2.6	Schemat systemu monitoringu hałasu [8].	23
Rys. 2.7	Schemat algorytmu detekcji [68].	24
Rys. 2.8	Definicja zdarzenia akustycznego [68].	25
Rys. 2.9	Charakterystyki widmowe hałasu samolotu odrzutowego opisane przez Roisina i Barbo [46].	27
Rys. 2.10	Schemat algorytmu, opracowanego przez Asensio i in. [2].	27
Rys. 3.1	Schemat dwuwarstwowej sieci neuronowej. Opracowanie własne.	31
Rys. 3.2	Schemat obrazujący zasadę działania warstwy konwolucyjnej oraz warstwy zbierającej na przykładzie max-poolingu. Konwolucja ze skokiem o wielkości 1 (ang. stride), warstwa zbiorcza ze skokiem o wielkości 2, bez paddingu [42].	34
Rys. 3.3	Architektura sieci LeNet-5 [34]. Opracowanie własne.	35
Rys. 3.4	Struktura bloku rezyduального [24].	35
Rys. 3.5	Schemat pojedynczej komórki sieci LSTM [58].	37
Rys. 3.6	Macierz pomyłek dla klasyfikacji binarnej. Opracowanie własne za [17].	38
Rys. 4.1	Procentowy udział w ruchu lotniczym w roku 2022 na lotniskach objętych pomiarami. Opracowanie własne na podstawie danych z systemu monitoringu.	44
Rys. 4.2	Lokalizacja Portu Lotniczego im. Lecha Wałęsy w Gdańsku wraz z miejscem instalacji punktów monitoringu hałasu [88].	45
Rys. 4.3	Przebieg tras startów i lądowań w roku 2022 [88].	47
Rys. 4.4	Lokalizacja Międzynarodowego Portu Lotniczego im. Wojciecha Korfanteo w Pyrzowicach wraz z miejscem instalacji punktów monitoringu hałasu [88].	48
Rys. 4.5	Przebieg tras startów i lądowań w roku 2022 [88].	50
Rys. 4.6	Przykładowe usytuowanie mikrofonu pomiarowego z zaznaczeniem kryteriów metodyki referencyjnej [76]. Kolorem czerwonym oznaczono fragmenty obiektów znajdujące się poza dozwoloną strefą. Opracowanie własne.	51
Rys. 4.7	Lokalizacja punktu pomiarowego PG1 [88] wraz z dokumentacją fotograficzną.	52
Rys. 4.8	Lokalizacja punktu pomiarowego PG2 [88] wraz z dokumentacją fotograficzną.	53

Rys. 4.9	Lokalizacja punktu pomiarowego PG3 [88] wraz z dokumentacją fotograficzną.....	54
Rys. 4.10	Lokalizacja punktu pomiarowego PG4 [88] wraz z dokumentacją fotograficzną.....	55
Rys. 4.11	Lokalizacja punktu pomiarowego PK1 [88] wraz z dokumentacją fotograficzną.....	56
Rys. 4.12	Lokalizacja punktu pomiarowego PK2 [88] wraz z dokumentacją fotograficzną.....	57
Rys. 4.13	Wnętrze stacji SV210C [86] oraz mikrofon GRAS 41AM [87].	58
Rys. 4.14	Schemat ideowy stacji SV210C [86].	59
Rys. 4.15	Fotografia stacji monitoringu hałasu SV200 [85].	59
Rys. 4.16	Wizualizacja przykładowych tras rejestrowanych przez odbiornik ADS-B (a) oraz wykorzystywane urządzenie (b).	60
Rys. 4.17	Lokalizacja punktów pomiarowych w lokalnym układzie współrzędnych z początkiem w najbliższym progu drogi startowej. Opracowanie własne.	61
Rys. 4.18	Analiza widm 1/3-oktawowych zarejestrowanych w analizowanych punktach pomiarowych dla operacji startu turboodrzuowego samolotu pasażerskiego B738. Opracowanie własne.	62
Rys. 4.19	Analiza trzech widm 1/3-oktawowych zarejestrowanych w punkcie pomiarowym PG2 dla operacji startu turboodrzuowego samolotu pasażerskiego B738. Opracowanie własne.	63
Rys. 4.20	Zestawienie zarejestrowanych w punktach pomiarowych historii czasowych poziomu dźwięku A dla operacji startu turboodrzuowego samolotu pasażerskiego B738. Opracowanie własne.	64
Rys. 4.21	Przykład wyznaczania czasu trwania zdarzenia oraz gradientów. Opracowanie własne.	65
Rys. 4.22	Porównanie widm 1/3-oktawowych oraz historii czasowych poziomu dźwięku A samolotu turboodrzuowego B738 i samolotu turbośmigłowego ATR72 w punkcie pomiarowym PK1. Opracowanie własne.	66
Rys. 4.23	Ekran korelacji zdarzeń dostępny dla operatorów.	67
Rys. 4.24	Histogramy czasów zdarzeń akustycznych w wybranych punktach pomiarowych. Opracowanie własne.	70
Rys. 4.25	Przykłady zdarzeń akustycznych o różnych czasach trwania, występujące w zbiorze danych wejściowych. Opracowanie własne.	71
Rys. 4.26	Zestawienie widm hałasu lotniczego i tła akustycznego zarejestrowanych w wybranych punktach pomiarowych. Opracowanie własne.	72
Rys. 4.27	Przykład zakłóconego zdarzenia akustycznego w postaci historii poziomu dźwięku A (po lewej) oraz spektrogramu (po prawej). Opracowanie własne.	73
Rys. 5.1	Przykład wyznaczania czasu rozpoczęcia (t_1) oraz czasu zakończenia (t_2) zdarzenia akustycznego. Opracowanie własne.	75
Rys. 5.2	Fragment interfejsu użytkownika aplikacji testowej.	78
Rys. 5.3	Analiza gradientów narastania i zaniku dla zbioru treningowego na przykładzie lotniska EPGD. Opracowanie własne.	78
Rys. 5.4	Wyniki treningu sieci CNN [25] na własnych danych wejściowych.	79
Rys. 5.5	Oczekiwany sposób funkcjonowania algorytmu detekcji hałasu lotniczego. Opracowanie własne.	83

Rys. 5.6	Trasa startu (a) oraz jego profil wysokościowy (b) i odpowiadające jej zdarzenia akustyczne rejestrowane w poszczególnych punktach pomiarowych (c). Opracowanie własne.....	84
Rys. 5.7	Pierwotna wersja architektury systemu detekcji. Opracowanie własne.	85
Rys. 5.8	Docelowa wersja architektury systemu detekcji. Opracowanie własne.	87
Rys. 6.1	Przykład ramki przedstawionej w formie spektrogramu 1/3-oktawowego przedstawiający a) sygnał klasy negatywnej, b) sygnał klasy pozytywnej. Opracowanie własne.	90
Rys. 6.2	Liczba ramek poszczególnych klas dla treningowego zbioru danych.	91
Rys. 6.3	Przykład dwóch zdarzeń zachodzących w jednym czasie. Opracowanie własne.	92
Rys. 6.4	Liczba ramek poszczególnych klas dla treningowego zbioru danych. Opracowanie własne.	94
Rys. 6.5	Przykłady zakłóconych zdarzeń akustycznych, związanych z przelotami statku powietrznego. Opracowanie własne.....	95
Rys. 6.6	Spektrograficzne reprezentacje zdarzenia a) zakłóconego, bez widocznego wpływu na charakter spektrogramu, b) zakłóconego z widocznym wpływem na charakter spektrogramu, c) niezakłóconego. Opracowanie własne.	95
Rys. 6.7	Podstawowy wariant architektury konwolucyjnej sieci neuronowej.	98
Rys. 6.8	Blok rezydualny, wykorzystany w architekturach resnet_1, resnet_2 i resnet_3.....	98
Rys. 6.9	Schemat sieci resnet_1.....	99
Rys. 6.10	Schemat sieci resnet_2.....	100
Rys. 6.11	Schemat sieci resnet_3.....	100
Rys. 6.12	Przykład wyboru plików z danymi treningowymi. Opracowanie własne.	102
Rys. 6.13	Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 1.	104
Rys. 6.14	Krzywe ROC (lewa strona) oraz PR (prawa strona) dla badanych poziomów filtracji przy ramce o długości a) 2.5 s, b) 45 s. W legendzie zawarto wartości pól pod krzywą.	105
Rys. 6.15	Krzywe ROC (lewa strona) oraz PR (prawa strona) dla badanych długości ramki przy poziomie filtracji a) brak filtracji, b) filtracja ramek przejściowych, c) filtracja zdarzeń o niewłaściwym czasie trwania. W legendzie zawarto wartości pól pod krzywą.	106
Rys. 6.16	Wartość funkcji straty treningu i walidacji w funkcji epoki dla długości ramki 45 s i poziomu filtracji a) 1a, b) 4.....	107
Rys. 6.17	Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 2.	109
Rys. 6.18	Wartości powierzchni pod krzywą PR w zależności od architektury sieci.	110
Rys. 6.19	Krzywe ROC (lewa strona) oraz PR (prawa strona) dla wybranych długości ramki a) 2,5 s, b) 15 s, c) 45 s. W legendzie zawarto wartości pól pod krzywą.....	111
Rys. 6.20	Wartość funkcji straty treningu i walidacji w funkcji epoki dla długości ramki 45 s i architektury sieci a) resnet 2, b) resnet 3, c) base cnn.	112
Rys. 7.1	Ilustracja złożenia wartości x_i dla poszczególnych ramek sygnału w uśredniony wskaźnik identyfikacji hałasu lotniczego. Opracowanie własne.	116

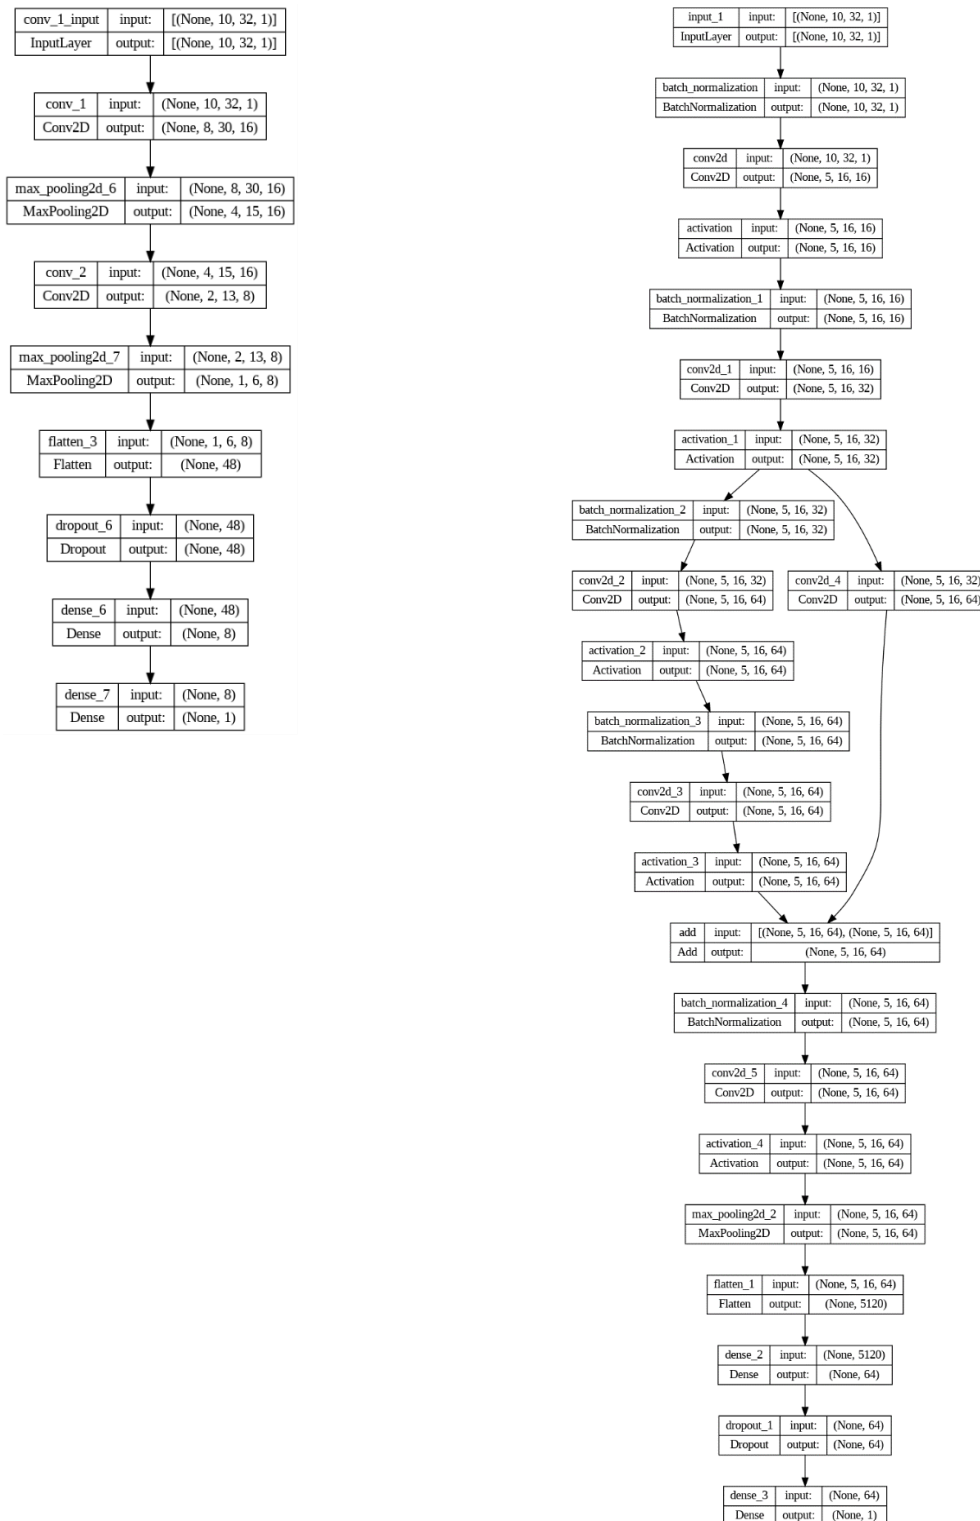
Rys. 7.2	Strojenie progu odcięcia metodą a) doboru wskaźnika F1, b) doboru wskaźnika MCC, c) wyznaczenia z krzywej PR, d) wyznaczenia z krzywej ROC metodą Yourdena.....	118
Rys. 7.3	Zestawienie wartości powierzchni pod krzywą ROC i PR – eksperyment 3.	119
Rys. 7.4	Wartości wskaźników F ₁ i MCC dla najlepszych modeli, w funkcji długości ramki.....	120
Rys. 7.5	Rozkład wartości wskaźnika F1 strojonych modeli dla długości ramki a) 2,5 s, b) 5 s, c) 10 s, d) 15 s, e) 30 s, f) 45 s.	121
Rys. 7.6	Rezultaty klasyfikacji w dziedzinie czasu: po lewej sieć resnet_2, próba 3, strojenie w punkcie PK2 metodą fscore, po prawej sieć base_cnn, próba 4, strojenie w punkcie PG3 metodą MCC.....	123
Rys. 7.7	Porównanie czasów początku zdarzeń odniesienia oraz zdarzeń wykrytych automatycznie.....	124
Rys. 7.8	Schemat sieci lstm_1 (po lewej) i lstm_2 (po prawej).	125
Rys. 7.9	Schemat sieci mixed_1 (po lewej) i mixed_2 (po prawej).	126
Rys. 7.10	Wyniki badania sieci rekurencyjnych, zestawione w rezultatach dla sieci rezydualnych resnet_2 i resnet_3.	127
Rys. 8.1	Widok ekranu użytkownika oprogramowania SMHL. Wyróżniony fragment sygnału został oznaczony przez badany algorytm jako hałas lotniczy.....	128
Rys. 8.2	Widok wykresu historii czasowej na platformie SvanNET, z zaznaczeniem wykrytych przez algorytm zdarzeń związanych z przelotami statków powietrznych.	129

SPIS TABEL

Tab. 4.1	Podstawowe dane lotniska EPGD [78].	45
Tab. 4.2	Procentowy udział w ruchu lotniczym w roku 2022 w Porcie Lotniczym im. L. Wałęsy w Gdańsku. Opracowanie własne na podstawie danych z systemu monitoringu.	46
Tab. 4.3	Podstawowe dane lotniska EPKT [78].	48
Tab. 4.4	Procentowy udział w ruchu lotniczym w roku 2022 w Międzynarodowym Porcie Lotniczym im. Wojciecha Korfanteo w Pyrzowicach. Opracowanie własne na podstawie danych z systemu monitoringu.	49
Tab. 4.5	Charakterystyka punktu pomiarowego PG1.	52
Tab. 4.6	Charakterystyka punktu pomiarowego PG2.	53
Tab. 4.7	Charakterystyka punktu pomiarowego PG3.	54
Tab. 4.8	Charakterystyka punktu pomiarowego PG4.	55
Tab. 4.9	Charakterystyka punktu pomiarowego PG2.	56
Tab. 4.10	Charakterystyka punktu pomiarowego PG2.	57
Tab. 4.11	Szerokości zdarzenia akustycznego związanego ze startem turbodrzutowego samolotu B738 w poszczególnych punktach pomiarowych. Opracowanie własne.	65
Tab. 4.12	Podsumowanie zarejestrowanych danych.	68
Tab. 5.1	Porównanie jakości detekcji dla dwóch badanych metod.	80
Tab. 6.1	Liczebność zbiorów danych treningowych dla poszczególnych długości ramki.	97
Tab. 6.2	Liczebność zbiorów danych treningowych dla poszczególnych długości ramki.	97
Tab. 6.3	Zestawienie wariantów danych do treningu.	102
Tab. 6.4	Wartości powierzchni pod krzywą ROC – eksperyment 1.	103
Tab. 6.5	Wartości powierzchni pod krzywą PR – eksperyment 1.	103
Tab. 6.6	Zestawienie trenowanych architektur.	108
Tab. 6.7	Wartości powierzchni pod krzywą ROC – eksperyment 2/.	109
Tab. 6.8	Wartości powierzchni pod krzywą PR – eksperyment 2.	109
Tab. 7.1	Zestawienie wariantów danych do treningu.	117
Tab. 7.2	Wartości powierzchni pod krzywą ROC – eksperyment 3.	119
Tab. 7.3	Wartości powierzchni pod krzywą PR – eksperyment 3.	119
Tab. 7.4	Wyniki po strojeniu dla 20 najlepszych realizacji.	122
Tab. 7.5	Wyniki klasyfikacji najlepiej dostrojonych modeli.	127

DODATKI

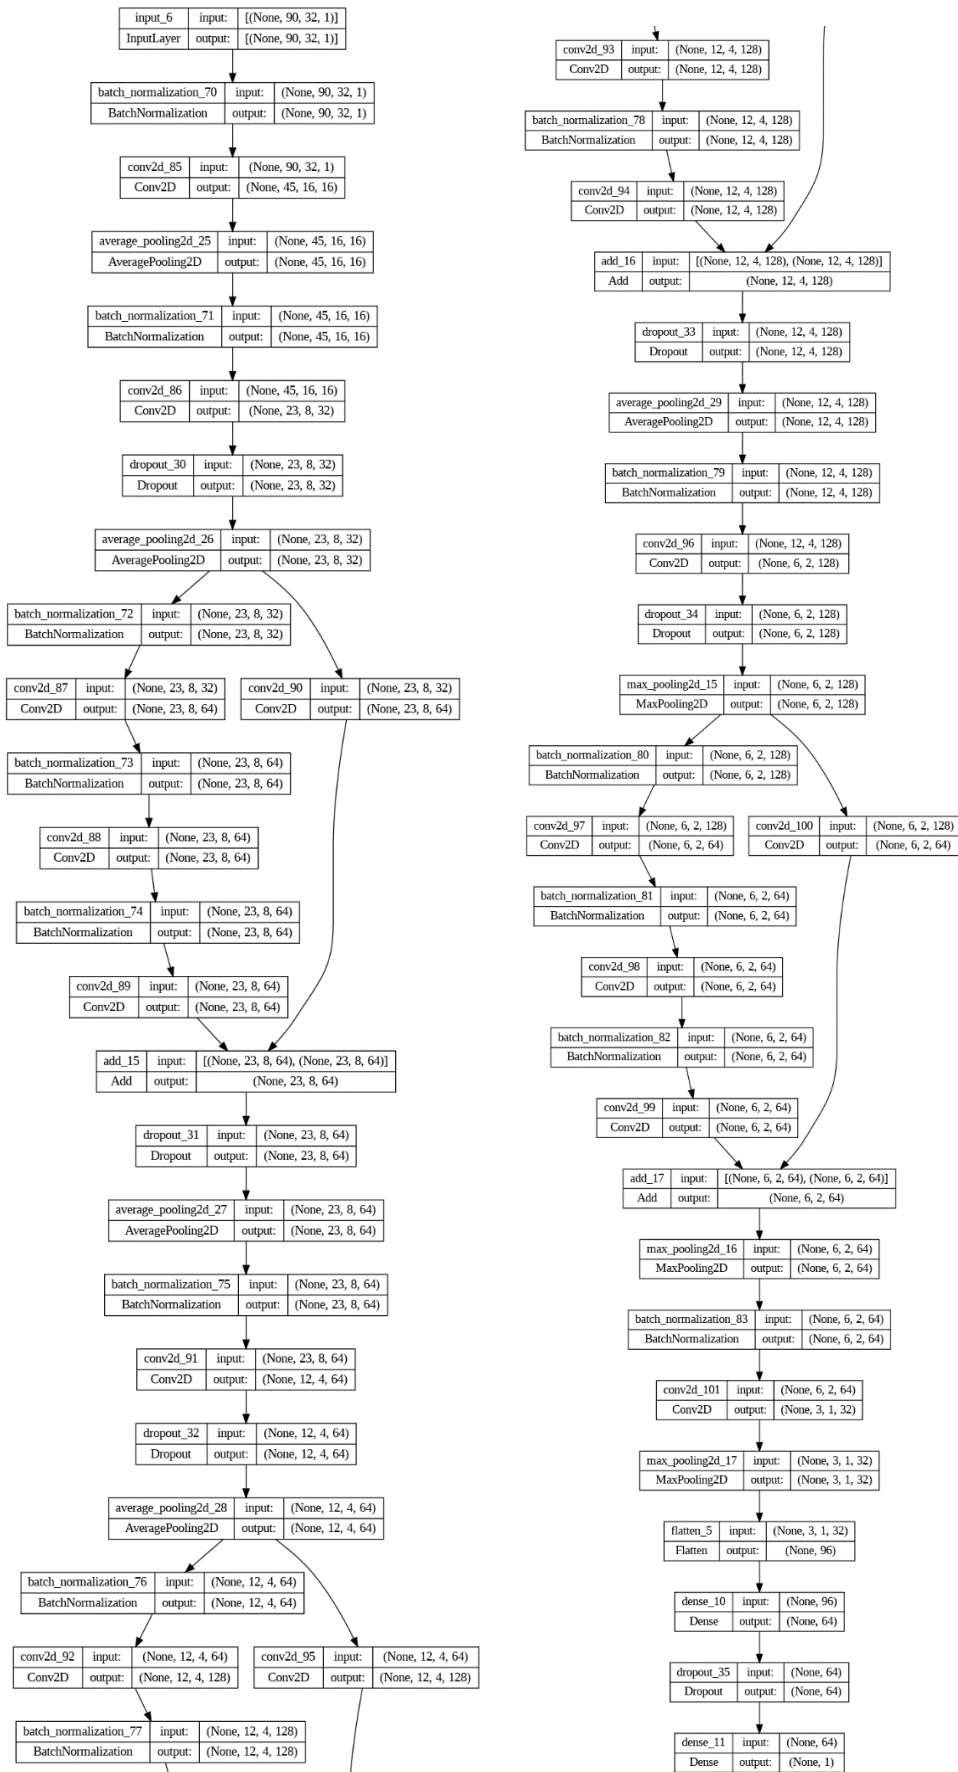
A. Szczegóły badanych architektur sieci



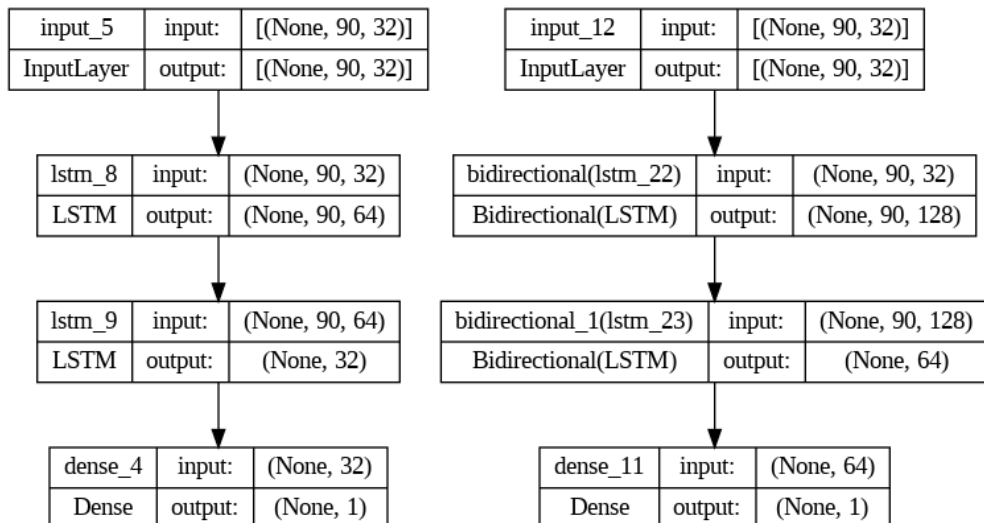
Rys. Z-1 Architektura base cnn (po lewej) i resnet 1 (po prawej)



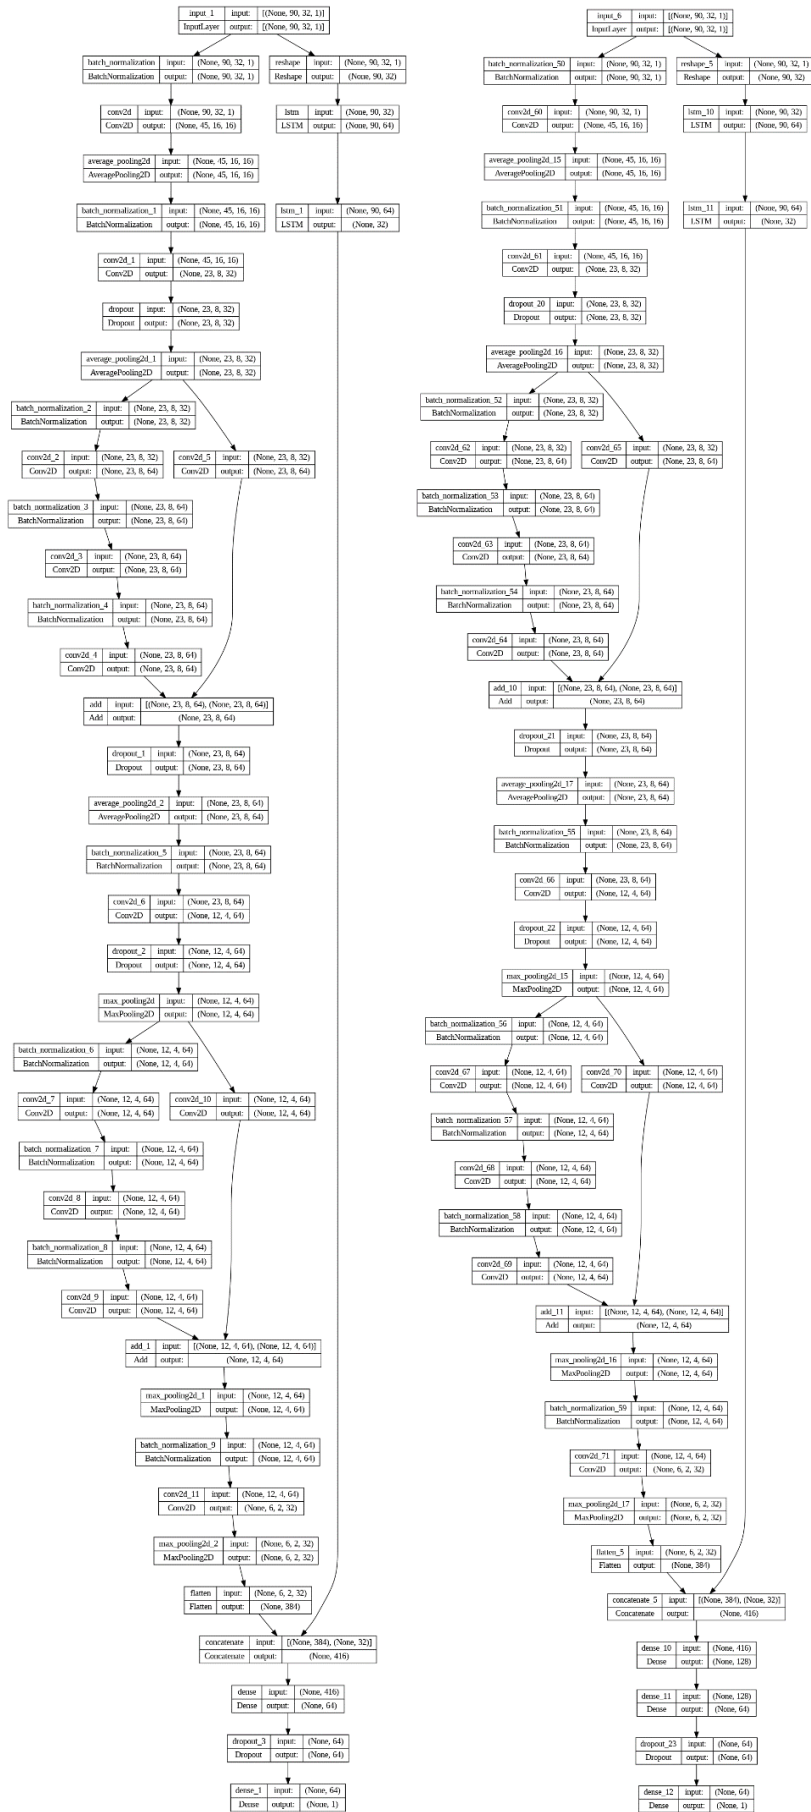
Rys. Z-2 Architektury resnet 2, resnet 2a, resnet 2b (od lewej do prawej)



Rys. Z-3 Architektura resnet 3



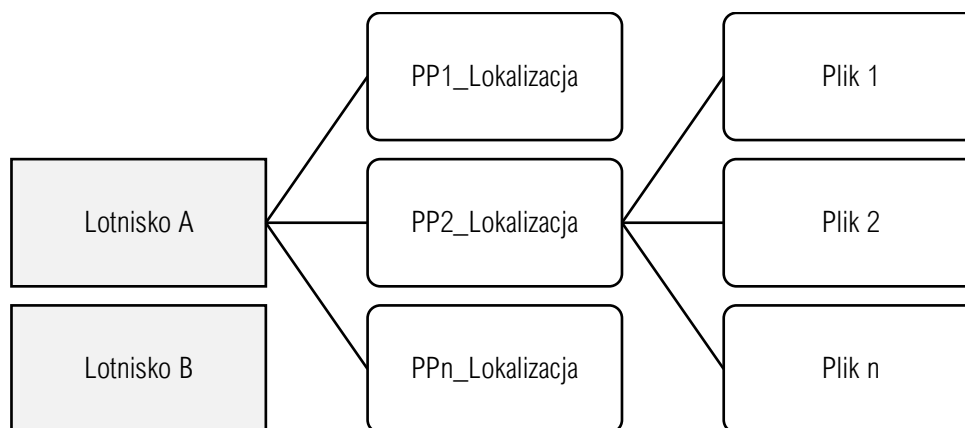
Rys. Z-4 Architektury lstm 1 (po lewej) i lstm 2 (po prawej)



Rys. Z-5 Architektury mixed 1 (po lewej) i mixed 2 (po prawej)

B. Szczegółowy opis implementacji systemu detekcji

Opracowany algorytm w pierwszej kolejności wdrożono w Systemie Monitoringu Hałasu Lotniczego w firmie SVANTEK Sp. z o.o. Do wytrenowanego modelu przekazywane były dane wejściowe, pozyskane z plików *svl*, zawierających 1/3-oktawowe spektrogramy oraz wartość poziomu dźwięku A, rejestrowane w punktach pomiarowych. Pliki zorganizowane były w drzewiastej strukturze katalogów (Rys. Z-6).



Rys. Z-6 Struktura katalogów z danymi akustycznymi

Pliki przetwarzane były przy użyciu stworzonego w języku Python skryptu, który wybierał pliki do analizy na podstawie podanej ścieżki dostępowej do katalogu lotniska oraz zakresu dat. Spośród dostępnych plików wybierane były jedynie te, które zapisano w wybranym okresie.

Skrypt parsował pliki, przetwarzając je do formatu tekstowego *csv* a pozyskane multispektrum konwertował do postaci trójwymiarowych macierzy ramek widmowych. Każda macierz odpowiadała zawartości jednego pliku. Macierze stanowiły dane wejściowe do wytrenowanego modelu (TD_90-pure resnet_2/run 2). Po przeprowadzeniu predykcji uzyskiwano wektor wartości wskaźnika identyfikacji hałasu lotniczego, który następnie był rektyfikowany przy użyciu wyznaczonego dla modelu optymalnego progu odcięcia. Z powstałego przebiegu wyznaczano punkty t_1 i t_2 , odpowiadające początkowi i końcowi zdarzenia akustycznego. Zdarzenia były zapisywane do systemowej bazy danych MS SQL, przy użyciu modułu *pyodbc*. Miejscem zapisu zdarzeń była tabela *DaneAkustyczne*, o strukturze przedstawionej w Tab. Z-1.

Tab. Z-1 Struktura tabeli DaneAkustyczne

Nazwa pola	Typ pola	Opis
Lotnisko_ID	int	Numer analizowanego lotniska
PunktPomiarowy_ID	int	Numer analizowanego punktu pomiarowego
Czas	datetime	Czas próbki z przyrządu pomiarowego
LEQ	float	Wartość poziomu dźwięku próbki
Wykryty	int	Informacja o wykryciu statku powietrznego: 1 : próbka zawiera sygnał hałasu lotniczego 0 : próbka zawiera sygnał tła

Dla każdego z wykrytych zdarzeń skrypt zapisywał w polu *Wykryty* wartość 1, w zakresie czasu odpowiadającym czasowi trwania zdarzenia. Numer lotniska podawany był jako parametr przed rozpoczęciem klasyfikacji, zaś numer punktu pomiarowego pozyskiwany był z nazwy katalogu, zawierającego dany plik pomiarowy.

Poniższy listing przedstawia kod źródłowy skryptu.

```

from datetime import datetime
import pandas as pd
import numpy as np
import pyodbc
from pathlib import Path
from svn_parser import parse_svn
from tensorflow import keras
from keras.saving import load_model
import pickle

def start_connection():
    server = 'server'
    database = 'SMHL'
    username = 'username'
    password = 'password'

    cnxn = pyodbc.connect('DRIVER={ODBC Driver 17 for SQL Server};SERVER='+server+
';DATABASE='+database+';UID='+username+';PWD='+ password)
    return cnxn

def input_tensor(noise_data, frame_len, offset, scaler):
    tensor = np.ndarray((noise_data.shape[0], frame_len, 32, 1), dtype=float)

    for i, frame in enumerate(get_frame(noise_data, frame_len)):
        f = frame[:, 1:]
        if not np.any(np.isnan(np.asarray(f, dtype=float))):
            tensor[i, :, :, :] = np.expand_dims((f + offset)/scaler, axis=2)
        else:
            tensor[i, :, :, :] = np.zeros((frame_len,32,1))
    return tensor

def get_frame(raw_data, frame_len, step = 1):
    n = 0
    samples_count = raw_data.shape[0]

    while n + frame_len < samples_count:
        yield raw_data[n:n+frame_len]
        n += step

def average_predictions(input_pred, frame_len):
    prediction = np.zeros(input_pred.shape[0])
    for i, p in enumerate(input_pred):
        if i < len(input_pred) - frame_len:
            prediction[i:i+frame_len] = prediction[i:i+frame_len] + np.repeat([p], frame_len)

    prediction /= frame_len
    return prediction

# define noise files, dates range, airport, point
main_dir = Path('/SvanData/'), input('Monitoring data directory: ')
airport = int(input("Airport id: "))

```

```

month = int(input("Month: "))
month_str = '0' + str(month)
month_str = month_str[-2:]
next_month = '0' + str(month + 1)
next_month = next_month[-2:]

date_from = datetime.strptime(f'2024-{month_str}-01 04:00', '%Y-%m-%d %H:%M')
date_to = datetime.strptime(f'2024-{next_month}-01 04:10', '%Y-%m-%d %H:%M')
conn = start_connection()

first_file = input('Enter first file: ')

# open model
model_dir = Path("TD_90-pure resnet_2/run 2")
frame_len = 90
threshold = 0.574
model = load_model(model_dir)
info_path = model_dir.joinpath('misc/scaling_info.dat').as_posix()
with open(info_path, 'rb') as info_file:
    offset, scaler = pickle.load(info_file)

for point_dir in main_dir.iterdir():
    point_number = int(point_dir.parts[-1][2])
    for n, file in enumerate(point_dir.glob('*svl')):
        file_date = datetime.fromtimestamp(file.lstat().st_mtime)
        if file_date < date_from or file_date > date_to: # pomiń pliki spoza zakresu dat
            continue

        print('Processing', file, file_date)

        if first_file:
            if file.stem != first_file:
                print(f'    First file set to {first_file}. Skipping.')
                continue
            else:
                first_file = None

        # open noise file
        noise_data = parse_svn(file, clear_tmp=True)
        if noise_data.shape[0] < 10 * frame_len: # pomiń krótkie pliki
            continue

        print('    Preparing input tensor')
        time_vector = pd.DataFrame(noise_data[:,0]).map(lambda x: x.to_datetime64()).to_numpy()
        input_data = input_tensor(noise_data, frame_len, offset, scaler)

        # calculate aircraft curve
        print('    Running classifier')
        aircraft_curve = average_predictions(model.predict(input_data), frame_len)
        classification = (aircraft_curve > threshold).astype('int')

        # create events table
        print('    Extracting events')
        events = []
        ev_start = None
        for i, v in enumerate(classification):
            if v == 1 and not ev_start:
                ev_start = i

            if v == 0 and ev_start and i - ev_start > 2 * 10:
                events.append([time_vector[ev_start], time_vector[i-1]])
                ev_start = None

        evs = np.asarray(events)
        evs = evs.reshape(evs.shape[:2])

        df = pd.DataFrame(evs)
        df.rename(columns={0: 'date_time_start', 1: 'date_time_end'}, inplace=True)

        cursor = conn.cursor()

        print(f'    Saving {df.shape[0]} events to database')
        for index, row in df.iterrows():
            t1 = row['date_time_start'].strftime('%Y-%m-%d %H:%M:%S.%f')[:-3]
            t2 = row['date_time_end'].strftime('%Y-%m-%d %H:%M:%S.%f')[:-3]
            q = f"UPDATE DaneAkustyczne SET Wykryty = 1 WHERE Lotnisko_ID = {airport} and
PunktPomiarowy_ID = {point_number} and Czas >= '{t1}' and Czas <= '{t2}'"
            cursor.execute(q)
            conn.commit()

        cursor.close()
conn.close()

```