



POLSKO-JAPOŃSKA
AKADEMIA TECHNIK
KOMPUTEROWYCH

ROZPRAWA DOKTORSKA

**Predykcja parametrów organów
i pizczątek organowych na podstawie
analizy pomiarów nieinwazyjnych**

Mgr inż. Damian Tadeusz WĘGRZYN

Polsko-Japońska Akademia Technik Komputerowych
Wydział Informatyki

Promotor:

Dr hab. Alicja WIECZORKOWSKA

Promotor pomocniczy:

Dr inż. Piotr WRZECIONO

Warszawa, 2026

Oświadczenie

Ja, niżej podpisany Damian Tadeusz Węgrzyn, autor rozprawy doktorskiej pt. „Predykcja parametrów organów i pischczalek organowych na podstawie analizy pomiarów nieinwazyjnych”, oświadczam, iż wyżej wskazaną rozprawę napisałem samodzielnie i żaden jej fragment lub całość nie były pisane przez osobę trzecią. Jednocześnie oświadczam, że:

- praca nie była wcześniej podstawą nadania stopnia doktora innej osoby,
- załączona wersja elektroniczna jest tożsama z wydrukiem rozprawy,
- wszystkie elementy pracy, które zostały wykorzystane do jej realizacji, a nie będące mojego autorstwa, zostały odpowiednio oznaczone oraz zostało podane źródło ich pochodzenia,
- przedstawiona przeze mnie wyżej wskazana praca nie narusza przepisów ustawy z dnia 4 lutego 1994 r. o prawach autorskich i prawach pokrewnych (tj. z dnia 17 maja 2006 r. Dz. U. Nr 90, poz. 631 z późn. zm.).

Mam świadomość, że złożenie nieprawdziwego oświadczenia skutkować będzie niedopuszczeniem do dalszych czynności postępowania w sprawie nadania stopnia doktora lub cofnięciem decyzji o nadaniu mi stopnia doktora oraz wszczęciem postępowania dyscyplinarnego.

Data: 16.01.2026 r.

Streszczenie

Niniejsza rozprawa prezentuje nowe metodologie, wykorzystujące uczenie maszynowe, w tym głębokie uczenie oraz generatywną sztuczną inteligencję, do analizy i modelowania parametrów akustycznych organów piszczalkowych oraz piszczalek labialnych. W szczególności, rozprawa obejmuje predykcję ciśnienia powietrza w organach piszczalkowych, modelowanie wpływu rozmieszczenia piszczalek na wiatrownicy na podstawowe parametry generowanego dźwięku piszczalek oraz klasyfikację ich typów warg. W rozprawie opracowano, na podstawie analizy danych, nowatorskie modele matematyczne, a także algorytmy uczenia maszynowego oraz głębokiego uczenia, które umożliwiają dokładne przewidywanie wartości parametrów fizycznych, takich jak ciśnienie powietrza w organach, na podstawie atrybutów akustycznych i geometrycznych piszczalek. Zastosowanie zaawansowanych technik analizy sygnałów dźwiękowych pozwoliło również na automatyczną klasyfikację typów warg piszczalek z wysoką skutecznością, używając danych dźwiękowych i spektralnych.

Badania objęły również analizę wpływu otoczenia piszczalek, w szczególności obecności przeszkód blisko warg, na parametry przepływu powietrza i generowanego dźwięku. Nieinwazyjne metody pomiarowe, oparte na rachunku przedziałowym, w połączeniu z modelami regresji, umożliwiły ilościowe opisanie tego zjawiska i jego wpływu na częstotliwość podstawową dźwięku oraz jego strukturę harmoniczną. Modelowanie tych efektów pozwala na lepsze zrozumienie interakcji fizycznych komponentów instrumentu, co ma znaczenie dla optymalizacji procesów strojenia i projektowania instrumentów.

Ważnym aspektem niniejszej pracy doktorskiej jest wdrożenie algorytmów do precyzyjnego wyznaczania ciśnienia powietrza w organach na podstawie ograniczonego zestawu danych fizycznych i akustycznych. Metody te wykorzystują techniki regresji i sieci neuronowe, a także generatywną sztuczną inteligencję, przynosząc nowe możliwości automatyzacji oraz ułatwiając rekonstrukcję i renowację organów. Dodatkowo, rozszerzono teorię akustyczną o wzory wykorzystujące parametry dźwięku z uwzględnieniem wpływu

odległości przeszkody na dźwięk generowany przez piszczałki labialne. Formuły te są efektem badań, opartych na analizie widmowej i parametrach czasowo-częstotliwościowych sygnałów dźwiękowych piszczałek labialnych.

Uzyskane wyniki badań dostarczają innowacyjnych metod do analizy danych akustycznych i fizycznych instrumentów muzycznych, wpisując się w nowoczesne trendy informatyczne, gdzie zaawansowane modele uczenia maszynowego i generatywnej sztucznej inteligencji są wykorzystywane do rozwiązywania problemów inżynierskich i akustycznych. Praca przyczynia się do rozwoju badań interdyscyplinarnych, łączących algorytmy obliczeniowe z fizyką instrumentów dętych oraz teorią muzyki, oferując nowe perspektywy badawcze i praktyczne metody dla środowiska budowniczych organów i akustyków. Przeprowadzenie takich badań nie byłoby możliwe bez teoretycznej i praktycznej wiedzy muzycznej oraz doświadczenia w użytkowaniu organów autora rozprawy, co umożliwiło synergę zaawansowanych algorytmów z organoznawstwem i udowodnienie stawianych tez badawczych.

Tezy badawcze, postawione w niniejszej rozprawie, zostały potwierdzone i udowodnione w opublikowanych badaniach. Po pierwsze wykazano, że obecność przeszkody w pobliżu wargi piszczałki labialnej powoduje mierzalne i przewidywalne zmiany podstawowych parametrów akustycznych, takich jak częstotliwość podstawowa i poziom dźwięku, co zostało opisane wzorem pozwalającym na ilościowe określenie tego zjawiska. Po drugie, zmiana częstotliwości podstawowej dźwięku piszczałki labialnej wywołana bliskością przeszkody może być efektywnie modelowana, w tym z wykorzystaniem rachunku przedziałowego oraz regresji logarytmicznej. Po trzecie, wytrenowane w ramach prowadzonych prac głębokie sieci neuronowe udowodniły swoją skuteczność w klasyfikacji typów warg piszczałek organowych na podstawie cech akustycznych, osiągając wysoką dokładność rozpoznawania. Wreszcie, zastosowane modele uczenia maszynowego oraz generatywnej sztucznej inteligencji pozwoliły na precyzyjne oszacowanie ciśnienia powietrza w organach piszczałkowych na podstawie fizycznych parametrów piszczałek labialnych i częstotliwości podstawowej, również dla instrumentów niekompletnych.

Warto zaznaczyć, że tezy postawione w niniejszej dysertacji zostały nie tylko gruntownie zweryfikowane i szczegółowo omówione w dołączonych publikacjach naukowych, ale również przetestowane i potwierdzone w praktyce. Wdrożenie proponowanych rozwiązań w rzeczywistych projektach

rekonstrukcji organów, takich jak unikalny pozytyw szkatulny z kontrkatedry św. Jana w Kamieniu Pomorskim, dowodzi skuteczności i praktycznej wartości opracowanych rozwiązań. Proponowane metodologie zyskały zastosowanie poza sferą teoretyczną, przekładając się na realne efekty w działaniach konserwatorskich i codziennej pracy organmistrzów. Takie podejście pozwala na znaczące wsparcie zarówno dla zachowania dziedzictwa kulturowego, jak i rozwoju nowoczesnych technologii informatycznych w obszarze akustyki i modelowania instrumentów muzycznych.

Abstract

This dissertation presents novel methodologies using machine learning, including deep learning and generative artificial intelligence, for the analysis and modeling of acoustic parameters of pipe organs and flue pipes. In particular, it focuses on the prediction of blowing pressure in pipe organs, modeling the impact of pipe placement on the windchest on the basic parameters of the sound generated by flue pipes, and the classification of their labium types. Based on data analysis, innovative mathematical models have been developed in this work, as well as machine learning - including deep learning - algorithms, which enable precise prediction of physical parameter values, such as blowing pressure, based on acoustic and geometric attributes of the flue pipes. Additionally, the use of advanced sound signal analysis techniques allowed for the automatic classification of pipe mouth types with high accuracy, using audio and spectral data.

The presented research also includes the analysis of the influence of the surroundings of the pipes, such as the presence of obstacles near the labia, on airflow parameters and the generated sound. Non-invasive measurement methods based on interval calculus, combined with regression models, enabled quantitative description of this phenomenon and its impact on the fundamental frequency and harmonic structure of the generated sound. Modeling these effects allows for better understanding of the interactions between the physical components of the instrument, which is important for optimizing tuning and instrument design processes.

An important aspect of the work is the implementation of algorithms for precise prediction of blowing pressure in a pipe organ, based on a limited set of physical and acoustic data. These methods use regression techniques and artificial neural networks, as well as generative artificial intelligence, bringing new automation possibilities and facilitating organ reconstruction and restoration. Additionally, the acoustic theory was extended with formulas using

sound parameters, taking into account the influence of the obstacle's distance on the sound generated by flue pipes. These formulas are the result of research based on the analysis of spectral and time-frequency parameters of sound signals from labial pipes.

The obtained results provide innovative methods for analyzing acoustic and physical data of musical instruments, aligning with modern trends in computer science, where advanced machine learning models and generative artificial intelligence are used to solve engineering and acoustic problems. This work contributes to the development of the interdisciplinary research, combining computational algorithms with the physics of wind instruments and music theory, offering new research perspectives and practical methods for organ builders and acousticians. Conducting such research would not have been possible without the author's theoretical and practical musical knowledge, as well as experience in organ playing, which enabled the synergy of advanced algorithms with organology and helped proving the research theses.

The research theses, posed in this dissertation, have been confirmed and proven in the published papers. First, it has been demonstrated that the presence of an obstacle near the labia of a flue pipe causes measurable and predictable changes in basic acoustic parameters, such as fundamental frequency and sound level, which has been described by a formula allowing quantitative determining of this phenomenon. Second, the change in the fundamental frequency of the flue pipe's sound, caused by the proximity of an obstacle, can be effectively modeled, using interval calculus and logarithmic regression. Third, deep neural networks trained as part of the carried research have proven effective in classifying the types of organ pipe labia based on acoustic features, achieving high recognition accuracy. Finally, machine learning models and generative artificial intelligence applied in this research allowed precise estimation of the blowing pressure in a pipe organ, based on physical parameters of flue pipes and their fundamental frequency, also for incomplete instruments.

The theses posed in this dissertation were not only thoroughly verified and discussed in the attached scientific publications, but also tested and confirmed in practice. The implementation of the proposed solutions in real restoration projects, such as the reconstruction of the unique chest organ from the co-cathedral of St. John in Kamień Pomorski, proves the effectiveness and practical value of the developed methods. The proposed methodologies have been practically applied, thus going beyond the theoretical domain, and yielding real

effects in conservation processes and the daily work of organ builders. Such an approach offers significant support for both cultural heritage preservation and the development of modern information technologies in the field of acoustics and musical instrument modeling.

Podziękowania

Przede wszystkim składam podziękowania mojemu Promotorowi, dr hab. Alicji Wieczorkowskiej oraz Promotorowi pomocniczemu, dr inż. Piotrowi Wrzeciono za nieocenioną opiekę mentorską, życzliwość i pomoc. Badania prezentowane w niniejszej rozprawie bez tego wsparcia nigdy by nie powstały.

Szczególne podziękowania kieruję również do Pana Władysława Cepki, prowadzącego Zakład Budowy i Rekonstrukcji Organów w Popowie, za udostępnienie warsztatu organmistrzowskiego do wykonania nagrań i pomiarów niezbędnych do badań, za eksperckie wskazówki oraz za zawsze serdeczną pomoc i otwartość.

Dziękuję także mojej rodzinie za umacnianie mnie w dążeniu do celu: moim rodzicom, żonie i dzieciom.

Na koniec dziękuję wszystkim, którzy mieli pozytywny wpływ na powstanie niniejszej rozprawy oraz mój rozwój.

Spis treści

1. Wprowadzenie	1
1.1. Motywacja	1
1.2. Tezy	3
1.3. Kontrybucje	3
2. Przegląd istniejącej wiedzy	5
2.1. Generowanie dźwięku w labialnej piszczałce organowej.....	6
2.1.1. Podstawy fizyczne i współczesne modele nieliniowe.....	6
2.1.2. Wpływ parametrów geometrycznych i materiałowych na generowany dźwięk piszczałki.....	7
2.1.3. Aerodynamika i proces intonacji.....	9
2.2. Cyfrowa akwizycja i analiza danych w badaniach akustycznych	11
2.2.1. Nieinwazyjne techniki pomiarowe jako źródło danych cyfrowych.....	11
2.2.2. Zaawansowane metody przetwarzania sygnałów wielokanałowych	12
2.2.3. Techniki lokalizacji i charakterystyki źródeł dźwięku.....	13
2.3. Modelowanie obliczeniowe i symulacja w analizie piszczałek organowych.....	13
2.3.1. Symulacje numeryczne	14
2.3.2. Modelowanie fizyczne w syntezie i analizie dźwięku.....	15
2.3.3. Oprogramowanie wspomagające projektowanie w skalowaniu głosów organowych w oparciu o modele fizyczne.....	16
2.4. Metody maszynowego, w tym głębokiego uczenia w akustyce muzycznej i syntezie dźwięku	16
2.4.1. Zastosowanie uczenia maszynowego w badaniach nad muzyką i akustyką	17
2.4.2. Rola głębokiego uczenia w analizie sygnałów dźwiękowych	17
2.4.3. Tworzenie obliczeniowo wydajnych modeli dla zastosowań czasu rzeczywistego	18

3. Cykl opublikowanych artykułów	19
3.1. Problem of placing the organ pipes on the windchest	20
3.2. Recognition of the flue pipe type using deep learning	22
3.3. The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe's mouth.....	23
3.4. The reconstruction of blowing pressure in pipe organ using machine learning.....	25
3.5. Predictive algorithms for determining blowing pressure in a pipe organ.....	26
4. Podsumowanie	29
5. Bibliografia	33
6. Artykuły dołączone do rozprawy	39
6.1. Problem of placing the organ pipes on the windchest	39
6.2. Recognition of the flue pipe type using deep learning	48
6.3. The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe's mouth.....	63
6.4. The reconstruction of blowing pressure in pipe organ using machine learning.....	79
6.5. Predictive algorithms for determining blowing pressure in a pipe organ.....	85

Rozdział 1

Wprowadzanie

W rozdziale tym podjęto tematykę badań nad akustyką piszczałek organowych, przedstawiając motywacje i cele badań. Zakres niniejszej rozprawy obejmuje zarówno teoretyczne, jak i praktyczne aspekty analizy dźwięku oraz modelowania aeroakustycznego, które mają na celu pogłębienie zrozumienia procesu generowania dźwięku w piszczałkach oraz istotności parametrów ich budowy. W dalszej części sformułowane zostaną tezy badawcze, motywacja podejmowanych badań, a także przedstawione zostaną oryginalne kontrybucje, jakie wnosi niniejsza rozprawa do nauki.

1.1. Motywacja

Sztuka budowania i renowacji organów piszczałkowych od wieków opiera się na wiedzy rzemieślniczej, gromadzonej przez pokolenia organmistrzów. Współczesne wyzwania, zwłaszcza w dziedzinie rekonstrukcji zabytkowych instrumentów oraz optymalizacji procesów strojenia i intonacji, podkreślają potrzebę zastosowania nowych metod naukowych i obliczeniowych. Badania prezentowane w niniejszej rozprawie są motywowane kilkoma kluczowymi kwestiami z zakresu organmistrzostwa i akustyki, które albo pozostają nierozwiązane przy użyciu tradycyjnych metod, albo są bardzo mało efektywne.

Pierwszą motywacją do podjęcia badań w obszarze łączącym nauki informatyczne z akustyką piszczałek organowych było wieloletnie doświadczenie autora niniejszej rozprawy w grze i utrzymaniu różnych organów piszczałkowych.

Istotne wyzwanie leży w złożoności akustycznej rozmieszczenia piszczałek na wiatrownicy organów. Bliskość piszczałek wargowych względem siebie lub przeszkody, takiej jak szafa organowa, powoduje zmiany w przepływie powietrza i skutkuje rozstrojeniem dźwięku generowanego przez piszczałki. Zjawisko to jest szczególnie problematyczne w przypadku małych instrumentów i stanowi problem dobrze znany organmistrzom, którzy

zauważają, że piszczałki idealnie nastrojone w warsztacie wymagają ponownego strojenia po zamontowaniu ich na wiatrownicy. Brak modelu ilościowego do przewidywania tych interakcji akustycznych sprawia, że proces strojenia jest nieefektywny i czasochłonny. Wymagane jest bowiem wówczas ponowne, długotrwałe strojenie setek lub nawet tysięcy piszczałek na miejscu instalacji organów, często odległym od warsztatu organmistrzowskiego. Potrzeba zamodelowania tego efektu w celu usprawnienia procesu strojenia jest jednym z motorów napędowych niniejszych badań.

Kolejną motywacją jest możliwość pogłębienia naukowego zrozumienia akustyki piszczałek wargowych poprzez wykorzystanie nowoczesnej analizy obliczeniowej. Charakterystyka akustyczna piszczałki jest ściśle powiązana z jej właściwościami fizycznymi. Fakt, że doświadczeni organmistrzowie potrafią słuchowo odróżnić różne konstrukcje piszczałek (np. typy warg) sugeruje, że widmo akustyczne dźwięku zawiera bogate, możliwe do sklasyfikowania informacje. Weryfikacja tej tezy za pomocą modeli obliczeniowych może utworzyć drogę dla nowych narzędzi do automatycznej analizy akustycznej i klasyfikacji dźwięku piszczałek organowych.

Następną inspiracją jest niezwykle istotny problem rekonstrukcji historycznych organów piszczałkowych, które uległy zniszczeniu w wyniku pożaru, działań wojennych lub zaniedbań. Podstawowym parametrem wymaganym do renowacji jest oryginalne ciśnienie powietrza w instrumencie. W niniejszej dysertacji terminem ciśnienie powietrza w organach określa się ciśnienie powietrza mierzone w miechu lub rezerwuarze organów, podawane zwykle jako podstawowy parametr w ich specyfikacji, wyrażane w milimetrach słupa wody. Wartość ta jest często nieznana, a próby jej ustalenia metodą prób i błędów mogą prowadzić do nieodwracalnego uszkodzenia bezcennych, zabytkowych piszczałek, ponieważ regulacja intonacji wymaga zmiany ich fizycznej budowy, tzn. dostosowania takich elementów jak wielkość, kształt i wycięcie warg, szerokość szczeliny, oraz długość i szerokość korpusu piszczałki. Przed opublikowaniem cyklu prac włączonych do niniejszej rozprawy nie istniały metody analityczne pozwalające na wyznaczenie ciśnienia powietrza w organach wyłącznie na podstawie zachowanych piszczałek, co uczyniło opracowanie nieinwazyjnej metody predykcyjnej kluczowym celem dla ochrony dziedzictwa kulturowego w zakresie zabytkowych organów.

Wreszcie, pojawienie się uczenia maszynowego, w tym głębokiego, oferuje potężne, oparte na danych podejście do sprostania tym wyzwaniom. Pomyślnie zastosowanie sieci neuronowych do rozpoznawania typów piszczałek wargowych na podstawie ich widm akustycznych wykazało potencjał tych technologii w dziedzinie akustyki organów. Sukces ten stanowił silną motywację do dalszego badania modeli maszynowego uczenia w bardziej złożonych

zadaniach, takich jak przewidywanie ciśnienia powietrza w organach na podstawie niekompletnego zestawu piszczałek i modelowanie nieliniowych efektów akustycznych obserwowanych w praktyce organmistrzowskiej. Niniejsze badania mają zatem na celu wypełnienie luki między tradycyjnym rzemiosłem organmistrzowskim a nowoczesną nauką informatyczną, oferując nowatorskie metodologie i rozwiązania służące ochronie zabytkowych instrumentów oraz podniesieniu efektywności rzemiosła organmistrzowskiego z korzyścią dla przyszłych pokoleń.

1.2. Tezy

W niniejszej rozprawie postawiono następujące tezy badawcze:

1. Istnieje zależność między obecnością przeszkody w polu bliskim wargi piszczałki labialnej a zmianą jej parametrów sygnałowych, co pozwala na predykcję zmiany częstotliwości podstawowej i poziomu dźwięku w procesie strojenia instrumentu.
2. Zjawisko nieliniowej zmiany częstotliwości podstawowej sygnału akustycznego piszczałki labialnej, wynikające z interakcji z przeszkodą, daje się opisać za pomocą modelu opartego na funkcji logarytmicznej, wykazującego wysoki stopień zgodności z rzeczywistymi danymi.
3. Zastosowanie głębokich sieci neuronowych do danych reprezentujących widmo sygnału akustycznego umożliwia automatyczną i wysoce skuteczną klasyfikację typów konstrukcyjnych warg piszczałek organowych.
4. Modele uczenia maszynowego umożliwiają rekonstrukcję parametru ciśnienia powietrza w organach piszczałkowych z wysoką precyzją, wykorzystując jedynie zbiór cech geometrycznych i częstotliwościowych niekompletnego zestawu piszczałek wargowych.

Wszystkie powyższe tezy zostaną udowodnione w dalszej części niniejszej rozprawy.

1.3. Kontrybucje

Niniejsza rozprawa wnosi następujący wkład do nauki:

1. Propozycja formuły opisującej wpływ bliskości przeszkody na częstotliwość podstawową dźwięku piszczałki labialnej. Formuła ta

opisuje wpływ bliskiego ułożenia piszczałek labialnych względem siebie na wiatrownicy organów piszczałkowych czy też skutki obecności innego rodzaju przeszkody w pobliżu warg piszczałki, oraz potwierdza możliwość rozstrojenia do półtonu temperowanego. Odkrycie to ma szczególne znaczenie w projektowaniu wiatrownic organowych, zwłaszcza w przypadku pozytywów organowych lub instrumentów budowanych w ograniczonych przestrzeniach.

2. Wzory regresji logarytmicznej opisujące zjawisko rozstrajania dźwięku dla różnych typów warg, przyspieszające strojenie i intonację.
3. Zastosowanie rachunku przedziałowego jako nieinwazyjnej metody obliczania parametrów dźwięku w piszczałkach organowych.
4. Wyznaczenie liczby Strouhala dla piszczałek labialnych i potwierdzenie jej stabilności.
5. Modele sztucznych sieci neuronowych do rozpoznawania typów warg piszczałek labialnych na podstawie ich widm akustycznych.
6. Opracowanie modeli uczenia maszynowego, uczenia głębokiego i generatywnej sztucznej inteligencji – pierwszych znanych metod dokładnego określania ciśnienia w organach piszczałkowych na podstawie jedynie kilku fizycznych parametrów piszczałek labialnych. Modele te są skuteczne również w sytuacji, gdy pozostała niewielka liczba zachowanych piszczałek.
7. Formuła opisująca ciśnienie powietrza w stopie piszczałki, zależna wyłącznie od wysokości wycięcia wargi piszczałki i jej częstotliwości podstawowej.
8. Propozycja nowatorskiej metodologii przewidywania ciśnienia w organach piszczałkowych z wykorzystaniem dużych modeli językowych (ang. Large Language Model, LLM).
9. Identyfikacja i walidacja kluczowych parametrów piszczałek do predykcji ciśnienia w organach piszczałkowych.

Rozdział 2

Przegląd istniejącej wiedzy

Niniejszy rozdział przedstawia przegląd najważniejszych zagadnień związanych z generowaniem dźwięku w labialnych pischzałkach organowych, analizą danych akustycznych, modelowaniem obliczeniowym parametrów dźwięku pischzałek, oraz nowoczesnymi metodami uczenia maszynowego, stosowanymi w akustyce muzycznej. Omówione zostaną zarówno podstawy fizyczne i modele nieliniowe, opisujące proces powstawania dźwięku w pischzałkach labialnych, jak i wpływ geometrycznych i materiałowych parametrów pischzałek na ich właściwości akustyczne. Przybliżone zostaną także techniki cyfrowej akwizycji danych, metody analizy sygnałów, oraz zaawansowane symulacje numeryczne. Ponadto, przedstawiono zastosowania maszynowego, w tym głębokiego, uczenia w analizie oraz syntezie dźwięków organów pischzałkowych, ze szczególnym uwzględnieniem pischzałek labialnych.

Szczegółowe omówienie podstaw fizycznych i akustycznych jest w przypadku niniejszej rozprawy niezbędne, gdyż stanowi fundament dla warstwy informatycznej badań. Dogłębne zrozumienie mechanizmu generowania dźwięku oraz zależności między geometrią pischzałki a jej parametrami widmowymi pozwala na ekstrakcję cech (ang. feature engineering), umożliwiających poprawną identyfikację typu wargi – kluczowy etap w projektowaniu skutecznych algorytmów uczenia maszynowego. Wiedza ta jest konieczna do zdefiniowania odpowiednich wektorów wejściowych dla głębokich sieci neuronowych, klasyfikujących typy warg, oraz do opracowania modeli regresyjnych i generatywnych, służących do predykcji ciśnienia. Ponadto, znajomość praw akustyki umożliwia weryfikację poprawności otrzymanych modeli obliczeniowych oraz ocenę, czy wyniki generowane przez algorytmy sztucznej inteligencji są fizycznie wiarygodne.

2.1. Generowanie dźwięku w labialnej piszczałce organowej

Współczesna wiedza na temat fizycznych aspektów powstawania dźwięku w labialnych piszczałkach organowych, znaczenie ich parametrów geometrycznych i materiałów, a także procesy intonacji i dynamika przepływu powietrza, są podstawą zrozumienia złożonych zjawisk aeroakustycznych, zachodzących w piszczałkach organowych, oraz ich modeli fizycznych i cyfrowych.

2.1.1. Podstawy fizyczne i współczesne modele nieliniowe

Fundamenty pod zrozumienie mechanizmu generowania dźwięku w piszczałkach organowych i jego zależności od ciśnienia powietrza w organach zostały położone przez wczesnych badaczy, którzy, mimo braku zaawansowanych narzędzi, trafnie zidentyfikowali kluczowe zjawiska. H.V. Helmholtz [20] przedstawił jakościowy opis zjawiska, poprawnie identyfikując rolę strumienia powietrza i jego interakcji z górną wargą jako podstawowego mechanizmu wzbudzającego dźwięk. W kolejnych dekadach podejmowano próby stworzenia dokładniejszych modeli ilościowych. Prace badaczy takich jak A. Mallock [31] czy A.C. Lunn [30] koncentrowały się na empirycznym badaniu zależności częstotliwości dźwięku od ciśnienia powietrza w organach, jednak ich modele wciąż nie wyjaśniały w pełni fizyki zjawiska, choć stanowiły krok naprzód. Również jakościowy model zaproponowany przez H. Smitha [43], stosunkowo prosty, poprawnie ujmował niektóre aspekty dynamiczne strumienia powietrza. Te wczesne teorie, choć często niekompletne, stanowiły bazę, na której opierały się późniejsze badania naukowe w tym obszarze.

Przełom w zrozumieniu fizyki piszczałki nastąpił wraz z rozwojem współczesnych modeli nieliniowych, których centralnym punktem jest teoria sprzężenia zwrotnego, zapoczątkowana w pracach N. Fletchera [16, 17]. Zgodnie z tą teorią, system piszczałki traktowany jest jako nieliniowy oscylator ze sprzężeniem zwrotnym. W tym ujęciu, turbulentny strumień powietrza w wargach piszczałki działa jak wzmacniacz, który dostarcza energię do układu. Rezonator, czyli korpus piszczałki, pełni rolę filtra, który selekcjonuje i wzmacnia określone częstotliwości. Kluczowe jest jednak to, że pole akustyczne wewnątrz rezonatora oddziałuje zwrotnie na strumień powietrza tuż przy jego wylocie ze szczeliny, modulując jego ruch i zmuszając go do oscylacji z częstotliwością rezonansową. Koncepcja ta była dalej rozwijana i udoskonalana przez badaczy takich jak S.A. Elder [14] i S. Yoshikawa [52], którzy tworzyli coraz bardziej zaawansowane modele ilościowe, umożliwiające przewidywanie warunków wzbudzenia oscylacji i zachowania piszczałki w różnych reżimach pracy.

Istotą wszystkich tych modeli, zarówno historycznych, jak i współczesnych, jest rola strumienia powietrza i nierozdzielnie z nią związane zjawisko tonu krawędziowego, znanego też jako ton eolski [18, 42]. Kiedy cienki strumień powietrza opuszcza szczelinę, jest z natury niestabilny - turbulentny. Gdy uderza on o ostrą krawędź górnej wargi, niestabilność ta gwałtownie wzrasta, co prowadzi do formowania się wirów po obu stronach wargi [9, 26]. W izolacji, bez obecności rezonatora, proces ten generuje jedynie słaby, szerokopasmowy szum lub dźwięk o nieokreślonej wysokości (ton krawędziowy). Jednak w kompletnej piszczałce, fala stojąca wewnątrz korpusu pobudza strumień powietrza do rytmicznego, naprzemiennego przełączania się między wewnętrzną a zewnętrzną stroną wargi. Ta regularna oscylacja strumienia, napędzana przez sprzężenie zwrotne od rezonatora, stanowi mechanizm cyklicznego dostarczania energii do słupa powietrza w piszczałce, podtrzymując jego drgania [15].

Finalnym efektem tego złożonego procesu aeroakustycznego jest dźwięk o określonej strukturze harmoniczej i charakterystyce promieniowania akustycznego. Chociaż oddziaływanie strumienia z wargą generuje szerokie spektrum częstotliwości, rezonator w postaci korpusu piszczałki działa jak filtr pasmowy, który wzmacnia jedynie te częstotliwości, które są bliskie jego własnym częstotliwościom rezonansowym, a tłumi pozostałe [15, 28, 45]. To właśnie ten proces filtracji kształtuje ostateczną barwę dźwięku, tworząc charakterystyczny dla danej piszczałki szereg tonów harmoniczych. Tak wytworzony dźwięk jest następnie promieniowany na zewnątrz, głównie z dwóch obszarów: z wycięcia piszczałki (otworu ograniczonego wargą dolną i górną) oraz z jej otwartego końca (w przypadku piszczałki o budowie otwartej). Badania [9] wykazały, że wycięcie zachowuje się akustycznie jak dipol, tj. układ dwóch blisko położonych źródeł dźwięku przeciwnych faz, podczas gdy otwarty koniec działa jak proste, pojedyncze źródło emitujące falę dźwiękową we wszystkich kierunkach równomiernie, czyli monopol. Charakterystyka tego promieniowania jest silnie zależna od częstotliwości - niższe harmoniczne rozchodzą się bardziej dookólnie, podczas gdy wyższe składowe tworzą bardziej złożone, kierunkowe wzory promieniowania, co ma kluczowe znaczenie dla sposobu, w jaki barwa instrumentu jest odbierana przez słuchacza w przestrzeni [3, 9, 17].

2.1.2. Wpływ parametrów geometrycznych i materiałowych na generowany dźwięk piszczałki

Choć przez długi czas korpus piszczałki traktowano jako pasywny rezonator, którego jedyną rolą jest filtrowanie widma dźwięku, współczesne badania jednoznacznie dowodzą kluczowego znaczenia wibracji mechanicznych ścian

korpusu w kształtowaniu jego finalnej barwy – zjawiska określonego mianem sprzężenia wibroakustycznego. Badania eksperymentalne [11] wykazały, że zarówno rodzaj materiału (np. różne rodzaje drewna), jak i grubość ścianek rezonatora mają mierzalny wpływ na strukturę harmoniczną generowanego dźwięku. Dzieje się tak, ponieważ ciśnienie akustyczne fali stojącej wewnątrz piszczałki pobudza jej ścianki do drgań. Pomiar wykonany za pomocą wibrometrii laserowej [12] nie tylko ostatecznie potwierdził istnienie tych wibracji, ale także wykazał, że są one w fazie z ciśnieniem akustycznym. Drgający korpus sam staje się wtórnym źródłem dźwięku, promieniując energię akustyczną, która miesza się z dźwiękiem pochodzącym z warg piszczałki [14]. Analiza sygnałów z użyciem zaawansowanych technik, takich jak analiza składowych niezależnych (ang. Independent Component Analysis, ICA), pozwoliła na separację tych dwóch składowych i dowiodła, że drgania mechaniczne mają swój unikalny wkład w ogólne spektrum akustyczne instrumentu [12, 23, 31]. Wybór materiału i jego grubość wpływają na częstotliwości rezonansowe samej struktury piszczałki, co z kolei modyfikuje pole akustyczne i przyczynia się do subtelnych różnic w barwie, od dawna znanych organmistrzom z praktyki [11, 47].

Kluczowy wpływ na barwę dźwięku ma również geometria układu warg piszczałki, czyli obszaru, w którym dźwięk jest generowany. Każdy element tego generatora odgrywa istotną rolę. Wysokość wycięcia, ostrość samej wargi górnej oraz obecność elementów pomocniczych, takich jak baczki czy wałek, determinują zarówno statyczną barwę dźwięku, jak i jego dynamiczne zachowanie [17, 47]. Baczki stabilizują strumień powietrza, zapobiegając jego rozpraszaniu na boki i koncentrując przepływ powietrza w procesie generowania dźwięku [41]. Precyzyjne ukształtowanie tych elementów jest podstawą procesu intonacji, podczas którego organmistrz ustawia brzmienie każdej piszczałki poprzez regulację jej barwy, poziomu dźwięku, transjentu początkowego, składu harmonicznego oraz innych parametrów akustycznych [44, 46]. Wpływ parametrów geometrycznych generatora dźwięku w piszczałce labialnej jest szczególnie widoczny w fazie ataku dźwięku, czyli w krytycznie ważnym dla percepcji transjencie początkowym [2, 4, 24, 50]. Symulacje numeryczne i badania eksperymentalne [48] pokazują, że parametry takie jak wysokość wycięcia bezpośrednio wpływają na to, jak szybko i stabilnie piszczałka reaguje na dostarczanie powietrza. Zbyt niskie lub zbyt wysokie wycięcie może prowadzić do niestabilnego ataku, pojawiania się niepożądanych przedęć lub powolnego narastania dźwięku. Zrozumienie tych zależności jest kluczowe dla projektowania instrumentów o pożądanej charakterystyce artykulacyjnej.

Poza standardowymi konstrukcjami, w budownictwie organowym stosuje się szereg konstrukcji specjalnych, które w unikalny sposób modyfikują

właściwości akustyczne piszczałek [37]. Doskonałym przykładem są piszczałki półkryte z kominkiem (rurką wystającą z pokrywy), takie jak głos Rohrflöte. Badania [27] wykazały, że kominek działa jak dodatkowy rezonator Helmholtza, który jest strojony tak, aby wzmocnić określoną składową harmoniczną. W praktyce, poprzez odpowiednie dobranie średnicy i długości kominka, można znacząco wzmocnić na przykład trzecią i piątą harmoniczną, nadając brzmieniu charakterystyczny, kwintowo-tercjowy, szemrzący charakter. Inne specjalne elementy, takie jak rolety stroikowe w piszczałkach otwartych, również wpływają na spektrum dźwięku, co dowodzi, że niemal każdy detal konstrukcyjny może mieć znaczenie akustyczne [39].

Ostatecznie, na zachowanie piszczałki ma wpływ również jej interakcja z systemem zasilania powietrzem, czyli konstrukcją wiatrownicy. Aspekt ten, choć często pomijany w uproszczonych modelach, ma kluczowe znaczenie, zwłaszcza w fazie narastania dźwięku (transjentu), determinując czas stabilizacji tonu oraz występowanie zjawisk przejściowych. Wiatrownica, będąca wspólną komorą powietrzną dla wielu piszczałek, może sama w sobie działać jak rezonator, prowadząc do niepożądanych sprzężeń akustycznych między piszczałkami. Ponadto, dynamika ciśnienia w kanale powietrznym, prowadzącym do stopy piszczałki, może znacząco wpływać na fazę ataku dźwięku, opóźniając ją lub modyfikując jej przebieg. Oznacza to, że piszczałka nie może być traktowana jako całkowicie izolowany system, a jej finalne brzmienie w kontekście całego instrumentu jest wynikiem złożonej interakcji z systemem zasilania powietrznego [4].

2.1.3. Aerodynamika i proces intonacji

Proces intonacji, będący w istocie sztuką swoistego rzeźbienia dźwięku, ma głębokie podstawy fizyczne, związane z nieliniową naturą systemu piszczałki. Intonacja obejmuje regulację nie tylko stroju, ale również barwy i poziomu dźwięku piszczałek. Każda piszczałka, w zależności od ciśnienia powietrza i precyzyjnej geometrii warg, może pracować w różnych, dyskretnych reżimach pracy (zakresach parametrów akustycznych, generujących stabilny ton o określonej barwie), co znaczy, że może generować dźwięk na różnych częstotliwościach – zazwyczaj harmonicznym rezonatora – lub w ogóle nie generować stabilnego tonu [45]. Zadaniem organmistrza-intonatora jest takie ukształtowanie elementów aparatu generującego dźwięk (m.in. wysokości wycięcia, szerokości szczeliny, ostrości nacięcia warg), aby dla danego ciśnienia roboczego w organach piszczałka pracowała w pożądanym i stabilnym częstotliwości podstawowej. Proces ten polega na precyzyjnym balansowaniu na granicy niestabilności, tak aby uzyskać dźwięk o bogatej barwie i szybkim, czystym ataku, unikając jednocześnie niepożądanych przedęć na wyższe

harmoniczne [44]. Zrozumienie reżimów pracy piszczałki, czyli tego, jak jej zachowanie zmienia się w funkcji ciśnienia i geometrii, jest kluczowe dla naukowego opisu procesu intonacji [45].

W historii budownictwa organowego wykształciły się dwie główne szkoły intonacyjne, różniące się fundamentalnie podejściem do regulacji przepływu powietrza: technika na otwartej i na zamkniętej stopie [46]. W drugiej metodzie, powszechnej w historycznym budownictwie, organmistrz celowo zwęża otwór w stopie piszczałki, używając go jako głównego regulatora ilości powietrza docierającego do warg. Pozwala to na uzyskanie łagodnego, śpiewnego ataku i delikatniejszej barwy. Z kolei w technice na otwartej stopie, charakterystycznej dla instrumentów orkiestrowych i postromantycznych, otwór w stopie pozostawia się relatywnie duży, a cała kontrola nad dźwiękiem odbywa się poprzez precyzyjne manipulacje w obrębie warg piszczałki. Taka technika prowadzi do uzyskania dźwięku o silniejszym, bardziej dosadnym ataku (z wyraźnym wybuchem), często jaśniejszej barwie i bogatszym widmem harmonicznym. Wybór techniki intonacyjnej ma zatem decydujący wpływ nie tylko na głośność i barwę, ale również na charakter artykulacyjny całego głosu organowego [45].

Niezależnie od wybranej techniki intonacyjnej, kluczową rolę odgrywa aerodynamika stopy piszczałki. Zadaniem stopy jest odpowiednie przygotowanie i ukształtowanie strumienia powietrza, zanim ten dotrze do szczeliny. Stopa nie jest więc jedynie elementem konstrukcyjnym, ale precyzyjnym urządzeniem aerodynamicznym. Jej wewnętrzny kształt oraz wielkość otworu wlotowego decydują o spadku ciśnienia i ilości powietrza zasilającego piszczałkę [5, 37]. Co więcej, wewnątrz stopy i tuż przed szczeliną (w tzw. komorze rdzeniowej) przepływ musi zostać ustabilizowany i uformowany w ciekłą, laminarną wstęgę. W tym celu organmistrzowie od wieków stosują specjalne nacięcia na rdzeniu, tzw. kernstiche. Symulacje numeryczne obliczeniowej mechaniki płynów (ang. Computational Fluid Dynamics, CFD) potwierdziły, że te drobne modyfikacje geometryczne pełnią kluczową funkcję – generują kontrolowane, podłużne wiry, które regulują profil prędkości strumienia i tłumią niekorzystne turbulencje poprzeczne, zapewniając stabilny i cichy przepływ przez szczelinę, co jest warunkiem koniecznym do uzyskania czystego tonu muzycznego [14, 49].

Nieodłącznym elementem dźwięku piszczałki labialnej jest szum, który powstaje w wyniku turbulentnego charakteru przepływu powietrza. Generowanie szumu zachodzi w kilku miejscach, jednak jego głównym źródłem jest sama istota mechanizmu aeroakustycznego: interakcja strumienia powietrza z górną wargą. Nawet w idealnie zaintonowanej piszczałce, strumień opuszczający szczelinę posiada pewien poziom turbulencji, a jego uderzenie o

ostrą krawędź wargi generuje szerokopasmowy szum. Charakterystyka tego szumu jest szczególnie istotna w fazie ataku dźwięku, gdzie tworzy on słyszalny puls lub wybuch – krótkotrwały, bogaty w wysokie częstotliwości komponent, który poprzedza ustalenie się tonu harmonicznego [48]. Ilość i barwa tego szumu są kluczowymi elementami charakterystyki danej piszczałki i podlegają precyzyjnej kontroli podczas procesu intonacji. Zbyt duża ilość szumu może prowadzić do brzmienia tzw. hałaśliwego lub też przewiewnego, podczas gdy jego całkowity brak skutkuje dźwiękiem płaskim i pozbawionym wyrazistości. Współczesne metody analizy aeroakustycznej, łączące symulacje CFD z modelami propagacji dźwięku, pozwalają na coraz dokładniejsze przewidywanie i analizę zarówno składowych tonalnych, jak i szumowych w dźwięku piszczałki [48, 49].

2.2. Cyfrowa akwizycja i analiza danych w badaniach akustycznych

Współczesne badania akustyczne wykorzystują zaawansowane technologie pomiarowe do nieinwazyjnego zbierania szczegółowych danych na temat procesów fizycznych, zachodzących w piszczałkach organowych. Metody te pozwalają badać przepływy powietrza i drgania mechaniczne, co daje głębszy wgląd w mechanizmy generowania dźwięku i kształtowania jego cech. Złożoność sygnałów pochodzących z wielu źródeł wymaga stosowania specjalistycznych technik przetwarzania danych, które umożliwiają izolowanie istotnych komponentów akustycznych i mechanicznych. Dzięki temu możliwe jest sprecyzowanie, które elementy instrumentu mają największy wpływ na końcową barwę i charakterystykę dźwięku, co ma bezpośrednie zastosowanie w doskonaleniu technik strojenia i konstrukcji instrumentów.

2.2.1. Nieinwazyjne techniki pomiarowe jako źródło danych cyfrowych

Nowoczesne, nieinwazyjne techniki pomiarowe stanowią fundament dla cyfrowej analizy w akustyce organów, umożliwiając zbieranie precyzyjnych danych bez zakłócania subtelnych zjawisk fizycznych, zachodzących w piszczałkach. Wśród nich kluczową rolę odgrywają metody optyczne do analizy pól przepływu. Anemometria laserowa dopplerowska (ang. Laser Doppler Anemometry, LDA) została z powodzeniem zastosowana do badania oscylacji strumienia powietrza w uproszczonych modelach piszczałek [12]. Pozwoliło to na dokładne, jednopunktowe pomiary prędkości i niestabilności strugi powietrza na jej drodze od szczeliny do górnej wargi, co jest kluczowe dla zrozumienia mechanizmu generowania tonu krawędziowego, stanowiącego

podstawowe źródło dźwięku [5, 49]. Techniką uzupełniającą jest welocymetria obrazowa cząstek (ang. Particle Image Velocimetry, PIV), która dostarcza znacznie bogatszych informacji, tworząc pełne, dwuwymiarowe mapy pola prędkości przepływu [22, 23, 32]. Dzięki wizualizacji całego obszaru wokół wycięcia piszczałki, PIV umożliwia obserwację, jak niestabilności w strumieniu powietrza ewoluują w spójne struktury wirowe, które synchronizują się z rezonującym słupem powietrza w korpusie piszczałki, co jest istotą generowania stabilnego dźwięku muzycznego [32]. Równie ważna jest wibrometria laserowa, która służy do bezkontaktowego pomiaru drgań mechanicznych korpusu piszczałki. Technika ta dostarczyła ostatecznych dowodów na istnienie sprzężenia wibroakustycznego, potwierdzając z wysoką precyzją historyczne obserwacje D.C. Millera [15]. W badaniach [12] wykazano, że ścianki piszczałki, zarówno drewnianej, jak i metalowej, faktycznie drgają zsynchronizowane w fazie ze zmianami wewnętrznego ciśnienia, a ich amplituda jest zależna od właściwości materiału, z którego są wykonane [11]. Potwierdza to, że korpus nie jest jedynie pasywnym rezonatorem, ale aktywnie uczestniczy w kształtowaniu finalnej barwy dźwięku [2].

2.2.2. Zaawansowane metody przetwarzania sygnałów wielokanałowych

Złożoność zjawisk zachodzących w piszczałce sprawia, że dane pomiarowe, często pochodzące z wielu czujników jednocześnie, wymagają zaawansowanych metod przetwarzania sygnałów w celu ekstrakcji użytecznych informacji. Przykładem jest zastosowanie wspomnianej analizy składowych niezależnych (ICA), która okazała się potężnym narzędziem do rozwiązywania problemu ślepej separacji źródeł (ang. Blind Source Separation, BSS). W badaniach nad wibracjami metalowej piszczałki labialnej [12] wykazano, że sygnał z mikrofonu był mieszaniną dźwięków pochodzących zarówno z warg piszczałki, jak i z drgających ścianek. Zastosowanie metody ICA pozwoliło na rozdzielenie tych składowych sygnału na podstawie ich właściwości statystycznych. Umożliwiło to wyizolowanie i osobną analizę sygnału akustycznego pochodzącego bezpośrednio od drgań mechanicznych, co dowiodło ich mierzalnego wkładu w ogólne spektrum akustyczne instrumentu. Innym zaawansowanym narzędziem jest dekompozycja ortogonalna (ang. Proper Orthogonal Decomposition, POD), stosowana do analizy wielkoskalowych zbiorów danych pochodzących z symulacji numerycznych (CFD) lub pomiarów PIV. POD jest metodą redukcji wymiarowości, która pozwala zidentyfikować w złożonym polu przepływu dominujące, spójne struktury energetyczne, czyli fale i wiry [32]. Dzięki temu możliwe jest uproszczenie opisu skomplikowanej dynamiki płynu i zidentyfikowanie tych jej modów, które są najbardziej istotne dla mechanizmu generowania dźwięku [29]. Płynem w tym kontekście jest powietrze przepływające przez piszczałkę, którego ruch jest nieliniowy i dynamiczny,

natomiast mody to charakterystyczne wzory drgań (tryby oscylacji) tego przepływu, które można traktować jako podstawowe elementy składowe dynamiki płynu. Identyfikacja istotnych modów pozwala skupić się na tych aspektach ruchu powietrza, które mają kluczowy wpływ na stabilne i efektywne generowanie dźwięku w piszczałce, upraszczając tym samym modelowanie skomplikowanego przepływu i ułatwiając analizę aeroakustyczną.

2.2.3. Techniki lokalizacji i charakterystyki źródeł dźwięku

Precyzyjne zlokalizowanie źródeł dźwięku i scharakteryzowanie ich właściwości emisji jest kluczowe dla pełnego poznania i zrozumienia mechanizmów akustycznych instrumentu [3]. Osiąga się to za pomocą dedykowanych technik pomiarowych i obliczeniowych. Mapowanie natężenia dźwięku, wykorzystujące specjalistyczne sondy z parą mikrofonów, pozwoliło na stworzenie szczegółowych map wektorów przepływu energii akustycznej wokół działającej piszczałki [7, 34]. Badania [34] jednoznacznie zidentyfikowały dwa główne obszary emisji: wycięcie, działające jak dipol akustyczny, oraz otwarty koniec rezonatora, zachowujący się jak monopól [9]. Wykazano także silną zależność charakterystyki promieniowania od częstotliwości – wyższe harmoniczne są promieniowane w sposób bardziej złożony i ukierunkowany niż ton podstawowy, co ma bezpośredni wpływ na percepcję barwy dźwięku. Opracowano również wydajne obliczeniowo metody rekonstrukcji właściwości samego rezonatora na podstawie pomiarów ciśnienia wewnątrz instrumentu podczas jego normalnej pracy. Jedną z takich technik, opartą na modelu macierzy transferu ciśnienia, pozwala na podstawie pomiarów w zaledwie kilku punktach wewnątrz piszczałki precyzyjnie obliczyć jej kluczowe parametry akustyczne, takie jak częstotliwości rezonansowe i impedancję wejściową [40]. Alternatywne podejście polega na przesuwaniu miniaturowego czujnika ciśnienia wzdłuż osi piszczałki w celu zrekonstruowania pełnego obrazu fali stojącej, co pozwala na bardzo dokładne zlokalizowanie efektywnego źródła dźwięku wewnątrz piszczałki [40].


2.3. Modelowanie obliczeniowe i symulacja w analizie piszczałek organowych

Symulacje i modelowanie obliczeniowe są nieodzownymi narzędziami w badaniach nad piszczałkami organowymi. Umożliwiają szczegółową analizę przepływów powietrza i dynamiki rezonatora. Jako że strumień powietrza w piszczałce może być modelowany jako płyn, w analizie wykorzystuje się obliczeniową mechanikę płynów, która pozwala badać wpływ drobnych detali

konstrukcyjnych na stabilność dźwięku, a metoda elementów skończonych umożliwia precyzyjne określenie parametrów rezonatora. Takie podejście ułatwia zrozumienie złożonych procesów aeroakustycznych i wspiera rozwój efektywnych algorytmów modelowania dźwięku oraz narzędzi projektowych, wspomagających strojenie i intonację piszczałek.

2.3.1. Symulacje numeryczne

Symulacje numeryczne stanowią kluczowe narzędzie w nowoczesnej analizie zjawisk fizycznych, zachodzących w piszczałkach organowych, pozwalając na wirtualne badanie procesów, które są trudne lub niemożliwe do zaobserwowania za pomocą technik eksperymentalnych [1, 38]. W tej dziedzinie dominuje obliczeniowa mechanika płynów (CFD), którą stosuje się do szczegółowego modelowania przepływu powietrza w kluczowych obszarach piszczałki, takich jak wargi i stopa. Symulacje CFD pozwalają na precyzyjną analizę kształtowania się strumienia powietrza w stopie piszczałki oraz jego interakcji z rdzeniem i szczeliną, co ma decydujący wpływ na charakterystykę generowanego dźwięku [16]. Budowę piszczałki wargowej przedstawiono na **Rys 1**. Dzięki tej metodzie możliwe jest zbadanie wpływu drobnych detali geometrycznych, takich jak nacięcia na rdzeniu, na redukcję turbulencji i stabilizację strumienia, co jest znaną praktyką intonacyjną organmistrzów [46]. Symulacje pozwalają również na wgląd w niezwykle złożony, a jednocześnie krótki proces ataku dźwięku – transjent początkowy, pokazując, jak strumień powietrza ewoluuje od stanu początkowego do stabilnych oscylacji napędzających rezonator [24, 33, 48, 50]. Co więcej, zaawansowane symulacje CFD, sprzęgające ze sobą równania przepływu Naviera-Stokesa i równania akustyczne, umożliwiają kompleksową analizę całego zjawiska aeroakustycznego, od generacji wirów przy wycięciu po propagację fali dźwiękowej [9]. Równoległe do CFD, w analizie numerycznej wykorzystuje się metodę elementów skończonych (ang. Finite Element Method, FEM). Służy ona głównie do modelowania części stacjonarnej układu, czyli rezonatora akustycznego. Za pomocą FEM można również precyzyjnie określić kluczowe parametry rezonatora, takie jak jego częstotliwości własne, współczynniki tłumienia oraz rozkłady ciśnienia akustycznego dla poszczególnych modów słupa powietrza [38], co jest niezbędne do zrozumienia, w jaki sposób korpus piszczałki filtruje i wzmacnia dźwięk generowany przy wargach.



Rys. 1. Budowa piszczałki labialnej.

2.3.2. Modelowanie fizyczne w syntezie i analizie dźwięku

Synteza dźwięku piszczałek organowych odgrywa kluczową rolę w analizie parametrów akustycznych, gdyż umożliwia realistyczne odtwarzanie sygnałów akustycznych na podstawie modeli fizycznych, weryfikując teorie bez fizycznych prototypów. Modele syntezy fizycznej piszczałek stanowią podstawę algorytmów cyfrowych do tworzenia wirtualnych organów i symulacji czasu rzeczywistego. Opis syntezy pozwala również na głębsze zrozumienie zależności między parametrami aerodynamicznymi a parametrami akustycznymi piszczałek.

Obok złożonych symulacji numerycznych, fundamentalną rolę w analizie, a zwłaszcza w syntezie dźwięku, odgrywa modelowanie fizyczne, które opisuje system generujący dźwięk za pomocą uproszczonych, ale fizycznie umotywowanych równań [10]. W historii badań nad piszczałkami można zaobserwować wyraźną ewolucję od wczesnych modeli jakościowych, proponowanych przez badaczy takich jak H. Smith [43] czy A. Mallock [31], które poprawnie identyfikowały kluczowe zjawiska, do znacznie bardziej

zaawansowanych modeli ilościowych, których podwaliny stworzył N. Fletcher [16]. Współczesne modele opierają się na koncepcji nieliniowej pętli sprzężenia zwrotnego, gdzie niestabilny strumień powietrza (wzmacniacz) oddziałuje z polem akustycznym rezonatora (filtr), a pole to z kolei moduluje zachowanie strumienia przy wyjściu ze szczeliny [15, 19, 33, 45]. Ta koncepcja pozwala na matematyczne opisanie, dlaczego piszczałka generuje stabilny dźwięk o określonej wysokości i barwie. Główną zaletą tych modeli jest ich wydajność obliczeniowa. Zastosowanie uproszczonych modeli fizycznych, które oddają istotę zjawiska sprzężenia zwrotnego, umożliwia tworzenie algorytmów syntezy dźwięku działających w czasie rzeczywistym [44]. Takie modele pozwalają na realistyczne cyfrowe odtworzenie nie tylko statycznego brzmienia piszczałki, ale również jej dynamicznych reakcji na zmiany ciśnienia powietrza w organach [30, 37], co otwiera drogę do tworzenia zaawansowanych wirtualnych instrumentów.

2.3.3. Oprogramowanie wspomagające projektowanie w skalowaniu głosów organowych w oparciu o modele fizyczne

Wiedza zdobyta dzięki modelowaniu fizycznemu znajduje również praktyczne zastosowanie w narzędziach informatycznych, wspierających pracę organmistrzów. Przykładem jest specjalistyczne oprogramowanie wspomagające projektowanie (ang. Computer-Aided Design, CAD), które wykorzystuje modele fizyczne do rozwiązania jednego z najtrudniejszych problemów w budownictwie organowym – skalowania głosów organowych [35]. Proces ten polega na zaprojektowaniu geometrii całej rodziny piszczałek (od największej do najmniejszej) w taki sposób, aby zachować spójny charakter brzmieniowy w całej skali instrumentu. Oprogramowanie takie, bazując na modelu fizycznym, jest w stanie przewidzieć, jak zmiana wymiarów piszczałki wpłynie na jej barwę, co pozwala projektantowi na świadome korygowanie parametrów geometrycznych w celu osiągnięcia pożądanego rezultatu artystycznego. Stanowi to doskonały przykład synergii między głębokim zrozumieniem fizyki instrumentu a nowoczesnymi narzędziami informatycznymi, które przekładają teorię na praktyczne zastosowania [7].

2.4. Metody maszynowego, w tym głębokiego uczenia w akustyce muzycznej i syntezie dźwięku

Współczesne metody maszynowego, w tym głębokiego uczenia mają zastosowanie w badaniach nad dźwiękiem piszczałek organowych, umożliwiając analizę i klasyfikację ich cech akustycznych, które są trudne do

uchwycenia za pomocą tradycyjnych metod. Pozwalają one na tworzenie modeli, które emulują złożone symulacje aeroakustyczne w czasie rzeczywistym, co znacznie przyspiesza procesy strojenia i intonacji instrumentu.

2.4.1. Zastosowanie uczenia maszynowego w badaniach nad muzyką i akustyką

W ostatnich dekadach uczenie maszynowe (ang. Machine Learning, ML) zrewolucjonizowało badania nad muzyką i akustyką, stając się podstawowym narzędziem w dziedzinie znanej jako pozyskiwanie informacji muzycznych (ang. Music Information Retrieval, MIR) [6, 51]. Algorytmy ML doskonale sprawdzają się jako narzędzia do odkrywania złożonych wzorców w dużych zbiorach danych muzycznych, które są zbyt obszerne i skomplikowane dla tradycyjnej analizy manualnej. Dzięki możliwości przetwarzania i analizy ogromnych korpusów muzycznych, modele te są w stanie identyfikować subtelne cechy stylistyczne, struktury harmoniczne, czy wzorce rytmiczne, co ma fundamentalne znaczenie dla muzykologii obliczeniowej i analizy repertuaru [36]. Zastosowania ML wykraczają jednak daleko poza analizę teoretyczną i znajdują szerokie zastosowanie w praktycznych problemach klasyfikacji, analizy i diagnostyki wibroakustycznej. W muzyce klasycznym przykładem jest automatyczna klasyfikacja gatunków muzycznych, rozpoznawanie instrumentów, czy identyfikacja wykonawców na podstawie nagrań audio [21].

2.4.2. Rola głębokiego uczenia w analizie sygnałów dźwiękowych

Szczególną rolę w analizie sygnałów audio odgrywa głębokie uczenie (ang. Deep Learning, DL), poddziedzina ML, wykorzystująca wielowarstwowe sieci neuronowe [25]. Przełom, jaki dokonał się dzięki DL, polega w dużej mierze na zdolności modeli do automatycznego uczenia się cech bezpośrednio z surowych danych audio. W tradycyjnym podejściu, sukces modelu zależał od ręcznego projektowania przez ekspertów zestawu cech akustycznych (np. Mel-Frequency Cepstral Coefficients, MFCC, czy też inne deskryptory widma lub postaci czasowej dźwięku), co było procesem żmudnym i często nieoptymalnym. Głębokie sieci neuronowe, zwłaszcza splotowe (ang. Convolutional Neural Network, CNN), są w stanie samodzielnie, w procesie treningu, wyodrębnić najbardziej relewantne i hierarchiczne cechy bezpośrednio ze spektrogramów, które są wizualną reprezentacją zmieniającego się w czasie widma sygnału audio [21, 36]. Oprócz zadań analitycznych, głębokie uczenie zrewolucjonizowało również sferę generowania i transformacji muzyki, głównie za sprawą zaawansowanych architektur głębokich, takich jak generatywne sieci adwersarialne (ang. Generative Adversarial Network, GAN) oraz wariacyjne

autoenkodery (ang. Variational Autoencoder, VAE). Modele te potrafią nie tylko generować nowe fragmenty muzyczne w określonym stylu, ale również dokonywać złożonych transformacji, takich jak transfer stylu (np. wykonanie utworu w stylistyce innego artysty) czy synteza brzmienia jednego instrumentu na podstawie gry innego, co otwiera zupełnie nowe możliwości w twórczości muzycznej i projektowaniu dźwięku [21].

2.4.3. Tworzenie obliczeniowo wydajnych modeli dla zastosowań czasu rzeczywistego

Jednym z największych wyzwań w zastosowaniu zaawansowanych modeli, zwłaszcza tych opartych na symulacjach fizycznych, jest ich duży koszt obliczeniowy, który uniemożliwia zastosowania interaktywne lub działające w czasie rzeczywistym. W odpowiedzi na ten problem, w ostatnich latach intensywnie rozwija się technika budowy modeli surogatowych, które wykorzystują sieci neuronowe do emulacji złożonych symulacji fizycznych. Proces przygotowania takiego modelu polega na wytrenowaniu sieci neuronowej na zbiorze danych wejściowych i odpowiadających im wyników uzyskanych z czasochłonnej symulacji (np. CFD). Po zakończonym treningu, sieć neuronowa staje się niezwykle szybkim modelem zastępczym, który jest w stanie z dużą dokładnością aproksymować wyniki symulacji dla nowych danych wejściowych w ułamku sekundy, co rewolucjonizuje proces projektowania i optymalizacji [8]. W kontekście syntezy dźwięku, szczególnie obiecujące jest podejście hybrydowe, zwane modelowaniem fizycznie zorientowanym, które łączy zalety modelowania fizycznego i uczenia maszynowego [36]. W tym podejściu, zamiast emulować cały system, tworzy się uproszczony model fizyczny, który opisuje podstawowe zjawiska, a sieć neuronowa jest uczona, aby modelować jedynie te jego części, które są silnie nieliniowe i trudne do opisanego analitycznego. Takie podejście pozwala na tworzenie interaktywnych, obliczeniowo wydajnych modeli do syntezy dźwięków, które zachowują fizyczną wiarygodność i oferują bogate możliwości ekspresji, niemożliwe do osiągnięcia za pomocą czysto empirycznych metod.

Rozdział 3

Cykl opublikowanych artykułów

W niniejszym rozdziale omówiono publikacje dołączone do rozprawy, wykazując zasadność tez postawionych w rozprawie, oraz zestawiono dane bibliograficzne tych prac.

Dane bibliograficzne publikacji dołączonych do rozprawy:

- 1) Węgrzyn, D. & Wrzeciono, P. (2019). **Problem of placing the organ pipes on the windchest**. *Vibrations in Physical Systems*, 1(30), 1-8.
https://vibsys.put.poznan.pl/_journal/2019-30-1/articles/vibsys_2019121.pdf.
- 2) Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A. (2021). **Recognition of the Flue Pipe Type Using Deep Learning**. In: M. Stettinger, G. Leitner, A. Felfernig, Z.W. Ras (eds) *Intelligent Systems in Industrial Applications. ISMIS 2020. Studies in Computational Intelligence*, vol 949. Springer, Cham, 80-93. https://doi.org/10.1007/978-3-030-67148-8_7.
- 3) Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A. (2022). **The Dependence of Flue Pipe Airflow Parameters on the Proximity of an Obstacle to the Pipe's Mouth**. *Sensors*, 22(1), 10.
<https://doi.org/10.3390/s22010010>.
- 4) Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A. (2024). **The Reconstruction of Blowing Pressure in Pipe Organ Using Machine Learning**. In B. Marcinkowski, A. Przybyłek, A. Jarzębowicz, N. Iivari, E. Insfran, M. Lang, H. Linger, & C. Schneider (eds), *Harnessing Opportunities: Reshaping ISD in the post-COVID-19 and Generative AI Era (ISD2024 Proceedings)*. Gdańsk, Poland: University of Gdańsk.
<https://doi.org/10.62036/ISD.2024.113>.
- 5) Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A. (2026). **Predictive Algorithms for Determining Blowing Pressure in a Pipe Organ**. *Bulletin of the Polish Academy of Sciences Technical Sciences*, 1(74), e156771.
<https://doi.org/10.24425/bpasts.2025.156771>.

3.1. Problem of placing the organ pipes on the windchest

Badania przedstawione w publikacji „Problem of placing the organ pipes on the windchest” dotyczą problemu rozmieszczenia piszczałek na wiatrownicy organowej, ze szczególnym uwzględnieniem wpływu bliskiego sąsiedztwa piszczałek na parametry akustyczne generowanego dźwięku. Sformułowana teza zakłada, że istnieje zależność między obecnością przeszkody w polu bliskim wargi piszczałki labialnej a zmianą jej parametrów sygnałowych, co pozwala na predykcję zmiany częstotliwości podstawowej i poziomu dźwięku w procesie strojenia instrumentu. Przeprowadzone badania potwierdziły tę tezę, wykazując znaczące obniżenie częstotliwości podstawowej, do około półtonu temperowanego, oraz spadek poziomu dźwięku w obecności przeszkody.

Eksperymenty odbyły się w warunkach kontrolowanych na stole intonacyjnym w warsztacie organmistrzowskim przy ciśnieniu powietrza w wiatrownicy ustawionym na 67 mm słupa wody oraz przy temperaturze 19°C. Do badań wybrano trzy typy piszczałek labialnych, reprezentatywne dla organów piszczałkowych. Dźwięk rejestrowano jednocześnie dwoma mikrofonami o charakterystyce dookólnej, umieszczonymi w stałych odległościach od warg piszczałek. Przeszkodę umieszczano w odległościach od 0 mm do 80 mm z krokiem 5 mm od wargi piszczałki. Dla odległości większych niż 80 mm nie zaobserwowano istotnych zmian.

Analiza częstotliwości podstawowej dźwięku prowadzona była dwustopniowo. W początkowym etapie zastosowano szybką transformatę Fouriera (ang. Fast Fourier Transform, FFT) o rozdzielczości 0,8 Hz do uzyskania orientacyjnej wartości częstotliwości. Następnie wykorzystano dyskretną transformatę Fouriera (ang. Discrete-Time Fourier Transform, DTFT) o dużo większej dokładności (0,01 Hz), zaimplementowaną w autorskim programie w środowisku Java. Pozwoliło to na precyzyjne ustalenie zmian częstotliwości w funkcji odległości przeszkody. Poziom dźwięku pierwszej harmoniczej określono na podstawie pomiarów kalibrowanych, z uwzględnieniem niepewności wyników, wyliczanej jako odchylenie standardowe z serii co najmniej pięciu pomiarów dla każdego ustawienia przeszkody.

Otrzymane wyniki jednoznacznie wskazały na spadek częstotliwości podstawowej w miarę zbliżania przeszkody do warg piszczałki. Najwyższe wartości rozstrojenia, sięgające spadku o około 100 centów (co odpowiada obniżeniu dźwięku o półton temperowany), odnotowano dla drewnianych piszczałek o profilu prostokątnym. Obniżenie częstotliwości malało wraz ze

zwiększaniem odległości przeszkody od piszczałki, aż do zaniku efektu powyżej 80 mm. Oprócz tego wykryto obniżenie poziomu głośności dźwięku nawet o około 4 dB. Analizy widmowe wykazały również tłumienie poszczególnych harmonicznym, szczególnie nieparzystych, co wpływa na charakterystykę barwy dźwięku i intonację, rozumianą jako zdolność utrzymania właściwej wysokości i jakości tonu całego głosu lub chóru piszczałek. Zmiany rozkładu harmonicznym mogą wymuszać korekty strojenia oraz kształtowania barwy, aby dany głos lepiej zgrywał się z pozostałymi rejestrami organów.

Badanie wykazało, że bliskie usytuowanie innych piszczałek na wiatrownicy powoduje wzajemne oddziaływania akustyczne skutkujące rozstrojeniem częstotliwości podstawowej i zmianą poziomu dźwięku. Powoduje to znaczne wydłużenie czasu strojenia, a w skrajnych przypadkach może uniemożliwić poprawne nastrojenie instrumentu. Zjawisko to jest szczególnie istotne w przypadku małych organów lub pozytywów, gdzie ilość miejsca na wiatrownicy jest ograniczona, a piszczałki ustawione są bardzo blisko siebie.

Dane empiryczne pozyskane w badaniach mogą posłużyć do tworzenia dokładniejszych modeli matematycznych, opisujących zjawiska zachodzące w piszczałkach pod wpływem przeszkód i są narzędziem umożliwiającym optymalizację konstrukcji wiatrownic. Wskazano, że uwzględnienie tych efektów w procesie projektowym jest niezbędne dla zachowania precyzyjnej intonacji i barwy dźwięku w organach piszczałkowych.

Wyniki dostarczyły ważnej wiedzy dla praktyki organmistrzowskiej oraz projektowania instrumentów, umożliwiając lepsze zrozumienie przyczyn problemów ze strojeniem, powstających przy gęstym rozmieszczeniu piszczałek. Znajomość i ujęcie tych zależności pozwala na unikanie niepożądanych rozstrojeń i poprawę jakości dźwięku w konstrukcji organów, szczególnie w sytuacjach ograniczonej przestrzeni dostępnej na wiatrownicy.

W podsumowaniu wykazano istnienie zależności między obecnością przeszkody w polu bliskim wargi piszczałki labialnej a zmianą jej parametrów sygnałowych (częstotliwości podstawowej i poziomu dźwięku), co umożliwia predykcję tych zmian w procesie strojenia organów. Zagadnienie to poddano szczegółowym badaniom i opisano w późniejszych publikacjach, stanowiących fundament dla udowodnienia czwartej tezy niniejszej rozprawy.

3.2. Recognition of the flue pipe type using deep learning

Publikacja „Recognition of the flue pipe type using deep learning” poświęcona jest zagadnieniu automatycznej identyfikacji typu warg piszczałek labialnych organów piszczałkowych na podstawie ich widm akustycznych z wykorzystaniem głębokich sieci neuronowych. W artykule postawiono i udowodniono tezę, że zastosowanie głębokich sieci neuronowych do danych reprezentujących widmo sygnału akustycznego umożliwia automatyczną i wysoce skuteczną klasyfikację typów konstrukcyjnych warg piszczałek organowych.

Badania prezentowane w pracy weryfikują praktycznie postawioną tezę poprzez eksperyment, w którym sztuczna sieć neuronowa (ang. Artificial Neural Network, ANN) została wytrenowana na wysokiej jakości zbiorze nagrań dźwiękowych piszczałek, zrealizowanych w warsztacie organmistrzowskim. Osiągnięta przez model sieci głębokiej średnia dokładność klasyfikacji na zbiorze testowym wyniosła aż 98,7%, a średnia harmoniczna precyzji i czułości była na poziomie 99,1%. Wyniki te potwierdzają, że zaproponowane podejście pozwala niezawodnie rozróżnić typy warg piszczałek (baczki, broda, płytki, wałek) na podstawie widma ich dźwięku, przy czym większość przypadków została poprawnie sklasyfikowana, a mylne rozpoznanie wystąpiło tylko w dwóch próbkach spośród 150.

Metodologia badań obejmowała profesjonalne nagranie dźwięków piszczałek różnych rejestrów i typów konstrukcji w kontrolowanych warunkach warsztatu organmistrzowskiego. Każda próbka dźwięku była analizowana pod kątem widma częstotliwościowego przy użyciu szybkiej transformacji Fouriera (FFT), ze zoptymalizowaną długością próbki i oknem Hamminga. Dane wejściowe do sieci neuronowej stanowiły wektory wartości mocy widma, natomiast wyjście wskazywało typ wargi. Zbiór 700 nagrań został podzielony na próbki treningowe, walidacyjne i testowe. Najlepsza architektura sieci neuronowej zawierała 11 warstw ukrytych z funkcjami aktywacji ReLU (ang. Rectified Linear Unit), warstwami wyłączenia (ang. dropout) oraz normalizacji wsadowej (ang. batch normalization), optymalizowanymi algorytmem Adadelta, co zapewniło wysoką stabilność procesu uczenia.

W toku pracy porównano różne architektury sieci – między innymi model oparty na pamięci krótko-długotrwałej (ang. Long Short-Term Memory, LSTM), modele przetrenowane na zbyt małych zbiorach danych, oraz modele z większą liczbą warstw ukrytych. Ostatecznie za optymalny uznano model 11-warstwowy, minimalizujący zjawisko przeuczenia (ang. overfitting), i przetestowany w procedurze 10-krotnej walidacji krzyżowej (ang. k-fold Cross

Validation). Wyniki walidacji potwierdziły stabilność rozwiązania i wysoką jakość prognozowania typu wargi na podstawie widma akustycznego.

Kontrybucją pracy jest potwierdzenie możliwości skutecznego wykorzystania głębokiego uczenia w klasyfikacji typów warg pischczalek organowych na podstawie cech akustycznych. Dodatkowo, zrealizowane eksperymenty stanowią punkt wyjścia do dalszych badań nad automatyzacją procesu intonacji organów oraz rozpoznawaniem parametrów dźwięku pischczalek. Wyniki przeprowadzonych eksperymentów sugerują, że metody głębokiego uczenia mogą wspomóc organmistrzów w procesie klasyfikacji oraz wyboru odpowiednich parametrów konstrukcyjnych i barwowych.

3.3. The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe's mouth

Publikacja przedstawia zależności parametrów przepływu powietrza w pischczalce labialnej od obecności przeszkody w pobliżu wargi pischczalki. W pracy zaprezentowano badania zjawiska wpływu przeszkód takich jak inne pischczalki lub obudowa organów na parametry dźwięku generowanego przez pischczalkę. W artykule tym została dowiedziona teza, iż zjawisko nieliniowej zmiany częstotliwości podstawowej sygnału akustycznego pischczalki labialnej, wynikające z interakcji z przeszkodą, daje się opisać za pomocą modelu opartego na funkcji logarytmicznej, wykazującego wysoki stopień zgodności z rzeczywistymi danymi.

Badania prowadzono z wykorzystaniem nieinwazyjnych metod pomiarowych w warsztacie organmistrzowskim, gdzie rejestrowano dźwięki pischczalek zwykle spotykanych rodzajów warg (np. bez dodatków, z baczkami, z wałkiem, z płytką) przy pomocy mikrofonów kalibrowanych zgodnie z normami elektroakustycznymi. Pomiarom poddano zmiany częstotliwości podstawowej dźwięku w zależności od odległości przeszkody ustawionej naprzeciw wargi. W spektrogramach analizowano widma dźwięków stosując szybką transformatę Fouriera (FFT) i dyskretną transformatę Fouriera (DTFT), co pozwoliło na precyzyjne określenie częstotliwości z dokładnością do 0,01 Hz.

Analiza danych uzyskanych w wyniku przeprowadzonych badań pokazała, że najważniejszym parametrem determinującym częstotliwość podstawową dźwięku jest prędkość przepływu powietrza w wargach pischczalki, która maleje wraz ze zbliżaniem się przeszkody. Bazując na zaobserwowanej zależności częstotliwości podstawowej dźwięku od prędkości przepływu strumienia, przyjęto stałą wartość liczby Strouhala, która łączy częstotliwość

drgań z wymiarem charakterystycznym (wysokością wycięcia wargi) i prędkością przepływu powietrza. Liczby Reynoldsa i Strouhala były obliczane przy użyciu wzorów uwzględniających parametry gazu oraz geometrię piszczałki. Uzyskane wyniki wskazują, że liczba Strouhala dla piszczałek labialnych jest niemal stała i wynosi około 0,2, co umożliwia wyrażenie częstotliwości podstawowej dźwięku jako funkcji logarytmicznej zależnej od odległości przeszkody od wargi, z wysokim współczynnikiem dopasowania modelu do danych zmierzonych, rzędu 0,91 do 0,97 dla różnych typów piszczałek.

Przeprowadzono analizę opartą na obliczeniach rachunku przedziałowego, który pozwolił oszacować przedziały zmian parametrów przepływu i częstotliwości bez konieczności stosowania inwazyjnych metod pomiarowych, które zniekształcałyby wyniki przez ingerencję w strumień powietrza. Takie podejście w tej dziedzinie jest innowacyjne i pozwoliło wyeliminować błędy pomiarowe charakterystyczne dla wcześniejszych badań.

Uzyskane modele regresyjne przyjęły postać wzoru logarytmicznego, przedstawionego w równaniu (1), precyzyjnie opisującego zmiany częstotliwości podstawowej dźwięku w funkcji odległości przeszkody, co ma praktyczne znaczenie dla optymalizacji procesu strojenia organów piszczałkowych. Modele te, dla różnych typów warg, można w praktyce zastosować, aby przewidywać i kompensować wpływ bliskiego ułożenia piszczałek lub zabudowy instrumentu na ich strojenie.

$$f_0(x) = a \ln\left(\frac{x}{x_0}\right) + (0.998 f_0(x_0)), \quad \text{dla } x > 0, x_0 > 0, x \leq x_0, \quad (1)$$

gdzie: a jest współczynnikiem regresji logarytmicznej zależnym od typu wargi piszczałki, x oznacza odległość przeszkody od wargi piszczałki, x_0 to odległość graniczna, przy której częstotliwość dźwięku przestaje zależeć od obecności przeszkody.

W artykule udowodniono, że zmiany częstotliwości podstawowej sygnału akustycznego piszczałki labialnej, wynikające z interakcji z przeszkodą, da się opisać za pomocą odpowiedniego modelu. Implementacja metod analizy przepływu powietrza wraz z rachunkiem przedziałowym umożliwiła budowę modeli ilościowych, które ułatwiają zarówno teoretyczne zrozumienie zjawiska, jak i praktyczne zastosowania w dziedzinie budowy i strojenia organów piszczałkowych. Dzięki temu praca wnosi nowy, jakościowy i ilościowy wkład w zrozumienie dynamiki strumienia powietrza w piszczałkach, który wcześniej był opisywany głównie empirycznie lub za pomocą mniej precyzyjnych metod.

3.4. The reconstruction of blowing pressure in pipe organ using machine learning

Publikacja „The reconstruction of blowing pressure in pipe organ using machine learning” koncentruje się na opracowaniu metody umożliwiającej precyzyjne oszacowanie wartości ciśnienia powietrza w organach piszczalkowych z wykorzystaniem modeli uczenia maszynowego. Celem jest przewidzenie ciśnienia powietrza na podstawie parametrów fizycznych piszczalek labialnych, takich jak wysokość wycięcia wargi oraz częstotliwość podstawowa dźwięku, nawet w sytuacji niepełnego instrumentu, gdzie brakuje części piszczalek lub miechów. W publikacji tej udowodniono czwartą tezę, iż modele uczenia maszynowego umożliwiają rekonstrukcję parametru ciśnienia powietrza w organach piszczalkowych z wysoką precyzją, wykorzystując jedynie zbiór cech geometrycznych i częstotliwościowych niekompletnego zestawu piszczalek wargowych.

Do badań wykorzystano syntetyczny zestaw danych, składający się z miliona symulowanych instrumentów, utworzonych przez losowy wybór podzbiorów piszczalek z czterech kompletnych organów o różnych ciśnieniach powietrza. Wygenerowanie i efektywne przetworzenie tak obszernej struktury danych wymagało rozwiązania problemów charakterystycznych dla dużych zbiorów danych (ang. Big Data), w tym implementacji dedykowanych algorytmów zapewniających unikalność generowanych próbek oraz optymalizacji zarządzania pamięcią operacyjną. Uzyskany w ten sposób duży i zróżnicowany zbiór danych pozwala nauczyć modele uwzględniające różne konfiguracje kompletności instrumentu. Przyjęto cztery kluczowe cechy wejściowe: wysokość wycięcia wargi piszczalki, prędkość przepływu powietrza, częstotliwość podstawową dźwięku, oraz ciśnienie w stopie piszczalki. Do szczegółowego wyliczania ciśnienia w organach zastosowano równanie nieliniowe oraz numeryczną metodę Newtona-Raphsona do rozwiązywania takich równań, opisujących zależności fizyczne.

Modele uczenia maszynowego, takie jak las losowy (ang. Random Forest, RF) i wielowarstwowy perceptron (ang. Multilayer Perceptron, MLP), wykazały wysoką skuteczność w przewidywaniu ciśnienia powietrza w organach na podstawie wybranych parametrów. W szczególności RF osiągnął współczynnik korelacji Pearsona 0,97 oraz dokładność predykcji sięgającą 96% w sytuacji, gdy do dyspozycji było 75% piszczalek instrumentu. Nawet przy zaledwie 10% zachowanych piszczalek model MLP pozwalał uzyskać oszacowanie ciśnienia z zadowalającą dokładnością. Analiza ważności cech wskazała, że kluczowym parametrem determinującym ciśnienie powietrza w organach jest wysokość

wycięcia wargi, a częstotliwość podstawowa również odgrywa istotną rolę, co jest zgodne z wiedzą organmistrzowską.

Wyniki potwierdzają, że modele uczenia maszynowego mogą skutecznie rekonstruować istotne parametry akustyczno-fizyczne nie tylko dla kompletnych, ale także dla poważnie uszkodzonych instrumentów, bez konieczności ingerencji w strukturę piszczałek. Proponowana metodologia stanowi innowacyjne i bezpieczne narzędzie dla procesów rekonstrukcji i konserwacji instrumentów, eliminując ryzyko destrukcji historycznych elementów przez ich regulacje metodą prób i błędów, obejmujące wielokrotne mechaniczne modyfikacje piszczałek, zmiany geometrii warg, skracanie korpusów czy eksperymentalne podnoszenie ciśnienia powietrza w organach.

Praca wyprowadza również wzór opisujący ciśnienie powietrza w stopie piszczałki jako funkcję wysokości wycięcia wargi oraz częstotliwości podstawowej dźwięku, co upraszcza teoretyczne i praktyczne podejście do strojenia i rekonstruowania organów piszczałkowych. Metodyka wykorzystania algorytmów uczenia maszynowego wraz ze szczegółową analizą numeryczną pozwala wyznaczyć ciśnienie powietrza w organach z dużą precyzją w warunkach ograniczonego zestawu danych, co stanowi przełom w ochronie i odbudowie historycznych organów. Niniejsza publikacja dowodzi czwartej tezy rozprawy, potwierdzając, że modele uczenia maszynowego pozwalają na wysoce precyzyjną rekonstrukcję ciśnienia powietrza w organach, nawet przy wykorzystaniu ograniczonego zbioru cech geometrycznych i częstotliwościowych, pochodzących z niekompletnego zestawu piszczałek.

3.5. Predictive algorithms for determining blowing pressure in a pipe organ

Publikacja „Predictive algorithms for determining blowing pressure in a pipe organ” rozszerza badania zawarte we wcześniejszej publikacji, dotyczącej rekonstrukcji ciśnienia powietrza w organach piszczałkowych z użyciem uczenia maszynowego, omawianej w poprzednim podrozdziale niniejszej rozprawy, pt. „The reconstruction of blowing pressure in pipe organ using machine learning”. Artykuł ten, podobnie jak uprzednia publikacja, dowodzi czwartej tezy, według której modele uczenia maszynowego umożliwiają rekonstrukcję ciśnienia powietrza w organach piszczałkowych z wysoką precyzją, wykorzystując jedynie zbiór cech geometrycznych i częstotliwościowych, również w przypadku niekompletnego instrumentu. Rozszerzenie to polega w szczególności na zastosowaniu generatywnej sztucznej inteligencji (ang. Artificial Intelligence, AI) wraz z tradycyjnymi

modelami uczenia maszynowego, co umożliwia efektywne uzyskanie predykcji ciśnienia powietrza w organach, nawet w przypadku instrumentów wysoce niekompletnych. Dokonano także walidacji zaproponowanej metodologii na innym, niewykorzystanym w treningu, instrumencie, uzyskując również wyższą dokładność prognoz przez wytrenowane modele.

Przyjętą przesłanką jest założenie, że parametry fizyczne piszczałek labialnych, takie jak wysokość wycięcia wargi oraz częstotliwość podstawowa generowanego dźwięku, umożliwiają dokładne przewidywanie wartości ciśnienia powietrza w stopie piszczałki. Podejście to stanowi formę inżynierii odwrotnej (ang. reverse engineering). W przeciwieństwie do tradycyjnego procesu budowy instrumentu, gdzie organmistrz najpierw ustala ciśnienie wiatrownicy, a następnie intonuje piszczałki, niniejsza metoda pozwala odtworzyć pierwotną wartość ciśnienia na podstawie analizy zachowanych, często niekompletnych organów. Ponadto udowodniono, że algorytmy uczenia maszynowego mogą skutecznie realizować ten proces inwersyjny, wykorzystując jedynie ograniczony zbiór parametrów geometryczno-częstotliwościowych, co fundamentalnie zmienia możliwości rekonstrukcji uszkodzonych instrumentów.

W porównaniu do poprzedniej pracy, badania zostały rozszerzone o sieci konwolucyjne (CNN), sieci rekurencyjne (ang. Recurrent Neural Network, RNN) oraz modele hybrydowe proponowane przez generatywne LLM, takie jak Gemini i Llama. Modele trenowano na 70% danych przy użyciu pięciokrotnej walidacji krzyżowej, walidowano na pozostałych 30%, zaś testowano na zestawie pochodzącym z nieużywanego w treningu instrumentu, pochodzącego z innej epoki i regionu geograficznego, co potwierdziło ogólność metody. Wprowadzono wielowątkową implementację modeli regresji z biblioteki Weka, wykorzystującą Executor i wyrażenia Lambda w Javie, co umożliwiło równoległe trenowanie modeli na milionie symulowanych zbiorów danych. Ta optymalizacja znacząco skróciła czas obliczeń z rzędu godzin do minut, przy jednoczesnym zapewnieniu unikalności generowanych zbiorów poprzez mechanizm indeksowania binarnego. Uzyskano również wyższą dokładność wytrenowanych modeli.

Wyniki wskazują na wysoką skuteczność predykcji ciśnienia powietrza w organach, szczególnie przy wykorzystaniu modeli lasu losowego (RF) i głębokiego sieciowego lasu decyzyjnego (ang. Deep Neural Decision Forest, DNDF), które osiągnęły dokładność przekraczającą 95% i wysokie wartości współczynnika korelacji Pearsona (około 0,97–0,99). Modele te wykazują stabilność wobec różnego stopnia kompletności danych wejściowych, a ich parametry oceny: średni błąd bezwzględny (ang. Mean Absolute Error, MAE), pierwiastek z błędu średniokwadratowego (ang. Root Mean Square Error,

RMSE), średni bezwzględny błąd procentowy (ang. Mean Absolute Percentage Error, MAPE) wskazują na bardzo niskie błędy predykcji. Analiza istotności cech wyodrębniła wysokość wycięcia wargi jako kluczowy parametr decydujący o wartości ciśnienia, co jest spójne z wiedzą fachową z zakresu organoznawstwa. Druga istotna cecha to częstotliwość podstawowa, która wpływa na prawidłowe strojenie i barwę dźwięku.

Korzystanie z generatywnej AI umożliwiło szybkie prototypowanie nowych architektur sieci neuronowych oraz automatyzację wyboru hiperparametrów, chociaż w badaniach zauważono ograniczenia związane z halucynacjami modelu oraz jego nieprzejrzyistością (problem czarnej skrzynki). Niemniej jednak wykorzystane w badaniach propozycje modeli, generowane przez AI, dały wysoką jakość predykcji.

Przedstawiona metodologia oferuje praktyczne narzędzie informatyczne dla organmistrzów, pozwalające na szybkie i precyzyjne odtworzenie ciśnienia powietrza w organach nawet w przypadkach poważnego uszkodzenia instrumentu. Wprowadzono wielowątkową implementację modeli regresji z biblioteki Weka z mechanizmem zapewnienia unikalności symulowanych zbiorów danych, oraz wykorzystano generatywną AI do projektowania architektur sieci neuronowych oraz treningów. Ponadto, na podstawie przeprowadzonych badań zaproponowano wzór opisujący ciśnienie powietrza w stopie piszczałki w funkcji wysokości wycięcia i częstotliwości, co usprawnia analityczne i praktyczne podejście do strojenia organów piszczałkowych.

Praca wnosi istotny wkład również w dziedzinę rekonstrukcji instrumentów muzycznych, wprowadzając skuteczne metody informatyczne, w tym AI, do ochrony i konserwacji dziedzictwa kulturowego. Zaproponowana metodologia umożliwia odtwarzanie parametrów historycznych organów piszczałkowych – takich jak ciśnienie powietrza w organach – bez ingerencji w zabytkowe piszczałki, co minimalizuje ryzyko nieodwracalnych uszkodzeń cennych artefaktów. Szczególnie w sytuacjach pożarów instrumentów, wojen i zaniedbań konserwatorskich, metodologia zaproponowana w przedstawionych badaniach stanowi przełomowe narzędzie umożliwiające odbudowę zniszczonych instrumentów przy zachowaniu ich autentyczności historycznej.

Rozdział 4

Podsumowanie

Podsumowując niniejszą rozprawę należy podkreślić, że wszystkie postawione tezy zostały zarówno teoretycznie zweryfikowane, jak i empirycznie potwierdzone w dołączonych publikacjach naukowych. Zaproponowane modele matematyczne i algorytmy uczenia maszynowego skutecznie opisują wpływ przeszkód, typów warg oraz innych parametrów fizycznych na parametry akustyczne piszczałek, a ponadto umożliwiają precyzyjne wyznaczanie ciśnienia powietrza w organach. Założenia badawcze znalazły swoje potwierdzenie nie tylko w analizach i symulacjach, lecz także w praktycznych zastosowaniach renowacyjnych, prowadzonych w praktyce organmistrzowskiej.

Pierwsza publikacja „Problem of placing the organ pipes on the windchest” analizuje wpływ bliskiego położenia piszczałek na wiatrownicy na parametry dźwięku, w tym rozstrojenie i poziom natężenia dźwięku. Pierwsza teza, mówiąca o istnieniu zależności między obecnością przeszkody w polu bliskim wargi piszczałki labialnej a zmianą jej parametrów sygnałowych, pozwalającej na predykcję zmiany częstotliwości podstawowej i poziomu dźwięku w procesie strojenia instrumentu, została potwierdzona w empirycznych pomiarach, a następnie analizach i obliczeniach, które wykazały rozstrojenie sięgające półtonu temperowanego w skrajnych przypadkach. Stanowi to istotne wyzwanie dla konstrukcji i strojenia organów zwłaszcza w ograniczonych przestrzeniach. W pracy dokonano cyfrowej analizy sygnałów akustycznych, co pozwoliło na sformułowanie ilościowych reguł opisujących zjawisko zaburzenia pola bliskiego wargi piszczałki przez przeszkodę oraz opracowanie wytycznych dla algorytmicznego wspomaganie procesu rozmieszczania piszczałek na wiatrownicy.

W artykule „Recognition of the flue pipe type using deep learning” zademonstrowano zastosowanie głębokich sieci neuronowych do automatycznego rozpoznawania typu warg piszczałek na podstawie ich widma akustycznego. Przygotowano obszerny zestaw wysokiej jakości nagrań dźwiękowych, wykonanych w warsztacie organmistrzowskim, umożliwiających skuteczny trening modeli sztucznych sieci neuronowych, które osiągnęły wysoką precyzję klasyfikacji. Teza o możliwości klasyfikacji typu

wargi piszczałki na podstawie analizy jej cech akustycznych została udowodniona dzięki skutecznym modelom głębokich sieci neuronowych. Ponadto badania te implikują, że metody głębokiego uczenia mogą efektywnie wspierać proces intonacji, dostarczając organmistrzowi obiektywnej informacji o typie konstrukcyjnym wargi piszczałki – kluczowym determinancie jej charakterystyki brzmieniowej. Automatyczna identyfikacja tego parametru na podstawie analizy widmowej, eliminująca konieczność wizualnej inspekcji trudno dostępnych elementów, umożliwia szybsze i precyzyjniejsze dostosowanie cech akustycznych instrumentu do zamierzonego efektu muzycznego, ograniczając przy tym poleganie wyłącznie na subiektywnej ocenie słuchowej.

Trzecia publikacja „The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe’s mouth” potwierdziła tezę o możliwości użycia głębokich sieci neuronowych do danych reprezentujących widmo sygnału akustycznego w celu automatycznej i wysoce skutecznej klasyfikacji typów konstrukcyjnych warg piszczałek organowych. Zastosowano metodę rachunku przedziałowego do nieinwazyjnych pomiarów zmian prędkości strumienia powietrza i częstotliwości podstawowej, co pozwoliło uwzględnić wpływ ułożenia sąsiednich piszczałek lub szafy organowej na strojenie. Opracowano wzory regresji logarytmicznej opisujące zjawisko rozstrojenia przy różnych typach warg, co pozwala na kwantyfikację wpływu bliskości sąsiednich piszczałek lub obudowy instrumentu na częstotliwość podstawową dźwięku. Dzięki temu organmistrzowie mogą precyzyjniej i szybciej dostosowywać strojenie, uwzględniając efekt interakcji przestrzennych między piszczałkami na ich parametry akustyczne, co znacząco redukuje liczbę iteracji strojenia i czasu poświęconego na końcowe dopracowanie stroju instrumentu. Jest to szczególnie istotne w warunkach ograniczonej przestrzeni montażowej, typowej dla mniejszych organów czy pozytywów, gdy wstępne strojenie odbywa się w warsztacie organmistrzowskim, a ostateczne musi być korygowane na miejscu instalacji – często oddalonym setki kilometrów od warsztatu – gdzie efekt bliskości piszczałek ujawnia się dopiero po montażu na wiatrownicy. Uzyskane wyniki badań, zaprezentowane w tej publikacji, znalazły praktyczne zastosowanie w rekonstrukcji pozytywu szkatulnego w Kamieniu Pomorskim, o czym wspomina sam organmistrz w dokumentacji dotyczącej rekonstrukcji instrumentu: *„Wykorzystanie tej pracy jest konieczne, gdyż budowa rekonstruowanego pozytywu wymaga takiego rozplanowania piszczałek, aby zminimalizować efekt rozstrojenia się ich wtedy, gdy drzwiczki pozytywu będą zamknięte. (...) bez przeprowadzonych badań, opisanych w powyższych pracach, rekonstrukcja pozytywu szkatulnego z Kamienia Pomorskiego byłaby całkowicie niemożliwa. Dzięki uzyskanym rezultatom, można przywrócić do pełnej funkcjonalności ten zabytkowy instrument.”*

Kolejna praca „The reconstruction of blowing pressure in pipe organ using machine learning” dowiodła tezy, że modele uczenia maszynowego umożliwiają rekonstrukcję parametru ciśnienia powietrza w organach piszczalkowych z wysoką precyzją. Zastosowanie takich modeli jest niezbędne do ochrony historycznych instrumentów przed nieodwracalnymi uszkodzeniami, gdyż organmistrzowie muszą mechanicznie zmieniać parametry warg (np. nacinać wycięcie) piszczalek, aby dostroić je do ciśnienia powietrza w organach, jeżeli przyjęli inne niż było pierwotnie. Zastosowano rozbudowane modele uczenia maszynowego wraz z zaawansowanymi strategiami treningowymi oraz rozwiązaniami programistycznymi dla skutecznego przetwarzania dużych zbiorów danych reprezentujących różne instrumenty. Praca demonstruje praktyczne aplikacje i potwierdza trafność założeń badawczych, wprowadzając innowacyjne metody dla budowniczych i konserwatorów organów.

Najnowsza publikacja „Predictive algorithms for determining blowing pressure in a pipe organ” rozszerza nowatorską metodologię wykorzystania uczenia maszynowego o użycie generatywnej sztucznej inteligencji do predykcji ciśnienia powietrza w organach piszczalkowych. W pracy tej zaproponowano również formułę opisującą ciśnienie powietrza w stopie piszczalki na podstawie wysokości wycięcia warg i częstotliwości podstawowej dźwięku piszczalki, a także szczegółowo omówiono implementację modeli uczenia maszynowego i sztucznych sieci neuronowych, które umożliwiają dokładne określenie ciśnienia nawet przy niekompletnych zestawach piszczalek, co ma kluczowe znaczenie w procesach renowacji.

Podsumowując, wyniki osiągnięte w ramach niniejszej rozprawy mają znaczący wpływ na codzienne działania organmistrzów, dostarczając im precyzyjnych metod do strojenia i rekonstrukcji instrumentów.

W przyszłości planowane jest rozszerzenie badań o analizę wpływu dodatkowych parametrów piszczalek, takich jak wymiary szczeliny czy proporcje długości do średnicy piszczalki na ciśnienie we wiatrownicy organów. Dalsze prace będą również skoncentrowane na optymalizacji modeli predykcyjnych, aby skutecznie działały nawet przy wysoce niekompletnych zestawach piszczalek. Projektowanie nowych architektur sieci neuronowych oraz technik regresji może przynieść jeszcze lepsze wyniki. Szybsze i dokładniejsze algorytmy znacząco skrócą czas rekonstrukcji instrumentów, jednocześnie ułatwiając i usprawniając pracę organmistrzów.

Rozdział 5

Bibliografia

1. Adachi S., Angster J. & Miklós A., **Numerical simulation of the flow in the flue organ pipe**, *Fortschritte Der Akustik*, 33 (2007) 1, pp. 225-226, https://pub.dega-akustik.de/DAGA_1999-2008/data/articles/003154.pdf [Dostęp: 16.01.2026].
2. Angster J. & Miklós A., **Properties of the Sound of Flue Organ Pipes**, in: Bader R. (ed.), "Springer Handbook of Systematic Musicology", Berlin-Heidelberg, Germany: Springer, 2018, pp. 141-155, doi: 10.1007/978-3-662-55004-5_8.
3. Angster J., Miklós A. & Rucz P., **Acoustics of Organ Pipes and Future Trends in the Research**, *Acoustics Today*, 13 (2017), pp. 10-18, <https://acousticstoday.org/wp-content/uploads/2021/08/Acoustics-of-Organ-Pipes-and-Future-Trends-in-the-Research-Judit-Angster-1.pdf> [Dostęp: 16.01.2026].
4. Angster J., Pitsch S. & Miklós A., **The influence of different types of windchests on the sound formation of flue organ pipes**, *Fortschritte der Akustik*, 30 (2004), pp. 1227-1228, https://pub.dega-akustik.de/DAGA_1999-2008/data/articles/001841.pdf [Dostęp: 16.01.2026].
5. Außerlechner H., Trommer T., Angster J. & Miklós A., **Experimental jet velocity and edge tone investigations on a foot model of an organ pipe**, *J. Acoust. Soc. Am.*, 126 (2009), pp. 878-886, doi: 10.1121/1.3158935.
6. Bianco M.J., Gerstoft P., Traer J., Ozanich E., Roch M.A., Gannot S. & Deledalle C.A., **Machine learning in acoustics: Theory and applications**, *J. Acoust. Soc. Am.*, 146 (2019) 5, pp. 3590-3628, doi: 10.1121/1.5133944.
7. Bordoni P., Ody P., Kotus J. & Kostek B., **Sounding Mechanism of a Flue Organ Pipe - A Multi-Sensor Measurement Approach**, *Sensors*, 24 (2024) 6, p. 1962, doi: 10.3390/s24061962.
8. Chen J., Tatar K. & Zappi V., **A Deep Learning Framework for Musical Acoustics Simulations**, *AIMC*, Aug. 2024, <https://aimc2024.pubpub.org/pub/5cl1cvmy> [Dostęp: 16.01.2026].

9. Cheong C., Joseph P., Park Y. & Lee S., **Computation of aeolian tone from a circular cylinder using source models**, *Appl. Acoust.* 69 (2008), pp. 110–126, doi: 10.1016/j.apacoust.2006.10.004.
10. Czyżewski A., Kostek B. & Zieliński S., **Synthesis of organ pipe sound based on simplified physical models**, *Arch. Acoust.*, 21 (1996), pp. 131–147, <https://acoustics.ippt.pan.pl/index.php/aa/article/view/986> [Dostęp: 16.01.2026].
11. Danihelová A., Štafura A., Čulík M. & Gergeľ T., **Influence of Wood and Thickness of Back Wall of Wooden Organ Pipe and Air Pressure in Windchest on Sound**, *Appl. Sci.*, 14 (2024) 17, p. 7897, doi: 10.3390/app14177897.
12. de Lauro E., de Martino S., Esposito E., Falanga M. & Tomasini E., **Analogical model for mechanical vibrations in flue organ pipes inferred by independent component analysis**, *J. Acoust. Soc. Am.*, 122 (2007), pp. 2413–2424, doi: 10.1121/1.2772225.
13. Dequand S., Willems J.F., Leroux M., Vullings R., van Weert M., Thieulot C. & Hirschberg A., **Simplified models of flue instruments: Influence of mouth geometry on the sound source**, *J. Acoust. Soc. Am.*, 113 (2003) 3, pp. 1724–1735, doi: 10.1121/1.1543929.
14. Elder S.A., **On the mechanism of sound production in organ pipes**, *J. Acoust. Soc. Am.*, 54 (1973) 6, pp. 1554–1564, doi: 10.1121/1.1914453.
15. Fabre B., Gilbert J. & Hirschberg A., **Modeling of wind instruments**, in: R. Bader (ed.), “Springer handbook of systematic musicology”, Berlin-Heidelberg, Germany: Springer, 2018, pp. 121–139, doi: 10.1007/978-3-662-55004-5_7.
16. Fletcher N.H., **Sound production by organ flue pipes**, *J. Acoust. Soc. Am.*, 60 (1976) 4, pp. 926–936, doi: 10.1121/1.381174.
17. Fletcher N.H. & Douglas L.M., **Harmonic generation in organ pipes, recorders, and flutes**, *J. Acoust. Soc. Am.*, 68 (1980), pp. 767–771, doi: 10.1121/1.384815.
18. Fujita H., **The characteristics of the Aeolian tone radiated from two-dimensional cylinders**, *Fluid Dyn. Res.*, 42 (2010), p. 015002, doi: 10.1088/0169-5983/42/1/015002.
19. Gautier F., Nief G., Gilbert J. & Dalmont J.P., **Vibro-acoustics of organ pipes – Revisiting the Miller experiment (L)**, *J. Acoust. Soc. Am.*, 131 (2012), pp. 737–738, doi: 10.1121/1.3651792.

20. Helmholtz H.V., **Theorie der Luftschwingungen in Röhren mit offenen Enden**, *J. Reine Angew. Math.*, 57 (1860), pp. 1–72, http://resolver.sub.uni-goettingen.de/purl?PPN243919689_0057 [Dostęp: 16.01.2026].
21. Herremans D. & Chuan C., **The emergence of deep learning: new opportunities for music and audio technologie**, *Neural Comput. and Appl.*, 32 (2020), pp. 913–914, doi: 10.1007/s00521-019-04166-0.
22. Hruška V. & Dlask P., **Connections between organ pipe noise and Shannon entropy of the airflow: preliminary results**, *Acta Acustica united with Acustica* 103 (2017), pp. 1100–1105, doi: 10.3813/AAA.919137.
23. Hruška V. & Dlask P., **Investigation of the sound source regions in open and closed organ pipes**, *Arch. Acoust.*, 3 (2019) 44, pp. 467–474, doi: 10.24425/aoa.2019.129262.
24. Hruška V. & Dlask P., **On a Robust Descriptor of the Flue Organ Pipe Transient**, *Arch. Acoust.*, 45 (2020), pp. 377–384, doi: 10.24425/aoa.2020.134054.
25. Humphrey E.J., Bello J.P. & LeCun Y., **Feature learning and deep architectures: new directions for music informatics**, *J. Intell. Inf. Syst.*, 41 (2013), pp. 461–481, doi: 10.1007/s10844-013-0248-5.
26. Kanda H. & Shimomukai K., **Numerical study of pressure distribution in entrance pipe flow**, *J. of Complex.*, 25 (2009) 3, pp. 253–267, doi: 10.1016/j.jco.2009.02.003.
27. Kokkelmans S., Verge M.P., Hirschberg A., Wijnands A.P.J. & Schoffelen R., **Acoustic behavior of chimney pipes**, *J. Acoust. Soc. Am.*, 105 (1999), pp. 546–551, doi: 10.1121/1.424590.
28. Liljencrants J., **End Correction at a Flue Pipe Mouth**, Johan Liljencrants on organs, pipes, air supply, <https://fonema.liljencrantz.se/mouthcorr/mouthcorr.htm> [Dostęp: 16.01.2026].
29. Lim H.C. & Razi F., **Experimental study of flow-induced whistling in pipe systems including a corrugated section**, *Energies*, 11 (2018), p. 1954, doi: 10.3390/en11081954.
30. Lunn A.C., **The influence of blowing pressure on pitch of organ pipes**, *Phys. Rev.*, 15 (1920) 5, pp. 446–449, doi: 10.1103/PhysRev.15.446.
31. Mallock A., **Note on the effect of wind pressure on the pitch of organ pipe**, *Proc. R. Soc. Lond.*, 95 (1918) 666, pp. 99–106, doi: 10.1098/rspa.1918.0051.
32. Mickiewicz W., **Particle Image Velocimetry and Proper Orthogonal Decomposition Applied to Aerodynamic Sound Source Region Visualization in Organ Flue Pipe**, *Arch. Acoust.*, 40 (2015), pp. 475–484, doi: 10.1515/aoa-2015-0047.

33. Nolle A.W. & Finch T.L., **Starting transients of flue organ pipes in relation to pressure rise time**, 91 (1992), pp. 2190–2202, doi: 10.1121/1.403653.
34. Ody P., Kotus J., Szczodrak M. & Kostek B., **Sound intensity distribution around organ pipe**, *Arch. of Acoust.*, 42 (2017) 1, pp. 13-22, doi: 10.1515/aoa-2017-0002.
35. Pitsch S., Rucz P., Angster J., Miklós A. & Kirschmann J., **Scaling software for labial organ pipes**, in: *Proc. AIA-DAGA*, Merano, 2013, pp. 299-302, <https://publica.fraunhofer.de/handle/publica/380398> [Dostęp: 16.01.2026].
36. Roch M.A., Gerstoff P., Kostek B. & Michalopoulou Z.H., **How machine learning contributes to solve acoustical problems**, *Acoust. Today*, 17 (2021) 4, pp. 48-57, doi: 10.1121/AT.2021.17.4.48.
37. Rucz P., Angster J. & Miklós A., **Examination of a novel organ pipe construction with blown open tongue**, *Fortschritte der Akustik*, 42 (2016), pp. 1292–1295, https://pub.dega-akustik.de/DAGA_2016/data/articles/000309.pdf [Dostęp: 16.01.2026].
38. Rucz P., **Determination of organ pipes' acoustic parameters by means of numerical techniques**, M.A. thesis, Budapest University of Technology and Economics, Hungary, 2009, https://www.hit.bme.hu/~rucz/pub/Rucz_-_Masters_Thesis.pdf [Dostęp: 16.01.2026].
39. Rucz P., Augusztinovicz F., Angster J., Preukschat T. & Miklós A., **Acoustic behaviour of tuning slots of labial organ pipes**, *J. Acoust. Soc. Am.*, 5 (2014) 135, pp. 3056–3065, doi: 10.1121/1.4869679.
40. Saenger K.L., **A pressure-based transfer matrix method and measurement technique for studying resonances in flutes and other open-input resonators**, *J. Acoust. Soc. Am.*, 147 (2020) 4, pp. 2556-2569, doi: 10.1121/10.0001102.
41. Sakamoto Y., Yoshikawa S. & Angster J., **Acoustical investigations on the ears of flue organ pipes**, in: "Forum Acusticum", EAA-Opakfi, Hungary, Budapest, 2005, pp. 647-651, https://www.academia.edu/18627118/Acoustical_investigations_on_the_ears_of_flue_organ_pipes [Dostęp: 16.01.2026].
42. Selfridge R., Moffat D., Avital E.J. & Reiss J.D., **Creating real-time aeroacoustic sound effects using physically informed models**, *J. Audio Eng. Soc.*, 66 (2018) 66, pp. 594–607, doi: 10.17743/jaes.2018.0033.
43. Smith H., **On the Physical Action taking place at the Mouth of Organ-pipes**, *Nat.*, 10 (1874), pp. 161–163, doi: 10.1038/010161d0.

44. Steenbrugge D. & de Baets P., **Aerodynamics of flue organ pipe voicing**, *International J. of Sustainable Construction and Des.*, 1 (2010) 1, pp. 162-173, doi: 10.21825/scad.v1i1.20421.
45. Steenbrugge D., **Flue organ pipe operating regimes and voicing practices**, in: "Acoustics 2012", Nantes, France: HAL, 2012, pp. 2789-2794, <https://hal.science/hal-00811336> [Dostęp: 16.01.2026].
46. Steenbrugge D., **Fluid mechanical aspects of open-and closed-toe flue organ pipe voicing**, *International J. of Sustainable Construction and Des.*, 2 (2011) 2, pp. 284-295, doi: 10.21825/scad.v2i2.20526.
47. Štafura A. & Nagy S., **The upper lip as a voicing element of wooden organ pipes**, *Akustika*, 25 (2016) 1, pp. 55-61.
48. Taesch C., Wik T., Angster J. & Miklós A., **Attack transient analysis of flue organ pipes with different cut-up height**, in: "Proceedings of the CFA/DAGA'04", Strasbourg, France, 22-25 March 2004, pp. 1239-1240, https://pub.dega-akustik.de/DAGA_1999-2008/data/articles/001844.pdf [Dostęp: 16.01.2026].
49. Vaik I. & Paal G., **Flow simulations on an organ pipe foot model**, *J. Acoust. Soc. Am.*, 133 (2013), pp. 1102-1110, doi: 10.1121/1.4773861.
50. Verge M.P., Fabre B., Mahu W.E.A., Hirschberg A., van Hassel R.R., Wijnands A.P.J., de Vries J.J. & Hogendoorn C.J., **Jet formation and jet velocity fluctuations in a flue organ pipe**, *J. Acoust. Soc. Am.*, 95 (1994), pp. 1119-1132, doi: 10.1121/1.408460.
51. Widmer G., **On the Potential of Machine Learning for Music Research**, in: E.R. Miranda (ed.), "Readings in Music and Artificial Intelligence," Routledge, New York, 2013.
52. Yoshikawa S., **Jet-wave amplification in organ pipes**, *J. Acoust. Soc. Am.*, 103 (1998), pp. 2706-2717, doi: 10.1121/1.423113.

Rozdział 6

Artykuły dołączone do rozprawy

6.1 Problem of placing the organ pipes on the windchest

Tytuł	Problem of placing the organ pipes on the windchest
Autorzy	Węgrzyn, D. & Wrzeciono, P.
Czasopismo	Vibrations in Physical Systems
Tom	30
Rok	2019
ID publikacji	2019121
Strony	1-8
URL	https://vibsys.put.poznan.pl/_journal/2019-30-1/articles/vibsys_2019121.pdf
Punkty ministerialne	70

Problem of placing the organ pipes on the windchest

Damian WĘGRZYN

*Polish-Japanese Academy of Information Technology
Koszykowa 86 St., 02-008 Warsaw
damian.wegrzyn@pj.edu.pl*

Piotr WRZECIONO

*Warsaw University of Life Sciences
Nowoursynowska 166 St., 02-787 Warsaw
piotr_wrzeciono@sggw.pl*

Abstract

This paper presents research showing the problem occurring in the construction of a pipe organ, related to the placement of the organ pipes on the windchest. The close location of the organ pipes to each other influences the parameters of the sound generated by the pipes. It causes an intonation problem, namely the detuning of the organ pipes if they are located too close to each other on the windchest. The presented measurements show the influence of a distance between pipes of various types on basic sound parameters, such as frequency or volume level. The research carried out shows that in extreme cases the detuning reaches a temperate half-tone. This has undoubtedly an impact on the tuning of organ pipes, especially in the case of a table organ or pipe organ built in a small space. In the future, the outcomes of the presented research can be applied in the windchest design.

Keywords: pipe organ, windchest, organ pipe distance.

1. Introduction

An organ is a musical instrument built of many pipes, placed on a windchest, i.e. a device used to distribute air between particular pipes [1]. While making the instrument, there is not much space for a large distance between these numerous pipes on a windchest. In the small instruments, e.g., table organs, the dimensions of the windchest are relatively small. As a consequence, intonation problems occur because the neighbouring pipes can influence each other's sound. The main reason for this kind of issues is the way of sound generation, because the necessary condition of proper working of the organ pipe (i.e. generating the sound) is a turbulent flow through the so-called mouth of the pipe [1]. Changes in the flow significantly affect the sound parameters.

This paper presents research on the impact of placing organ pipes (on the windchest) on the basic sound parameters. This problem is a critical issue from the viewpoint of organbuilders, as well as musicians playing small organs. The final goal of this

research is to create a model of the behaviour of organ pipes during tuning and intonation.

The results presented in this paper are new in the area of research on the acoustics of pipe organs. Previous publications relate primarily to the work of the organ pipe as a sound source without taking into account its environment [2, 3, 5, 6, 8, 9, 10].

2. Measurements

The presented research was carried out on the intonation table in an organbuilder's workshop. The air pressure in the windchest was set to 67 mm water gauge. In the organbuilding community, the measurement of relative pressure is commonly applied, using the u-tube manometer filled with water. The air temperature in the workshop was 19°C.

We performed the sound measurements using the sound recording at various distances from the obstacle. For each distance, the measurement was performed at least five times. The obstacles were set at distances from 0 mm to 80 mm, in 5 mm steps. At a distance equal to or greater than 80 mm, we did not notice changes in the parameters of the recorded signal.



Figure 1. Measuring point and sample measurement for Bourdon 8-foot: a) without obstacles, and b) with an obstacle

The measurements (Figure 1) were made for labial pipes representing various types: Principal 4-foot (open, metal, 75% tin and 25% lead, English bay leaf mouth with 29,4 mm width, 37,9 mm internal diameter, 530 mm wavelenght, the theoretical frequency: 323.16 Hz), Bourdon 8-foot (open, oakwood, external mouth with 41,1 mm width, 41,9 x 51,9 mm internal dimensions, 580 mm wavelenght, the theoretical

frequency: 295.3 Hz) and Bourdon 16-foot (stopped, oakwood, external mouth with 41,8 mm width, 42,4 x 54,5 mm internal dimensions, 590 mm wavelength, the theoretical frequency: 145.15 Hz). They are basic voices in almost every pipe organ, so we consider them representative for our research.

The sound was recorded using two measuring microphones at the same time with omnidirectional characteristics, the sensitivity of 10 mV/Pa, and an equivalent noise level of 20 dBA. The microphone no. 1 was positioned at a distance of 58 mm from the top of the pipe, and microphone no. 2 at a distance of 49 mm from the mouth of the pipe. During the recordings, Class 1 acoustic calibrator was also used (1 kHz, 94 dB).

3. Analysis and results

During the measurements, significant changes in the pitch of the pipe were noticed in the case of a small distance between the pipe mouth and the obstacle. As a consequence, the decision was made to analyse the following sound parameters: the fundamental frequency (F_0) depending on the distance of the obstacle from the mouth of the pipe, and the sound level of the first harmonic. The frequency analysis was performed in two stages. In the first stage, the fundamental frequency was found using the FFT [4] in GNU Octave programming language. The accuracy of the transform was 0.8 Hz. Due to the insufficient accuracy of this transform, the DTFT [4] in a program written by the authors in the Java environment was used in the next stage. The DTFT calculations were made in the range of $F_0 \pm 5$ Hz, for F_0 calculated in the first stage. The assumed DTFT accuracy was 0.01 Hz. Due to the usage of the calibration signal, the first harmonic's sound level analysis for the recordings was also performed (Figure 3).

The measurement uncertainty was calculated as a standard deviation from the obtained results. For the F_0 frequency, the following formula was used:

$$\sigma_{F_0} = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (F_0[k] - \mu_{F_0})^2} \quad (1)$$

where: μ_{F_0} - average F_0 , N - number of measurements, k - measurement number

Analogously to (1), the measurement uncertainty of the first harmonic's sound level was also calculated. Tables 1-3 present the results of the analysis. The dependencies between the F_0 frequency of the pipe and the distance from the obstacle are presented in Figure 2.

Distances between sounds in the equal temperament are described by intervals. Interval is the difference between two sounds. Cent is a logarithmic unit of interval measurement [7]. For each interval, the difference W_{F_0} between the measured sound and the sound without the obstacle was calculated using the following formula:

$$W_{F_0} = 1200 \cdot \log_2 \left(\frac{F_0(x)}{F_0(80)} \right) \quad (2)$$

where x is the distance from the obstacle.

Table 1. The list of measurements for the organ pipe - Bourdon 16-foot stopped, c sharp.

x	μ_{F_0}	σ_{F_0}	W_{F_0}	Microphone no. 1		Microphone no. 2	
				F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$	F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$
[mm]	[Hz]		[cent]	[dB]			
0	131.44	0.02	-99.8	86.32	0.03	103.46	0.02
5	135.12	0.01	-52.0	87.86	0.03	105.51	0.03
10	136.95	0.01	-28.7	89.32	0.02	105.61	0.03
15	137.82	0.02	-17.7	88.91	0.03	105.88	0.02
20	138.30	0.02	-11.7	88.30	0.06	106.02	0.05
25	138.60	0.02	-7.9	88.02	0.03	105.74	0.02
...							
80	139.24	0.02	0.0	87.01	0.04	104.33	0.04

Table 2. The list of measurements for the organ pipe - Bourdon 8-foot open, b.

x	μ_{F_0}	σ_{F_0}	W_{F_0}	Microphone no. 1		Microphone no. 2	
				F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$	F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$
[mm]	[Hz]		[cent]	[dB]			
0	238.14	0.01	-103.1	109.15	0.04	106.61	0.04
5	246.02	0.03	-46.8	111.73	0.03	109.83	0.02
10	249.22	0.03	-24.4	112.18	0.09	109.63	0.09
15	250.61	0.04	-14.8	112.37	0.04	110.08	0.05
20	251.30	0.02	-10.0	112.41	0.06	110.18	0.07
25	251.76	0.03	-6.9	112.55	0.08	110.13	0.08
30	251.99	0.01	-5.3	112.60	0.04	110.20	0.04
35	252.19	0.06	-3.9	112.54	0.06	109.92	0.07
40	252.30	0.04	-3.1	112.58	0.03	109.89	0.03
45	252.38	0.02	-2.6	112.63	0.04	109.69	0.04
...							
80	252.76	0.02	0.0	111.55	0.04	106.99	0.04

Table 3. The list of measurements for the organ pipe - Principal 4-foot, e'.

x	μ_{F_0}	σ_{F_0}	W_{F_0}	Microphone no. 1		Microphone no. 2	
				F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$	F ₀ Sound level L _{Zeq}	Measurement uncertainty $\sigma_{L_{Zeq}}$
[mm]	[Hz]		[cent]	[dB]			
5	320.59	0.03	-35.3	95.72	0.02	97.45	0.04
10	324.14	0.02	-16.3	97.77	0.03	99.80	0.05
15	325.28	0.01	-10.1	98.04	0.05	100.70	0.07
20	325.81	0.02	-7.3	98.20	0.04	101.34	0.05
25	325.90	0.01	-6.9	98.22	0.02	101.67	0.03
30	326.16	0.01	-5.5	98.19	0.03	101.94	0.04
35	326.28	0.01	-4.9	98.34	0.36	102.01	0.03
40	326.37	0.01	-4.4	97.98	0.03	101.90	0.04
45	326.44	0.01	-4.0	97.99	0.02	101.90	0.03
50	326.49	0.02	-3.7	97.93	0.03	101.80	0.03
55	326.52	0.01	-3.6	97.90	0.02	101.67	0.04
...							
80	327.19	0.04	0.0	98.32	0.02	100.92	0.03




Figure 2. The dependence of the fundamental frequency F_0 of the organ pipe on the distance from the obstacle - Bourdon 16-foot stopped, c sharp.




Figure 3. The sound level depending on the distance from the obstacle - Bourdon 8-foot open, b.

The spectra shown in Figure 4 present changes in the harmonics of the pipe sound. All harmonics have a significantly lower sound level at a close distance of the obstacle from the pipe. Odd harmonics (i.e. frequencies $k \cdot F_0$, where $k=1,3,5,7\dots$), in the case of an open pipe, have a much lower sound level than without any obstacle. This phenomenon is typical for stopped pipes, but not for the open ones.




Figure 4. The spectrum of the organ pipe without the obstacle (left) and with the obstacle at 0 mm distance (right) – Bourdon 8-foot open b, microphone no. 1.

4. Musical consequences

Based on the measurements, it was found that the presence of an obstacle near the pipe has a significant impact on the pitch of the generated sound. These changes can be as much as circa -100 cents (Figure 5), which in the case of equal temperament means lowering sound pitch by a semitone. An additional consequence of this phenomenon is the time-consuming tuning and intonation of organs, if the pipes are located close to each other. The most considerable change in F_0 frequency in terms of the distance was observed for wooden pipes with a rectangular profile.

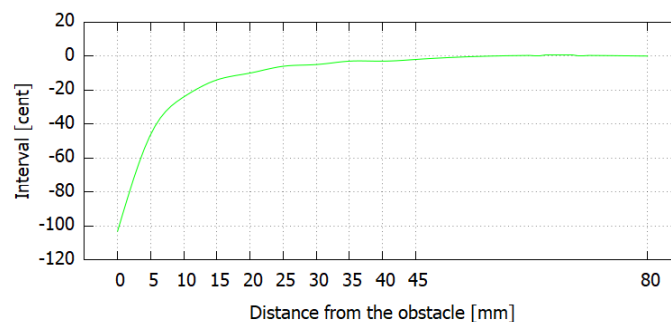


Figure 5. The interval between the tone of the organ pipe without obstacle and with the obstacle - Bourdon 8-foot open h.

There was also a change in the sound level depending on the distance observed (Figure 3). For the studied pipes, these changes were about 4 dB. Such a change may also cause intonation problems.

5. Conclusions

The results of the presented measurements show an evident effect of the distance between the pipe and the obstacle on the parameters of the generated sound. In the case of pipe organs, such obstacles are other pipes placed on the windchest. These changes are significant for organ building. It can be expected that in the case of the dense arrangement of the pipes, the instrument may not be able to tune.

We found that the impact of the obstacle on sound generation by the organ pipe exists even when the distance between the obstacle and the mouth of the pipe is relatively large. For this reason, knowledge about the behaviour of the organ pipe near the obstacle is very important in the process of designing a windchest.

Acknowledgments

The authors thank the organbuilder Władysław Cepka for providing the workshop and organ pipes for research.

References




1. J. Angster, A. Miklos, P. Rucz, *Acoustics of Organ Pipes and Future Trends in the Research*, *Acoustics Today*, 13 (2017) 10 – 18.
2. H. Außerlechner, T. Trommer, J. Angster, A. Miklos, *Experimental jet velocity and edge tone investigations on a foot model of an organ pipe*, *The Journal of the Acoustical Society of America* 126 (2009) 878 – 886.
3. S. Kokkelmans, M.P. Verge, A. Hirschberg, A.P.J. Wijnands, R. Schoffelen, *Acoustic behavior of chimney pipes*, *The Journal of the Acoustical Society of America* 105 (1999) 546 – 551.
4. B.P. Lathi, *Linear Systems and signals*, Oxford University Press, New York 2010.
5. E. de Lauro, S. de Martino, E. Esposito, M. Falanga, E. Tomasini, *Analogical model for mechanical vibrations in flue organ pipes inferred by independent component analysis*, *The Journal of the Acoustical Society of America* 122 (2007) 2413 - 2424.
6. A.W. Nolle, T.L. Finch, *Starting transients of flue organ pipes in relation to pressure rise time*, 91 (1992) 2190 – 2202.
7. E. Prout, *Harmony: Its Theory and Practice*, Cambridge University Press, New York 2011.
8. P. Rucz, F. Augusztinovicz, J. Angster, T. Preukschat, A. Miklos, *Acoustic behaviour of tuning slots of labial organ pipes*, *The Journal of the Acoustical Society of America* 135 (2014) 3056 – 3065.
9. I. Vaik, G. Paal, *Flow simulations on an organ pipe foot model*, *The Journal of the Acoustical Society of America*, 133 (2013) 1102 – 1110.
10. M.P. Verge, B. Fabre, W.E.A. Mahu, A. Hirschberg, R.R. van Hassel, A.P.J. Wijnands, J.J. de Vries, C.J. Hogendoorn, *Jet formation and jet velocity fluctuations in a flue organ pipe*, *The Journal of the Acoustical Society of America*, 95 (1994) 1119 – 1132.

6.2 Recognition of the flue pipe type using deep learning

Tytuł	Recognition of the flue pipe type using deep learning
Autorzy	Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A.
Konferencja	International Symposium on Methodologies for Intelligent Systems (ISMIS)
Materiały konferencyjne	Intelligent Systems in Industrial Applications
Rok	2020
Strony	80-93
DOI	10.1007/978-3-030-67148-8_7
Punkty ministerialne	20



Recognition of the Flue Pipe Type Using Deep Learning

Damian Węgrzyn¹(✉) , Piotr Wrzeciono² , and Alicja Wieczorkowska¹ 

¹ Polish-Japanese Academy of Information Technology,
Koszykowa 86, Warsaw, Poland

damian@wegrzyn.info, alicja@poljap.edu.pl

² Warsaw University of Life Sciences, Nowoursynowska 166, Warsaw, Poland
piotr.wrzeciono@sggw.edu.pl

Abstract. This paper presents the usage of deep learning in flue pipe type recognition. The main thesis is the possibility of recognizing the type of labium based on the sound generated by the flue pipe. For the purpose of our work, we prepared a large data set of high-quality recordings, carried out in an organbuilder's workshop. Very high accuracy has been achieved in our experiments on these data using Artificial Neural Networks (ANN), trained to recognize the details of the pipe mouth construction. The organbuilders claim that they can distinguish the pipe mouth type only by hearing it, and this is why we decided to verify if it is possible to train ANN to recognize the details of the organ pipe, as this confirms a possibility that a human sense of hearing may be trained as well. In the future, the usage of deep learning in the recognition of pipe sound parameters may be used in the voicing of the pipe organ and the selection of appropriate parameters of pipes to obtain the desired timbre.

Keywords: Flue pipe · Deep learning · Labium recognition

1 Introduction

A pipe organ consists of many pipes of various types, collected in ranks and stops. The majority of pipes is divided into two groups according to the method of sound generation: flue (labial) pipes and reed pipes [1]. Flue pipes have a variety of timbres which are achieved by the modifications of the pipe mouth. It is critical to the resulting sound because it influences the pipes' voice which has to be tuned [13]. The procedure of achieving a harmonious overall sound for the whole rank is called voicing [14].

The pipe mouth has a significant impact on a vibrating air jet [2, 6, 7, 16, 17]. In the case of flue pipes, there are four additions that can be applied to change the mouth of the pipe: ears, beard, plate, and roller (Fig. 1). These additions do

Partially supported by research funds sponsored by the Ministry of Science and Higher Education in Poland.

not occur together. They make the pipe sound lower and darker. Moreover, the sound generation is smoother and faster. Research confirms that the generated sound has a stronger, more pronounced fundamental frequency, and the amount of the harmonics is increased by these four additions. Another effect is the growth of the level of the fundamental frequency accompanied by the lowered level of other harmonics, and a slight decrease in sound pitch. The organbuilders also mention a perceptible impact of the mouth end correction on the airstream [14].




Fig. 1. Different types of elements added to flue organ pipes (from left): ears, beard, plate, roller.

Experienced organbuilders are able to recognize various stops. The main aim of this paper is to contribute to the verification of the thesis that the trained listener, e.g. organist or organbuilder, can distinguish between types of pipe mouth by listening to the generated steady-state sound. Verifying this thesis using listening tests is very difficult because it requires carrying out tests on a large number of specialists, so such tests are not feasible. Therefore, we used deep learning methods that allow creating ANNs whose structure and functions resemble the work of the human brain. Deep Learning is used in machine learning to perform natural tasks of the human brain, e.g. sound recognition.

2 Methodology

For the purpose of our research, we recorded sounds of organ pipes of various fundamental frequencies in the organbuilder’s workshop. We measured the sound level for all pipes recorded. Next, the audio data were analyzed, and used for ANN training, aiming at the recognition of the details of the pipe mouth.

The ANNs have been used in research related to the area of music for over 20 years [4, 8, 18]. Various types of networks are used in current research, especially the Convolutional Neural Network (CNN) [9] or the Long Short-Term Memory (LSTM) [12]. Thanks to them, it is possible to achieve good results and perform complex music processing tasks.

2.1 Recordings and Measurements

We performed the recordings and measurements in the organbuilder’s workshop, on the voicing chest. The air temperature was 18.5 °C. The air pressure in the windchest was set to 80 mm water gauge. The atmospheric pressure in the workshop was 1004 hPa.

The sound measurements were performed before the recording. Each recorded sound was generated by a pipe for about 4 s. Several sounds were recorded for each pipe. The measurements were made for various flue pipes tuned to miscellaneous frequencies, as shown in Table 1.

Table 1. Pipes used in our research.

Labium	Register	No of recordings	Construction
Ears	Principal 4-foot	70	Open, pewter (75% tin, 25% lead)
Beard	Bourdon 8-foot	61	Open, oakwood
	Bourdon 16-foot	33	Stopped, oakwood
	Dolce Flute 8-foot	53	Open, spruce
	Flute 4-foot	86	Open, spruce
Plate	Gamba 8-foot	57	Open, metal (55% lead, 45% tin)
Roller	Bass Principal 16-foot	185	Open, pine
	Geigen Principal 8-foot	156	Open, pine

Recordings were made using one measuring microphone with omnidirectional characteristics, the sensitivity of 10 mV/Pa and an equivalent noise level of 20 dBA. This microphone was positioned at a distance of 37 mm from the mouth (Fig. 2). The measurement system was calibrated using Class 1 acoustic calibrator (1 kHz, 114 dB).

2.2 Data Sets

The data sets used for training, validation and testing of ANN were prepared as follows. In the first stage, the recordings of 700 sounds were transformed



Fig. 2. Microphone setting in the process of pipe sound recording.

into frequency spectra using Fast Fourier Transform (FFT) [11], calculated for a frame length of 2048 samples using the Hamming window (48 kHz sampling rate was applied). One frame from the central part of each sound, representing the steady-state, was selected for further analysis. Examples of power spectra for each flue pipe type (in [dB] scale) are shown in Fig. 3. The obtained frequency components of the spectrum, as well as the level of each component, were saved in a file. The highest frequencies – above 16.5 kHz – have been omitted due to the very low level of these harmonics. This allowed us to reduce the number of inputs, and maintain the stability of training results. For each input record, i.e. for each pipe, one of four output categories has been assigned: ears, beard, plate, or roller.

In the second stage, the collected data representing 700 sounds were randomly divided into three subsets: 400 sounds for training, 150 for validation and 150 for tests. The ANN was trained, validated and tested using these data sets.

2.3 The Structure of the Artificial Neural Network

The ANN model and structure were prepared in the Python programming language using the Scikit-learn library in the Deep Cognition tool [3]. This paper presents the ANN model for which the best accuracy has been achieved.

The data set in the form of 700 records (as described in Sect. 2.2), one record per sound, was used as input. Data were stored in a file, where the 700 columns represent the values of FFT power spectrum for consecutive frequency bins, and the 700 rows represent the analyzed sounds. The output values belong to a set of four categories: ears, beard, plate, roller. They were assigned to each row as a 701st column.




Fig. 3. Spectra of flue pipes: a) ears, b) beard, c) plate, d) roller.

The hidden layer consists of 11 layers, as shown in Table 2. Three types of core layers were used: dense, activation, dropout and one type of normalization layers - batch normalization. For simplicity, both input and output were 700 in each case, except for the last instance, where output is equal to the number of categories.

The dense layer is a regular densely-connected ANN layer with a linear activation function:

$$f(x) = a \times x \quad (1)$$

where: a – the slope of the line.

The activation layer applies an activation function to the output. In all cases, a Rectified Linear Units (ReLU) function was used, which is an approximation of the Softplus function by simple zeroing negative values:

$$f(x) = \max(0, x) \quad (2)$$

This procedure speeds up both the implementation and the calculation of the algorithm and significantly accelerates the convergence of the stochastic gradient descent method [10].

The dropout layer randomly bypasses certain neurons during network training. Only part (p) of the layer's neurons are left and the rest are ignored. The method is implemented by applying a binary mask (r_n) to the output values of

Table 2. Scheme of the ANN layers of the best model.

No	Layer	Output dimensions
–	Input	700
1	Dense	700
2	Activation	700
3	Batch normalization	700
4	Dropout	700
5	Dense	700
6	Batch normalization	700
7	Activation	700
8	Dropout	700
9	Dense	700
10	Activation	700
11	Dense	4
–	Output	4

each layer. The r_n mask is different for each layer and is generated with every forward propagation [15]:

$$y'_n = \frac{r_n * y_n}{p} \quad (3)$$

where: y'_n – a modified output vector; y_n – an input vector.

Fraction to drop in dropout layers was set to 0.2.

The batch normalization layer normalizes the activations of the previous layer at each batch. A feature-wise normalization was used during this research, in which each feature map in the input is normalized separately. The batches were set to the size of 32.

The Adadelata optimizer was used during training, which is a per-dimension learning rate method for gradient descent. This method does not require manual tuning of a learning rate and is robust to noisy gradient information, various model architectures, data sets modalities and choices of hyperparameters [19]. The parameters of this optimizer were left at their default values: the initial learning rate was 1 and the rho hyperparameter, which is a decay factor that corresponds to the fraction of gradient to keep at each time step, was set to 0.95.

3 Results

The best ANN model used in our research has achieved high training and validation accuracy. The prepared data set was used in circa 60% for training, 20% for validation and 20% for tests. Weights were saved on each epoch and the

validation dataset was used to tune the parameters. The training was limited to 20 epochs because further iterations did not significantly improve accuracy. The best epoch in terms of train accuracy was the last one.

The average train accuracy that was achieved during this research was 0.9116 and the validation average accuracy was 0.9563. The obtained accuracy is shown in Fig. 4.

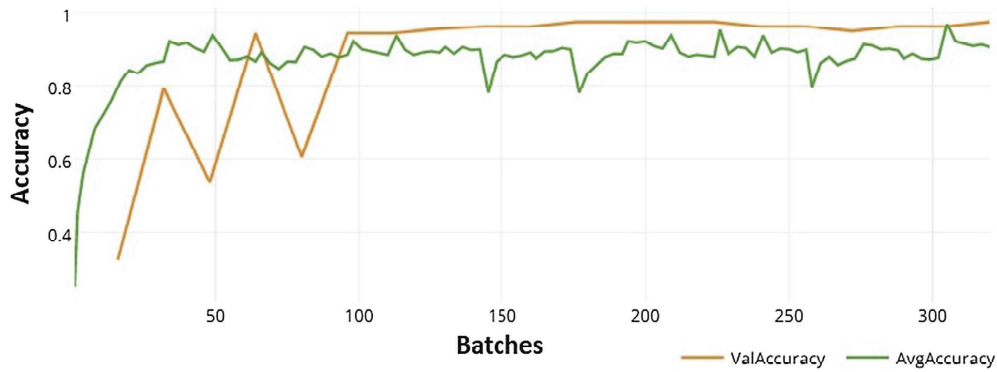


Fig. 4. The best average accuracy (AvgAccuracy) and validation accuracy (ValAccuracy).

During training of the model, the average loss of 1.1433 has been achieved. The validation loss reached near 0.0001. Figure 5 shows the decreasing loss with the increase in the number of batches.

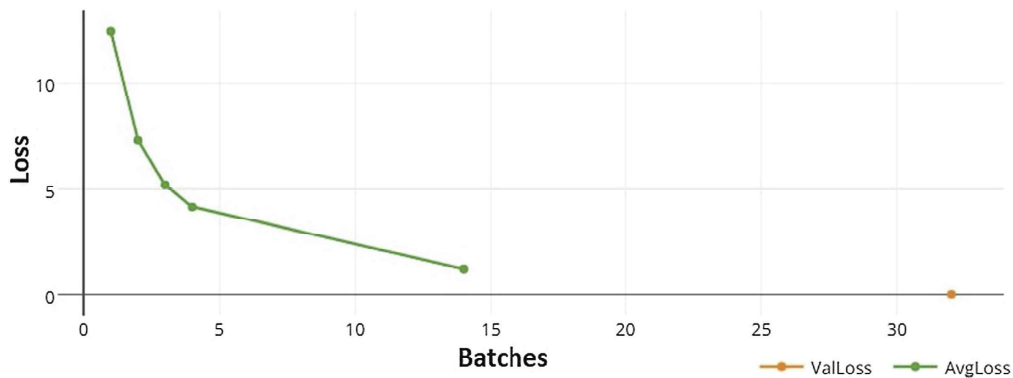


Fig. 5. The best average loss (AvgLoss) and validation loss (ValLoss).

Of the 150 tested flue pipes with various labia, only two were recognized incorrectly, i.e. instead of a beard, the ANN recognized a roller. The confusion matrix presented in Table 3 shows that the selected neural network model obtains very high-quality classification results. The classifier accuracy is 0.987, while the macro average of the F1 score is 0.991.

Table 3. Confusion matrix with classification accuracy, precision, recall and F1 score.

	True ears	True beard	True plate	True roller
Predicted as ears	16	0	0	0
Predicted as beard	0	43	0	0
Predicted as plate	0	0	15	0
Predicted as roller	0	2	0	74
Classification accuracy	0.987			
	Precision	Recall	F1	
Ears	1	1	1	
Beard	1	0.956	0.977	
Plate	1	1	1	
Roller	0.974	1	0.987	
Macro average	0.993	0.989	0.991	

4 Discussion

The result of using the ANN presented in Sect. 3 is the best of all analyzed. Its construction was preceded by several other experiments related to modeling using deep learning.

Firstly, we tried a model with a Recurrent Neural Network using LSTM architecture [5] whose structure is presented in Table 4. The embedding layer was used as the first layer with a 0.2 dropout rate and 5000 input dimensions. This layer turns indexes into dense vectors of fixed size. The LSTM layer had an input length of 100 and the dropout rate for gates set to 0.2 with hyperbolic tangent (tanh) activation function. The dense layer was used with a sigmoid activation function.

The best result for the LSTM model was achieved when 70% of the dataset was trained, 15% validated and 15% tested. The training average accuracy that has been achieved was 0.4736 and validation accuracy 0.5875 (Fig. 6) while average training and validation loss was close to 0 (Fig. 7).

In the second experiment, we built a model that was trained on 90%, validated and tested each on 5% of the data set. The following results were obtained: the average accuracy and validation were 1 (Fig. 8) and the average and validation loss were 0 (Fig. 9).

This type of behavior is characteristic of the overtrained ANN. Therefore, the training population was reduced to circa 70% that allowed to achieve more reliable results.

The problem of overtrained ANN occurred also during tests with an experimental model based on extended hidden layers consisting of 40 layers. By using the iterative method of selecting the appropriate number of layers, we decided to use 22 mixed dense, activation and dropout layers that allowed achieving reliable accuracy lower than 1 and loss higher than 0 (Table 5).

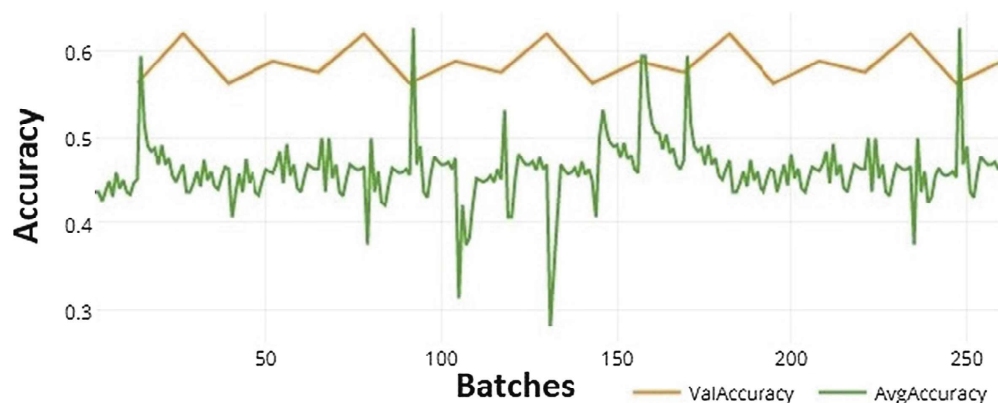


Fig. 6. The average accuracy (AvgAccuracy) and validation accuracy (ValAccuracy) for the LSTM model.

Table 4. Scheme of the ANN layers of the experimental model with LSTM layers.

No	Layer	Output dimensions
–	Input	700
1	Embedding	128
2	LSTM	128
3	Dense	4
–	Output	4

As a result, the average validation accuracy was 0.5104 (Fig. 10) and was not satisfactory. That model was improved by reducing it to 11 layers in total and adding two instances of the batch normalization layer (Table 2).

We considered the obtained model to be sufficient in terms of achieved accuracy and loss. Further modifications to the model would allow obtaining slightly better results than those already achieved, therefore we decided to use it as the final ANN model in our research, as presented in Sect. 2.3.

The chosen model was also tested in K-Fold Cross Validation, where K parameter was set to 10. Randomly selected 400 samples were used for training, 50 for validation and 200 for tests. Other parameters and hyperparameters remained unchanged. The average train accuracy that was achieved during these tests was 0.9696 with loss of 4.3602 and the validation average accuracy was 0.8406 with the loss of 0.3286. The obtained accuracies and losses are shown in Fig. 11.

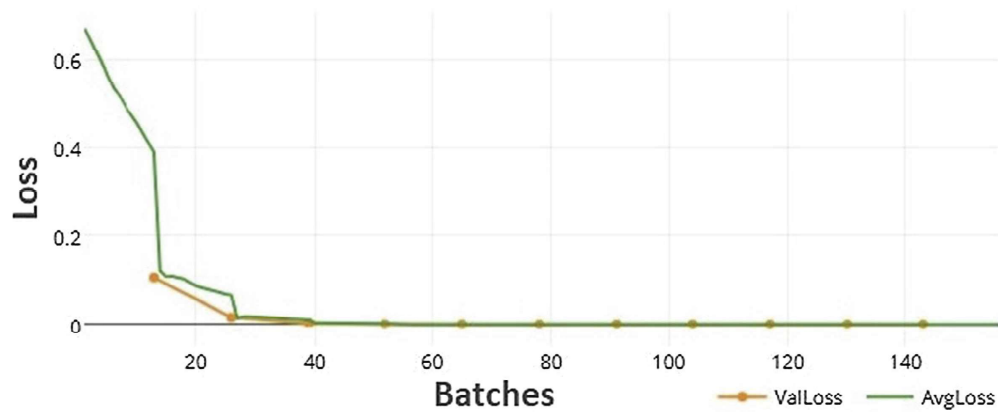


Fig. 7. The average loss (AvgLoss) and validation loss (ValLoss) for the LSTM model.




Fig. 8. The average accuracy (AvgAccuracy) and validation accuracy (ValAccuracy) for training with 90% of the data set.


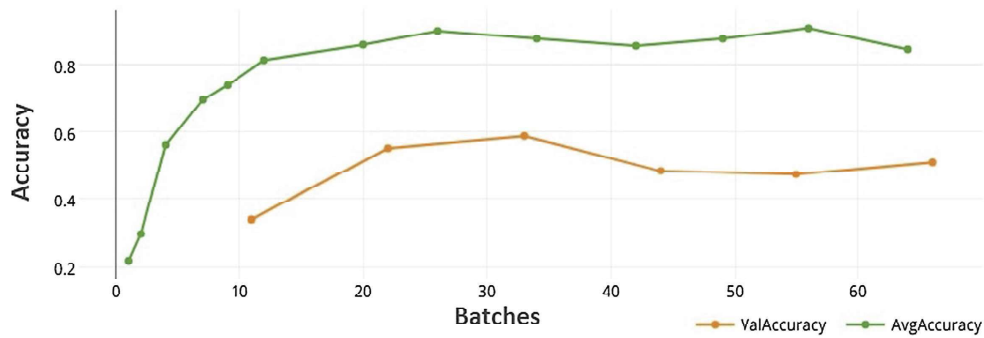


Fig. 9. The average loss (AvgLoss) and validation loss (ValLoss) for training with 90% of the data set.

Table 5. Scheme of the ANN layers of the experimental model with 22 hidden layers.

No	Layer	Output dimensions
–	Input	700
1	Dense	700
2	Activation	700
3	Dense	700
4	Activation	700
5	Dropout	700
6	Dense	700
7	Activation	700
8	Dense	700
9	Activation	700
10	Dropout	700
11	Dense	700
12	Activation	700
13	Dense	700
14	Activation	700
15	Dense	700
16	Activation	700
17	Dense	700
18	Activation	700
19	Dropout	700
20	Dense	700
21	Activation	700
22	Dense	4
–	Output	4

**Fig. 10.** The average accuracy (AvgAccuracy) and validation accuracy (ValAccuracy) for training with circa 70% of data set and 22 hidden layers.

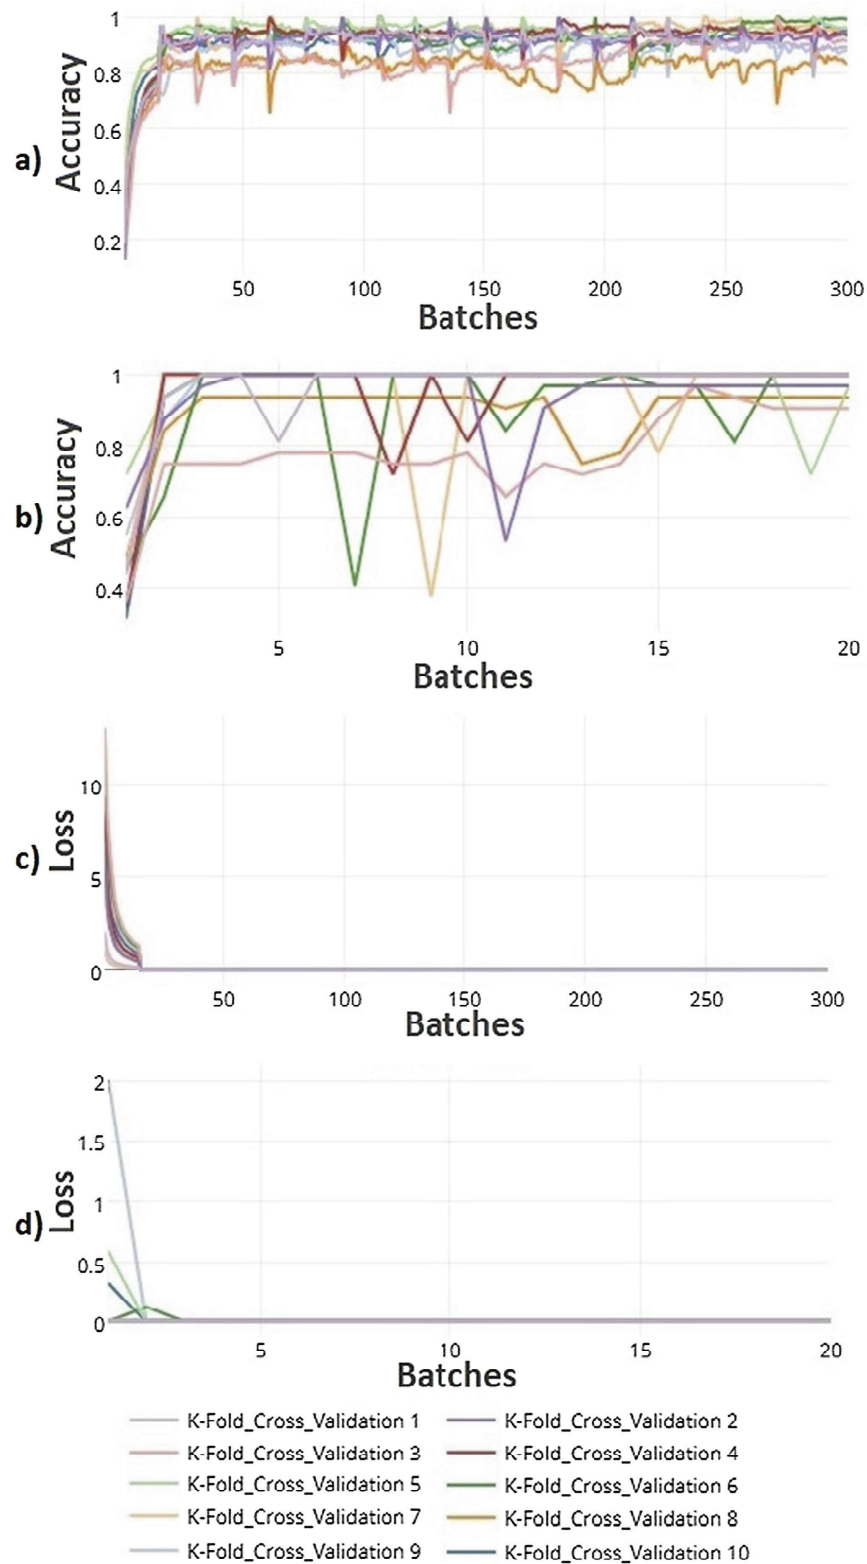


Fig. 11. The average: a) training accuracy, b) validation accuracy, c) training loss and d) validation loss for K-Fold Cross Validation.

5 Conclusions

The obtained results based on the experiments with various ANN models allowed us to choose the model that achieves high accuracy with low loss.

This research confirms that it is possible to recognize the flue pipe type basing on the spectrum. Therefore, it can also be assumed that an experienced listener, who knows well various organ pipe voices, can also correctly recognize the type of labium. This paper is also the incipience to further usage of deep learning methods in the area of a pipe organ.

Acknowledgements. Special thanks to the organbuilder Władysław Cepka for his invaluable help and providing the workshop and organ pipes for sound recording.

References

1. Angster, J., Rusz, P., Miklos, A.: Acoustics of organ pipes and future trends in the research. *Acoust. Today* **1**(13), 10–18 (2017)
2. Außerlechner, H., Trommer, T., Angster, J., Miklos, A.: Experimental jet velocity and edge tone investigations on a foot model of an organ pipe. *J. Acoust. Soc. Am.* **2**(126), 878–886 (2009). <https://doi.org/10.1121/1.3158935>
3. Deep Cognition Homepage. <https://deepcognition.ai>. Accessed 24 Apr 2020
4. Herremans, D., Chuan, C.: The emergence of deep learning: new opportunities for music and audio technologies. *Neural Comput. Appl.* **32**, 913–914 (2020). <https://doi.org/10.1007/s00521-019-04166-0>
5. Hochreiter, S., Schmidhuber, J.: Long short-term memory. *Neural Comput.* **9**(8), 1735–1780 (1997). <https://doi.org/10.1162/neco.1997.9.8.1735>
6. Hruška, V., Dlask, P.: Investigation of the sound source regions in open and closed organ pipes. *Arch. Acoust.* **3**(44), 467–474 (2019). <https://doi.org/10.24425/aoa.2019.129262>
7. Hruška, V., Dlask, P.: Connections between organ pipe noise and Shannon entropy of the airflow: preliminary results. *Acta Acustica United Acustica* **103**, 1100–1105 (2017)
8. Humphrey, E.J., Bello, J.P., LeCun, Y.: Feature learning and deep architectures: new directions for music informatics. *J. Intell. Inf. Syst.* **41**, 461–481 (2013). <https://doi.org/10.1007/s10844-013-0248-5>
9. Koutini, K., Chowdhury, S., Haunschmid, V., Eghbal-zadeh H., Widmer, G.: Emotion and theme recognition in music with frequency-aware RF-regularized CNNs. *MediaEval 1919*, 27–29 October 2019. ArXiv abs/1911.05833. Sophia Antipolis (2019)
10. Krizhevsky, A., Sutskever, I., Hinton, G.: ImageNet classification with deep convolutional neural networks. In: *Advances in Neural Information Processing Systems*, pp. 1097–1105 (2012). <https://doi.org/10.1145/3065386>
11. Lathi, B.P.: *Linear systems and signals*, 2nd edn. Oxford University Press, New York (2010)
12. Lehner, B., Widmer, G., Bock., S.: A low-latency, real-time-capable singing voice detection method with LSTM recurrent neural networks. In: *2015 23rd European Signal Processing Conference (EUSIPCO)*, Nice, pp. 21 – 25 (2015). <https://doi.org/10.1109/EUSIPCO.2015.7362337>

13. Rucz, P., Augusztinovicz, F., Angster, J., Preukschat, T., Miklos, A.: Acoustic behaviour of tuning slots of labial organ pipes. *J. Acoust. Soc. Am.* **5**(135), 3056–3065 (2014). <https://doi.org/10.1121/1.4869679>
14. Sakamoto, Y., Yoshikawa, S., Angster, J.: Acoustical investigations on the ears of flue or-GAN pipes. In: *Forum Acusticum*, pp. 647-651. EAA-Opakfi Hungary, Budapest (2005)
15. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R.: Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.* **15**, 1929–1958 (2014). <https://doi.org/10.5555/2627435.2670313>
16. Vaik, I., Paal, G.: Flow simulations on an organ pipe foot model. *J. Acoust. Soc. Am.* **2**(133), 1102–1110 (2013). <https://doi.org/10.1121/1.4773861>
17. Verge, M., Fabre, B., Mahu, W., Hirschberg, A., et al.: Jet formation and jet velocity fluctuations in a flue organ pipe. *J. Acoust. Soc. Am.* **2**(95), 1119–1132 (1994). <https://doi.org/10.1121/1.408460>
18. Widmer, G.: On the potential of machine learning for music research. In: Miranda, E.R. (ed.) *Readings in Music and Artificial Intelligence*. Routledge, New York (2013)
19. Zeiler, M.: ADADELTA: an adaptive learning rate method. <https://arxiv.org/abs/1212.5701>. Accessed 24 Apr 2020

6.3 The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe's mouth

Tytuł	The dependence of flue pipe airflow parameters on the proximity of an obstacle to the pipe's mouth
Autorzy	Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A.
Czasopismo	Sensors
Tom	22
Rok	2022
Strony	1-15
DOI	10.3390/s22010010
Punkty ministerialne	100

Article

The Dependence of Flue Pipe Airflow Parameters on the Proximity of an Obstacle to the Pipe's Mouth

Damian Węgrzyn ^{1,*}, Piotr Wrzeciono ² and Alicja Wieczorkowska ^{1,*}

¹ Polish-Japanese Academy of Information Technology, 02-008 Warsaw, Poland

² Institute of Information Technology, Warsaw University of Life Sciences, 02-776 Warsaw, Poland; piotr_wrzeciono@sggw.edu.pl

* Correspondence: damian@wegrzyn.info (D.W.); alicja@poljap.edu.pl (A.W.)

Abstract: This paper describes the influence of the presence of an obstacle near the flue pipe's mouth on the air jet, which directly affects the parameters of the sound generated by the flue pipe. Labial pipes of the most common types of mouth were tested. The method of interval calculus was used instead of invasive measuring instruments. The obtained results prove that the proximity of an obstacle affects the sound's fundamental frequency, as the airflow speed coming out of the flue pipe's mouth changes. The relationship between the airflow speed, the value of the Reynolds number, and the Strouhal number was also established. The thesis of the influence of the proximity of an obstacle on the fundamental frequency of the sound of a flue pipe was generalized, and formulas for calculating the untuning of the sound of the pipe were presented for various types of mouth.

Keywords: flue pipe; organ tuning; pipe's mouth; obstacle

Citation: Węgrzyn, D.; Wrzeciono, P.; Wieczorkowska, A. The Dependence of Flue Pipe Airflow Parameters on the Proximity of an Obstacle to the Pipe's Mouth. *Sensors* **2022**, *22*, 10. <https://doi.org/10.3390/s22010010>

Academic Editor: Chiman Kwan

Received: 27 October 2021

Accepted: 17 December 2021

Published: 21 December 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Pipe organ tuning is a tedious process. Some of them require many series of tweaks during tuning. Finally, it is possible to tune the instrument. This is one of the reasons why probably no one has analyzed the problems accompanying the tuning process so far.

Another problem is the undoubted lack of time to undertake tests and the lack of willingness to break the routine in the activities performed. Knowledge in the field of organ building is handed down from generation to generation. The next problem is the lack of a sufficient explanation in the scientific papers regarding the everyday work of organbuilders. There are conferences or meetings about organ building but from the musicians' point of view, not the organbuilders. There are no conferences where the organbuilders could exchange their experiences or discuss together the problems bothering them.

The impetus for this research on the optimization of organ tuning are the problems that have been mentioned by organbuilders for many generations [1,2]. The untuning problem is significant due to its wide range. Two issues suggested the existence of regularities describing the phenomenon of organ untuning. The first one is the situation when the organbuilder tunes the pipes in the workshop on the intonation table, then takes them to the instrument in the destination building, mounts them on the windchest and it turns out that they are not finely tuned. The second issue is in the situation of tuning pipes enclosed in an organ case. The organbuilder finishes tuning the ranks, closes the case and the pipes again are not tuned. This is the issue with small organs, e.g., chest organs.

The problem of untuning is an issue worthy of attention. It is a popular issue as it concerns the work of every organbuilder. Optimizing the tuning process will significantly shorten the time of tuning pipes. This entails savings also in expenditure on the construction or renovation of the instrument, which in the case of the pipe organ is usually one of the key elements of investment. In addition, it will facilitate work with small organs.

In a previous publication [3] the authors have proved that a common element of the tuning process of instruments with pipes densely located on the windchest or closed in a small case is the influence of the proximity of the obstacle to the pipe's lips. The problem was spotted and experimentally tested on several pipes. The research presented in this paper covers flue pipes of the most common types of mouths and generalizes the thesis of the influence of the proximity of an obstacle on the fundamental frequency of the sound of a pipe. Moreover, the influence of this phenomenon on the parameters of the generated sound was analyzed.

The state-of-the-art research in the area of sound generation in organ pipes raises various aspects, e.g., airflow analysis [4–6], or transient state in the process of sound initiation [7–9]. The experiments and simulations of sound formation in pipes are reported in literature as well [10–12]. There are also works in the field of the acoustics of resonators [13–15]. A more detailed review of the state-of-the-art research is presented in Section 7, together with the discussion of our results.

This paper contributes to the research area of sound generated by flue pipes. First of all, it aims to facilitate the process of pipe organ tuning. The results of this research apply to the pipe organ, in which the flue pipes are close to an obstacle. Such an obstacle may be the organ case or the adjacent pipes, which are the obstacles for each other. A good example is a chest organ, where the space on the windchest is limited. We propose an equation that allows determining the fundamental frequency of a pipe's sound depending on the proximity of an obstacle. This issue is practical and will facilitate the daily work of organbuilders. The novelty is the use of a non-invasive method, with calculations based on the interval calculus.

The paper is organized as follows. Section 2 presents the methodology of measurements and obtaining input data for calculations. Section 3 shows the analysis and processing of the measurement data. Section 4 presents the interval calculus used for further calculations. Section 5 describes the key aspects of sound generation in a labial pipe. The results of the obtained research are presented in Section 6. Section 7 is a discussion and comparison of the results obtained in other works. The outcomes of the research are presented in the Conclusions section.

2. Measurements

The measurements of the pipes—both geometric dimensions and acoustic measurements—were carried out on the intonation table in the organbuilder's workshop. We used two measurement microphones Behringer ECM8000 with omnidirectional characteristics, 1.0 mV/Pa sensitivity, and 20 dBA equivalent noise level. The first of them was used for recording the sound at the top of the pipe (distance from the pipe top about 5 cm), and the second one near the pipe lip (distance from the lip about 5 cm). The sampling rate was 48 kHz. The recordings were repeated at least 5 times. The positioning of the microphones is shown in Figure 1. All photographs in this paper were taken by its authors.









The recordings were made after calibration using an acoustic sound level calibrator Sonopan KA-50 (1 kHz, 94 dB, class 1, IEC 60942:2017 [16], calibration certificate) and a digital sound analyzer Sonopan DSA-50 (class 1, IEC 61672-1:2013 [17], calibration certificate). The Behringer U-Phoria UMC1820 USB audio interface was also used in the sound recording process. Audacity and MATLAB were used as the audio recording software platforms, along with JACK Audio Connection Kit as a sound server. An Asus Zenbook computer with the Intel Core i7 processor, 12 GB of RAM and openSUSE Tumbleweed operating system was used in this work.

An obstacle with an area many times larger than the area of the cut-up was set parallel to the lip and we made 10 measurements at a distance of an integer multiple of 5 mm. The distance of 0 mm means the minimum distance from the lip that could be achieved for a given type of labium (without ears, with ears, with a roller, with a plate, etc.). The analyzed types of pipes with their dimensions, construction and photos are presented in Table 1. The details of the construction of the organ pipe are illustrated in Section 5.



Figure 1. The position of the microphones during recording: (a) front view, (b) side view.

Table 1. Analyzed flue pipes.

Labium photo								
Labium type	English bay leaf	Beard	Beard	Beard	Beard	Plate	Roller	Roller
Stops	Principal 4ft	Bourdon 8ft	Bourdon 16ft	Dolce Flute 8ft	Flute 4ft	Gamba 8ft	Bass Principal 16ft	Geigen Principal 8ft
Construction	Open, pewter (75% tin, 25% lead)	Open, oakwood	Stopped, oakwood	Open, pine	Open, spruce	Open, metal (55% lead, 45% tin)	Open, pine	Open, pine
Lip width [mm]	29.4	41.1	41.8	18.5	35.4	29	108	80.5
Internal pipe dimensions [mm]	37.9	41.9 × 51.9	42.4 × 54.5	19.4 × 29.2	35 × 51	35.3	106 × 140	79 × 96
Wavelength [mm]	530	580	590	290	975	920	2096	2471

3. Data Analysis

In the first step, we selected the central part of each of the audio recordings, representing the steady state. Next, these fragments were transformed into spectra using the Fast Fourier Transform (FFT) with a Hanning window of 65536 samples. The spectrum calculated via the FFT was used to determine the range in which the fundamental frequency (the first harmonic, usually denoted as f_0) of the sound is located. To determine the precise frequency values, Discrete-time Fourier Transform (DTFT) [18] was calculated in the ranges found with the FFT. The DTFT $X(e^{j\omega})$ for the discrete sequence of the signal $x[n]$ is given by Equation (1):

$$X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x[n] e^{j\omega n} \quad (1)$$

Equation (2) determines the measurement uncertainty σ_M of the obtained results. We used the standard deviation σ_M for individual values of the fundamental frequency.

$$\sigma_M = \sqrt{\frac{1}{n-1} \sum_{k=1}^n (M[k] - \mu_M)^2} \quad (2)$$

where: μ_M is the average of the set $M = \{M[1], \dots, M[n]\}$, $M[k]$ is the k -th value of the M set, n is a number of measurements.

The use of DTFT allowed us to determine the fundamental frequency f_0 for each recording with an accuracy of 0.01 Hz, as we calculated DTFT for the frame length equal to the entire sound (about 5 s). The sound level for f_0 was also calculated in relation to the sound level generated by the calibrator and the measurement uncertainty σ_M from Equation (2).

To describe the changes in sound frequency in the situation of the presence of an obstacle, the intervals W_{f_0} were calculated, which are expressed in cents and are the musical distances between two sounds. Equation (3) was used to calculate each of the intervals, where x is the distance of the obstacle from the pipe lip and x_0 is the distance, at which the sound frequency does not depend on the obstacle. Figure 2 shows the relationship between f_0 and x .

$$W_{f_0} = 1200 \log_2 \left(\frac{f_0(x)}{f_0(x_0)} \right) \quad (3)$$




Figure 2. The interval of the fundamental frequency changes in relation to the distance between the obstacle and the pipe lip of Flute 4-foot D sharp.

Based on the measurements of the behavior of flue pipes, generating sound in the condition of the presence of an obstacle near the labia, we observed the following effects:

- The fundamental frequency of the pipe decreases as the obstacle is closer to the lip. The changes of the pipe sound frequency depending on the distance of the obstacle to the mouth of the pipe are presented in Table 2;
- The spectrum of the sound recorded at the mouth of the pipe may differ significantly from the spectrum of the sound at the top of the resonator (i.e. significant difference in the number of harmonics may be observed);
- The fundamental frequency of the pipe, measured at the top of the pipe resonator, is sometimes different from the fundamental frequency measured at the lip of the pipe. It can be seen in the spectrum, especially on the logarithmic frequency scale, as the harmonics of the sound do not overlap, as shown in Figure 3;

- In the spectrum of some pipes, there are additional components that are not harmonics of the fundamental frequency of the pipe, see Figure 4.

Table 2. The dependence of the pipe sound frequency on the distance of the obstacle to the mouth of the pipe (the symbol “-” denotes that the pipe generated no sound in this case).

Distance from the Obstacle	Bourdon 16ft Stopped C Sharp	Bourdon 8ft Open B	Principal 4ft E1	Gamba 8ft f Sharp	Geigen Principal 8ft Open C	Bass Principal 16ft Open D	Dolce Flute 8ft Open B	Flute 4ft Open D Sharp
x [mm]	f_0 [Hz]							
0	131.44	238.14	-	185.68	64.45	69.69	458.15	149.15
5	135.12	246.02	320.59	186.26	64.80	71.15	464.61	153.18
10	136.95	249.22	324.14	186.46	64.92	71.85	466.35	154.70
15	137.82	250.61	325.28	186.55	65.06	72.41	467.53	155.16
20	138.30	251.30	325.81	186.60	65.16	72.61	468.13	155.46
25	138.60	251.76	325.90		65.17	72.79		155.58
30		251.99	326.16		65.22	72.98		155.68
35		252.19	326.28		65.28	73.10		155.74
40		252.30	326.37		65.31	73.19		
45		252.38	326.44		65.33	73.28		
50			326.49		65.35	73.32		
55			326.52		65.39	73.38		
60					65.39	73.41		
65					65.40	73.41		
70					65.45	73.26		
75						73.31		
80						73.32		
85						73.34		
x_0 (no obstacle)	139.24	252.76	327.19	186.91	65.49	73.49	469.52	155.98




Figure 3. The spectrum of the Bass Principal 16-foot D pipe at the lip (red dotted plot) and the top (grey solid line plot) after normalization to the maximum sound level value for the immediate proximity of the obstacle (0 mm) at the pipe’s lip. As we can see, the harmonics do not overlap. The fundamental frequency, calculated by DTFT with 0.01 Hz frequency resolution, is 69.91 Hz at the lip and 69.69 Hz at the top (a difference of about 5 cents, which can be heard by a trained musician, especially when such a sound is accompanied by another playing pipe).




Figure 4. Dolce Flute 4-foot B spectrum for the immediate proximity to the obstacle (0 mm) at the pipe lip. A linear frequency scale has been used to help locate harmonics that are equally spaced on this scale.

4. Interval Calculus

Inserting any measuring instrument inside the pipe disturbs the basic parameters of the sound. The measurement is disturbed also during inserting a measuring instrument between the lip and the obstacle. The same applies to the doping of coloring substances to the air jet in the pipe, as this changes the gas density and its thermal parameters, and thus also distorts the results of the measurements. Consequently, there is a problem with carrying out a direct flow measurement. To solve the impossibility of making the measurement, various mathematical methods to estimate calculations, such as interpolation or approximation, were reviewed.

In this paper, the interval calculus is used to approximate the flue pipe airflow parameters. The use of this method makes it possible to find the data intervals that depend on other known ranges. Interval operations are performed on numerical intervals, and the operation result is also in the interval form. This method began to be developed in the 1960s [19,20] and it is currently used, i.a. to track the uncertainty of various origins, as a tool for finding values that satisfy a specified condition, or as a way of solving nonlinear equations and their systems [21].

This paper uses interval arithmetic based on the operations on intervals [22], presented in Equations (4)–(8).

$$[\underline{a}, \bar{a}] + [\underline{b}, \bar{b}] = [\underline{a} + \underline{b}, \bar{a} + \bar{b}] \quad (4)$$

$$[\underline{a}, \bar{a}] - [\underline{b}, \bar{b}] = [\underline{a} - \bar{b}, \bar{a} - \underline{b}] \quad (5)$$

$$[\underline{a}, \bar{a}] \cdot [\underline{b}, \bar{b}] = [\min(\underline{a}\underline{b}, \underline{a}\bar{b}, \bar{a}\underline{b}, \bar{a}\bar{b}), \max(\underline{a}\underline{b}, \underline{a}\bar{b}, \bar{a}\underline{b}, \bar{a}\bar{b})] \quad (6)$$

$$[\underline{a}, \bar{a}] / [\underline{b}, \bar{b}] = [\underline{a}, \bar{a}] \cdot [1/\bar{b}, 1/\underline{b}], 0 \notin [\underline{b}, \bar{b}] \quad (7)$$

$$\odot \in \{+, -, \cdot, / \}, a \in \mathbf{a} = [\underline{a}, \bar{a}], b \in \mathbf{b} = [\underline{b}, \bar{b}] \text{ implies } a \odot b \in \mathbf{a} \odot \mathbf{b} \quad (8)$$

where: \underline{a} is the start point of the first interval, \bar{a} is the end point of the first interval, \underline{b} is the start point of the second interval, \bar{b} is the end point of the second interval, \mathbf{a} , \mathbf{b} are sets, **min** is the minimum value of the set, **max** is the maximum value of the set.

In the case of interval arithmetic, the result of operations on numbers is contained in the result of operations on intervals. In addition, we used an interval extension of a

function, the so-called inclusion function \mathbf{g} of g . It is equivalent to the real-valued function g , satisfying the relationship (9).

$$\{G(y) \mid y \in \mathbf{y}\} \subseteq \mathbf{g}(\mathbf{y}) \quad (9)$$

where: y is an element belonging to the interval, \mathbf{y} is the interval.

To determine the dependence of some intervals on others we used the natural interval extension, consisting of the same operations as the real-valued function from Equation (9). Additionally, to verify the obtained results, the function h_z as the centered form of the inclusion function of h was used [22], satisfying Equation (10).

$$H_z(\mathbf{y}) = h(z) + (\nabla h(\mathbf{y}) \cdot (\mathbf{y}-z)), \text{ where } z \in \mathbf{y} \quad (10)$$

where: \mathbf{y} is the interval, z is the middle point of \mathbf{y} interval, $\nabla h(\mathbf{y})$ is a derivative of $h(\mathbf{y})$ function.

5. Fundamentals of a Sound Generation in a Labial Pipe

To generate a sound in a labial pipe, it is necessary to induce turbulent flow [23]. In the pipe, this is achieved by using a very narrow flue in the so-called languid and a wedge cutting the air jet in the form of the upper lip. The wedge angle is usually 30° [24]. The general structure of a flue pipe is shown in Figure 5.




Figure 5. The structure of a flue (labial) pipe.

In the basic model of sound generation by a pipe, the phenomena related to turbulent flow are ignored. This model is based on the assumption of an ideal standing plane wave. For such assumptions, we obtain the following dependencies [25]:

$$\lambda_o = 2l_p \quad (11)$$

$$\lambda_s = 4l_p \quad (12)$$

Equation (11) determines the wavelength of the wave generated by an open pipe, where λ_o is the wavelength in an open pipe, and l_p is the length of the resonator. In Formula (12), λ_s is the wavelength for a stopped pipe. The length of the pipe is measured from the lower lip to the end of the sliding collar or the end of the pipe resonator (if there is no sliding collar).

The frequency of the sound is related to the wavelength through the speed of sound propagation c , as shown in Equation (13):

$$f_{pipe} = \frac{c}{\lambda} \quad (13)$$

where: f_{pipe} is the fundamental frequency of the pipe's sound [Hz], c is the speed of sound [$m \cdot s^{-1}$] and λ is the wavelength [m].

The speed of sound c in a gas depends primarily on temperature, as shown in Equation (14) [26]. Therefore, the fundamental frequency of the pipe sound must be calculated for a specific temperature, which often differs significantly between the organbuilder's workshop and the destination place where organ pipes are ultimately assembled.

$$c = \sqrt{\kappa \frac{p}{\rho}} = \sqrt{\frac{C_p}{C_v} \frac{RT}{\mu}} \quad (14)$$

where: c is the speed of sound, κ is the adiabatic exponent, p is static pressure of the gas, ρ is gas density, C_p is the specific heat capacity of gas under constant pressure, C_v is the specific heat capacity at constant volume, R is a molar gas constant $8.3144621 \text{ J} \cdot \text{mol}^{-1} \cdot \text{K}^{-1}$, T is temperature [K], μ is the molar mass of the gas. For dry air: $\kappa = 1.401$, $\mu = 0.029 \text{ kg} \cdot \text{mol}^{-1}$. For the measurement temperature of $19 \text{ }^\circ\text{C}$, the speed of sound in the air is $c \approx 343 \text{ m} \cdot \text{s}^{-1}$.

The air jet in a flue pipe is turbulent already in the case of sound initiation, in the so-called initial transient. The vortices are noticeable in the first stages of air jet formation, in the foot of the pipe [27]. At the exit of the air jet from the flue and after reaching the upper lip, significant vortices can be observed in the flowing air mass [28]. The airflow remains turbulent even away from the mouth of the pipe [4]. Contemporary works on the generation of sound in labial pipes use models that take into account the phenomena related to the flow, and we also decided to follow this approach [4,5,27,29]. Expressions (11) and (12) in these papers are only treated as a starting point for further analyzes.

If there is an obstacle near the pipe's mouth, there is one more element to consider, namely aerodynamic drag D [30], see Equation (15). Approaching the obstacle to the pipe's mouth increases the area of S_D , drag D increases, and velocity v decreases.

$$D = C_D \frac{\rho \cdot v^2}{2} S_D \quad (15)$$

where: ρ is the fluid density, v is the fluid speed in relation to the pipe's body, C_D is the drag coefficient, S_D is the cross-sectional area of the object exposed to the flow (i.e., the area of the orthographic projection on a plane perpendicular to the direction of the flow).

The drag coefficient C_D depends on the flow velocity, the shape of the streamlined body, and the Reynolds number. The Reynolds number value determines whether the fluid motion is laminar or turbulent. The transition between laminar and turbulent flow occurs at a critical Reynolds number. The critical Reynolds number, below which turbulent flow is not observed, is used in thermodynamics. There is no one, universal value of the critical Reynolds number that assures sound generation [31]. This value is determined empirically depending on the type of flow. The Reynolds number R_e is calculated using Equation (16). For flows in the ranges of large Reynolds number values (over 2000), in which the boundary layer is turbulent, the aerodynamic drag D does not change because the drag coefficient C_D is constant [30].

$$R_e \stackrel{\text{def}}{=} \frac{u \cdot l}{\nu} \quad (16)$$

where: u is the flow speed of the fluid (liquid or gas) [$m \cdot s^{-1}$], l is the characteristic dimension or length [m], and ν is the kinematic viscosity [$m^2 \cdot s^{-1}$].

The characteristic dimension or length l concerns the distance, which directly influences the stability of the fluid movement. When the flow is turbulent, the drag coefficient depends only on the Reynolds number, and when it does not change, the drag coefficient does not change either [30,32]. In the pipe there is a turbulent flow, so the drag coefficient C_D can be assumed to be constant. For air at a temperature of about $20 \text{ }^\circ\text{C}$, the kinematic viscosity is $\nu = 1.461 \cdot 10^{-5} \text{ m}^2 \cdot \text{s}^{-1}$ [33].

Previous measurements and calculations [34,35] have shown that the value of $R_e = 2300$ is the critical Reynolds number for flows in circular tubes. A flow is always turbulent above

that value. In non-circular tube flow systems, the critical Reynolds numbers are different. Moreover, no constant values of critical Reynolds number can be used as they depend on the characteristic dimension or length of various measurable objects. In our case, the characteristic dimension l was the distance of the wedge cutting off the air jet in the form of the upper lip from the flue, from which the air is coming out. This selection was based on the papers [7,8,36].

Our work is based on sound generation model taking flow into account [4,5,27,29], as we are interested in flow and fundamental frequency changes. Using the model described in equations from (11) to (14), it is possible to estimate the fundamental frequency of the organ pipe sound, but if there is an obstacle near the pipe's mouth, the difference between the frequency calculated using this model and the frequency measured from the signal (using the Fourier transform) can be even about 100 cents, i.e., a semitone. In this case, the phenomenon of sound generation by a turbulent flow should also be considered. The generated sound in this context was described by Vincenc Strouhal [37]. He defined the dependence connecting the velocity of the fluid flow u (in liquid or gas), the characteristic dimension l , and the fundamental frequency of the sound f_0 generated by turbulent flow. This relationship is called the Strouhal number S_r and is described by Equation (17):

$$S_r = f_0 \frac{l}{u} \quad (17)$$

The conditions of the phenomenon described by V. Strouhal are present during the generation of sound in the organ pipe. These conditions are: turbulent flow and the presence of a resonator, in which a certain characteristic dimension l can be distinguished [11]. As the air flows, the vortices in the cylinder propagate from opposite sides at a certain fundamental frequency. It results in a fluctuating lift force, depending on the fundamental frequency f_0 , and the relationship between them is described by the Strouhal number [12], see Equation (17). In our case, approaching the obstacle to the pipe's mouth causes the flow velocity changes, and we can use Equation (17) to solve for the fundamental frequency f_0 . Therefore, f_0 can be expressed as a function of the Strouhal number.

The relationship between the Reynolds number and the Strouhal number can be determined using Equation (16) and Equation (17), as shown in Equation (18):

$$R_e = f_0 \frac{l^2}{S_r \cdot \nu} \quad (18)$$

The research on the relationship between the Reynolds number and the Strouhal number [14] shows that the above relationship can also be described by Equation (19):

$$S_r = \alpha + \frac{\tau}{\sqrt{R_e}} \quad (19)$$

where: α and τ are constants depending on various intervals of the Reynolds number.

Table 3 presents the values of these constants for the Reynolds number in the situation of exceeding the critical Reynolds number, which is the transition value for turbulent motion. These constants were calculated with the use of linear interpolation by H. Fujita [13].

Table 3. The values of the constants α and τ , depending on the intervals of the Reynolds number, used in Equation (19) [13].

R_e	[360, 1300)	[1300, 5000)	[5000, 2×10^5)	[2×10^5 , 10^6)
α	0.2257	0.2040	0.1776	0.5760
τ	-0.4402	0.3364	2.2023	-175.956

6. Results

6.1. Determination of Strouhal and Reynolds Numbers for Labial Pipes

An organ pipe generates a sound only when the airflow is turbulent. Thus, the Reynolds number in this situation exceeds its critical value, hence $Re > 2300$ [5]. Additionally, since $f_0 \gg 1$, the Reynolds number is very large. Using Equation (19) and the interval calculus [22], it is possible to determine the range, in which the value of the Strouhal number S_r for the fundamental frequency of the pipe f_0 will fall.

The calculated S_r intervals, depending on the R_e intervals, are presented in Table 4. For example, the S_{r1} interval, depending on the interval $R_{e1} = [2300, 5000]$, is obtained as shown below. Using the interval arithmetic for Equation (19) and the values of the constants α and τ (Table 3) for a corresponding R_{e1} range, the interval S_{r1} can be calculated as in Equation (20):

$$S_{r1} = 0.2040 + \left(\frac{0.3364}{\sqrt{2300}}, \frac{0.3364}{\sqrt{5000}} \right) = 0.2040 + (0.048, 0.007) = (0.2088, 0.211) \quad (20)$$

Table 4. Interval values of the Strouhal number S_r depending on the intervals of Reynolds number R_e for labial pipes.

R_e	[2300, 5000)	[5000, 10^4)	[10^4 , 2×10^5)
S_r	(0.2088, 0.211]	(0.1996, 0.2088]	(0.1825, 0.1996]

The results of calculations presented in Table 4 show that in the case of labial pipes, the expected value of the Strouhal number is in the range [0.1825, 0.211]. Thus, it can be assumed that S_r is approximately constant and the mean for this range is $S_r \approx 0.2$. Since the characteristic dimension l (the mouth height, called cut-up, see Figure 5) is also constant, then according to Equation (17), the higher the flow velocity u , the higher the frequency f_0 . As the value of u decreases, the frequency f_0 also decreases. Moreover, for the constants l and S_r and the known fundamental frequency f_0 , the flow velocity u can be determined by Equation (17), and then the Reynolds number R_e can be determined from Equation (19), as shown in Table 5.

Table 5. Values of Reynolds number R_e and flow velocity u for analyzed flue pipes at $S_r = 0.2$.

Pipe	Bourdon 16ft Stopped c Sharp	Bourdon 8ft Open b	Principal 4ft e1	Gamba 8ft F Sharp	Geigen Principal 8ft Open C	Bass Principal 16ft Open D	Dolce Flute 8ft Open B	Flute 4ft Open D Sharp
f_0 [Hz]	139.240	252.76	327.2	186.91	65.49	73.49	469.52	155.98
l [mm]	16.53	15.65	7.51	8.1	15	33	8	12.4
u [m·s ⁻¹]	11.51	19.78	12.29	7.57	4.91	12.13	18.78	9.67
R_e	13021	21187	6315	4197	5043	27389	10284	8208

6.2. The Influence of an Obstacle on the Change of Flow Velocity

Let k be an integer multiple of 5 mm. We will analyze the influence of an obstacle, placed at distances being integer multiples of 5 mm to the pipe's mouth, on the fundamental frequency of the generated sound. Based on the Strouhal number analysis in Section 6.1, it can be assumed that the value of S_r is constant. Let f_k be the fundamental frequency of the pipe, calculated by DTFT for the k -th distance, and f_{k+1} for $k + 1$ distance. We denote the airflow velocities in the pipe's mouth for the k -th measurement as u_k , and similarly u_{k+1} for $k + 1$. Then we have the following dependencies, presented in Equations (21) and (22):

$$f_k = S_r \frac{u_k}{l}, \quad f_{k+1} = S_r \frac{u_{k+1}}{l} \quad (21)$$

$$\frac{f_k}{f_{k+1}} = \frac{u_k}{u_{k+1}} \quad (22)$$

In this case, the change of the Reynolds number R_e from Equation (18) will depend only on the fundamental frequency f_0 , which will depend on the flow velocity u (Equation (17)).

According to the Kozena-Carman formula [38], for large Reynolds numbers $R_e > 4000$, the aerodynamic drag coefficient is very small, close to zero [38,39]. Therefore, in the area of influence of the obstacle on the flue pipe sound, the flow velocity should decrease linearly, assuming that the measurement is made every integer multiple of a distance value—in our case by $k \cdot 5$ mm. Therefore, if for each pair $(f_k; f_{k+1})$ the value of the f_{k+1}/f_k ratio will be similar, then in the flue pipe the velocity of the airflow is directly proportional to the fundamental frequency f_0 of the generated sound.

The performed calculations show that the ratio f_{k+1}/f_k calculated for a single pipe is almost constant and is approximately 1.003. The measurement uncertainty, i.e., the divergence between the calculated and the measured frequency, does not exceed 1% for five-fold measurements of the fundamental frequency of the pipe sound. The smallest dispersion of these proportions is 0.1%. Moreover, calculations from the interval calculus prove to be a good representation of this phenomenon, since the Strouhal number is approximately constant.

6.3. The Dependence of the Fundamental Frequency on the Change in the Distance of the Obstacle from the Pipe's Mouth

The relation of the decrease in the fundamental frequency f_0 of the pipe sound as the obstacle is located closer to the mouth of the pipe looks similar for all analyzed types of mouth. The characteristics of this phenomenon are very close to the logarithmic curve (see e.g., Figure 6). Since the occurring phenomena are similar, even though they take place in different geometric conditions, logarithmic regression coefficients were determined according to Equation (23), describing the dependence of the fundamental frequency of the pipe sound on the distance of the obstacle. The data necessary to calculate the sound frequency using Equation (23) for specific pipes are shown in Table 6, i.e., the logarithmic regression coefficients a and b , the distance x_0 at which the fundamental frequency of the pipe sound is not changed by the obstacle, and the coefficient of determination r^2 , that is a measure of the extent to which the model fits into the sample.




Figure 6. The dependence of the distance of the obstacle from the lips for the Bass Principal 16ft open D.

$$f_0(x) = a \ln\left(\frac{x}{x_0}\right) + b, \text{ for } x > 0, x_0 > 0, x \leq x_0 \quad (23)$$

where: a, b are the logarithmic regression coefficients, x is the distance of the obstacle from the pipe lip and x_0 is the distance, at which the sound frequency does not depend on the obstacle.

Table 6. Logarithmic regression coefficients and the coefficient of determination for the dependence of the fundamental frequency on the distance between the obstacle and the pipe's mouth.

Pipe	Bourdon 16ft Stopped c Sharp	Bourdon 8ft Open b	Principal 4ft e1	Gamba 8ft F Sharp	Geigen Principal 8ft Open C	Bass Principal 16ft Open D	Dolce Flute 8ft Open B	Flute 4ft Open D Sharp
x_0 [mm]	30	50	60	25	75	90	25	40
a [Hz]	0.91	1.76	2.14	0.13	0.12	0.45	1.32	0.83
b [Hz]	138.37	252.50	327.35	186.65	65.36	73.39	468.16	155.83
b_2	0.994	0.999	1.001	0.999	0.998	0.999	0.997	0.999
r^2	91%	96%	85%	88%	84%	90%	95%	97%

Equation (23) was modified by introducing the b_2 coefficient, shown in Equation (24), connecting the b coefficient with the fundamental frequency of the pipe f_0 . The calculated values of b_2 are presented in Table 6.

$$b_2 = \frac{b}{f_0(x_0)} \quad (24)$$

The b_2 coefficient does not change much. The measurement uncertainty σ_M for different mouth types is 0.001, which is 0.1% of the mean. Thus, it can be assumed that b_2 is constant for all pipes and equals 0.998. This generalization allows using Equation (25) for all pipes in stops, within a specific type of mouth.

$$f_0(x) = a \ln\left(\frac{x}{x_0}\right) + (0.998 f_0(x_0)), \text{ for } x > 0, x_0 > 0, x \leq x_0 \quad (25)$$

where: a is the logarithmic regression coefficient depending on pipe's mouth type.

7. Discussion

One of the assumptions of the presented research was the use of methods that do not interfere with the sound generated in a labial pipe. Research carried out by other authors, to investigate the laws of physics for turbulent air flow, used techniques to color the air, e.g., doping with smoke [6] or inserting the instrumentation inside the pipe [40]. The insertion of the instrument disturbs the basic thermodynamic parameters, which are the basis for calculations and quantitative conclusions. The same problem appears in the situation of introducing coloring pigments that change the parameters of the gas. We were able to carry out the measurements without interfering with the airflow. Thus, the thermodynamic parameters of the air jet remained unchanged. Due to the above measurement limitations, to determine the value of the Strouhal number, we used the interval calculus. It was also not used before in the literature related to the analysis of the pipes.

Czyżewski et al. [11] noted that the ratio of the airflow velocity from the flue u to the product of the frequency f_0 and the distance from the upper lip to the flue l is constant. Although the authors did not explicitly specify that, this value is the Strouhal number. Hruška and Dlask [7] proved that there is a strong correlation between the Principal Component Analysis component and the reciprocal of the Strouhal number in the initial transient of the pipe sound. Cheong et al. [9], as well as Selfridge et al. [12], confirm the thesis that for Aeolian tone the Strouhal number is constant. In the case of the cylinder, for the

fundamental frequency, which dominates the fluctuating lift force, the value of $S_r \approx 0.2$ was determined. The stability of the Strouhal number is also confirmed by other researchers [15], analyzing turbulent flow generated by airflow through a flue. They prove that for Reynolds numbers $R_e > 2000$, the value of the Strouhal number is approximately constant. The authors examining the whistling effect in the tubular system came to similar conclusions [41].

The influence of the obstacle proximity on the sound parameters is often omitted in research. e.g., Ody et al. [10], while carrying out the measurements in the set of pipes, did not consider the too close position of the pipes to each other, which could have a significant influence on the results presented in that paper.

This paper quantitatively determines the phenomenon of changes in the sound parameters of a labial pipe. Such measurement is difficult due to disturbances caused by measuring instruments when they are used close to the pipe's mouth. This approach has not been used in another study so far. It is worth mentioning that the obtained results are directly dependent on the basic principles of turbulent flow or on the Strouhal phenomenon, which occurs in items similar to the pipes, such as in tubes or slits.

It is worth noting that the coefficient of determination r^2 for proposed Equation (25) is 91% on average. It is not an ideal match but this indicates that the function model is sufficiently fitted to the data obtained from measurements and DTFT, which is confirmed by the plots of DTFT values and the values calculated from Equation (25), as shown in Figure 7. Future work may address the issue of developing an improved model of the function $f_0(x)$, presented in Equation (25).

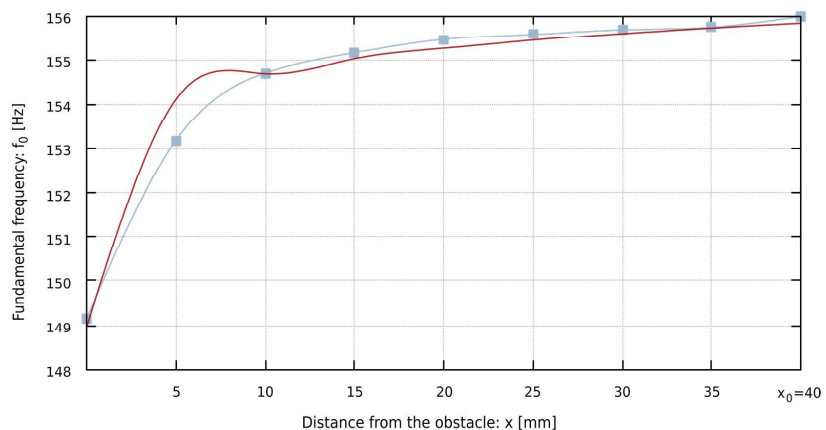


Figure 7. The comparison of the plots representing the dependence of the fundamental frequency f_0 on the distance of the obstacle x from the pipe's mouth for Flute 4ft open D sharp. The grey squares represent the measured data (using DTFT). The grey solid line plot shows the interpolated fundamental frequency for the measured data. The red dotted plot shows data calculated from Equation (25).

8. Conclusions

The results of the presented measurements and analyzes of the behavior of the basic parameters of the sound generated by the labial pipe in the presence of an obstacle prove that:

1. The fundamental frequency of the sound is directly proportional to the speed of the airflow in the pipe's mouth;
2. The speed of the airflow in the pipe's mouth increases with the distance of the obstacle from the pipe's mouth;
3. The value of the Reynolds number in the pipe increases with the distance of the obstacle from the pipe's mouth;

4. The value of the Strouhal number for a labial pipe does not change significantly and can be approximated by a constant value.

The thesis about the dependence of the fundamental frequency of the sound on the distance between the obstacle and the pipe's mouth was also generalized. The formula describing the untuning of the pipe sound is presented for different types of mouth. The obtained logarithmic regression formulas have a high coefficient of determination, which proves that the models fit the data sufficiently. The proposed Equation (25) can be used in organbuilders' practice of pipe tuning. The authors believe that this formula is suitable for use in organ building.

The research was carried out in a non-invasive way that does not influence sound parameters, with the use of interval calculus, which has not been used so far in the area of pipe acoustics. Thanks to the use of this method, the obtained conclusions are quantitative.

The conducted research is innovative due to the analysis of the sound parameters of the pipes depending on the obstacles (possibly being other pipes, or organ case) in their surroundings. This is the first study that accurately describes the dependence of the Strouhal number on the fundamental frequency of a sound in the proximity of other pipes or obstacles. Moreover, the use of the method of interval calculus instead of the use of invasive measuring instruments is new. The introduction of measuring equipment significantly disturbs the results because it becomes an additional obstacle for the emitted air jet.

Future work will focus on improving the proposed model for determining the fundamental frequency of sound depending on the proximity of an obstacle. Additionally, interval calculus can be used as a method of determining the ranges for the data inquired for in other research, where invasive measurement methods have been used so far.

Author Contributions: Conceptualization, D.W. and P.W.; methodology, D.W., P.W. and A.W.; software, D.W.; validation, P.W., A.W. and D.W.; formal analysis, P.W. and A.W.; investigation, D.W.; resources, D.W.; data curation, D.W. and P.W.; writing—original draft preparation, D.W.; writing—review and editing, A.W. and P.W.; visualization, D.W.; supervision, A.W.; project administration, D.W.; funding acquisition, A.W. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: All necessary and relevant data are included in this paper.

Acknowledgments: The authors would like to express their special thanks to Władysław Cepka for providing the organbuilder's workshop, pipes and the intonation table.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Helmholtz, H.V. Theorie der Luftschwingungen in Röhren mit offenen Enden. *J. Reine Angew. Math.* **1860**, *57*, 1–72.
2. Audsley, G.A. *The Art of Organ Building*; Dodd, Mead and Company: New York, NY, USA, 1905.
3. Węgrzyn, D.; Wrzeczono, P. Problem of placing the organ pipes on the windchest. *Vib. Phys. Syst.* **2019**, *30*, 2019121.
4. Mickiewicz, W. Particle Image Velocimetry and Proper Orthogonal Decomposition Applied to Aerodynamic Sound Source Region Visualization in Organ Flue Pipe. *Arch. Acoust.* **2015**, *40*, 475–484, <http://dx.doi.org/10.1515/aoa-2015-0047>.
5. Vaik, I.; Paál, G. Flow simulations on an organ pipe foot model. *J. Acoust. Soc. Am.* **2013**, *133*, 1102–1110, <http://dx.doi.org/10.1121/1.4773861>.
6. Yoshikawa, S. Jet-wave amplification in organ pipes. *J. Acoust. Soc. Am.* **1998**, *103*, 2706–2717, <https://doi.org/10.1121/1.423113>.
7. Hruška, V.; Dlask, P. On a Robust Descriptor of the Flue Organ Pipe Transient. *Arch. Acoust.* **2020**, *45*, 377–384.
8. Taesch, C.; Wik, T.; Angster, J.; Miklos, A. Attack transient analysis of flue organ pipes with different cut-up height. In Proceedings of the CFA/DAGA'04, Strasbourg, France, 22–25 March 2004; pp. 1239–1240.
9. Cheong, C.; Joseph, P.; Park, Y.; Lee, S. Computation of aeolian tone from a circular cylinder using source models. *Appl. Acoust.* **2008**, *69*, 110–126, <https://doi.org/10.1016/j.apacoust.2006.10.004>.
10. Ody, P.; Kotus, J.; Szczodrak, M.; Kostek, B. Sound intensity distribution around organ pipe. *Arch. Acoust.* **2017**, *42*, 13–22, <https://doi.org/10.1515/aoa-2017-0002>.

11. Czyżewski, A.; Kostek, B.; Zieliński, S. Synthesis of organ pipe sound based on simplified physical models. *Arch. Acoust.* **1996**, *21*, 131–147.
12. Selfridge, R.; Moffat, D.; Avital, E.J.; Reiss, J.D. Creating real-time aeroacoustic sound effects using physically informed models. *J. Audio Eng. Soc.* **2018**, *66*, 594–607, <https://doi.org/10.17743/jaes.2018.0033>.
13. Fujita, H. The characteristics of the Aeolian tone radiated from two-dimensional cylinders. *Fluid Dyn. Res.* **2010**, *42*, 015002, <https://doi.org/10.1088/0169-5983/42/1/015002>.
14. Fey, U.; König, M.; Eckelmann, H. A new Strouhal-Reynolds-number relationship for the circular cylinder in the range $47 < Re < 2 \times 10^5$. *Phys. Fluids* **1998**, *10*, 1547–1549, <https://doi.org/10.1063/1.869675>.
15. Henrywood, R.H.; Agarwal, A. The aeroacoustics of a steam kettle. *Phys. Fluids* **2013**, *25*, 107101, <https://doi.org/10.1063/1.4821782>.
16. International Electrotechnical Commission. *IEC 60942:2017 Electroacoustics—Sound Calibrators*; International Electrotechnical Commission: Geneva, Switzerland, 2017.
17. International Electrotechnical Commission. *IEC 61672-1:2013 Electroacoustics—Sound Level Meters—Part 1: Specifications*; International Electrotechnical Commission: Geneva, Switzerland, 2013.
18. Oppenheim, A.V.; Buck, J.R.; Schafer, R.W. *Discrete-Time Signal Processing*; Prentice Hall: Upper Saddle River, USA, 2001; Volume 2.
19. Warmus, M. Calculus of approximations. *Bull. Acad. Polon. Sci.* **1956**, *4*, 253–259.
20. Moore, R.E. *Interval Analysis*; Prentice Hall: Englewood Cliffs, NJ, USA, 1966; Volume 4.
21. Gutowski, M.W. *Introduction to Interval Calculi and Methods*; BEL Studio: Warsaw, Poland, 2004.
22. Kubica, B.J. *Interval Methods for Solving Nonlinear Constraint Satisfaction, Optimization and Similar Problems*; Springer: Cham, Switzerland, 2019.
23. Fletcher, N.H.; Rossing, T.D. *The Physics of Musical Instruments*, 2nd ed.; Springer: New York, NY, USA, 1998; pp. 711–734.
24. Fletcher, N.H.; Douglas, L.M. Harmonic generation in organ pipes, recorders, and flutes. *J. Acoust. Soc. Am.* **1980**, *68*, 767–771, <https://doi.org/10.1121/1.384815>.
25. Benson, D. *Music: A Mathematical Offering*; Cambridge University Press: Cambridge, UK, 2007.
26. Kinsler, L.E.; Frey, A.R.; Coppens, A.B.; Sanders, J.V. *Fundamentals of Acoustics*; John Wiley & Sons: Hoboken, NJ, USA, 1999.
27. Verge, M.P.; Fabre, B.; Mahu, W.E.A.; Hirschberg, A.; Van Hassel, R.R.; Wijnands, A.P.J.; De Vries, J.J.; Hogendoorn, C.J. Jet formation and jet velocity fluctuations in a flue organ pipe. *J. Acoust. Soc. Am.* **1994**, *95*, 1119–1132, <http://dx.doi.org/10.1121/1.408460>.
28. Batchelor, C.K.; Batchelor, G.K. *An Introduction to Fluid Dynamics*; Cambridge University Press: Cambridge, UK, 2000.
29. Hruška, V.; Dlask, P. Investigation of the Sound Source Regions in Open and Closed Organ Pipes. *Arch. Acoust.* **2019**, *44*, 467–474.
30. Hoerner, S.F. *Fluid Dynamics*; Hoerner: Brick Town, NJ, USA, 1965.
31. Lamb, H. *Hydrodynamics*, 6th ed.; Cambridge University Press: Cambridge, UK, 1932; pp. 675–677.
32. Bear, J. *Dynamics of Fluids in Porous Media*; Courier Corporation: North Chelmsford, MA, USA, 2013.
33. Streeter, V.L. (Ed.) *Handbook of Fluid Dynamics*; McGraw-Hill Book Company: New York, NJ, USA, 1961.
34. Rott, N. Note on the history of the Reynolds number. *Annu. Rev. Fluid Mech.* **1990**, *22*, 1–12, <https://doi.org/10.1146/annurev.fl.22.010190.000245>.
35. Gersten, K. *Boundary-Layer Theory*; Springer: Cham, Switzerland, 2017; p. 416.
36. Vinuesa, R.; Bobke, A.; Örlü, R.; Schlatter, P. On determining characteristic length scales in pressure-gradient turbulent boundary layers. *Phys. Fluids* **2016**, *28*, 055101, <https://doi.org/10.1063/1.4947532>.
37. Strouhal, V. *Über eine Besondere Art der Tonerregung*; Stahel: Würzburg, Germany, 1878.
38. Kozeny, J. *Hydraulik*; Springer: Vienna, Austria, 1953.
39. Eisenklam, P. Flow of gases through porous media: PC Carman. London: Butterworths Scientific Publications, 1956. x+ 182 pp. 22 illustrations. 30s. *Combust. Flame* **1957**, *1*, 124–125.
40. Gautier, F.; Nief, G.; Gilbert, J.; Dalmont, J.P. Vibro-acoustics of organ pipes—Revisiting the Miller experiment (L). *J. Acoust. Soc. Am.* **2012**, *131*, 737–738, <https://doi.org/10.1121/1.3651792>.
41. Lim, H.C.; Razi, F. Experimental study of flow-induced whistling in pipe systems including a corrugated section. *Energies* **2018**, *11*, 1954, <https://doi.org/10.3390/en11081954>.

6.4 The reconstruction of blowing pressure in pipe organ using machine learning

Tytuł	The reconstruction of blowing pressure in pipe organ using machine learning
Autorzy	Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A.
Konferencja	International Conference on Information Systems Development (ISD)
Materiały konferencyjne	Harnessing Opportunities: Reshaping ISD in the post-COVID-19 and Generative AI Era
Rok	2024
Strony	1-5
DOI	10.62036/ISD.2024.113
Punkty ministerialne	140

The Reconstruction of Blowing Pressure in Pipe Organ Using Machine Learning

Damian Tadeusz Węgrzyn

Polish-Japanese Academy of Information Technology

Warsaw, Poland

damian@wegrzyn.info

Piotr Wrzeciono

Acoustic Measurement Laboratory, Warsaw University of Life Sciences

Warsaw, Poland

piotr_wrzeciono@sggw.edu.pl

Alicja Wieczorkowska

Polish-Japanese Academy of Information Technology

Warsaw, Poland

alicja@poljap.edu.pl

Abstract

The reconstruction of a pipe organ involves determining the blowing pressure. The lack of information about the pressure value may even result in irreversible damage to the pipes, as the adjustment of the sound parameters that depend on the pressure requires changing the physical structure of the pipes. In this paper, we provide a methodology for determining the blowing pressure in a pipe organ, and present a formula describing the air pressure in the pipe foot, depending only on the height of the pipe's cut-up and the fundamental frequency. We apply machine learning to determine the blowing pressure, based on the parameters of only a percentage of pipes. We found that the height of the cut-up and the fundamental frequency allow determining the blowing pressure. The more pipes, the higher the accuracy, but even 10% of pipes can be sufficient.

Keywords: pipe organ, blowing pressure, foot pressure, reconstruction, machine learning.

1. Introduction

Fire can destroy valuable works, as happened in Notre Dame de Paris. The historical pipe organ in St. Elizabeth's Church in Wrocław burned completely, and rebuilding it took years. The data for the reconstruction were obtained by analyzing historical sources and other preserved instruments built by the same organbuilder. However, such data are not always available; sometimes the instrument must be restored from its picture only.

A pipe organ has a fixed relative air pressure, i.e. pressure in the windchest relative to the respective atmospheric pressure of the environment. It is most often measured in millimeters of water gauge (mm H₂O). Relative pressure is a permanent attribute of the organ because all the pipes of the organ are adjusted to the appropriate pressure value, which affects the basic sound parameters of the pipes.

The value of air pressure in the pipe organ is essential not only during its construction but also in the reconstruction process. It is usually impossible to determine its value based on the preserved elements of the wind pressure system. In such a case, it is necessary to change the structure of the (usually antique) pipes, e.g., by cutting them or deforming the pipe's mouth. Thus, incorrect selection of the pressure by the organbuilder may result in the destruction of the instrument due to irreversible damage to the pipes.

In this work, we investigate the determination of blowing pressure to protect the reconstructed instruments and facilitate the reconstruction work of organbuilders. This is important because many damaged instruments require reconstruction, e.g., in the case of fire or warfare. So far, there are no methods to reproduce the pressure value used in a damaged pipe organ, based on the pipes alone.

2. Methodology

The purpose of this study is to create a model that, after receiving selected pipe attributes at the input, will indicate the blowing pressure at the output. To train a model that works in various situations, a sufficiently large set of input data is needed. Since the pressure value for pipe organs does not vary much and is usually in the range of 50-100 mm of water gauge, data from four instruments with different blowing pressures were used.

We generated one million input datasets, where each input dataset simulates one damaged instrument. Each dataset contains data from one instrument only, representing the percentage of randomly selected pipes from all pipes available in this instrument. Creating all possible subsets of k pipes within a single instrument with n pipes would require generating all possible variations without repetition V_n^k . Usually, in a pipe organ, $n \gg 1000$. For example, if 50% of the pipes remain ($k=500, n=1000$), we would need about $3.3 \cdot 10^{1433}$ variations, and with 10% of the instrument remaining ($k=100, n=1000$), about $6 \cdot 10^{297}$ variations. Therefore, we have not conducted this research on all possible subsets, as such inputs are extreme big data. It is technically difficult to train a model on all variations due to the time required and/or memory limitations. On the other hand, there is no need to train the model on all possible subsets, thus we limited training to one million input datasets.

2.1. Solutions to Key Issues Encountered

Creating a million instruments to be used as input data causes problems. The first one is to ensure the uniqueness of randomly generated instruments, as obtaining unique sets of pipes within one instrument ensures that after dividing these data into randomly chosen train and test sets there is no overlap between them, and no train data are used in tests. This research uses a pseudo-random number generator to draw pipes to be included in datasets. To avoid, on the one hand, the generator falling into periodicity and, on the other hand, possible repetitions of pipe sets, a mechanism of indexing pipes in sets was implemented, ensuring the uniqueness of pipe sets.

We encountered various technical problems when developing our software. To speed up the calculations, each regressor we used has been rewritten to a multi-threaded version, using the Executor class and Lambda expressions in Java. Unfortunately, regressors from the Weka library in multi-threaded training require synchronization of model threads and the input data, which significantly increases the training time. Additionally, we had to deal with the RAM usage problem, to avoid program stopping because of running out of memory with the increase of the number of pipe sets. Therefore, RAM monitoring and memory cleaning via manual control of the garbage collector were used.

2.2. Programming Language and Libraries

We chose Java language for its memory management. Firstly, we needed a statically typed language (with variable types assigned before using them), to accurately reserve the space for variables and optimize memory usage. Secondly, we needed a mechanism of immutable objects which ensures that the object remains permanent after its creation, to achieve secure and efficient memory management. In addition, Java provides efficient support for multithreading, which allows parallel execution of different tasks.

The Application Programming Interface (API) of the Weka library, version 3.9.6, was used in the software development process. We chose the Weka platform due to its constantly updated API and a large collection of implemented machine learning (ML) methods. All regression algorithms implemented in Weka were tested, in various configurations and with various hyperparameter settings, to obtain the best solution.

Additionally, we used the Deeplearning4j library, version 1.0.0-M2.1, and the Nd4j sub-module, which allows loading, executing, and retraining TensorFlow models. We

used several popular artificial neural network (ANN) models for regression problems, in various hyperparameter configurations. The results obtained using these models were compared with the results obtained using ML algorithms from the Weka library, see Section 4.

3. Our Data

Based on our previous research, we use four input attributes, the values of which were different for each pipe: cut-up height, airflow velocity, fundamental frequency, and air pressure in the pipe's foot. The input data used to train and test models represent either measured or calculated values. The output value is the blowing pressure, measured in millimeters of water gauge; this value is predicted using ML and deep learning. Our data describe 186 pipes representing 20 voices from four complete instruments. The blowing pressure is constant per instrument. In the case of incomplete instruments, when bellows and a significant percentage of pipes are missing, it is difficult to determine the blowing pressure, and the trial-and-error method may lead to the destruction of historical pipes.

The first (measured) attribute is the height h of the pipe mouth's cut-up, in millimeters, see Fig. 1. The values of this attribute were taken from data provided in The Diapason [2,3,4,5,6], a journal devoted to organ and church music.




Fig. 1. Construction of a flue pipe with the height of the cut-up h indicated

The second (calculated) input attribute is the fundamental frequency of the pipe's sound. We used a musical interval to calculate the third attribute, which is the ratio of frequencies, constant and equal to $^{12}\sqrt{2}$ for consecutive semitones in the twelve-tone equal-tempered scale, and tuned relative to a standard pitch A (440 Hz).

The third (calculated) input attribute is the velocity v of the airflow in a pipe, in meters per second. A constant value of the Strouhal number $S_t = 0.2$ was assumed for the calculations, as we found in our previous work [11] that it is approximately stable for labial pipes. The airflow velocity v in a flue pipe is calculated as

$$v = F_0 \cdot h / S_t \quad (1)$$

where F_0 is the fundamental frequency of the pipe's sound (Hz). In addition, we assume that the pipe was properly voiced, which means that the pipe sounds as intended (without beats). To achieve proper voicing, the edge tone produced in the cut-up must be of the same frequency as the resonator.

The fourth (calculated) input attribute is the air pressure in the pipe's foot p_p . This value differs from the blowing pressure and varies between pipes. We used the following formula to determine the pressure p_p in the foot of a flue pipe, which depends on the pipe mouth's cut-up height h , and the fundamental frequency of the pipe's sound F_0 :

$$7.25 \cdot ^{1.401}\sqrt{p_p} - p_p + 4.38 \cdot F_0^2 \cdot h^2 = 0 \quad (2)$$

This parameter uses both the second and the third parameter, in a non-linear equation.

The pressure calculated using Eq. (2) does not take into account losses in the airflow and indicates an absolute pressure. To determine the value of relative pressure, used in blowing pressure measurement, the ambient pressure must be subtracted from the calculated pressure p_p , and the units converted to millimeters of water gauge.

Solving Eq. (2) is not trivial, but can be done numerically or graphically. Based on the graphical solution, we can find that Eq. (2) has a unique solution, but this is an inaccurate method. In this work, we used the Newton-Raphson (tangent) method as an iterative numerical method for finding the zeros of functions in a given range.

4. Results

We compared all trained models using the following evaluation metrics [7]: Pearson's correlation coefficient (r), mean absolute error (MAE), root-mean-square error (RMSE), relative absolute error (RAE), root relative square error (RRSE), mean absolute percentage error (MAPE), and the accuracy of model predictions (ACC), calculated as a percentage ratio of number of predictions such that $|y_i - x_i| \leq 3$ (where x_i is an actual value and y_i is the predicted value), to the total number of predictions. We used this ACC measure because the admissible error in the blowing pressure is ≤ 3 mm H₂O. It is caused by the measurement error made by the organbuilder, and the differences in the height of various components of the wind system relative to the ground.

The most important metric in the assessment was the ACC. The models that performed best were the Random Forest (RF) and the Multilayer Perceptron (MLP). Table 1 presents evaluation results for the best three models, for four percentages of the pipes drawn into the pipe set (simulating the remained pipes in an instrument), namely: 75%, 50%, 30%, and 10% of the full set of pipes.

Table 1. The evaluation of the top three ML algorithms for training on 75%, 50%, 30%, and 10% of all pipes

Remaining pipes	Rate	Model	r	MAE	RMSE	RAE [%]	RRSE [%]	MAPE [%]	ACC [%]
75%	1	Random Forest	0.9748	0.8026	1.8425	13.3937	22.3954	1.04	96
	2	Multilayer Perceptron	0.6917	4.4587	9.3577	74.4061	113.7408	5.01	79
	3	Perceptron	0.5401	4.9927	8.3555	83.3173	101.5594	5.23	74
50%	1	Random Forest	0.9500	0.9240	2.4315	15.4078	31.0516	1.27	93
	2	Multilayer Perceptron	0.8185	4.5038	8.5188	78.3698	108.6010	5.06	84
	3	SMOreg	0.5442	3.3364	6.9143	55.6211	88.2979	4.07	72
30%	1	Random Forest	0.8643	2.0476	4.1983	33.2862	50.2947	2.62	85
	2	Multilayer Perceptron	0.6269	4.8913	8.5585	78.7294	101.8898	5.41	83
	3	Recurrent Neural Network	0.4389	4.5010	8.4934	72.7459	98.9981	5.49	68
10%	1	Multilayer Perceptron	0.4712	4.4961	8.1038	73.3760	100.0896	5.10	84
	2	SMOreg	0.0861	4.4882	9.2748	71.1717	111.8923	4.99	76
	3	Convolutional Neural Network	0.1247	4.5639	9.6412	73.9562	113.2431	5.12	75

The training was repeated several times (up to 50 repetitions for RF) and similar values of evaluation measures were obtained, which confirms the repeatability of the results. We built a RF with 200 decision trees with a maximum depth of 5 and the number of attributes to randomly investigate set to 4, but even a RF with only 10 trees yielded good results, thus we present results for this small RF, which are even better than for 200 trees.

In addition, we analyzed the importance of individual input attributes in our best RF model. The most important one is the cut-up height (58.48%) and the second one is the fundamental frequency (25.56%), which is consistent with organ building knowledge.

5. Related Research and Discussion

The air pressure in the foot of the pipe depends mainly on the blowing pressure, but also on the geometric dimensions of the foot hole and the flue. [9] experimentally confirmed the relationship between the air pressure in the foot of the pipe and the size of the foot hole. [1] measured the pressure in the foot of the pipe using a pressure sensor. Pipes with similar geometrical features, used in their research, had pressure values similar to the

values in our work, which confirms the correctness of the calculated pressure values.

The influence of changing the blowing pressure on the sound generated by pipes is well-known. The change of the blowing pressure changes the amplitude of the generated sound, its pitch and timbre. [10] confirmed the increase in sound frequency with increasing blowing pressure and vice versa. With the decrease in blowing pressure, the sound becomes darker and duller. If pressure increases, a discontinuity of pressure at the mouth is observed, caused by the centrifugal force of the curvilinear flow.

A fixed value of blowing pressure allows for a strong and clear sound. The blowing pressure cannot change significantly, and if the pressure is too high, overblowing, typical of wind instruments, occurs. [8] also describes the feedback cycle operating regime for pipe blowing, which includes cut-up, blowing pressure, and the flue width. Therefore, tuned pipes are adjusted to a limited blowing pressure range.

6. Conclusions

The issue of restoring pressure in a pipe organ has been so far an unsolvable problem. In most cases, the restored organs are incomplete, with bellows and a high percentage of pipes missing. The proposed solution based on ML and ANN models yields high accuracy and confirms the possibility of determining the blowing pressure. Our methodology is currently the only alternative to the trial-and-error method, that may destroy the historical pipes, as there is no method to calculate the blowing pressure.

Eq. (2) in this work proposes a formula describing the air pressure in the labial pipe's foot depending only on its fundamental frequency and cut-up height, with no other variables. We also confirmed the relationship between flue pipe attributes and blowing pressure. We found that the height of the cut-up is the most important feature. Fundamental frequency is also important, as it affects the proper voicing of a pipe. These two attributes suffice to determine the blowing pressure (the others can be calculated), and their importance is confirmed in RF.

References

1. Außerlechner, H.J., Trommer, T., Angster, J., Miklós, A.: Experimental jet velocity and edge tone investigations on a foot model of an organ pipe. *J. Acoust. Soc. Am.* 126 (2), 878-886 (2009)
2. McNeil, M.: 1863 E. & G. G. Hook Opus 322 Church of the Immaculate Conception Boston, Massachusetts Part 1. *The Diapason* 1292 (7), pp. 17-19 (2017)
3. McNeil, M.: The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 1. *The Diapason* 1305 (8), pp. 16-20 (2018)
4. McNeil, M.: The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 2. *The Diapason* 1306 (9), pp. 20-25 (2018)
5. McNeil, M.: The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 3. *The Diapason* 1307 (10), pp. 26-28 (2018)
6. Redman, R.: Louis Debierre Choir Organ, 1884. *The Diapason* 1298 (1), pp. 18-19 (2018)
7. Shcherbakov, M.V., Brebels, A., Shcherbakova, N.L., Tyukov, A.P., Janovsky, T.A., Kamaev, V.A.E.: A survey of forecast error measures. *World Appl. Sciences J.* 24, 171-176 (2013)
8. Steenbrugge, D.: Flue organ pipe operating regimes and voicing practices. In: *Acoustics 2012, France, Nantes* (2012)
9. Steenbrugge, D.: Fluid mechanical aspects of open-and closed-toe flue organ pipe voicing. *International J. of Sustainable Construction and Des.* 2 (2), 284-295 (2011)
10. Steenbrugge, D., De Baets, P.: Aerodynamics of flue organ pipe voicing. *International J. of Sustainable Construction and Des.* 1 (1), 162-173 (2010)
11. Węgrzyn, D., Wrzeciono, P., Wiczorkowska, A.: The Dependence of Flue Pipe Airflow Parameters on the Proximity of an Obstacle to the Pipe's Mouth. *Sensors* 22 (1), 10 (2022)

6.5 Predictive algorithms for determining blowing pressure in a pipe organ

Tytuł	Predictive algorithms for determining blowing pressure in a pipe organ
Autorzy	Węgrzyn, D., Wrzeciono, P. & Wieczorkowska, A.
Czasopismo	Bulletin of the Polish Academy of Sciences: Technical Sciences (BPASTS)
Numer	1
Tom	74
Rok	2026
Strony	1-13
DOI	10.24425/bpasts.2025.156771
Punkty ministerialne	100

Predictive algorithms for determining blowing pressure in a pipe organ

Damian T. WĘGRZYN¹ , Piotr WRZECIONO² , and Alicja A. WIECZORKOWSKA¹ 

¹ Polish-Japanese Academy of Information Technology, Warsaw, Poland

² Acoustic Measurements Laboratory, Warsaw University of Life Sciences, Warsaw, Poland

Abstract. The reconstruction of a pipe organ involves determining the blowing pressure. The lack of information about the pressure value significantly prolongs the process of instrument restoration. In addition, it may even result in irreversible damage to the pipes, as the adjustment of the sound parameters that depend on the pressure requires changing the physical structure of the pipes. In this paper, we provide a methodology for determining the blowing pressure in a pipe organ. We also present a formula describing the air pressure in the pipe foot, depending only on the height of the pipe's cut-up and the fundamental frequency. We apply machine learning to determine the blowing pressure, based on the parameters of only a percentage of pipes. Moreover, we use generative artificial intelligence, which achieves outstanding prediction accuracy. We conclude that the height of the cut-up and the fundamental frequency allow determining the blowing pressure. The more pipes, the higher the accuracy, but even 10% of pipes can be sufficient.

Keywords: pipe organ; blowing pressure; foot pressure; reconstruction; machine learning; generative artificial intelligence.

1. INTRODUCTION

Fire can destroy valuable works, as happened in Notre-Dame de Paris and in St. Elizabeth's Church in Wrocław. Warfare, robbery, or even incompetent repairs may also destroy pipe organs or the original features of the instrument. The historical pipe organ in Wrocław burned completely, and rebuilding it took years. The reconstruction work may employ IT methods [1, 2], which were also used in this case. The data for the reconstruction were obtained by analyzing historical sources and other preserved instruments built by the same organbuilder [3]. However, such data are not always available; sometimes the instrument must be restored from its picture only [4].

The pipe organ is one of the oldest musical instruments. At the end of the 4th century, CE, bellows were invented to supply organs with pressurized air called wind. The usage of a big pipe set requires a mechanism to regulate the pressure supplied to the pipes. Initially, water was used to stabilize air pressure. Ensuring the stability of pressure in the windchest of a pipe organ is a fundamental issue, as it guarantees the stability of the parameters of the generated sound. Today, this is achieved using pressure regulators, which control the airflow in particular pipes [5]. Weights placed on the bellows adjust the set pressure value. Occasionally, there are large pipe organs that use not just one, but several air supply systems for different sets of ranks [6]. Air supply systems provide constant air pressure in each pipe, which ensures even volume throughout the instrument.

A pipe organ has a fixed relative air pressure, i.e., pressure relative to the respective atmospheric pressure. It is measured using a water-filled U-shaped tube (water manometer), with one end open to the atmosphere, and the measured pressure applied to the other end. The manometer reading shows the difference between the tops of the water column on both sides, caused by raising the initial water level by the measured pressure of the windchest. The difference in water level is usually measured in millimeters of water gauge (mm H₂O), or in inches, and shows the pressure difference between the pressure in the windchest and the environment. This unit is commonly used in blowing pressure measuring, and the Pascal unit, from the International System of Units, is generally not used; 1 mm H₂O = 9.80665 Pa. Relative pressure is a permanent attribute of the organ because all the pipes of the organ are adjusted to the appropriate pressure value, which affects the basic sound parameters of the pipes. The pipe organ consists of flue (labial) and reed (lingual) pipes, and the same low-pressure value is used for both. Very rare are the special reed pipes, for which the pressure is 255 mm water column [7]. Flue pipes are always present in pipe organs and constitute the vast majority of all pipes. The exception is the regal, which consists solely of reed pipes, but this is a very rare instrument.

The value of air pressure in the pipe organ is essential not only during its construction, but also in the reconstruction process. It is usually impossible to determine its value based on the preserved elements of the wind pressure system. In such a case, it is necessary to change the structure of the (usually antique) pipes, e.g., by cutting them or deforming the pipe's mouth. Thus, incorrect selection of the pressure by the organbuilder may lead to the destruction of the instrument due to irreversible damage to the pipes.

*e-mail: damian@wegrzyn.info

Manuscript submitted 2025-05-05, revised 2025-08-26, initially accepted for publication 2025-10-19, published in January 2026.

In this work, we extend the previous research on the determination of blowing pressure based on the parameters of the pipes [8]. Our main goal is to protect the reconstructed instruments and facilitate the work of organbuilders in the reconstruction process. Restoring the blowing pressure is a time-consuming process, and our methodology helps reduce the time and costs involved. This is important because many damaged instruments require reconstruction, e.g., in the case of fire or warfare.

So far, there are no methods to reproduce the pressure value used in a damaged pipe organ, based on the pipes alone. Air pressure values vary by region and era. Baroque pipe organ usually has lower pressure than Romantic ones, and French pipe organ differs from German ones in terms of air pressure and the way of the pipe voicing [5]. The pressure may also depend on the style and period of construction of the instrument, the material used to build the pipes, the size and design of the instrument, the construction of the windchest, the way of playing at that time, the nature of the place, etc. However, the pipe sound generation is a physical phenomenon, in which the style of organ construction, era, or geography is irrelevant. The edge tone, one of the two sources of sound generated in an organ pipe, is related to the cut-up. The second sound source is at the top of the pipe. In the case of a properly voiced pipe, both of these sound sources have to be in tune.

Reproducing the blowing pressure is much easier when all pipes remain, as the bellows are then usually retained as well. However, in most cases, some or even most of the pipes are missing in the reconstructed pipe organs, and then the pressure cannot be calculated, analytically, numerically, or using computational fluid dynamics (CFD) methods. The pressure in the bellows is determined by the load placed on it. In this way, the pressure in the bellows is stabilized, almost independently of the degree of filling. Wedge bellows behave differently because the load on the bellows depends on the opening angle, but they are rare. Since we are dealing with a proportional-integral-derivative (PID) controller stabilization system, with the blower as the flow source, and the bellows applied to stabilize the pressure, CFD methods are not applicable, as we are not simulating the flow. Instead, in the process of organ reconstruction, we are dealing with an opposite situation than in the time of building the pipe organ, when other parameters of the instrument were adjusted to the blowing pressure. This reverse approach, where we determine the blowing pressure based on the physical characteristics of the pipes, is a form of reverse engineering.

The motivation for our research was to verify whether it is possible to determine the blowing pressure value based on an incomplete set of pipes. This boils down to establishing the relationship between the parameters of the remained pipes and the pressure of a pipe organ. Nowadays, machine learning (ML), including deep learning (DL), contributes significantly to the development of acoustics [9]. Unlike conventional acoustics and signal processing, ML relies on a data-driven approach. With sufficient training data, ML can uncover complex relationships between features and the predicted values, as well as interactions among the features themselves. By leveraging large datasets, ML can develop models that capture various acoustic phenomena,

e.g., source separation, acoustic modeling, and timbre analysis [10, 11]. This is why we decided to use ML to find a solution to a problem that cannot be solved analytically.

Intuitively, this problem can be solved by training artificial neural networks (ANNs) on the recordings of pipe organ sounds, but they usually do not exist or cannot be obtained due to the lack of pressure information. The results obtained in our tests confirm that it is possible to overcome the problem of the lack of pipes and determine the pressure with high accuracy. ML and DL models trained can determine the pressure based on data from other pipes of the instrument. The main features from which the models infer the pressure value are the cut-up height of the labial pipes and the air pressure in the pipe's foot. We also give a formula for determining the pressure in the foot depending on its construction features.

A reconstruction process without basic data is difficult, and usually relies on already available methods or software [2]. In our case, this is not possible, so we created software for reproducing the basic parameters of the windchest, i.e., the blowing pressure.

The rest of the paper is organized as follows. Section 2 presents the methodology of the research, and Section 3 describes the data that were used for training and testing the models. Section 4 describes the input data processing, and Section 5 presents the obtained results. In Section 6, we compare our formula with other studies in the area of the analysis of flue pipes and blowing pressure, including a discussion of the limitations of our study. Section 7 concludes our work.

The main contribution of this research is the development of a methodology for determining the blowing pressure in a pipe organ. It empirically confirms the relationship between the physical features of the labial pipes and the blowing pressure, which allows the training of a model to determine the value of this pressure with high accuracy. The second contribution is a proposal for a formula describing the air pressure in the foot of the pipe. The next innovation is the incorporation of generative artificial intelligence (AI) to check what architectures it proposes for prediction, and to compare them with our results obtained using ML. An additional finding is the identification of key parameters influencing the blowing pressure. Additionally, we prepared a multi-threaded implementation of Weka regressors, which accelerated their training with various hyperparameters. This work also improves the pipe organ parameters reconstruction process and contributes to the area of pipe organ science in establishing the value of the pressure in the windchest, and paves the way for further research.

2. METHODOLOGY

Based on the so far good results of using ML in the field of examining the influence of the pipe's mouth parameters on the characteristics of the generated sound [12], we decided to investigate the relationship between the pipe parameters and the blowing pressure using ML, especially ANNs. The purpose of this study is to create a model that, after receiving selected pipe attributes at the input, will indicate the blowing pressure at the output. To train a model that works in various situations, a suf-

ficiently large set of input data is needed. Since the pressure value for pipe organs does not vary much and is usually in the range of 50–100 mm of water gauge [13], data from four instruments with different blowing pressures were used (66, 71, 74, and 94 mm H₂O). The same pipe stops (e.g., principal, octave, flute) repeat in various pipe organs. Materials from which organ pipes are made affect the timbre of the generated sound, i.e., the harmonics, but not its basic physical parameters, such as the fundamental frequency [14]. This allows data collection to be limited to only a few instruments, without the need to use data from multiple instruments.

Based on these data, we generated one million input datasets, where each input dataset simulates one damaged instrument. Each dataset contains data from one instrument only, representing the percentage of randomly selected pipes from all pipes available in this instrument. For 75% of pipes, one dataset contained an average of 180 samples, for 50% an average of 90 samples, for 30% an average of 55 samples, and for 10% an average of 20 samples. Creating all possible subsets of k pipes within a single instrument with n pipes would require generating all possible variations without repetition V_n^k , defined as

$$V_n^k = n! / (n - k)!, \quad (1)$$

where n is the number of all pipes and k is the number of pipes remaining in the damaged instrument. Usually, in a pipe organ, $n \gg 1000$. For example, if 50% of the pipes remain ($k = 500$, $n = 1000$), we would need about $3.3 \cdot 10^{1433}$ variations, and with 10% of the instrument remaining ($k = 100$, $n = 1000$), about $6 \cdot 10^{297}$ variations. Therefore, we have not conducted this research on all possible subsets, as such inputs are extremely big data. It is technically difficult to train a model on all variations due to the time required and/or memory limitations. On the other hand, there is no need to train the model on all possible subsets; thus, we limited training to one million input datasets. This value seems reasonable because it is large enough and does not require extensive random-access memory (RAM) resources.

2.1. Solutions to key issues encountered

Creating a million instruments to be used as input data causes problems. The first one is to ensure the uniqueness of randomly generated instruments, as obtaining unique sets of pipes within one instrument ensures that, after dividing these data into randomly chosen train and test sets, there is no overlap between them, and no train data are used in tests. We applied 5-fold cross-validation during training. Additionally, we also tested the trained models on another (fifth) instrument [15], which was not used in training nor evaluation of the models, i.e., data gathered from another pipe organ, with a different blowing pressure (80 mm H₂O).

This research uses a pseudo-random number generator to draw pipes to be included in datasets. To avoid, on the one hand, the generator falling into periodicity [16] and, on the other hand, possible repetitions of pipe sets, a mechanism of indexing pipes in sets was implemented. All pipes within one instrument are numbered sequentially. After generating the sets of randomly selected pipes, each set was assigned a binary number, with the

number of digits equal to the number of pipes in this instrument. Each digit corresponds to the presence (1) or absence (0) of the corresponding pipe in the set. Thanks to this one-hot approach, a binary number representing each set was obtained, which allowed verifying the uniqueness of the sets. In the case of repetitions, new sets were generated, and the uniqueness of the sets was verified again. We assume that a pipe set is unique if at least 20% of its pipes differ from other sets. This simulates differences between real organs, as the same stops in pipe organs frequently occur; too small differences (e.g., just one different pipe) could lead to overtraining of ML algorithms.

The second issue is the problem of memory (space) complexity. To accelerate the model learning process, the optimal solution is to load all the training data of the model into the memory. As mentioned before, the data were processed to ensure uniqueness, which increased space complexity. To ensure smooth operation of our software, we carefully control RAM usage, see Subsection 4.1.

2.2. Programming language, libraries, and generative artificial intelligence

When choosing a programming language for our software, two popular languages with libraries for ML were taken into account: Java and Python. We chose the Java language for its better memory management. Firstly, we needed a statically typed language (with variable types assigned before using them) to accurately reserve the space for variables and optimize memory usage. Secondly, we needed a mechanism of immutable objects that ensures that the object remains permanent after its creation, to achieve secure and efficient memory management. In addition, Java provides efficient support for multithreading, which allows the parallel execution of different tasks.

The Application Programming Interface (API) of the Weka library, version 3.9.6 [17], was used in the software development process. We chose the Weka platform due to its constantly updated API and a large collection of implemented ML methods. In our research, the problem of regression is addressed, i.e., the output of our software is a real number. Therefore, all regression algorithms implemented in Weka were tested, in various configurations and with various hyperparameter settings, to obtain the best solution. Namely, we used the following algorithms: random forest (RandomForest), linear regression (SimpleLinearRegression), support vector machine for regression (SMOreg), sequential minimal optimization (SMO), radial basis function network (RBFNetwork), and single- and multi-layer perceptron (MultilayerPerceptron). These algorithms were designed for batch or incremental learning.

Additionally, we used the Deeplearning4j library, version 1.0.0-M2.1 [18], and the Nd4j sub-module, which allows loading, executing, and retraining TensorFlow models. We used several popular ANN models for regression problems in various hyperparameter configurations. Namely, we used convolutional neural networks and recurrent neural networks, including long short-term memory (LSTM) and dense (DenseLayer) layers. The results obtained using these models were compared with the results obtained using ML algorithms from the Weka library, see Section 4.

For all ML algorithms applied in our work, we used default values of their hyperparameters, unless specified otherwise in Section 5.

In this work, we also decided to use generative AI: Gemini, version 1.5 Pro [19], and Llama, version 3.2 [20], which are large language models (LLMs). The LLMs we used were not fine-tuned, and the default settings of their generation parameters were applied. These chatbots were applied to see what generative AI has to offer to analyze relationships between attributes, suggest hyperparameters for various ANNs, and train and test selected ANN models. Generative AI models, even without specific training in predicting pipe organ blowing pressure, can create valuable neural network architectures based on the provided attributes. They focus on key input data, applying proven design principles to capture complex relationships between features. The proposed models can serve as rapid prototypes for further optimization and leverage interdisciplinary knowledge, offering a flexible and efficient approach to solving the problem.

We found that Gemini hallucinates when data is imported from external sources, i.e., publicly available data in CSV format, as described in Section 4.1. The imaginary models achieved high accuracy and other results as expected, which could confirm their effectiveness. However, an in-depth analysis of the models and dialogue with the Gemini chatbot revealed hallucinations, i.e., fabricated information. Additionally, the results were unstable, as they varied between different chats. Therefore, we discarded models built on external data and only analyzed results for input data limited to 1315 lines that did not cause hallucinations when using Gemini. We did not encounter similar problems using a local LLM, i.e., Llama. Furthermore, the results obtained by Llama are better than those obtained using Gemini.

3. OUR DATA

Based on the analysis of the related research, we selected a small set of input attributes, described in this section. This allowed us to avoid data redundancy and, as a result, overfitting when creating the models. In our selection of features, we focused on ensuring their high predictive values, which influences the construction of more effective models. We use four input attributes, the values of which were different for each pipe. These attributes are: cut-up height, fundamental frequency, airflow velocity, and air pressure in the pipe's foot. The input data used to train and test models represents either measured or calculated values. The output value is the blowing pressure p_w , measured in millimeters of water gauge; this value is predicted using ML and DL. The air pressure in the foot of the pipe is different from the blowing pressure. The blowing pressure is usually stable for the entire instrument or sometimes for a large group of pipes, while the pressure in the foot of the pipe is different for each pipe. In the case of incomplete instruments, when bellows and a significant percentage of pipes are missing, it is difficult to determine the blowing pressure, and the trial-and-error method may lead to the destruction of historical pipes.

Our data describe 191 pipes representing 21 stops from five complete instruments. The collected data are publicly available

in The Diapason [15, 21–25], a journal dedicated to the organ, harpsichord, carillon, and church music. The data representing our input and output attributes are hard to obtain, as access to most pipes in instruments is usually almost impossible, because they are set tightly. Access for measurements is possible when disassembling the instrument for renovation, which happens rarely. In the literature, lip dimensions are usually not published together with blowing pressure; they are most often published separately. Such data cannot be used for the training of ML algorithms, as we need both input and output values. This is why we only have data for five instruments.

The first (measured) attribute is the height h of the pipe mouth's cut-up, in millimeters, see Fig. 1. The values of this attribute were measured by organbuilders and were published in The Diapason, as mentioned above.




Fig. 1. Construction of a flue pipe with the height of the cut-up h indicated

The second (calculated) attribute is the fundamental frequency F_0 of the pipe's sound. It can be calculated in two ways. The first one is based on the wavelength of the sound

$$F_0 = c/\lambda, \quad (2)$$

where c is the speed of sound (m/s), and λ is the wavelength (m). In the case of instruments tuned in the equal temperament system, the second method to determine F_0 can be used. It is based on musical intervals and is calculated as the ratio of frequencies, which is constant and equal to $\sqrt[12]{2}$ for consecutive semitones in the twelve-tone equal-tempered scale, and tuned relative to a standard pitch A (around 440 Hz). We used this method to calculate the second attribute because it is faster than determining the wavelength for each pipe individually.

The third (calculated) input attribute is the velocity v of the airflow in a pipe, in meters per second. A constant value of the Strouhal number $S_t = 0.2$ was assumed for the calculations. The previous research published in [12] indicates that this value for labial pipes is constant when rounded to one decimal place, regardless of the type of pipe or its mouth. The airflow velocity v in a flue pipe is calculated as

$$v = F_0 \cdot h/S_t. \quad (3)$$

In addition, we assume that the pipe was properly voiced, which means that the pipe sounds as intended (without beats).

To achieve proper voicing, the edge tone produced in the cut-up must be of the same frequency as the resonator.

The fourth (calculated) input attribute is the air pressure p_p in the pipe's foot. As mentioned above, the value of p_p differs from the blowing pressure p_w and varies between pipes. When analyzing the outflow of air from the pipe's flue, this phenomenon can be considered as an adiabatic outflow of gas from a container with a higher pressure to an area with a lower pressure, with constant pressure in the container. In the case of a pipe organ, the pressure in the windchest and thus in the pipe foot is constant, as the roller valve and the bellows regulate the air supplied by the blower. Next, the wind duct supplies air to the windchest at the same pressure, see Fig. 2.




Fig. 2. Construction of the wind supply system of a pipe organ

Assuming an adiabatic outflow of an ideal gas without heat exchange and mechanical work from the container, the Saint Venant-Wantzel formula [26] for the velocity v of such outflow can be used

$$v = \sqrt{2 \frac{\kappa}{\kappa - 1} \cdot \frac{p_p}{\rho} \left(1 - \left(\frac{p_e}{p_p} \right)^{(\kappa - 1)/\kappa} \right)}, \quad (4)$$

where $\kappa = 1.401$ is the adiabatic exponent, p_p is the pressure in the pipe's foot (Pa), $p_e = 1013.25$ Pa is the pressure outside (ambient), and $\rho = 1.225$ kg/m³ is the density of dry air at 15°C. In the situation of air intake by the blower from the same room where the windchest is located, the temperature is assumed to be constant. We can next transform (4), with the constants κ , p_e , ρ , as above, and use (3). As a result, we receive the following formula to determine the pressure p_p in the foot of a flue pipe, which depends on the pipe mouth cut-up height h and the fundamental frequency F_0 of the pipe's sound [8]

$$7.25 \cdot \sqrt[1.40]{p_p} - p_p + 4.38 \cdot F_0^2 \cdot h^2 \approx 0, \quad (5)$$

where 7.25 and 4.38 are approximate values (rounded to two decimal places), resulting from transformations of (3) and (4). The approximation in (5) results from these approximations; for exact values, this formula is an equation.

As we can see, the fourth parameter (p_p) uses both the first attribute (h) and the second one (F_0), in a nonlinear equation. The pressure calculated using (5) does not consider losses in the airflow, and it indicates an absolute pressure. To determine

the value of relative pressure p_{rel} , used in blowing pressure measurement, the ambient pressure p_e must be subtracted from the obtained pressure p_p , and the units converted to mm H₂O

$$p_{rel} = (p_p - p_e) / \xi, \quad (6)$$

where $\xi = 9.80665$ Pa/mm H₂O is the conversion factor applied to convert Pascals to millimeters of water gauge.

We use (5) to calculate the fourth input attribute, i.e., the air pressure in the foot of a pipe. This equation is a nonlinear, transcendental equation – it is not an algebraic equation because it contains the variable p_p under the root of the noninteger degree $\kappa = 1.401$. It is not possible to solve this type of equation analytically. Therefore, we attempted a geometric solution to achieve an intuitive insight into the structure of the solution. Based on the graphical solution, we can find that (5) has a unique solution. Unfortunately, this method proved to be inaccurate in determining the solution. Solving this equation requires the use of numerical methods that iteratively allow the solution to be determined with higher precision, especially for more complex values of fractional roots. In this work, we used the Newton-Raphson tangent method [27] as an iterative numerical method for finding the zeros of functions in a given range. It is often used in numerical analysis or optimization and is applied to nonlinear equations whose derivatives are easy to calculate. This method proved to be effective, and the solutions obtained were consistent with those obtained graphically.

4. DATA PROCESSING

We used the input data sets, prepared as shown in Section 3, to generate ML and DL models. We used the software we wrote for this research for this purpose. Additionally, we also used generative AI, as described in Subsection 4.2.

4.1. Programming ML and ANN models

The software for this research was written in the IntelliJ IDEA IDE, version 2023.3.4, using Java SE Development Kit, version 19.0.2, and Apache Maven, version 3.9.6. We used a Dell EMC PowerEdge R540 server with two Intel Xeon Silver 4110 2.10 GHz CPUs (16 physical cores) and 96 GB of ECC DDR4 2133 MHz RAM. Our software allows performing the following steps.

The first step is to set (by the user) the model options, and the number of pipes to be randomly selected in each draw from input data, to create the sets of pipes to be used in training and testing of ML algorithms. Next, data from CSV files are loaded into RAM. The file consists of four columns with input attributes and one column with an output attribute. All features are numeric, with two decimal places. The features (descriptors) of the pipes are: cut-up (mm), airflow velocity (m/s), fundamental frequency (Hz), and pressure in the pipe's foot (mm H₂O). The output data is the blowing pressure (mm H₂O).

The next step is to generate simulated sets of pipes, stored as two-dimensional arrays of double-precision floating-point numbers. Next, a procedure which ensures that each set is unique is executed, see Subsection 2.1. The unique sets that simulate pipe sets from different instruments are saved as two lists,

namely the list of the Instance class objects for ML algorithms in Weka, and the list of the DataSet class objects for DL models in Deeplearning4j. These lists of objects are randomly divided into a nonoverlapping train set (70%) and test set (30%). For memory efficiency, only the training and test lists are kept. Additionally, the train and test sets for both lists are normalized to the range $[0, 1]$ after splitting into train and test sets, to avoid bias in the test data.

Next, regressors are trained on the prepared train data in a separate module. Additionally, we used five-fold cross-validation in training. All algorithms from the Weka library [17] and ANN models from Deeplearning4j [18], which are suitable for regression problems, were successively trained on the same data, see Subsection 2.2. The observed variance in the results within the folds for each model was negligible and did not affect the final ranking of the compared algorithms. Therefore, to maintain maximum clarity and to focus on the key performance differences between the models, we have chosen to present only the mean values of the performance.

The trained models are next tested on the test data. The following measures are calculated to evaluate the obtained results [28, 29]: the Pearson's correlation coefficient (r), mean absolute error (MAE), root-mean-square error (RMSE), relative absolute error (RAE), root relative square error (RRSE), mean absolute percentage error (MAPE), and acceptable error rate (AER), which is a version of the MAE adjusted to this research. The metrics used in the model evaluation are shown in (7)–(13)

$$r = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{\sqrt{\left[n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 \right] \cdot \left[n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2 \right]}}, \quad (7)$$

$$\text{MAE} = \frac{\sum_{i=1}^n |x_i - y_i|}{n}, \quad (8)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}}, \quad (9)$$

$$\text{RAE} = \frac{\sum_{i=1}^n |x_i - y_i|}{\sum_{i=1}^n |x_i - \bar{x}|} \cdot 100\%, \quad (10)$$

$$\text{RRSE} = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \cdot 100\%, \quad (11)$$

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right|, \quad (12)$$

$$\text{AER} = t_3 \cdot 100\% / n, \quad (13)$$

where x_i is an actual value, y_i is the predicted value, \bar{x} is an arithmetic mean of all actual values, n is the total number of predictions, and t_3 is a number of predictions such that $|y_i - x_i| \leq 3$. We used the AER measure because the admissible error in the blowing pressure is ≤ 3 mm H₂O, which is caused by two reasons. Firstly, the measurement error made by the organbuilder is ≤ 1 mm H₂O. Secondly, the difference in pressure in the air supply system itself can vary because of differences in the height of the position of various components of the system relative to the ground. Assuming that the position difference between the bellow h_1 and the windchest h_2 is not greater than 3 m, the change in pressure between the bellow p_1 and the windchest p_2 may be circa 3 mm H₂O. This results from the Bernoulli's equation [30] for an ideal gas and adiabatic transformations

$$p_1 - p_2 = \rho \left(g (h_2 - h_1) + \left(\frac{v_2^2 - v_1^2}{2} \right) \right), \quad (14)$$

where $g \approx 9.81$ m/s² is gravitational acceleration, v_1 is the velocity of the air coming out of the bellows, and v_2 is the velocity of the air entering the windchest. Additionally, to ensure the reliability of the r correlation results, we applied the standard z-score measure, confirming the set absence of outliers (z-scores in the range from -1.34 to 1.97).

We encountered various technical problems when developing our software. We started with single-threaded processing of regressors, but with an increasing number of the generated sets of pipes, the time of model training increased to the order of hours. To speed up the calculations, each regressor we used has been rewritten to a multi-threaded version, using the Executor class and Lambda expressions in Java. Unfortunately, regressors from the Weka library in multi-threaded training require synchronization of model threads and the input data, which significantly increases the training time. Additionally, we had to deal with the RAM usage problem, to avoid the program stopping because of running out of memory, with the increase in the number of pipe sets. Therefore, RAM monitoring and memory cleaning via manual control of the garbage collector were used. Another problem was posed by a pseudo-random number generator applied in the process of generating the sets of pipes. In the case of a small number of pipes remaining in the set, we found repetitions in the generated sets. This confirms that it is necessary indeed to use a procedure that ensures the uniqueness of pipe sets, which we implemented as described in Subsection 2.1.

4.2. Application of generative AI

We used generative AI [19, 20] to suggest ANN architectures and compare its proposals with our results obtained from Weka and Deeplearning4j. We provided the chatbot commands with one prompt. In the case of Gemini, its length could not be longer than 1316 lines: 1315 lines of data and 1 line of instructions. Llama, however, was tested locally, on the server described in Subsection 4.1. The prompt for both LLMs¹ consists of:

- The command to analyze the data provided below.

¹https://github.com/damianwegrzyn/LLMs_prompt

Predictive algorithms for determining blowing pressure in a pipe organ

- Information that the data is numeric, stored in five columns separated by commas, with the first four columns storing input attributes, and the fifth one the output value.
- The command to propose three of the most adequate ANN architectures and their hyperparameters, based on the analysis of the provided data.
- The command to train the proposed ANN models on 70% of randomly selected data rows, which should be normalized and scaled before training.
- The command to evaluate models on the remaining 30% of data rows, which should be normalized and scaled before testing.
- The command to print numerical values of model evaluation measures (all accurate to four decimal places): r, MAE, RMSE, in percentage: RAE, RRSE, MAPE, and the AER calculated as $AER = t_3/n$
- Only for Gemini: input data in the form of 1315 lines (i.e., 1315 pipes).

The Gemini chatbot proposed ANN architectures and their hyperparameters presented in Table 1. Table 2 presents Llama's proposals based on the same prompt as Gemini, but for the full

Table 1

The architectures and hyperparameters of the ANNs proposed by Gemini

ANN type	Architecture	Hyperparameters	Data preparation
Multilayer perceptron (MLP)	Input layer: 4 neurons Hidden layer 1: 16 neurons, rectified linear unit (ReLU) activation Hidden layer 2: 8 neurons, ReLU activation Output layer: 1 neuron, linear activation	Optimizer: Adam Learning rate: 0.001 No. of epochs: 100 Batch size: 32 Loss function: mean squared error (MSE)	The data was normalized and scaled using the standard MinMax scaler.
Recurrent neural network (RNN)	Input layer: 4 neurons Hidden layer 1: 16 neurons, ReLU activation Hidden layer 2: 8 neurons, ReLU activation Output layer: 1 neuron, linear activation	Optimizer: Adam Learning rate: 0.001 No. of epochs: 100 Batch size: 32 Loss function: MSE Dropout: 0.2 Bidirectional: True	The data was normalized and scaled using the standard MinMax scaler.
Convolutional neural network (CNN)	Input layer: 4 neurons Convolutional layer 1: 32 filters, size 3×3 , ReLU activation Max pooling layer 1: Pool size 2×2 Convolutional layer 2: 32 filters, size 3×3 , ReLU activation Max pooling layer 2: Pool size 2×2 Fully connected layer 1: 128 neurons, ReLU activation Output layer: 1 neuron, no activation	Optimizer: Adam Learning rate: 0.001 No. of epochs: 100 Batch size: 32 Loss function: MSE	The input data was normalized using standard scaling (z-score). The target value was scaled using a logarithm.

Table 2

The architectures and hyperparameters of the ANNs proposed by Llama

ANN type	Architecture	Hyperparameters	Data preparation
Deep neural decision forest (DNDF)	Input layer: 4 neurons Decision tree layer: 16 trees, max depth 5 Neural layer: 2 hidden layers, 16 neurons each, ReLU activation Output layer: 1 neuron	Optimizer: stochastic gradient descent Learning rate: 0.01 No. of epochs: 50 Batch size: 64 Loss function: MSE Early stopping: True	The data was normalized and scaled using the MinMax scaler.
Multilayer perceptron (MLP)	Input layer: 4 neurons Hidden layer 1: 32 neurons, ReLU activation Hidden layer 2: 16 neurons, ReLU activation Output layer: 1 neuron	Optimizer: Adam Learning rate: 0.001 No. of epochs: 100 Batch size: 32 Loss function: MSE	The data was normalized and standardized using z-score scaling.
Fully connected neural network (FCNN)	Input layer: 4 neurons Hidden layer 1: 64 neurons, Tanh activation Hidden layer 2: 32 neurons, Sigmoid activation Output layer: 1 neuron	Optimizer: root mean square propagation (RMSprop) Learning rate: 0.0005 No. of epochs: 100 Batch size: 128 Loss function: MSE	The data was scaled using the robust scaler. Outliers in target values were clipped.

set of input data. The model evaluation measures are described in Subsection 4.1.

5. RESULTS

We compared all trained models using the following evaluation metrics, listed in Subsection 4.1: r, MAE, RMSE, RAE, RRSE, MAPE, and AER. The most important metric in the assessment was the acceptable error rate (AER). The models that performed best were the random forest (RF) and the multilayer perceptron (MLP). We publish the best trained models for future research purposes², and present the dependence of their AER on the number of remaining pipes in the instrument in Fig. 3.

The perceptron and sequential minimal optimization for regression (SMOreg) algorithms also performed well. Table 3 presents evaluation results for the best three models, for four percentages of the pipes drawn into the pipe set (simulating the remained pipes in an instrument), namely: 75%, 50%, 30%, and 10% of the full set of pipes.

Considering the specificity of the data and the training target, we find the trained algorithms very useful. The value of Pearson's correlation coefficient of 0.97 for the RF with 75% of the pipes remaining indicates a strong correlation between the predictions and the actual values. A low mean value of absolute differences between model predictions and actual values, i.e., MAE, also indicates good performance and accurate predictions. The MAPE value, often used as a loss function in regression, was always less than 5.5%. This confirms that the

²https://github.com/damianwegrzyn/ML_models

Table 3

The evaluation of the top three ML algorithms for training on 75%, 50%, 30%, and 10% of all pipes

Remaining pipes	Rank	Model	AER [%]	r	MAE	RMSE	RAE [%]	RRSE [%]	MAPE [%]
75%	1	RF	96	0.97	0.80	1.84	13.39	22.40	1.04
	2	MLP	79	0.69	4.46	9.36	74.41	113.74	5.01
	3	Perceptron	74	0.54	4.99	8.36	83.32	101.56	5.23
50%	1	RF	93	0.95	0.92	2.43	15.41	31.05	1.27
	2	MLP	84	0.82	4.50	8.52	78.37	108.60	5.06
	3	SMOreg	72	0.54	3.34	6.91	55.62	88.30	4.07
30%	1	RF	85	0.86	2.05	4.20	33.29	50.29	2.62
	2	MLP	83	0.63	4.89	8.56	78.73	101.89	5.41
	3	RNN	68	0.44	4.50	8.49	72.75	99.00	5.49
10%	1	MLP	84	0.47	4.50	8.10	73.38	100.09	5.10
	2	SMOreg	76	0.09	4.49	9.27	71.18	111.89	4.99
	3	CNN	75	0.12	4.56	9.64	73.96	113.24	5.12




Fig. 3. The dependence of the accuracy of RF (grey solid line) and MLP (red dotted line) models on the number of remained pipes

output values predicted by these algorithms are close to actual values. The RMSE of 1.84 shows that large error values are rare; low RMSE indicates that predictions rarely differ much from actual values. RAE and RRSE allow comparing the quality of forecasts between different models and between input data of different scales. The obtained low values of these measures confirm the good quality of the obtained models. These results confirm that it is possible to predict the blowing pressure in a pipe organ using ML and the features described in Section 3.

The training was repeated several times (up to 50 repetitions for RF), and similar values of evaluation measures were obtained, which confirms the repeatability of the results. We built an RF with 200 decision trees with a maximum depth of 5 and the number of attributes to randomly investigate set to 4, but

even an RF with only 10 trees yielded good results; thus, we present results for this small RF, which are even better than for 200 trees. For at least 30% of pipes remaining in the set, the RF was unbeatable and showed high resistance to outliers, but its quality dropped significantly for 10% of remaining pipes in the set.

In addition, we analyzed the importance of individual input attributes in our best RF model. We used the built-in functionality in Weka to determine the importance of attributes, which is calculated as mean decrease in impurity; the higher the score, the more important the feature is.

Figure 4 presents the importance of features in our best RF model. As we can see, all features contribute to predictions, and the height of the cut-up is the most important feature. This confirms the dependence of the blowing pressure on the features we used, and is consistent with organ building knowledge.




Fig. 4. The importance of individual input attributes in the best model RF for 75% of the remaining pipes

The perceptron and the MLP were adapted to solve the regression problem by changing the activation function to a linear function (no activation) and changing the cost function to mean squared error (MSE). Training was performed for 100 to 1000 epochs, with a step of 100 epochs, and with additional train-

ing for 1500 and 2000 epochs. Both models achieved the best results for the following hyperparameters: learning rate for the backpropagation algorithm equal to 0.3, momentum rate for the backpropagation algorithm equal to 0.2, training for 100 epochs, with a validation threshold equal to 20 (default value), the size of the validation set equal to 20, and the seed for the random number generator equal to 1. The MLP model consisted of three hidden layers.

The SMOreg model is also worth attention. It is a regression algorithm based on support vector machines that uses the sequential minimal optimization. This model is especially useful for nonlinear regression problems because it can automatically extract a data transformation function that allows the model to fit the data better. Models built using linear regression, i.e., linear regression and simple linear regression, yielded worse results, and their accuracy was low.

CNN and RNN models also yielded satisfactory results, especially for the lowest investigated percentage of remaining pipes: CNN for 10% and RNN with DenseLayer for 30% of remaining pipes. Thus, as the number of remaining pipes decreases, more complex ML algorithms are better at discovering the relationships within the input data.

We also applied generative AI to compare our results with the results obtained by Gemini AI (for data limited to 1315 lines). As shown in Table 4, these models achieved similar results for various types of ANNs.

Table 4

The evaluation of the ANN models proposed and created by Gemini on the 1315 pipes dataset

Rank	Model	AER [%]	r	MAE	RMSE	RAE [%]	RRSE [%]	MAPE [%]
1	MLP	95	0.99	2.78	4.23	5.94	10.13	3.87
2	RNN	94	0.99	2.75	3.93	5.24	7.85	2.14
3	CNN	92	0.95	2.13	3.02	6.22	9.16	5.43

The obtained model accuracies are high, but they were achieved for the limited input data set, which is in accordance with our expectations. It is worth noting that relying on limited input data for AI evaluation may not fully capture the model performance in diverse scenarios.

We also verified the ANN architectures proposed by Llama. The results obtained by Llama are presented in Table 5. The best accuracy was achieved by the deep neural decision forest (DNDF) [31] model: 97%, which is a better result than for the RF model. The DNDF is a decision tree model that guides representation learning in the initial layers of a CNN and replaces the traditional fully connected layers with a decision forest for the final prediction. This distinguishes DNDF from traditional neural networks. It is especially effective in the case of nonlinear relationships between input and output variables. The high performance of the RF and DNDF models indicates that the use of tree structures is an effective method for predicting blowing pressure. MLP and fully connected neural network (FCNN) also yield high accuracy, comparable to Gemini models.

Table 5

The evaluation of the ANN models proposed and created by Llama

Rank	Model	AER [%]	r	MAE	RMSE	RAE [%]	RRSE [%]	MAPE [%]
1	DNDF	97	0.99	2.02	2.34	15.54	14.34	1.38
2	MLP	95	0.98	3.49	4.06	16.49	16.73	2.17
3	FCNN	94	0.96	3.37	3.96	15.91	26.67	2.32

Such good results, obtained from both LLMs, open the possibility of further research toward model optimization. Modern AI learning support techniques, such as techniques embeddings AI, vector database, or retrieval augmented generation, can be used to train the ANN models on large datasets and yield even better results.

We also checked the performance of the best trained models, i.e., RF and MLP, using the data representing the fifth instrument [15] as a test set. This instrument was not used in training. The instrument comes from a different region (Germany) and era (baroque) than the pipe organs we used to train the models. The evaluation results are presented in Table 6. They confirm the usefulness of both models.

Table 6

The evaluation of RF and MLP models on the test instrument, not used in the training process

Re-main-ing pipes	Rank	Model	AER [%]	r	MAE	RMSE	RAE [%]	RRSE [%]	MAPE [%]
75%	1	RF	94	0.95	0.97	2.02	14.02	28.20	1.19
	2	MLP	75	0.67	4.56	10.13	77.42	117.10	5.92
50%	1	RF	92	0.93	1.01	2.86	15.83	32.75	1.30
	2	MLP	82	0.77	4.62	8.64	80.00	114.21	5.53
30%	1	RF	84	0.86	2.11	4.32	37.09	59.04	2.84
	2	MLP	81	0.57	4.97	8.84	80.10	109.36	5.88
10%	1	MLP	83	0.47	4.50	8.74	75.43	104.83	5.27
	2	RF	70	0.24	5.00	10.22	67.04	91.28	4.71

6. RELATED RESEARCH AND DISCUSSION

Determining the blowing pressure in a pipe organ is not often discussed in the literature; works on sound pressure level (SPL) or acoustic pressure [32] and their measurement are more often found. Saenger [33] presents the method of SPL measurement in a labial resonator, and Rucz [34] shows the pressure distribution for various modes in the resonator. Smith [35] states that the sound generation process has two components: a standing wave and turbulence coming from the upper lip or tongue. Angster and Miklós [13] present the edge tone as a sound source in the pipe. Ody *et al.* [36] confirm that the second sound source is at the top of the flue pipe.

The influence of the cut-up height on the labial pipe voicing is confirmed by research and organ-building practice [37, 38]. Adachi *et al.* [39] prove that even a small change in the pipe's

mouth results in significant changes in the sound characteristics. The influence of the mouth on the sound is also seen in other flute instruments, such as the recorder or the transverse flute [40]. Each change of the upper lip results in a spectrum change, as studied by Stafura and Nagy [41]. Angster and Miklós [13] proved that shortening the upper lip reduces the amount of air flowing into the pipe; the decrease in air jet velocity results either from the increase in the distance of the upper lip from the flue (shortening of the upper lip) or from the decrease in pressure. The influence of lip parameters on the velocity of the air jet was confirmed by Fabre *et al.* [42]. Mallock [43] found that the fundamental frequency of the pipe's sound depends on the jet velocity. An increase in air velocity increases frequency, up to a certain limit. Our research results also show that the cut-up height is the most important attribute influencing the blowing pressure, which is consistent with the above-mentioned research.

The velocity of the air jet is usually determined from Bernoulli's equation [44,45]. Steenbrugge [46] and Steenbrugge and de Baets [47] published a formula for calculating the air jet flow velocity depending on the pressure in the pipe's foot. By modifying this formula, if the flow velocity is given, the value of the relative pressure in the pipe foot (in mm H₂O) can be determined

$$p_{\text{rel}} \approx \frac{\rho v^2}{19.6}. \quad (15)$$

The velocity of the jet coming from the flue was experimentally measured by Außerlechner *et al.* [48] and Elder [49]. The velocity values for similar pipes are very close to the values we calculated. The air jet velocity value was also experimentally measured in various pipes by Węgrzyn *et al.* [12]. Węgrzyn *et al.* [50] also confirmed the influence of the air jet velocity on the pipe's fundamental frequency.

The air pressure in the foot of the pipe depends mainly on the blowing pressure, but also on the geometric dimensions of the foot hole and the flue [13]. Fletcher and Rossing [7] stated that the foot hole (the air intake) of the pipe effectively controls the pressure exerted on the flue slit. Steenbrugge [46] experimentally confirmed the relationship between the air pressure in the foot of the pipe and the size of the foot hole. Angster *et al.* [51] proved that different types of windchests affect the pressure in the pipe foot, with the blowing pressure unchanged. Lunn [52] and Steenbrugge [46] experimentally confirmed that the pressure drop at the foot hole should be assumed. Due to frictional losses, the pressure in the foot of the pipe is less than the bellow pressure [52]. Kanda and Shimomukai [30] numerically proved that the pressure at the walls of the foot is lower than in the central core. This phenomenon even occurs for the Reynolds number lower than 5000. Außerlechner *et al.* [48] measured the pressure in the foot of the pipe using a pressure sensor. Pipes with similar geometrical features, used in their research, had pressure values similar to the values in our work, which confirms the correctness of the calculated pressure values.

The influence of changing the blowing pressure on the sound generated by pipes is well-known [6]. The change of the blowing pressure changes the amplitude of the generated sound, its

pitch, and timbre [45,53]. Steenbrugge and de Baets [47] confirmed the increase in sound frequency with increasing blowing pressure and vice versa. With the decrease in blowing pressure, the sound becomes darker and duller [47]. If pressure increases, a discontinuity of pressure at the mouth is observed, caused by the centrifugal force of the curvilinear flow [52].

A fixed value of blowing pressure allows for a strong and clear sound [36]. The blowing pressure cannot change significantly, and if the pressure is too high, overblowing, typical of wind instruments, occurs. Rucz *et al.* [45] analyzed the dynamic organ pipe invented by Zacharias. Due to the use of a blown open tongue with free reed, this pipe can be adjusted to blowing pressure between circa 5 and 110 mm H₂O. Tuned pipes, commonly used in the pipe organ, do not allow the blowing pressure to change significantly. Steenbrugge [54] also describes the feedback cycle operating regime for pipe blowing, which includes cut-up, blowing pressure, and the flue width. Therefore, tuned pipes are adjusted to a limited blowing pressure range.

6.1. Limitations of the study

The main limitation of this study is that our methodology can be applied only to pipe organs with bellows with a reservoir. It does not apply to wedge bellows, which are rare. Another key requirement is the presence of flue pipes. If only reed pipes survive, our method will not apply either. In addition, for the blowing pressure predictions to achieve acceptable accuracy, the remaining flue pipes should constitute at least 10% of all pipes. Moreover, it is also required to gather pipe attributes, namely cut-up height and fundamental frequency.

Due to the lack of dimensions of the pipe's mouth published together with the blowing pressure, our models were trained only on four pipe organs. From the point of view of organ building and the physics of sound generation, the attributes we selected allow us to generalize our methodology to other pipe organs.

The limitation of interpretation is the admissible error in the accuracy of the determined blowing pressure. It accepts a pressure error of 3 mm H₂O and a difference in the relative position of the windchest to the bellows of up to 3 m.

The implementation limitation of ML and ANN training was the restriction of input data to one million datasets, due to the available amount of 96 GB of the server RAM. Furthermore, in the case of using Gemini, the input data was limited to 1315 pipes due to the limitation of the input prompt in the case of this chatbot.

When analyzing the results of generative AI, it is worth noting the occurring hallucinations (Gemini and external data collection), i.e., a phenomenon in which an LLM generates information that is false, fabricated, or has no basis in its training data, but presents it confidently and convincingly. This carries the risk that the generated proposals for ANN architectures and the obtained evaluation values may be false. The second problem is the black box problem, i.e., the impossibility of fully understanding and explaining how chatbots achieve the presented results. Since an LLM internal processing is not based on human-interpretable rules but on complex patterns learned from data, it is difficult to identify subtle, hidden errors, bias contained in the training data, or the model limitations that could have influenced the final

results. However, we were aware of the aforementioned limitations. Thus, we verified the responses from the LLMs to avoid the impossibility of research reproducibility. The results from the LLMs are consistent with the outcomes from the evaluation of our trained models.

7. CONCLUSIONS

The issue of restoring blowing pressure in a pipe organ has so far been an unsolvable problem. In most cases, the restored organs are incomplete, with bellows and a high percentage of pipes missing. The proposed solution, based on ML and ANN models, yields high accuracy and confirms the possibility of determining the blowing pressure. Our methodology is currently the only alternative to the trial-and-error method, which may destroy the historical pipes, as there is no method to calculate the blowing pressure. We also propose a faster yet equally effective way of determining the blowing pressure using commonly available tools such as LLMs, which facilitates the practical application of our solution.

The most efficient ML model if the majority of pipes in the remaining instrument is the RF model, with an accuracy of 96%. In an extreme situation, when circa 90% of the pipes are missing, the MLP model is the most effective one, with an accuracy of 82%. Among the tested models that use the ANNs, the best predictor is the DPDF model, which achieved an accuracy of 97%. Other ANN models also achieved high results, exceeding 92%.

Equation (5) proposes a formula describing the air pressure in the labial pipe's foot depending only on its fundamental frequency and cut-up height, with no other variables as we used a constant Strouhal number, determined in the previous work for various mouth and pipe types [12]. We also confirmed the relationship between flue pipe attributes and blowing pressure. We found that the height of the cut-up is the most important feature. Fundamental frequency is also important, as it affects the proper voicing of a pipe. These two attributes suffice to determine the blowing pressure (the others can be calculated), and their importance is confirmed in RF.

In our training, we used a variety of organ pipes, i.e., different types, constructions, and mouths. They came from instruments with different blowing pressures. As mentioned in Section 1, the era or origin of the organ is not important, because we selected input attributes that characterize the physical properties of the sound, not its timbre. Thanks to this, we obtained diversity that allows for generalization of our methodology also to other pipe organs, not included in the training dataset. We confirmed this by testing our best ML models on the data from a pipe organ that was not used in training. It is worth noting that this pipe organ comes from a different era and region than those used in training.

The proposed methodology of determining blowing pressure is an important achievement, which applies state-of-the-art information technology in the broader process of renovation and reconstruction of historical objects, thus increasing financial efficiency and minimizing trial-and-error attempts. Sometimes, only illustrations of the pipes have been preserved, but the in-

strument has not survived [4]. If these graphics are of good quality, they may be used to restore the blowing pressure. It would significantly improve the instrument rebuilding process while maintaining the authenticity of the original sound. Our findings may help not only organ builders in the reconstruction of destroyed pipe organs, but also in determining the pressure in the windchest during new instrument building. Another area that may benefit is the analysis of fluid flows, especially in the problems of unknown value of constant fluid pressure. The next area of the application of our results is acoustic modeling. The ability to accurately determine the blowing pressure can aid in the creation of precise acoustic models that predict sound behavior depending on changes in the construction of the pipes or the windchest system.

In future work, we would like to investigate the influence of other organ pipe attributes (flue dimensions, scaling, i.e., ratio of pipe length to diameter, etc.) on blowing pressure. Moreover, the models for determining the blowing pressure can be optimized to be efficient even in the case of highly incomplete instruments. Designing a new neural network architecture or machine learning regression technique may yield better results than the commonly available models we used. Faster and more accurate algorithms would significantly shorten the process of reconstructing the instrument and facilitate the daily work of organbuilders.

ACKNOWLEDGEMENTS

Open access was founded by the Research Center of PJAiT, supported by the Ministry of Science and Higher Education in Poland.

REFERENCES

- [1] R. Bork, "The Design Geometry of Notre-Dame in Paris," *J. Soc. Archit. Hist.*, vol. 81, no. 1, pp. 21–41, 2022, doi: [10.1525/jsah.2022.81.1.21](https://doi.org/10.1525/jsah.2022.81.1.21).
- [2] I. Trizio, E. Demetrescu, and D. Ferdani, Eds. *Digital Restoration and Virtual Reconstructions. Case Studies and Compared Experiences for Cultural Heritage*. Cham, Switzerland: Springer, 2023, doi: [10.1007/978-3-031-15321-1](https://doi.org/10.1007/978-3-031-15321-1).
- [3] M. Szostak, "The rebirth of Michael Engler's treasure in Wrocław," *The Organ*, no. 400, pp. 4–19, May-Jul. 2022.
- [4] P. Wrzeciono, "Pattern Recognition in Music on the Example of Reconstruction of Chest Organ from Kamień Pomorski," *Sensors*, vol. 21, no. 12, p. 4163, June 2021, doi: [10.3390/s21124163](https://doi.org/10.3390/s21124163).
- [5] D. Bush and R. Kassel, Eds. *The Organ: An Encyclopedia*. New York, NY, USA: Routledge, 2004, ch. 11, pp. 322–323, doi: [10.4324/9780203643914](https://doi.org/10.4324/9780203643914).
- [6] J. Angster, P. Rucz, and A. Miklós, "Acoustics of organ pipes and future trends in the research," *Acoust. Today*, vol. 13, no. 1, pp. 10–18, 2017. [Online]. Available: <https://acousticstoday.org/wp-content/uploads/2021/08/Acoustics-of-Organ-Pipes-and-Future-Trends-in-the-Research-Judit-Angster-1.pdf>. [Accessed: May 9, 2025].
- [7] N.H. Fletcher and T.D. Rossing. *The physics of musical instruments*. New York, NY, USA: Springer, 1998, doi: [10.1007/978-0-387-21603-4](https://doi.org/10.1007/978-0-387-21603-4).

- [8] D. Węgrzyn, P. Wrzeciono, and A. Wieczorkowska, “The Reconstruction of Blowing Pressure in Pipe Organ Using Machine Learning,” in *Harnessing Opportunities: Reshaping ISD in the post-COVID-19 and Generative AI Era (ISD2024 Proceedings)*, B. Marcinkowski *et al.*, Eds. Gdańsk, Poland: University of Gdańsk, 2024, doi: [10.62036/ISD.2024.113](https://doi.org/10.62036/ISD.2024.113).
- [9] M.A. Roch, P. Gerstoft, B. Kostek, and Z.H. Michalopoulou, “How machine learning contributes to solve acoustical problems,” *Acoust. Today*, vol. 17, no. 4, pp. 48–57, 2021, doi: [10.1121/AT.2021.17.4.48](https://doi.org/10.1121/AT.2021.17.4.48).
- [10] M.J. Bianco *et al.*, “Machine learning in acoustics: Theory and applications,” *J. Acoust. Soc. Am.*, vol. 146, no. 5, pp. 3590–3628, Nov. 2019, doi: [10.1121/1.5133944](https://doi.org/10.1121/1.5133944).
- [11] J. Chen, K. Tatar, and V. Zappi, “A Deep Learning Framework for Musical Acoustics Simulations,” *AIMC*, Aug. 2024. [Online]. Available: <https://aimc2024.pubpub.org/pub/5cl1cvmv>. [Accessed: May 9, 2025].
- [12] D. Węgrzyn, P. Wrzeciono, and A. Wieczorkowska, “The Dependence of Flue Pipe Airflow Parameters on the Proximity of an Obstacle to the Pipe’s Mouth,” *Sensors*, vol. 22, no. 1, p. 10, Dec. 2022, doi: [10.3390/s22010010](https://doi.org/10.3390/s22010010).
- [13] J. Angster and A. Miklós, “Properties of the Sound of Flue Organ Pipes,” in *Springer Handbook of Systematic Musicology*, R. Bader, Ed. Berlin – Heidelberg, Germany: Springer, 2018, pp. 141–155, doi: [10.1007/978-3-662-55004-5_8](https://doi.org/10.1007/978-3-662-55004-5_8).
- [14] A. Danihelová, A. Štafura, M. Čulík, and T. Gergež, “Influence of Wood and Thickness of Back Wall of Wooden Organ Pipe and Air Pressure in Windchest on Sound,” *Appl. Sci.*, vol. 14, no. 17, p. 7897, Sep. 2024, doi: [10.3390/app14177897](https://doi.org/10.3390/app14177897).
- [15] M. McNeil, “The Sound of Gottfried Silbermann. Part 2,” *The Diapason*, vol. 1357, no. 1, pp. 13–19, Jan. 2023.
- [16] P. L’Ecuyer, “Random Number Generation,” in *Handbook of Computational Statistics. Springer Handbooks of Computational Statistics*, J. Gentle, W. Härdle, Y. Mori, Eds., Heidelberg, Germany: Springer, 2012, doi: [10.1007/978-3-642-21551-3_3](https://doi.org/10.1007/978-3-642-21551-3_3).
- [17] Waikato Environment for Knowledge Analysis. “The Weka workbench,” Weka 3 – Data Mining with Open Source Machine Learning Software in Java. [Online]. Available: <https://ml.cms.waikato.ac.nz/weka>. [Accessed: May 9, 2025].
- [18] Eclipse DeepLearning4j Development Team. “Eclipse DeepLearning4j.” GitHub. [Online]. Available: <https://github.com/deeplearning4j>. [Accessed: May 9, 2025].
- [19] Google AI. “Gemini.” Gemini. [Online]. Available: <https://gemini.google.com/app>. [Accessed: May 9, 2025].
- [20] Meta AI. “Llama.” Llama. [Online]. Available: <https://www.llama.com>. [Accessed: May 9, 2025].
- [21] M. McNeil, “1863 E. & G.G. Hook Opus 322 Church of the Immaculate Conception Boston, Massachusetts Part 1,” *The Diapason*, vol. 1292, no. 7, pp. 17–19, Jul. 2017.
- [22] M. McNeil, “The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 1,” *The Diapason*, vol. 1305, no. 8, pp. 16–20, Aug. 2018.
- [23] M. McNeil, “The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 2,” *The Diapason*, vol. 1306, no. 9, pp. 20–25, Sep. 2018.
- [24] M. McNeil, “The 1864 William A. Johnson Opus 161, Piru Community United Methodist Church Piru, California, Part 3,” *The Diapason*, vol. 1307, no. 10, pp. 26–28, Oct. 2018.
- [25] R. Redman, “Louis Debierre Choir Organ, 1884,” *The Diapason*, vol. 1298, no. 1, pp. 18–19, Jan. 2018.
- [26] S.L. Arsenjev, I.B. Lozovitski, and Y.P. Sirik, “The Flowing System Gasdynamics, Part 3: Saint-Venant-Wantzel formula modern form,” *ArXiv*, Feb. 2003, doi: [10.48550/arXiv.physics/0302038](https://doi.org/10.48550/arXiv.physics/0302038).
- [27] S.C. Chapra and R.P. Canale, “The Newton-Raphson Method,” in *Numerical Methods for Engineers*, 7th ed., S.C. Chapra and R.P. Canale, Eds., New York, NY, USA: McGraw-Hill, 2002, pp. 151–156.
- [28] J. Benesty, J. Chen, Y. Huang, and I. Cohen, “Pearson Correlation Coefficient,” in *Noise Reduction in Speech Processing. Springer Topics in Signal Processing 2*, I. Cohen, Y. Huang, J. Chen, and J. Benesty, Eds., Berlin – Heidelberg, Germany: Springer, 2009, doi: [10.1007/978-3-642-00296-0_5](https://doi.org/10.1007/978-3-642-00296-0_5).
- [29] M.V. Shcherbakov, A. Brebels, N.L. Shcherbakova, A.P. Tyukov, T.A. Janovsky, and V.A. Kamaev, “A survey of forecast error measures,” *World Appl. Sci. J.*, vol. 24, pp. 171–176, 2013, doi: [10.5829/idosi.wasj.2013.24.itmies.80032](https://doi.org/10.5829/idosi.wasj.2013.24.itmies.80032).
- [30] H. Kanda and K. Shimomukai, “Numerical study of pressure distribution in entrance pipe flow,” *J. Complex.*, vol. 25, no. 3, pp. 253–267, 2009, doi: [10.1016/j.jco.2009.02.003](https://doi.org/10.1016/j.jco.2009.02.003).
- [31] P. Kotschieder, M. Fiterau, A. Criminisi, and S.R. Buló, “Deep Neural Decision Forests,” in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, 2015, pp. 1467–1475, doi: [10.1109/ICCV.2015.172](https://doi.org/10.1109/ICCV.2015.172).
- [32] P. Bordoni, P. Oद्या, J. Kotus, and B. Kostek, “Sounding Mechanism of a Flue Organ Pipe - A Multi-Sensor Measurement Approach,” *Sensors*, vol. 24, no. 6, pp. 1962, Mar. 2024, doi: [10.3390/s24061962](https://doi.org/10.3390/s24061962).
- [33] K.L. Saenger, “A pressure-based transfer matrix method and measurement technique for studying resonances in flutes and other open-input resonators,” *J. Acoust. Soc. Am.*, vol. 147, no. 4, pp. 2556–2569, Apr. 2020, doi: [10.1121/10.0001102](https://doi.org/10.1121/10.0001102).
- [34] P. Rucz, “Determination of organ pipes’ acoustic parameters by means of numerical techniques,” M.A. thesis, Budapest University of Technology and Economics, Hungary, 2009.
- [35] H. Smith, “On the Physical Action taking place at the Mouth of Organ-pipes,” *Nature*, vol. 10, pp. 161–163, Jul. 1874, doi: [10.1038/010161d0](https://doi.org/10.1038/010161d0).
- [36] P. Oद्या, J. Kotus, M. Szczodrak, and B. Kostek, “Sound intensity distribution around organ pipe,” *Arch. Acoust.*, vol. 42, no. 1, pp. 13–22, Jul. 2017, doi: [10.1515/aoa-2017-0002](https://doi.org/10.1515/aoa-2017-0002).
- [37] J. Liljencrants. “End Correction at a Flue Pipe Mouth.” Johan Liljencrants on organs, pipes, air supply. [Online]. Available: <https://fonema.liljencrantz.se/mouthcorr/mouthcorr.htm>. [Accessed: May 9, 2025].
- [38] S. Pitsch, P. Rucz, J. Angster, A. Miklós, and J. Kirschmann, “Scaling software for labial organ pipes,” in *Proc. AIA-DAGA*, Merano, Mar. 2013.
- [39] S. Adachi, J. Angster, and A. Miklós, “Numerical simulation of the flow in the flue organ pipe,” *Fortschritte Der Akustik*, vol. 33, no. 1, pp. 225–226, 2007. [Online]. Available: https://pub.degaakustik.de/DAGA_1999-2008/data/articles/003154.pdf. [Accessed: May 9, 2025].
- [40] S. Dequand, J.F. Willems, M. Leroux, R. Vullings, M. van Weert, C. Thieulot, and A. Hirschberg, “Simplified models of flue instruments: Influence of mouth geometry on the sound source,” *J. Acoust. Soc. Am.*, vol. 113, no. 3, pp. 1724–1735, Feb. 2003, doi: [10.1121/1.1543929](https://doi.org/10.1121/1.1543929).

Predictive algorithms for determining blowing pressure in a pipe organ

- [41] A. Stafura and S. Nagy, "The upper lip as a voicing element of wooden organ pipes," *Akustika*, vol. 25, pp. 55–61, Mar. 2016.
- [42] B. Fabre, J. Gilbert, and A. Hirschberg, "Modeling of wind instruments," in *Springer handbook of systematic musicology*, R. Bader, Ed., Berlin – Heidelberg, Germany: Springer, 2018, pp. 121–139, doi: [10.1007/978-3-662-55004-5_7](https://doi.org/10.1007/978-3-662-55004-5_7).
- [43] A. Mallock, "Note on the effect of wind pressure on the pitch of organ pipe," *Proc. R. Soc. Lond.*, vol. 95, no. 666, pp. 99–106, Oct. 1918, doi: [10.1098/rspa.1918.0051](https://doi.org/10.1098/rspa.1918.0051).
- [44] N.H. Fletcher, "Sound production by organ flue pipes," *J. Acoust. Soc. Am.*, vol. 60, no. 4, pp. 926–936, Oct. 1976, doi: [10.1121/1.381174](https://doi.org/10.1121/1.381174).
- [45] P. Rucz, J. Angster, and A. Miklós, "Examination of a novel organ pipe construction with blown open tongue," *Fortschritte der Akustik*, vol. 42, pp. 1292–1295, 2016. [Online]. Available: https://pub.dega-akustik.de/DAGA_2016/data/articles/000309.pdf. [Accessed: May 9, 2025].
- [46] D. Steenbrugge, "Fluid mechanical aspects of open-and closed-toe flue organ pipe voicing," *Int. J. Sustain. Construct. Des.*, vol. 2, no. 2, pp. 284–295, 2011, doi: [10.21825/scad.v2i2.20526](https://doi.org/10.21825/scad.v2i2.20526).
- [47] D. Steenbrugge and P. de Baets, "Aerodynamics of flue organ pipe voicing," *Int. J. Sustain. Construct. Des.*, vol. 1, no. 1, pp. 162–173, 2010, doi: [10.21825/scad.v1i1.20421](https://doi.org/10.21825/scad.v1i1.20421).
- [48] H.J. Außerlechner, T. Trommer, J. Angster, and A. Miklós, "Experimental jet velocity and edge tone investigations on a foot model of an organ pipe," *J. Acoust. Soc. Am.*, vol. 126, no. 2, pp. 878–886, Aug. 2009, doi: [10.1121/1.3158935](https://doi.org/10.1121/1.3158935).
- [49] S.A. Elder, "On the mechanism of sound production in organ pipes," *J. Acoust. Soc. Am.*, vol. 54, no. 6, pp. 1554–1564, Dec. 1973, doi: [10.1121/1.1914453](https://doi.org/10.1121/1.1914453).
- [50] D. Węgrzyn, P. Wrzeciono, and A. Wiczorkowska, "Recognition of the Flue Pipe Type Using Deep Learning," in *Intelligent Systems in Industrial Applications. ISMIS 2020*, M. Stettinger, G. Leitner, A. Felfernig and Z.W. Raś, Eds., Cham, Switzerland: Springer, 2021, doi: [10.1007/978-3-030-67148-8_7](https://doi.org/10.1007/978-3-030-67148-8_7).
- [51] J. Angster, S. Pitsch, and A. Miklós, "The influence of different types of windchests on the sound formation of flue organ pipes," *Fortschritte der Akustik*, vol. 30, pp. 1227–1228, 2004. [Online]. Available: https://pub.dega-akustik.de/DAGA_1999-2008/data/articles/001841.pdf. [Accessed: May 9, 2025].
- [52] A.C. Lunn, "The influence of blowing pressure on pitch of organ pipes," *Phys. Rev.*, vol. 15, no. 5, pp. 446–449, May 1920, doi: [10.1103/PhysRev.15.446](https://doi.org/10.1103/PhysRev.15.446).
- [53] B. Baretzky, M. Friesel, and B. Straumal, "Reconstruction of historical alloys for pipe organs brings true baroque music back to life," *MRS Bull.*, vol. 32, no. 3, pp. 249–255, Mar. 2007, doi: [10.1557/mrs2007.30](https://doi.org/10.1557/mrs2007.30).
- [54] D. Steenbrugge, "Flue organ pipe operating regimes and voicing practices," in *Acoustics 2012*, Nantes, France: HAL, Apr. 2012, pp. 2789–2794. [Online]. Available: <https://hal.science/hal-00811336>. [Accessed: May 9, 2025].