



UNIwersYTET
IM. ADAMA MICKIEWICZA
W POZNANIU

Instytut Biologii Środowiska

Wydział Biologii

Skuteczność wykrywania ptaków
w pasywnym monitoringu akustycznym

mgr Dominika Winiarska

Promotor: prof. dr hab. Tomasz Stanisław Osiejuk

Promotor pomocniczy: dr Paweł Szymański

Zakład Ekologii Behawioralnej

Poznań 2024



UNIWERSYTET
IM. ADAMA MICKIEWICZA
W POZNANIU

Institute of Environmental Biology

Faculty of Biology

The effectiveness of bird species detection
in passive acoustic monitoring

mgr Dominika Winiarska

Supervisor: prof. dr hab. Tomasz Stanisław Osiejuk

Auxiliary supervisor: dr Paweł Szymański

Department of Behavioural Ecology

Poznań 2024

Spis treści

	strona
Lista publikacji wchodzących w skład rozprawy doktorskiej	7
Streszczenia	8
Wstęp	12
Rozdział 1: Detection ranges of forest bird vocalizations: guidelines for passive acoustic monitoring	23
Suplement Rozdziału 1: Detection ranges of forest bird vocalizations: guidelines for passive acoustic monitoring	37
Rozdział 2: Methods of acoustic data processing affect species detectability in passive acoustic monitoring	47
Suplement Rozdziału 2: Methods of acoustic data processing affect species detectability in passive acoustic monitoring	79
Rozdział 3: Year-round vocal activity of two African barbet species	89
Suplement Rozdziału 3: Year-round vocal activity of two African barbet species	101
Rozdział 4: Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos	110
Suplement Rozdziału 4: Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos	122
Rozdział 5: Common cuckoo vocalisations as an indicator of the avian diversity – a study with passive acoustic monitoring	128
Suplement Rozdziału 5: Common cuckoo vocalisations as an indicator of the avian diversity – a study with passive acoustic monitoring	153
Podsumowanie	162
Wsparcie finansowe	167
Podziękowania	168
Oświadczenia współautorów	169

Lista publikacji wchodzących w skład rozprawy doktorskiej:

1. Winiarska, D., Szymański, P., Osiejuk, TS. 2024. Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Scientific Reports* 14, 894. <https://doi.org/10.1038/s41598-024-51297-z>
2. Winiarska, D., Szymański, P., Osiejuk, TS. Methods of acoustic data processing affect species detectability in passive acoustic monitoring – po pierwszej recenzji w czasopiśmie *Ibis*.
3. Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>
4. Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos. *African Journal of Ecology* 62, e13280. <https://doi.org/10.1111/aje.13280>
5. Winiarska, D., Jankowiak, Ł., Tryjanowski, P., Osiejuk, TS. Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring.

Pozostałe publikacje powstałe podczas doktoratu:

Winiarska, D., Jankowiak, Ł., Tryjanowski, P., Osiejuk, TS. Day-after impact of simulated rival encounter in the common cuckoo – w recenzji w czasopiśmie *Journal of Ethology*.

Beridze, B., Mahamoud-Issa, M., Żmudzinski, M., Bednarz, P. A., Filutowska, Z. K., Sikora, B., **Winiarska, D.**, Carmona, D., Angeoletto, F. 2023. Welcome to the (urban) jungle: notes on new science, biological evolution in cities. *European Journal of Ecology* 9(2). <https://doi.org/10.17161/eurojcol.v9i2.19518>

Streszczenia

Streszczenie

Pasywny monitoring akustyczny (ang. passive acoustic monitoring, w skrócie PAM) to technika polegająca na nagrywaniu dźwięków otoczenia przy użyciu rozmieszczonych w środowisku automatycznych urządzeń rejestrujących. Jest to coraz powszechniej stosowane narzędzie badawcze umożliwiające bezobsługowe, bezinwazyjne, niezależne od wpływu obserwatora i w pełni programowalne w kontekście schematów czasowych rejestrowanie krajobrazów dźwiękowych (ang. soundscapes), w których często zawarte są wokalizacje zwierząt. PAM, rozwijający się od lat 90-ych XX-wieku, znalazł zastosowanie w badaniach różnych grup zwierząt, w tym ptaków. Pomimo postępu technologicznego i rozpowszechnienia metody wiele aspektów jej zastosowania pozostaje jeszcze niejasnych, m.in. skuteczność wykrywania wokalizacji poszczególnych gatunków ptaków czy rzeczywistych dystansów z jakich można je wykryć. Propagacja dźwięku w środowisku, np. w lesie, zależy od wielu czynników fizycznych (np. temperatury czy wilgotności), które wpływają na stopień jego degradacji, a tym samym utrudniają ustalenie dokładnego dystansu detekcji. W rozdziale 1 niniejszej rozprawy, który stanowi opublikowaną już pracę w czasopiśmie *Scientific Reports*, przeprowadziłam eksperymenty propagacyjne dźwięku w lasach Puszczy Zielonki (Wielkopolska) w celu ustalenia naturalnych dystansów wykrywania ptaków. Wyniki dostarczają danych dotyczących dystansów detekcji dla różnych gatunków ptaków oraz identyfikują czynniki środowiskowe wpływające na rozchodzenie się dźwięku. Rozdział 2 (praca w trakcie procesu recenzji w czasopiśmie *Ibis*) to dalsze opracowanie danych z eksperymentu propagacyjnego, które miało na celu analizę porównawczą skuteczności trzech metod wykrywania wokalizacji ptaków: odsłuchowej, wizualnej analizy spektrogramów (wzrokowej) i automatycznej przy użyciu oprogramowania BirdNET. W pracy tej przeanalizowałam czynniki wpływające na wykrywalność wokalizacji ptaków dla każdej z metod, określiłam dystanse wykrywania gatunków dla wszystkich metod wykrywania oraz oszacowałam skuteczność metody automatycznej w badaniach akustycznych pod kątem czasu pracy i efektywności w porównaniu do manualnej detekcji. W rozdziałach 3 (praca opublikowana w czasopiśmie *Emu – Austral Ornithology*) oraz 4 (praca opublikowana w czasopiśmie *African Journal of Ecology*) wykorzystałam oprogramowanie do automatycznej detekcji Kaleidoscope Pro do porównania skuteczności pasywnego monitoringu i metod

automatycznych w szacowaniu aktywności wokalne czterech afrykańskich gatunków ptaków różniących się liczebnością populacji. Prace te pokazują ich całoroczne wzorce aktywności wokalne w kontekście sezonowych zmian klimatu i pogody oraz określają skuteczność wykorzystanych metod do długoterminowych badań ptaków. W rozdziale 5 (praca recenzowana w czasopiśmie *Ecological Indicators*), z wykorzystaniem oprogramowania BirdNET, przeprowadziłam porównanie skuteczności manualnego wykrywania gatunków w krótkim przedziale czasowym (próbki) do automatycznego wykrywania gatunków na kilkugodzinnych nagraniach. Sprawdziłam także czy indeksy (lub wskaźniki) akustyczne, które są liczbową reprezentacją energii akustycznej na nagraniu potencjalnie korelującą z intensywnością wokalizacji, odzwierciedlają różnorodność gatunkową ptaków. Modelem w tych badaniach była kukułka *Cuculus canorus*, która według niektórych badań jest dobrym wskaźnikiem wyższej różnorodności gatunkowej ptaków. Praca ta zwraca uwagę na niską efektywność wskaźników akustycznych oraz niedoszacowanie liczby gatunków uzyskanej przy pomocy manualnej metody detekcji, a także wskazuje na wiarygodność obecności kukułki jako indikatora obszarów o większej liczbie ptaków.

Słowa kluczowe: pasywny monitoring akustyczny, dystans detekcji, prawdopodobieństwo detekcji, skuteczność wykrywania, automatyczna detekcja

Abstract

Passive acoustic monitoring (hereby PAM) is a technique that involves deploying sound recording devices, such as autonomous recording units, in natural environments to record soundscapes. This scientific tool is increasingly used as it allows for unattended and non-invasive recording of soundscapes incorporating animal vocalisations in fully programmable temporal schemes. PAM has been developing since the 1990s and has been applied in research of various animal groups, including birds. Despite technological advancements, many aspects of this method remain unclear, such as the effectiveness of detecting birds and their detection distances. The sound in natural environments, such as forests, is subject to many physical factors (such as temperature or humidity) that influence its degradation and impede the determination of the exact detection distance. In Chapter 1 of this dissertation, which is a published article in *Scientific Reports* journal, I conducted experiments in the Zielonka forest (Greater Poland region) to determine the natural distances of bird detection. The results provide data on detection distances for various bird species and identify environmental factors that influence sound propagation. Chapter 2 (manuscript under review in *Ibis* journal) is a further development of the experiment results, where I conducted research comparing the effectiveness of three detection methods: auditory, visual based on spectrogram analysis, and automatic using BirdNET software. In this work, I analysed factors influencing bird detectability, determined detection distances of birds for all methods, and assessed the effectiveness of the automatic method in acoustic research in terms of working time and results compared to manual detection. In Chapters 3 and 4 (work published in journals: *Emu – Austral Ornithology* and *African Journal of Ecology*), I used the automatic detection software Kaleidoscope Pro to compare the effectiveness of passive monitoring and automatic methods in estimating the vocal activity of four African bird species of various abundances. These publications show annual activity patterns of chosen species in the context of seasonal changes and weather and determine the effectiveness of the methods used for long-term research in remote places. In Chapter 5 (manuscript currently being reviewed in the *Ecological Indicators* journal), I compared manual surveys conducted within a short period with automatic species detection on several-hour recordings using BirdNET. I also tested whether acoustic indices, which are numeric representations of the acoustic energy present on the recording, reflect bird species richness. This work was done in the context of common cuckoo *Cuculus canorus* vocalisations, which, according to some previous works, is a good predictor of the areas of greater bird species richness. This work points to the imperfection of acoustic indices and the underestimation of

the number of species obtained with manual detection and shows the effectiveness of the common cuckoo as an indicator of the areas of greater bird species numbers.

Keywords: passive acoustic monitoring, detection distance, detection probability, detection effectiveness, automatic detection

Wstęp

Pasywny monitoring akustyczny

Komunikacja dźwiękowa zwierząt od lat fascynuje naukowców, ponieważ jest bardzo zróżnicowana i u wielu gatunków niezwykle złożona. Sygnały akustyczne produkowane przez zwierzęta zawierają liczne informacje na temat m.in. gatunku, płci, wieku czy wielkości danego osobnika, a także mogą dostarczać danych na temat liczebności gatunku (Catchpole & Slater 2008). Te sygnały, w postaci fali dźwiękowej, rozchodzą się sferycznie od źródła i mogą być wykrywane z wielu miejsc jednocześnie, podczas gdy obserwacja wizualna zwierząt zazwyczaj wymaga wysiłku w lokalizacji osobnika (Wiley & Richards 1978), ponieważ z reguły jest możliwa do przeprowadzenia tylko z konkretnych punktów, w których zwierzęcia nie zasłaniają przeszkody fizyczne. Ma to znaczenie zwłaszcza w środowisku zalesionym, co dodatkowo utrudnia fakt, że zwierzęta dość szybko się przemieszczają, uniemożliwiając dokładne zbadanie ich cech fizycznych innych, niż stwierdzenie gatunku czy płci osobnika. Z tego powodu badania dzikich zwierząt coraz częściej wykorzystują nowoczesne techniki, takie jak teledetekcja czy fotopułapki i wideopułapki, które pozwalają na uchwycenie naturalnych zachowań zwierząt ze względu na brak obecności obserwatora, który często stanowi przyczynę ograniczającą lub wręcz uniemożliwiającą naturalne zachowania wielu gatunków.

Jedną z takich technik jest coraz bardziej popularny pasywny monitoring akustyczny (ang. *passive acoustic monitoring*, w skrócie PAM). Jest to metoda polegająca na nagrywaniu dźwięków środowiska (tzw. krajobrazu dźwiękowego, ang. *soundscape*) za pomocą rozmieszczonych w nim automatycznych urządzeń rejestrujących (tzw. rekorderów lub rejestratorów; Sugai et al. 2019). Metoda ta, rozwijająca się intensywnie od lat 90. XX wieku, pozwala na bezinwazyjne badanie środowisk lądowych i wodnych oraz naturalnych zachowań różnych grup organizmów, od owadów po ssaki (Gibb et al. 2019; Sugai et al. 2019). Dzięki PAM możliwe jest, przykładowo, badanie nawet całorocznych wzorców aktywności (Pérez-Granados & Schuchmann 2020), wykorzystania środowiska i rozmieszczenia gatunków (Sugai et al. 2019), czy intensywności wokalizacji zwierząt (Budka et al. 2021). Jednym z najczęściej badanych taksonów są ptaki, ze względu na fakt, że znaczna część z nich w niemal wszystkich aspektach swojego życia wykorzystuje komunikację dźwiękową (Catchpole & Slater 2008).

Aby jak najefektywniej nagrywać krajobraz dźwiękowy i w konsekwencji pożądane gatunki, rejestratory używane w PAM są dziś całkowicie programowalne, tzn. mogą nagrywać

w wybranym schemacie, np. kilkuminutowym, godzinnym czy całodobowym (Gibb et al. 2019). Głównymi ograniczeniami tej metody są pojemność karty pamięci, na której zapisywane są pliki dźwiękowe (najczęściej w formacie .wav), oraz pojemność baterii, od której zależy czas pracy urządzenia; jednak wraz z postępem technologicznym ograniczenia te tracą na znaczeniu stanowiąc przeszkodę jedynie w długoterminowych badaniach (Ross et al. 2023). Rejestratory po umieszczeniu w docelowym miejscu (instalowane np. na pniach drzew) mogą działać nieprzerwanie, a jedyna ingerencja dotyczy wspomnianej wymiany baterii czy karty pamięci, która jest zależna od długości okresu nagrywania. Najnowocześniejsze urządzenia pozwalają nawet na zdalną transmisję dźwięku do serwera i wspomaganie zasilania panelem słonecznym, co w niektórych lokalizacjach i środowiskach może umożliwić bezobsługową pracę przez lata (Sethi et al. 2018). Dane zgromadzone przy użyciu tej techniki mogą być przechowywane i wykorzystywane nawet wiele lat po ich uzyskaniu (Gibb et al. 2019). Cyfrowo zapisany dźwięk nie podlega degradacji, a pliki pozostają bezpieczne, jeśli regularnie wykonywane są kopie zapasowe.

Mimo zaawansowania, wiele aspektów stosowania PAM wciąż pozostaje słabo rozpoznanych. Jednym z takich elementów jest skuteczność wykrywania gatunków ptaków. Przez skuteczność rozumiem tutaj rzeczywistą odległość, z jakiej nagrywane gatunki ptaków rejestrowane są przez rekordery w sposób umożliwiający ich jednoznaczne rozpoznanie. I choć powszechnie wiadomo, że skuteczność ta jest duża, to zróżnicowanie parametrów akustycznych wokalizacji różnych gatunków, oraz wpływ warunków środowiska, zarówno biotycznych (inne zwierzęta, roślinność), abiotycznych (np. hałas spowodowany wiatrem), jak również liczne i skomplikowane interakcje między tymi czynnikami powodują, że określenie rzeczywistej skuteczności (dla konkretnych układów: gatunek – warunki) jest trudne.

Propagacja dźwięku

Propagacja lub innymi słowy, rozprzestrzenianie się dźwięku, zależy od wielu czynników, co jest widoczne zwłaszcza w naturalnym środowisku jakim jest na przykład las. Zgodnie z prawem odwrotnego kwadratu, za każdym razem, gdy dystans od źródła dźwięku zwiększy się dwukrotnie, energia dźwięku (rozumiana jako energia mechaniczna przenoszona przez powietrze, która powstała w wyniku drgań krtani) zmaleje czterokrotnie, a ciśnienie akustyczne (czyli zmiana ciśnienia w powietrzu spowodowana rozchodzeniem się fali dźwiękowej) obniży się dwukrotnie (Marten & Marler 1977). Odpowiada to utracie mocy akustycznej o 6 dB na każde podwojenie dystansu od źródła dźwięku (Wiley & Richards 1978), co przekłada się na prosty wniosek – im dalej od źródła dźwięku, tym słabiej go słychać.

Ponieważ sygnały akustyczne wydawane przez zwierzęta rozchodzą się sferycznie w atmosferze, efekt ten wynika z faktu, że wyprodukowana niemalże punktowo (w krtani ptaka) energia akustyczna, rozkłada się na coraz większą powierzchnię sfery im dalej od jej źródła się znajduje.

Absorpcja energii akustycznej przez cząsteczki gazów powietrza jest dodatkowym źródłem utraty mocy sygnału (Wahlberg & Larsen 2017). Efekt oddziaływania atmosfery zależny jest od temperatury, wilgotności, a także częstotliwości samego dźwięku, ponieważ dźwięki różnej częstotliwości mają odpowiednio odmienną długość fali i są inaczej absorbowane przez cząsteczki powietrza. Na przykład, przy wilgotności względnej 30% i temperaturze 20°C dźwięk o częstotliwości 2 kHz (średnia częstotliwość mowy ludzkiej) traci około 0.25 dB na każde 100 m. Za to śpiew ptaka o wysokiej częstotliwości 8 kHz, przy niskiej wilgotności 10% (i tej samej jak powyżej temperaturze), będzie wytracał aż 5 dB na 100 m (Wahlberg & Larsen 2017). Niezależnie od charakterystyk wokalizacji, wyższa wilgotność i niższa temperatura sprzyjają propagacji na większe odległości (MacLaren et al. 2018; Winiarska et al. 2024). Co ważne, warunki pogodowe zmieniają się w ciągu dnia, zatem fala dźwiękowa będzie rozchodzić się inaczej np. rano i po południu. Poza bezpośrednim wpływem składników pogody na osłabienie siły sygnału i w konsekwencji na dystans propagacji, dźwięki geofoniczne, takie jak szum wiatru lub deszczu, nie tylko pogarszają jakość nagrania, ale także maskują dźwięki otoczenia.

Dodatkowo, do naturalnego osłabienia siły sygnału, włączają się liczne powierzchnie odbijające dźwięk zależne od topografii terenu, które oprócz absorpcji sygnału deformują go poprzez rozproszenie i odbicie. Od rzeźby terenu będzie zależało, czy dźwięk będzie niósł się na większe odległości (np. ze wniesienia), czy będzie degradował szybciej (np. napotykając zbocze wzgórza). W przypadku środowiska leśnego elementami ograniczającymi propagację sygnałów dźwiękowych są pnie drzew, struktura kory, liście, a także podszyt, które dodatkowo generują pogłos i są w dużej mierze zależne od pory roku (Richards 1981; Blumenrath & Dabelsteen 2004). Wymienione elementy i efekty z nimi związane także różnicują się w zależności od zagęszczenia lasu oraz typu roślinności – dźwięk będzie napotykał inne struktury w młodym olsie, a inne w borze wysokogórskim. Pozostałe niuanse dotyczące propagacji dźwięku obejmują powstawanie cienia akustycznego (czyli miejsca, w którym sygnał jest znacznie osłabiony, co jest spowodowane np. zasłonięciem przez drzewo), czy rozchodzenie się fali dźwiękowej związane z wysokością, na jakiej położone jest źródło dźwięku lub jego odbiorca (Wiley & Richards 1978). Wszystkie te elementy sprawiają, że ustalenie dystansu detekcji dla ptaków jest niezmiernie trudne. W każdym środowisku, a nawet w tym samym miejscu, warunki będą inne o różnych porach dnia, co będzie się przekładać na rozchodzenie się dźwięku (Darras et al. 2016).

Prawie wszystkie zmienne związane z otoczeniem mają duży wpływ na to, jak daleko będzie rozchodzić się fala dźwiękowa. Najważniejszym jednak czynnikiem, od którego zależy

dystans propagacji, jest samo źródło dźwięku. W zależności od gatunku ptaka, jego wielkości i parametrów wokalizacji, takich jak częstotliwość czy amplituda (rozumiana jako poziom głośności), a nawet wysokości z jakiej wydaje dźwięki (Blumenrath & Dabelsteen 2004), potencjał jego możliwości wokalnych – w sensie osiąganego aktywnego zasięgu – też będzie inny. Ptaki o większej masie ciała z reguły wydają dźwięki o niższej częstotliwości; te zaś mają tendencję do rozchodzenia się na większe dystanse. Nie bez znaczenia jest również rodzaj produkowanych wokalizacji, np. gwizdy o wysokiej częstotliwości będą służyć do komunikacji raczej krótkodystansowej, zaś dźwięki harmoniczne (czyli zwielokrotnione podstawowe częstotliwości danego sygnału) mogą przenosić się na dalsze odległości. W przypadku badań nad jednym gatunkiem częstym problemem jest maskowanie jego głosu przez inne ptaki zamieszkujące dany obszar, co utrudnia jego wykrywanie (Ross et al. 2023). Wszystko to sprawia, że porównania danych uzyskanych przy użyciu PAM są często utrudnione.

Problemy związane z PAM

Standaryzacja badań z użyciem PAM jest zagadnieniem skomplikowanym ze względu na różnice w parametrach nagrywania (różnice w jakości nagrań) i propagacji dźwięku zależne od typów środowisk. Przykładowo, sóweczka *Glaucidium passerinum* wykryta w lesie gospodarczym w Polsce mogłaby zostać nagrana z odległości 500 metrów (Winiarska et al. 2024), zaś podobnej jakości głos z lasu w Finlandii będzie nagrany z 200 metrów (Baroni et al. 2023). Wynika to ze wspomnianych wcześniej różnic między środowiskami, zarówno w obrębie struktury terenu, jak i mikroklimatu danego obszaru. O ile nie stanowi to dużego problemu przy rozpoznawaniu osobników lub badaniu ich indywidualności wokalnej, to w przypadku prac szacujących liczebność czy zagęszczenie jest wyzwaniem ze względu na zmienny dystans wykrywania oraz powierzchnię areалу osobniczego. Dodatkowo, nagrania uzyskane w różnych lokalizacjach i często przy użyciu różnych urządzeń są nieporównywalne. O ile mniejsze różnice będą wykazywać rejestratory umieszczone w obrębie tego samego środowiska, tak porównanie nagrań np. z różnych długości geograficznych jest niezmiernie trudne. Powstało kilka publikacji, które sugerują kalibrację sprzętu i pomiary akustyczne w wybranym do badań miejscu (Darras et al. 2016, 2018; Yip et al. 2017), jednak metody te są stosunkowo czasochłonne i raczej rzadko stosowane. Przeprowadzenie eksperymentu z propagacją mającego na celu ustalenie akustyki danego obszaru wymaga dodatkowych środków w postaci większej liczby dni badań (co przy badaniach prowadzonych podczas okresu lęgów jest niezmiernie trudne, ponieważ często jest ściśle związane z krótkotrwałym okresem ustalania terytoriów czy wysiadywania), lub środków pieniężnych przeznaczonych na dłuższy pobyt w danym miejscu.

Problemem związanym z wnioskowaniem na podstawie danych akustycznych jest również metoda analizy. Do tej pory głównymi sposobami umożliwiającymi analizę nagrań była metoda odsłuchowa, polegająca na przesłuchiwaniu nagrań oraz notowaniu poszczególnych wokalizacji czy gatunków, oraz metoda wizualna, polegająca na analizie spektrogramów, które są wizualnym zapisem nagrań dźwiękowych na ekranie komputera (Ross et al. 2023). Metody te, podobnie jak rozpoznawanie gatunków przez obserwatora w terenie, są obarczone pewną tendencyjnością związaną z jego umiejętnościami oraz percepcją, tzw. błędem obserwatora (ang. observer bias; Borker et al. 2015). Z tego względu niektóre gatunki na nagraniach mogą zostać pominięte lub błędnie oznaczone, co dodatkowo zwiększa niepewność związaną z porównywaniem nagrań uzyskanych przy użyciu PAM. Zaletą w tym wypadku jest fakt, że nagrania są trwałe i mogą być analizowane wielokrotnie przez różnych obserwatorów, co może zmniejszyć błąd obserwatora, jednak wymaga to dodatkowych nakładów pracy. Jedną rozwijanych i bardzo obiecujących metod jest automatyczna analiza nagrań przy użyciu uczenia maszynowego (Ross et al. 2024). Oprogramowanie do automatycznej detekcji, na podstawie wprowadzonych parametrów lub algorytmów rozpoznawania bazujących na udostępnionych danych treningowych, wyszukuje i generuje listę sygnałów, które zgodnie z jego modelem działania pasują do pożądaných dźwięków (Kahl et al. 2021). Technologia ta jest wciąż udoskonalana, ponieważ algorytmy uczenia maszynowego wciąż generują liczne błędy. Wiele sygnałów kwalifikowanych przez nie jako te pożądane przez użytkownika, to sygnały o podobnych parametrach, jednak często należące do innych gatunków, lub po prostu dźwięki otoczenia, takie jak deszcz czy wiatr. Z tego względu proces automatycznej detekcji obecnie nadal wymaga nadzoru obserwatora/eksperta, choć umożliwia on przeanalizowanie większej ilości danych niż manualne sprawdzanie (Borker et al. 2015; Digby et al. 2013).

Cele pracy

Głównym celem mojej rozprawy była ocena efektywności PAM poprzez uzyskanie informacji na temat rzeczywistych dystansów, na jakich możemy wykrywać ptaki na nagraniach w naturalnym środowisku. W tym celu przeprowadziłam eksperyment propagacji wokalizacji 31 gatunków ptaków, aby ustalić naturalne, specyficzne dla poszczególnych gatunków, dystanse ich wykrywania. Jest to pierwsza praca wskazująca dokładne odległości, na jakich wykrywane są europejskie gatunki ptaków. Eksperyment został wykonany w dwóch środowiskach leśnych (iglastym i liściastym) na terenie kompleksu leśnego Puszczy Zielonki, niedaleko Poznania, gdzie na transekcie o długości 500 m umieściłam 10 rejestratorów w odległości 50 m od siebie, które miały wtórnie nagrywać śpiewy lub głosy ptaków odtwarzane z ich naturalną głośnością. Głośnik na początku transektu został umieszczony na wysokości 3, 6 oraz 9 m, aby symulować naturalne

warunki śpiewu specyficzne dla gatunku. Jest to uzasadnione tym, że niektóre gatunki preferują wokalizowanie z niższych partii drzew, a inne z koron. Do swojej pracy wybrałam gatunki o jak najbardziej różnorodnych cechach wokalizacji, tj. gatunki o wysokiej lub niskiej częstotliwości, oraz wysokiej lub niskiej głośności. Eksperyment został przeprowadzony w okresie od kwietnia do czerwca 2021, aby uchwycić zmiany wegetacyjne i ich wpływ na dystanse wykrywania. Poszczególne odtwarzania miały miejsce na początku każdego miesiąca. Efektem eksperymentu jest praca opublikowana w czasopiśmie *Scientific Reports* (rozdział 1), w której prezentujemy dokładne dystanse detekcji dla wszystkich 31 dziennych gatunków ptaków oraz identyfikujemy czynniki środowiskowe i osobnicze, które mają największy wpływ na rozchodzenie się fali dźwiękowej w lesie.

Kolejnym etapem testowania efektywności PAM było zastosowanie oprogramowania do automatycznego wykrywania wokalizacji gatunków i sprawdzenie, jak skuteczne jest w porównaniu z człowiekiem. Tym razem zebrany materiał dźwiękowy w eksperymencie propagacji z rozdziału 1 został przeanalizowany w kontekście efektywności trzech typów metod powszechnie stosowanych do wykrywania wokalizacji w obrębie nagrań, a więc słuchowej, wizualnej i automatycznej. Jak już wspomniałam, obecnie analiza nagrań dźwiękowych ograniczona jest do detekcji manualnej (metodą odsłuchową i wzrokową poprzez analizę spektrogramów), oraz automatycznej (ze względu na coraz bardziej rozwijającą się technologię i więcej programów do analizy). Ze względu na fakt, że dźwięk musi mieć odpowiednio wysoką amplitudę, aby zostać nagrany, oraz być zwizualizowanym na spektrogramie (Digby et al. 2013), założyłam, że dystanse detekcji będą różnić się między wykorzystanymi metodami. Ponieważ odległe dźwięki o niskiej amplitudzie często są nagrywane, ale siła ich sygnału nie jest wystarczająca, aby zapewnić ich wizualną reprezentację (Digby et al. 2013), nasuwa to prosty wniosek, że słuchowo można wykryć ptaki z dalszej odległości, niż wzrokowo. Jest to o tyle istotne dla metody wykrywania, że obserwator jest w stanie usłyszeć i dostrzec na spektrogramie wokalizacje, które jednocześnie mogą być niewystarczająco „głośne” dla algorytmu do wykrycia. W tym badaniu uwzględnione zostały też ptaki nocne, które nie zostały włączone do pierwszej pracy ze względu na fakt, że sowy najczęściej są słyszalne w odległości większej niż 500 m, a najdalszy rejestrator na transekcje umieszczony był na takim właśnie dystansie. Dla wykrywania metodą automatyczną jednak dystans ten jest wystarczający, ponieważ wokalizacje muszą mieć odpowiednią siłę sygnału, aby zostały wykryte, a na tak dużej odległości dźwięki znacznie tracą na sile, co utrudnia detekcję przy użyciu tej metody (Digby et al. 2013). W pracy porównałam trzy metody wykrywania – odsłuchową, wzrokową oraz automatyczną przy użyciu BirdNET (algorytmu uczenia maszynowego do automatycznej detekcji gatunków; Kahl et al. 2021) – na przykładzie 42 gatunków (31 dziennych i 11 nocnych). Efektem jest publikacja (rozdział 2, obecnie praca jest recenzowana w czasopiśmie

Ibis), w której identyfikujemy czynniki wpływające na wykrywalność daną metodą oraz oceniamy skuteczność metody automatycznej, która najpewniej zdominuje badania akustyczne.

Drugim celem mojej rozprawy było praktyczne sprawdzenie, jak można wykorzystać PAM do badania różnych gatunków ptaków w naturalnym środowisku. Założeniem projektu było zbadanie całorocznej aktywności wokalne wybranych gatunków afrykańskich ptaków – w tym celu przeanalizowałam nagrania pochodzące z 2016 roku z Kamerunu. Przy użyciu oprogramowania umożliwiającego automatyczną detekcję dźwięków na podstawie wprowadzonych parametrów (Kaleidoscope Pro, Wildlife Acoustics, USA), sprawdziłam, czy można uzyskać reprezentatywne wzorce aktywności ptaków nawet dla gatunków o niskiej liczebności. Do pracy wybrałam dwa gatunki wężali (Lybiidae) – wężaczka żółtorzytnego *Pogoniulus bilineatus* oraz wężaczka żółtogrzebietego *P. coryphaea*, oraz dwa gatunki turakowatych (Musophagidae) – turaka kameruńskiego (*Tauraco bannermani*) i szyszaka (*Corythaeola cristata*). Wszystkie te gatunki występują w Kamerunie, jednak podczas okresu badań liczebność wężaczka żółtogrzebietego oraz szyszaka była wyraźnie niższa, niż pozostałych dwóch gatunków, co pozwoliło na sprawdzenie działania oprogramowania do automatycznej detekcji w kontekście liczby wykrytych wokalizacji w stosunku do całkowitej liczby wykrytych sygnałów oraz tego, czy możliwe jest ustalenie prawdopodobnych wzorców aktywności dla mniej licznych gatunków. Mimo podobieństw w obrębie rodzin, wybrane gatunki charakteryzują się odmiennymi parametrami wokalizacji, co pozwoliło na dokładniejsze przetestowanie skuteczności oprogramowania pod kątem pożądaných parametrów sygnału. Rezultatem tych badań są publikacje, które ukazały się w czasopiśmie *Emu – Austral Ornithology* (wężale, rozdział 3) oraz w *African Journal of Ecology* (turakowate, rozdział 4), w których porównujemy wzorce aktywności obu par gatunków oraz oceniamy skuteczność PAM w kontekście uzyskania odpowiednio dużej liczby danych na temat wybranych gatunków, pozwalających wysunąć nowe wnioski na temat ich biologii, oraz użytego oprogramowania do badania ptaków w niedostępnych miejscach przez długi czas.

Kolejnym sposobem na sprawdzenie możliwości wykorzystania PAM było porównanie manualnego wykrywania ptaków prowadzonego na krótkich fragmentach nagrań oraz analizy automatycznej przeprowadzonej na kilkunastogodzinnych nagraniach. W tym celu w 2022 roku nagrywałam krajobraz dźwiękowy obszaru rolniczego (Wielkopolska) przez 8 godzin, a następnie manualnie oznaczałam słyszane i widziane na spektrogramie gatunki podczas analizy komputerowej na 10-minutowych fragmentach wyciętych z tych nagrań. Dla porównania uzyskanego manualnie zestawu gatunków zostały przeanalizowane 8-godzinne nagrania za pomocą oprogramowania do automatycznej detekcji (BirdNET). Aby sprawdzić, czy nagrania z krajobrazu rolniczego pokazują zmienność akustyczną tego obszaru wykorzystałam też wybrane indeksy akustyczne, które są liczbową reprezentacją energii akustycznej na nagraniu; w teorii ich wartości

powinny reprezentować różnorodność dźwiękową danej próbki (Sueur et al. 2014). Porównanie metod zostało przeprowadzone w kontekście bioindykacyjnej roli kukułki zwyczajnej *Cuculus canorus*, której obecność na danym obszarze może wskazywać na bogactwo gatunkowe ptaków (Møller et al. 2016, Morelli et al. 2017). Jest to związane z tym, że kukułka jest pasożytem lęgowym i aby zwiększyć swój sukces rozrodczy, samce w teorii mogą wokalizować więcej na terenach z większą różnorodnością ptaków, by przyciągnąć więcej samic. Aby tego dokonać, głosy kukułek również były wykrywane przy użyciu oprogramowania do automatycznej detekcji (Kaleidoscope Pro). Efektem tych badań jest rozdział 5, praca obecnie recenzowana w czasopiśmie *Ecological Indicators*, w której prezentujemy porównanie obu metod szacowania składu gatunkowego, efektywność indeksów akustycznych oraz rolę kukułki jako gatunku wskaźnikowego.

Bibliografia

- Baroni, D., Hanzelka, J., Raimondi, T., Gamba, M., Brommer J.E., & Laaksonen, T. 2023. Passive acoustic survey reveals the abundance of a low-density predator and its dependency on mature forests. *Landsc. Ecol.* 38, 1939–1954. <https://doi.org/10.1007/s10980-023-01667-1>
- Blumenrath, S.H. & Dabelsteen, T. 2004. Degradation of Great Tit (*Parus Major*) Song Before And After Foliation: Implications for Vocal Communication in a Deciduous Forest. *Behaviour* 141: 935–958. <https://doi.org/10.1163/1568539042360152>
- Borker, A.L., Halbert, P., Mckown, M.W., Tershy, B.R., Croll, D.A., 2015. A comparison of automated and traditional monitoring techniques for marbled murrelets using passive acoustic sensors: Acoustic Monitoring of Murrelets. *Wildl. Soc. Bull.* 39: 813–818. <https://doi.org/10.1002/wsb.608>
- Budka, M., Skierczyńska, A., Antczak, M. & Osiejuk, T.S. 2021. Nocturnal singing by diurnal birds in Afrotropical highlands. *J. Ornithol.* 162: 435–445. <https://doi.org/10.1007/s10336-020-01842-0>
- Catchpole, C.K. & Slater, P.J.B. 2008. Bird Song. Biological Themes and Variations. Cambridge University Press, Cambridge, UK.
- Darras, K., Furnas, B., Fitriawan, I., Mulyani, Y. & Tschardtke, T. 2018. Estimating bird detection distances in sound recordings for standardizing detection ranges and distance sampling. *Methods Ecol. Evol.* 9: 1928–1938. <https://doi.org/10.1111/2041-210X.13031>
- Darras, K., Pütz, P., Fahrurrozi, Rembold, K. & Tschardtke, T. 2016. Measuring sound detection spaces for acoustic animal sampling and monitoring. *Biol. Conserv.* 201: 29–37. <https://doi.org/10.1016/j.biocon.2016.06.021>
- Digby, A., Towsey, M., Bell, B.D., Teal, P.D., 2013. A practical comparison of manual and autonomous methods for acoustic monitoring. *Methods Ecol. Evol.* 4: 675–683. <https://doi.org/10.1111/2041-210X.12060>
- Gibb, R., Browning, E., Glover-Kapfer, P. & Jones, K.E. 2019. Emerging opportunities and challenges for passive acoustics in ecological assessment and monitoring. *Methods Ecol. Evol.* 10: 169–185. <https://doi.org/10.1111/2041-210X.13101>
- Kahl, S., Wood, C.M., Eibl, M. & Klinck, H. 2021. BirdNET: A deep learning solution for avian diversity monitoring. *Ecol. Inform.* 61: 101236. <https://doi.org/10.1016/j.ecoinf.2021.101236>
- MacLaren, A.R., Crump, P.S., Royle, J.A. & Forstner, M.R.J. 2018. Observer-free experimental evaluation of habitat and distance effects on the detection of anuran and bird vocalizations. *Ecol. Evol.* 8: 12991–13003. <https://doi.org/10.1002/ece3.4752>

- Marten, K. & Marler, P. 1977. Sound transmission and its significance for animal vocalization - I. Temperate habitats. *Behav. Ecol. Sociobiol.* 2: 271–290. <https://doi.org/10.1007/BF00299740>
- Møller, A.P., Morelli, F., Mousseau, T.A. & Tryjanowski, P. 2016. The number of syllables in Chernobyl cuckoo calls reliably indicate habitat, soil and radiation levels. *Ecol. Indic.* 66: 592–597. <https://doi.org/10.1016/j.ecolind.2016.02.037>
- Morelli, F., Møller, A.P., Nelson, E., Benedetti, Y., Tichit, M., Šímová, P., Jerzak, L., Moretti, M. & Tryjanowski, P. 2017. Cuckoo as indicator of high functional diversity of bird communities: A new paradigm for biodiversity surrogacy. *Ecol. Indic.* 72: 565–573. <https://doi.org/10.1016/j.ecolind.2016.08.059>
- Pérez-Granados, C. & Schuchmann, K.-L. 2020. Monitoring the annual vocal activity of two enigmatic nocturnal Neotropical birds: the Common Potoo (*Nyctibius griseus*) and the Great Potoo (*Nyctibius grandis*). *J. Ornithol.* 161: 1129–1141. <https://doi.org/10.1007/s10336-020-01795-4>
- Richards, D.G. 1981. Environmental Acoustics and Censuses of Singing Birds. *Stud. Avian Biol.* 6: 297–300.
- Ross, S.R.P.-J., O’Connell, D.P., Deichmann, J.L., Desjonquères, C., Gasc, A., Phillips, J.N., Sethi, S.S., Wood, C.M., & Burivalova, Z. 2023. Passive acoustic monitoring provides a fresh perspective on fundamental ecological questions. *Funct. Ecol.* 37: 959–975. <https://doi.org/10.1111/1365-2435.14275>
- Sethi, S.S., Ewers, R.M., Jones, N.S., Orme, C.D.L., Picinali, L. 2018. Robust, real-time and autonomous monitoring of ecosystems with an open, low-cost, networked device. *Methods Ecol Evol.* 9: 2383–2387. <https://doi.org/10.1111/2041-210X.13089>
- Sugai, L.S.M., Silva, T.S.F., Ribeiro, J.W. & Llusia, D. 2019. Terrestrial Passive Acoustic Monitoring: Review and Perspectives. *BioScience* 69: 15–25. <https://doi.org/10.1093/biosci/biy147>
- Sueur, J., Farina, A., Gasc, A., Pieretti, N., & Pavoine, S. 2014. Acoustic indices for biodiversity assessment and landscape investigation. *Acta Acust.* 100(4): 772–781. <https://doi.org/10.3813/AAA.918757>
- Wahlberg, M., Larsen, O.N. 2017. Propagation of sound. In C. Brown, & T. Riede (Eds.), *Comparative Bioacoustics: An Overview* (pp. 62-119). Bentham Science Publishers, UAE.
- Wiley, R.H. & Richards, D.G. 1978. Physical constraints on acoustic communication in the atmosphere: Implications for the evolution of animal vocalizations. *Behav. Ecol. Sociobiol.* 3: 69–94. <https://doi.org/10.1007/BF00300047>

- Winiarska, D., Szymański, P. & Osiejuk, T.S. 2024. Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Sci. Rep.* 14: 894. <https://doi.org/10.1038/s41598-024-51297-z>
- Yip, D.A., Leston, L., Bayne, E.M., Sólymos, P. & Grover, A. 2017. Experimentally derived detection distances from audio recordings and human observers enable integrated analysis of point count data. *Avian Conserv. Ecol.* 12. <https://doi.org/10.5751/ACE-00997-120111>

Rozdział 1

Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring

Dominika Winiarska, Paweł Szymański, Tomasz S. Osiejuk

Scientific Reports 14, 894. 2024.

<https://doi.org/10.1038/s41598-024-51297-z>

Suplement Rozdziału 1

Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring

Dominika Winiarska, Paweł Szymański, Tomasz S. Osiejuk

Scientific Reports 14, 894. 2024.

<https://doi.org/10.1038/s41598-024-51297-z>

Rozdział 2

Methods of acoustic data processing affect species
detectability in passive acoustic monitoring

Dominika Winiarska, Paweł Szymański, Tomasz S. Osiejuk

Ibis, manuskrypt po pierwszej recenzji

Methods of acoustic data processing affect species detectability in passive acoustic monitoring

Authors Dominika Winiarska^{1*}, Paweł Szymański¹, Tomasz S. Osiejuk¹

¹ Department of Behavioural Ecology, Institute of Environmental Biology, Faculty of Biology, Adam Mickiewicz University, Poznań, Poland

Correspondence author*: Dominika Winiarska, dmwiniarska1@gmail.com

Abstract

Passive acoustic monitoring (PAM) efforts have recently been accelerated by the development of automated detection tools, enabling quick and reliable analysis of recordings. However, automated methods are still susceptible to errors, and human processors achieve more accurate results. Our study evaluates the efficacy of three detection methods (auditory, visual, and automated using BirdNET) for 43 European bird species (31 diurnal and 12 nocturnal), analysing the impact of various factors on detection probability across different distances. We conducted transmission experiments in two forest types from March to June, examining various factors, including call characteristics, weather conditions, and habitat features, to assess their impact on detection probability at different distances. Our findings reveal that species detection distance varies with each detection method, with listening to recordings obtaining the highest detectability, followed by the visual method. Although BirdNET is less accurate, it still proves reliable for detection, especially for loud species. Large diurnal and small nocturnal species were detected the most. Our study emphasises the importance of considering detection methods to maximise species detectability for effective PAM research.

Keywords: bioacoustics, passive acoustic monitoring, detection distance, acoustic analysis, automated analysis

Introduction

Passive acoustic monitoring (PAM) has become increasingly popular for studying animal populations, capturing detailed information about species or individuals through their vocal activity (Shonfield & Bayne, 2021; Sugai et al., 2019). Because many bird species are known to rely on vocal communication in most aspects of their lives, they are among the most common taxa to study using PAM. PAM uses autonomous recording units (ARUs), programmable devices that can be placed in remote areas without human surveillance, to record soundscapes. Hence, PAM can be invaluable for data collection of elusive species (Borker et al., 2015) or during the nighttime (Shonfield & Bayne, 2021). While ARUs allow for long-term recording and generate substantial amounts of data (Gibb et al., 2019), the analysis of such large-volume acoustic data poses a significant challenge for PAM.

Prior to data analysis, it is important to consider the detection probability of species, which is the likelihood of detecting it, as this term is based on two concepts: availability and perceptibility. Vocalising birds are available for detection, but they also need to be noticed by the observer (Nichols et al., 2009; Sólymos et al., 2013). In the context of PAM, the process is simplified as we assume that all available birds are recorded and can be detected, thus making the detection method the most important part of data processing. Nowadays, despite the availability of several tools enabling automated detection of species vocalisations, the extraction of acoustic data from real-field recordings continues to rely upon traditional methods, including listening to the recordings and visual inspection of spectrograms (Priyadarshani et al., 2018b; Sugai et al., 2019; Ware et al., 2023). Manual detection depends on the observer's perception, although less so than in point counts, where the observer is subjected to the effects

of the surroundings, like the direction and distance of the bird (Naguib & Wiley, 2001; Celis-Murillo et al., 2009). According to Bayne et al. (2017), aural examination of the recordings is an effective method to capture the avian assemblage in the survey area, although it depends on the hearing abilities and identification skills of the observer (Farmer et al., 2012; Mortimer & Greene, 2017). PAM allows for the reanalysis of acoustic data, which reduces observer bias (Borker et al. 2015), but still depends on an individual's perceptive abilities.

Despite its usefulness, manual detection is time-consuming and generally not viable for large datasets (Borker et al., 2015; Swiston & Mennill, 2009). For this reason, automated detection methods are continuously improving and there are multiple tools to choose from to analyse acoustic data (Priyadarshani et al., 2018b). One such tool that is receiving a lot of scientific attention nowadays (e.g. Pérez-Granados, 2023a; Ware et al., 2023) is BirdNET (Kahl et al., 2021), a machine-learning algorithm allowing for automated detection and recognition of over 6000 species (Wood & Kahl, 2024). The recognition process involves segmenting recordings into 3-second intervals for analysis and assigning confidence scores to identified species based on their likelihood. The resulting list ranks detected species vocalisations by confidence level, with higher scores indicating greater certainty in identification (Kahl et al., 2021; Wood & Kahl, 2024). However, in automated detection, the observer also supervises the detection process and often manually confirms the candidate species or sounds detected by the software, which also depends on the skills and perception. Although automated analysis may still be prone to errors without human supervision (Sugai et al., 2019), it enables the analysis of incomparably more data than human observers would be able to process (Borker et al., 2015; Swiston & Mennill, 2009; Ware et al., 2023).

Regardless of the method, we can adjust the obtained results to a minimal extent, e.g. by increasing the detection space of a recorder (or radius, which is the area covered by the device, Darras et al., 2016; Llusia et al., 2011) through adjusting its microphone's gain to capture faint

sounds, thereby potentially increasing the number of detections. This can, however, worsen the quality of the recording (Sugai et al., 2020). While many aspects of PAM are extensively discussed (e.g., Darras et al., 2018), the detection method is often overlooked in the discussion on PAM standardisation, although it may significantly impact the outcomes of PAM studies. For instance, some vocalisations may not have significantly higher amplitude than the background noise, making them dimly represented in a spectrogram (Digby et al., 2013). In such cases, automated detection algorithms struggle as they typically require a threshold difference in relative amplitude between the signal of interest and noise (Bardeli et al., 2010; Stowell et al., 2019). However, these vocalisations may still be detectable to the human ear, contributing to the list of detections (Winiarska et al., 2024). Therefore, we can assume that the detection method will also affect detection distance, which is the distance at which the species can be detected, and, in consequence, the number of detections. Nonetheless, the detection still heavily relies on the proximity of individual birds to the device and the loudness of their vocalisations (Yip et al., 2017b). Alas, the detection distance or propagation of a species' vocalisation differs highly according to the song post, environment, vegetation, local conditions, and area topography (e.g., Hauptert et al., 2023; MacLaren et al., 2018; Winiarska et al., 2024; Yip et al., 2017a). These factors combined make detections incomparable across studies, highlighting the significance of considering additional variables.

This study aimed to assess how bird species' detection distance varies across the methods of detecting vocalisations manually (audibly and visually) and automatically (BirdNET). To achieve that, we conducted range-testing transmission experiments to evaluate environmental and species-specific variables that influence the probability of detection of 43 species of temperate birds in the forest regarding each method. We tested whether each of the vocalisations would be possible to detect audibly, visually and/or automatically at the same setup across the changing conditions during the breeding season. Our specific goals were to (i)

test the effectiveness of each detection method, (ii) assess distances at which species may be detected with each method, and (iii) identify factors that influence the detection probability of each method.

Material and methods

Study site

The experiments were conducted within the Zielonka forest, a temperate woodland situated near Poznań in western Poland (52°32'43.8" N 17°09'02.3" E). Two transects were established, with an initial separation of approximately 400 m, gradually increasing to around 900 m towards their ends (Figure S1). The first transect featured a coniferous forest, hereby pine forest, primarily dominated by the Scots Pine *Pinus sylvestris*. The second transect was an adjacent deciduous forest, hereby beech forest, with prevalent species being Common Beech (*Fagus sylvatica*) and Sessile Oak (*Quercus petraea*). The pine forest had an average tree height of around 22 m and a canopy diameter of approximately 4 m, with an average stand age of 48 years (ranging from 44 to 53 years). In contrast, the beech forest had trees reaching roughly 25 m in height, with a mean canopy diameter of 9 m, and a more varied age distribution, averaging 116 years (ranging from 12 to 257 years). While the pine forest appeared slightly denser due to its smaller canopy size, both sites were categorised as moderately dense forests. Notably, the leaves in the beech forest displayed gradual development throughout the study period. In April, small buds formed on the trees, followed by the emergence of small leaves in May, which fully matured by June. The underbrush in the pine forest, comprised of taller grasses and ferns, experienced noticeable growth in June. In contrast, the beech forest retained a layer of leaves from the previous year that underwent minimal changes throughout the season. The topography of both sites was relatively flat to eliminate any influence from terrain structure on sound

propagation. Furthermore, both locations were situated approximately 3 km away from the nearest public road and paved surface, ensuring minimal anthropogenic noise interference.

Design of transmission experiment

Experiments were conducted between March and June 2021 over two consecutive days each month, with one day allocated to each transect (9 days in total due to one separation of diurnal and nocturnal experiments). Playbacks started approximately one hour after sunrise and sunset to maintain consistency during elongating days. For each transect, we deployed 10 Song Meters SM4 (Wildlife Acoustics, Maynard, MA, USA) at 50-meter intervals, ranging from 50 to 500 meters from a loudspeaker (locations determined using a Garmin GPSMAP 65s with an average accuracy of ± 3 meters). Built-in omnidirectional microphones with a sensitivity of -35 ± 4 dB and a signal-to-noise ratio of 80 dB were calibrated using a VOLTCRAFT SLC-100. Positioned at a height of 4 meters on tree trunks, the ARUs recorded uncompressed .wav files at a 48 kHz sampling rate and 16-bit resolution. A JBL XTREME 3 loudspeaker (Harman, CA, USA) with an output power of 25W RMS and a frequency response range of 53.5–20000 Hz was mounted on trees at heights of 3, 6, and 9 meters at the beginning of each transect, with subsequent height choices pseudorandomised to minimise biases. Meteorological conditions, including temperature, wind speed, and humidity, were measured at the experiment's start and end using a Benetech GT8907 weather meter (Shenzhen, China). Throughout all experimental days, conditions remained favourable, characterised by a gentle breeze ($<1\text{m/s}$) and no rainfall. Meteorological data can be seen in the Table S1.

Vocalisations used for playback

To compare the detection methods and determine what factors influence detection probability, we selected 43 species with vocalisations varying in terms of frequency and amplitude (31 diurnal songbirds, 11 owls and European Nightjar *Caprimulgus europaeus*). We chose to study

all owl species living in Poland, including those with diurnal habits and inhabiting open areas (e.g. Barn Owl *Tyto alba* or Little Owl *Athene noctua*), as their vocalisation traits add to a range of vocal characteristics analysed which might offer additional insights into the detection probability of this order. To follow the grouping of the previous study (Winiarska et al., 2024), all owls and European Nightjar are referred to as ‘owls’ or ‘nocturnal species’. A list of all species with their vocalisation parameters can be seen in Table S2. All species were divided into groups based on the mean body mass (for a large male of each species, Billerman et al., 2022) and the peak frequency. To do this, we used the principal component analysis, which revealed that the variation was mainly explained by the peak frequency (Table S3, Figure S2 and Figure S3). Among diurnal birds, the groups included: 1) **small** songbirds, emitting vocalisations ranging from 3055 to 7020 Hz, 2) **medium**-sized species such as woodpeckers and thrushes, vocalising within frequencies of 1890 to 3620 Hz, and 3) **large** birds, including pigeons and the Common Cuckoo *Cuculus canorus*, with vocalisations occurring at relatively low frequencies of 430–690 Hz. For nocturnal species, the grouping included: 1) **small** owls alongside the European Nightjar, vocalising at frequencies of 880–2090 Hz, 2) **medium**-sized species from the genus *Asio* and the Tawny Owl *Strix aluco*, with vocalisation frequencies ranging from 323 to 930 Hz, and 3) **large** owls like the Eagle Owl *Bubo bubo*, emitting low calls within the range of 235–410 Hz.

At the start of each playback, we emitted three 1000 Hz pure tones generated with Avisoft SASLab Pro (version 5.2.14, R. Specht, Berlin, Germany) to ease the temporal synchronisation of the recordings. This was followed by species-specific vocalisations, played sequentially, typically including territorial songs and calls, tailored to fit a 1-minute duration. The number of repetitions varied based on song and call sequence duration, ranging from 2 to 6. Each species segment was indicated by three 1000 Hz pure tones to mark the playback section. Diurnal experiments lasted about 45 minutes, while nocturnal ones lasted about 20 minutes. Most

recordings used as playbacks were obtained from *The Bird Songs of Europe, North Africa and Middle East* (Schultze & Dingler, 2007). They were inspected for quality and filtered 500 Hz outside the band of the focal species to clear the recordings from noise. Amplitudes were modified in Avisoft SAS Lab Pro to match the real amplitude at which the species is calling (based on the literature or similar-size and genus species data). To double-check the amplitude levels, all recordings were played three times with the fixed setup of the loudness of the speaker and recorder and amplitude was measured once again. To do that, we placed the speaker and decibel meter 2 m apart on tripods at 1.6 m above ground. Measurements were taken outdoors in quiet conditions (ambient noise < 42 dB SPL) and based on fast-time A-weighting using a CHY 650 Sound Level Meter (Ningbo, China).

Acoustic data processing

In total, we analysed 7740 sound files (5580 diurnal and 2160 nocturnal), each one being a 1-minute sample of 43 species from re-recorded data at a given distance, transect, height, and month. All samples were examined visually and audibly as at longer distances, some vocalisations could be heard but not seen on spectrograms. If the vocalisation could be seen or heard, the detection was marked. This was done by one person (DW) with prior knowledge of which species' vocalisation to search for in each recording, not to count local birds as there was significant masking along the transect due to many individuals inhabiting the forest vocalising at the time of experiments. To validate the verification, we conducted a blind analysis of separate 1-minute samples done by PS and TO. We encrypted 310 random sound files from the diurnal dataset, and all species seen or heard were noted. This resulted in 95% unanimity (295 samples out of 310). All analyses were conducted with the use of Raven Pro 1.6 (Cornell Lab of Ornithology, Ithaca) at default settings, including Hann window with 512 samples, Jet colour map, and brightness and contrast at 50. For automated detection analysis, we employed a machine learning detector (BirdNET version 2.2) implemented in Raven Pro 1.6. We applied

the minimum confidence threshold of 0.1 (on a scale from 0 to 1), as lower values resulted in excessive detection numbers with many false positives. Additionally, we employed a 1-second overlap to better fit shorter vocalisations, and a global list of species because it resulted in more detections. All detections were verified manually. Similarly to manual methods to investigate detection distances, we focused only on true positive detections and maximum scores for each 1-minute sample.

Statistical analysis

Statistical analyses were conducted in R (R Core Team 2022). We decided to join the diurnal and nocturnal databases together to better show the overall factors that influence the detection probability of species. To investigate whether species' detection probability is affected by the distance from a loudspeaker, environmental factors and method of detection, we built a generalised linear mixed-effects model (GLMMs) with binomial error distribution and logit link function with the help of the 'glmmTMB' package (Brooks et al., 2022). The response variable was a value indicating whether a given species' vocalisation was detected in a recording (1) or not (0). The detection method (three levels: audible, visual, automated), transect type (two levels: pine vs. beech) and time of day (day vs. night) were introduced as fixed factors. Predictor variables that included distance from a loudspeaker, month and height of loudspeaker placement were on an ordinal scale. We also incorporated the covariates scaled between 0 and 1, including time, temperature, humidity, body mass of the species, vocalisation duration, sound pressure level of species vocalisations (SPL), and peak frequency. To investigate the combined influence of the variables we included interaction terms between those that were connected, such as method and distance, month and transect, experiment timing and time, weather variables or species characteristics. We included a random intercept for each species and a random slope for the distance within each species. Initially, we tested the data for

the multicollinearity of the vocal characteristic as well as weather measurements, but this was not an issue.

In addition, we developed GLMM with a beta distribution and logit link to assess BirdNET's accuracy in detecting species vocalisations depending on a known distance. The response variable was BirdNET's maximum score for each correct detection, with predictor variables including distance, month, transect, height, time, humidity, temperature, peak frequency, SPL, species body mass, and call duration. Distance was treated as a random slope, while species was a random factor. Similarly to the first model, we included interaction terms between linked variables to test their combined impact.

Model diagnostics were performed with the use of the 'DHARMA' package (Hartig, 2022). Within the text, means are given with standard deviations (\pm sd).

Results

Overall, we detected re-recorded diurnal species vocalisations audibly in 1697 (30.4%), visually in 1338 (24%), and automatically in 626 (11.2%) out of 5580 audio samples. Out of 2161 of the nocturnal species' samples, we detected re-recorded species audibly in 2016 (96.3%), visually in 1814 (83.9%), and automatically in 1022 (47.3%) samples.

Listening to the recordings was the most efficient method, while automated detection was the least efficient (Table 1). As expected, the detection probability was negatively correlated with the distance at which the vocalisation was re-recorded. The species were more likely to be detected in the beech forest and when they were broadcasted from lower heights. More detections were stated at night and at earlier hours in both setups, with higher detection probability later in the season. Among species characteristics, only body mass alone had a strong positive effect on detection probability, whereas increasing peak frequency in relation to body mass also positively affected obtained distances. Higher SPL and peak frequency posed a

major effect on detection probability, but their overall outcome was insignificantly important. Also, none of the weather variables significantly affected detection probability as their estimate values were minor.

Confidence scores for BirdNET detections were only slightly lower at further distances from the loudspeaker than at closer distances (Table 2). Significantly higher scores were obtained at night and when the vocalisations were played from lower heights. Weather conditions and vocal characteristics did not strongly affect the obtained scores, except for the higher SPL having a positive effect on them and longer call duration a negative one. Scores were also higher in larger birds with higher SPL but lowered when they emitted longer calls.

Of the three methods assessed, listening to the recordings yielded the highest number of detections in both diurnal and nocturnal species analyses (Figure 1), identifying up to 96.3% of sound files in a group of large owls and at least 49.6% of samples of a group of the medium diurnal species. We also noted 100% detectability for the Scops Owl *Otus scops* with the audible method. The visual method resulted in fewer detections than listening, yet the difference between audible and visual approaches was rather small (7% in small owls to 14% in small diurnal group). BirdNET correctly detected at least 17.3% of re-recorded vocalisations of the diurnal medium species and achieved a maximum of 58.8% detection accuracy in a group of small owls (Figure 2). All of the methods detected species at a 500 m distance, with 156 audible detections, 99 visual detections, and 19 detections made with the automated method.

In particular, BirdNET was successful in detecting calls of the Little Owl (86% correct detections, mean score of 0.58 ± 0.25), and Boreal Owl *Aegolius funereus* (73%, mean score of 0.73 ± 0.29 , and the highest general score of 0.9999 among all species at 50 m distance). In diurnal species, the most detections were stated for the Stock Dove *Columba oenas* (54.7% and a mean score of 0.66 ± 0.3), followed by the Common Cuckoo (35.9%, 0.39 ± 0.25). In the case of diurnal medium-sized birds, the Black Woodpecker *Dryocopus martius* achieved fairly low

scores at 200 m and higher at 250 m, where it was still readily visible on the spectrogram (Figure 2). In Table S4, we present the effective detection radius (EDR; Yip et al. 2017b) counted for each species and method. For species relatively well detected by all methods, the difference between EDR for each method is small (e.g., 0 m difference between auditory and visual method and 6 m between auditory and automated method in the case of Eurasian Treecreeper *Certhia familiaris*). The largest differences were noted in the species that were easily detectable with manual methods but were difficult for the algorithm to detect (e.g., Short-eared Owl *Asio flammeus*, with a difference of 1115,08 m between audible and BirdNET EDR).

Table 1. The results of the model investigating factors that influence the general detection probability. Significant effects ($p < 0.05$) are in bold.

	Estimate	Std. Error	z value	p-value
Intercept	7.987	1.201	6.651	<0.001
Method: automated	-4.894	0.194	-25.252	<0.001
Method: visual	-1.312	0.162	-8.079	<0.001
Distance	-2.102	0.187	-11.211	<0.001
Month	0.319	0.063	5.038	<0.001
Transect: Beech	1.282	0.372	3.443	0.001
Height	-0.060	0.039	-1.552	0.121
Time of day: Night	3.316	0.939	3.530	<0.001
Time	-0.112	0.045	-2.485	0.013
Humidity	-0.063	0.037	-1.687	0.092
Temperature	0.024	0.076	0.321	0.748
Peak frequency	1.056	1.030	1.025	0.305
SPL	1.174	0.943	1.245	0.213
Body mass	6.096	2.496	2.442	0.015
Call duration	0.375	1.439	0.260	0.795
Method: automated x Distance	-0.022	0.033	-0.676	0.499
Method: visual x Distance	-0.054	0.027	-1.978	0.048
Month x Transect: Beech	-0.256	0.074	-3.443	0.001
Time of day: Night x Time	-0.346	0.133	-2.594	0.009
Humidity x Temperature	0.029	0.043	0.682	0.495
Peak frequency x SPL	-1.213	0.891	-1.361	0.173

Peak frequency x Body mass	4.038	1.660	2.433	0.015
SPL x Body mass	-0.397	2.214	-0.179	0.858
Peak frequency x Call duration	-0.313	1.480	-0.212	0.832
SPL x Call duration	-2.714	1.396	-1.944	0.052
Body mass x Call duration	-0.040	3.988	-0.010	0.992
Peak frequency x SPL x Body mass	-0.232	1.657	-0.140	0.889
Peak frequency x SPL x Call duration	-2.183	1.355	-1.611	0.107
Peak frequency x Body mass x Call duration	0.163	2.505	0.065	0.948
SPL x Body mass x Call duration	-5.063	3.561	-1.422	0.155
Peak frequency x SPL x Body mass x Call duration	-3.797	2.309	-1.644	0.100

Table 2. The results of the model assessing factors influencing the scores produced by BirdNET.

Significant effects ($p < 0.05$) are in bold.

	Estimate	Std. Error	z value	p-value
Intercept	-0.197	0.660	-0.299	0.765
Distance	-0.009	0.001	-9.943	<0.001
Month	0.048	0.056	0.868	0.385
Transect: Beech	0.338	0.267	1.267	0.205
Height	-0.160	0.031	-5.250	<0.001
Time of day: Night	1.570	0.477	3.289	0.001
Time	-0.075	0.041	-1.807	0.071
Humidity	0.039	0.033	1.174	0.240
Temperature	0.095	0.067	1.427	0.154
Peak frequency	-0.227	0.640	-0.355	0.723
SPL	1.108	0.568	1.951	0.051
Body mass	-0.893	1.558	-0.573	0.566
Call duration	-1.064	0.868	-1.227	0.220
Month x Transect: Beech	0.027	0.052	0.509	0.611
Time of day: Night x Time	0.141	0.097	1.452	0.147
Humidity x Temperature	0.040	0.037	1.078	0.281
Peak frequency x SPL	0.608	0.508	1.197	0.232
Peak frequency x Body mass	-0.252	1.001	-0.252	0.801
SPL x Body mass	2.588	1.348	1.919	0.055
Peak frequency x Call duration	-1.079	0.924	-1.169	0.243
SPL x Call duration	-0.510	0.754	-0.676	0.499
Body mass x Call duration	-2.618	2.473	-1.059	0.290

Peak frequency x SPL x Body mass	1.593	0.944	1.686	0.092
Peak frequency x SPL x Call duration	-0.465	0.773	-0.601	0.548
Peak frequency x Body mass x Call duration	-1.688	1.519	-1.112	0.266
SPL x Body mass x Call duration	-0.419	1.992	-0.210	0.834
Peak frequency x SPL x Body mass x Call duration	-0.374	1.261	-0.297	0.767

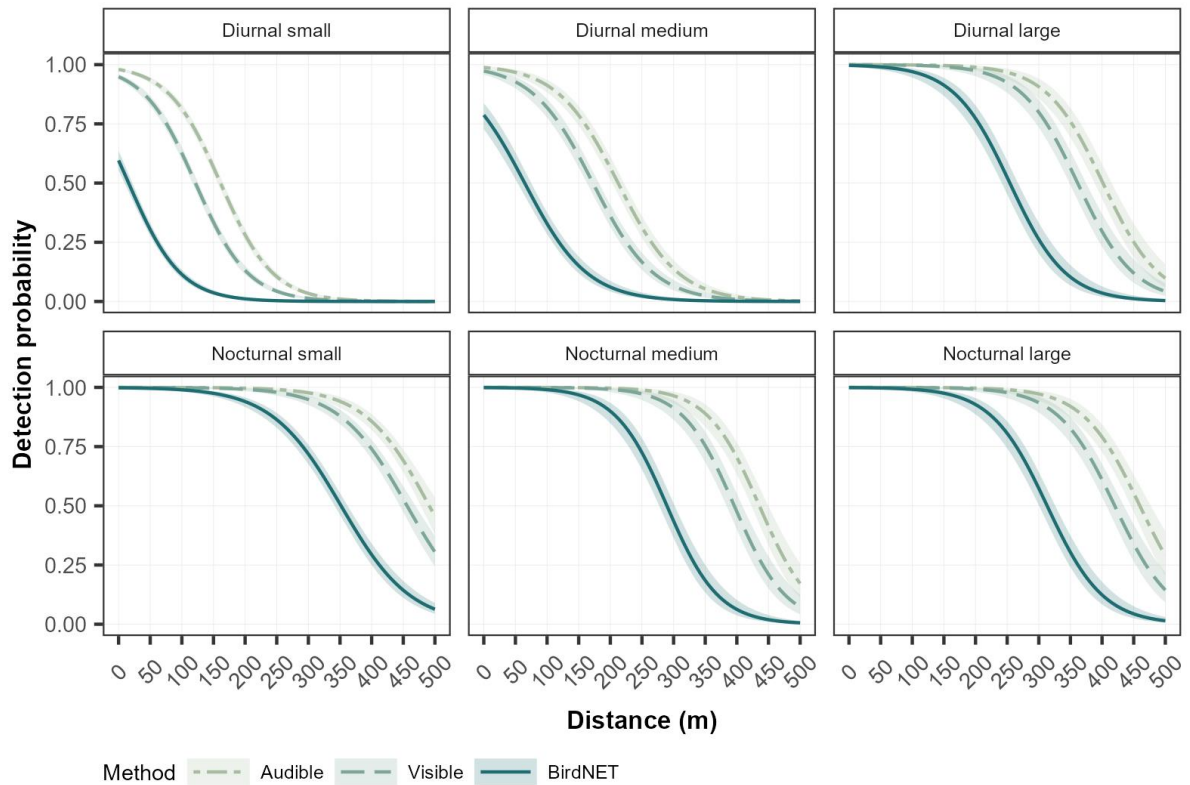


Figure 1. Fitted detection probability curves according to each method and species group showing how detection probability varies with distance across different species groups when different detection method is used. Curves were modelled using the generalised linear model method, with a shaded area representing a 95% confidence interval. The distance of 0 is counted for the playback recording.

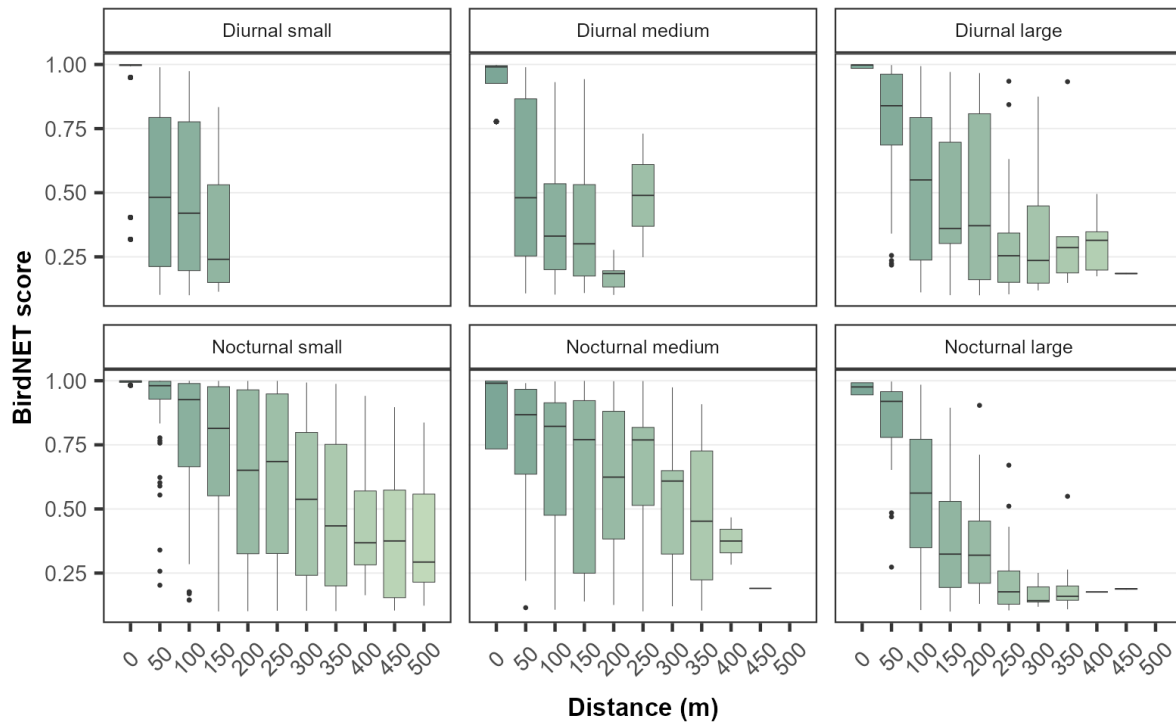


Figure 2. Boxplots of maximum BirdNET detection scores according to each distance for each group. Each boxplot illustrates the distribution of maximum detection scores for a specific distance within each species group. Boxplots show median, first and third quartile and extreme values. The distance of 0 is counted for the playback recording.

Discussion

In this study, we used transmission experiments of territorial songs and calls of 31 diurnal and 12 nocturnal European bird species to determine whether a method of detecting sounds of interest from real-field recordings affects the detection probability of species vocalisations. While controlling for environmental conditions and a distance from the sound source, we showed that listening to the recordings may detect given vocalisations at the furthest distances, followed by visual and, lastly, automated detection methods. Our study contributes to the effort of establishing standardised procedures for acoustic surveys, which is vital for the effective planning of research or monitoring using PAM.

Detection method

In general, listening to the recordings provided the highest detection probabilities of re-recorded vocalisations while visual recognition failed to detect the signals of low strength at farthest distances (Digby et al., 2013). Real-field recordings collected by ARUs often feature background noise, either anthropogenic or biological such as the presence of other bird species vocalising. This can limit the effectiveness of visual detection methods due to spectro-temporal masking of sounds of interest by non-focal signals, which is also a strong limiting factor for the obtained distance (Hauptert et al., 2023). In our study, some species exhibited more pronounced differences between visibility and audibility in the recordings reflected in their EDR values (Table S4). These differences arise from the recorder's effective range, which captures sounds from a distance that do not have significantly higher energy than background noise to be visually represented in the spectrogram and thus cannot be detected with visual and automated methods. However, this also depends on the perceptive abilities, as careful listening might provide more information on the detection at distant locations. In our study, larger diurnal species were detected at greater distances than smaller species as their vocalisations are characterised by higher amplitudes and lower frequencies, which tend to propagate further. In contrast, small owls were detected further among nocturnal birds, probably because of their more distinctive and predominantly tonal calls at non-masked frequencies. Even though detection probability depended on various environmental factors, and while generally weather conditions are considered a strong predictor of detections (e.g., MacLaren et al., 2018; Winiarska et al., 2024), their overall effect was not that important in our study. Habitat type and time of the season seem to be more prominent in this case, but environmental variables in our study are merely an approximation of their real effect in the field. Because our work focuses on maximum distances with a limited number of repeated experiments and in PAM we do not tend to control for these variables as ARUs typically record for prolonged time series, detectability

in real-field recordings will differ and most likely be higher according to species availability and local conditions.

Although we did not comprehensively measure the algorithm's performance (but see Pérez-Granados, 2023b; Ware et al., 2023), BirdNET proved to be a reliable tool for species detection (Bota et al., 2023), especially for owls, with higher scores noted in the nocturnal dataset. Higher BirdNET performance in detecting nocturnal groups can presumably be attributed not only to the specific call characteristics of these species but mainly to favourable nighttime conditions, such as low ambient noise and lack of masking, which was only present during the Tawny Owl playbacks. Distance was an important factor influencing obtained scores, with their values decreasing at further distances, yet it had very little effect on them, which is interesting given that it was the main predictor in similar studies (Knight & Bayne, 2018). BirdNET algorithm encountered difficulty detecting even those species that were readily visible on the spectrogram. The software did not recognise at all the Long-tailed Tit *Aegithalos caudatus* and the Red Crossbill *Loxia curvirostra* at any of the rerecorded points except from the original recording used as playback, where they only scored 0.32 and 0.4, respectively. This could result from the faint and unstructured songs that these species produce. BirdNET also faced challenges recognising songs of several common European species, such as the Common Chiffchaff *Phylloscopus trochilus* or the Common Nightingale *Luscinia megarhynchos* (Figure S4). This may seem confusing as originally, it achieved high detection scores with the Common Nightingale (Kahl et al., 2021). We argue that the complexity of a song's structure likely contributes to faster degradation during propagation through the environment due to the presence of diverse, often higher frequencies, making it more challenging for the algorithm to accurately recognise the species. There was also masking from local birds that could impede detection. Additionally, BirdNET occasionally failed to detect species at closer distances but did so at farther (Figure 2, Figure S4 and S5). This is because automated recognition

performance is affected by the signal-to-noise ratio (Kahl et al., 2021), which is usually lower in PAM recordings, especially at more distant locations from the source. Our experiments were conducted in natural surroundings, and thus, the vocalisations may have been masked by local species or breeze which diminished the outcome of automated analysis. These factors combined seem to contribute to the algorithm's lowered performance. Nevertheless, automated detection required the least amount of time, as listening to the recordings took approximately 130 hours, visual detection required around 60 hours, and automated detection took about 40 hours. This shows that the proportion of time dedicated to the analysis and the amount of analysed material shifts towards automated methods. Automated tools are also continuously being developed and even BirdNET can be trained to improve the classifier to the researchers' needs (Kahl et al., 2021). Still, obtained detection distances will differ according to observer skills and perception, required even in automated methods to confirm true positive detections, the presence of local birds vocalising, and environmental factors.

PAM planning

Understanding detectability is fundamental for PAM studies, as it is the main reason for the incomparability of the recordings. Choosing the appropriate detection method will affect the results and thus influence the conclusions drawn from the data. For example, distance sampling done with the visual detection method may yield more accurate results than BirdNET, as in our study, the automated method provided underestimated detection values due to the weakened signal strength at further distances. This is linked to the observer's perception as species available for detection will not be detected in certain situations depending on the signal strength or chosen detection method. In the case of automated methods, detectability also depends on the score set to automated software as it will affect the effective sampling radius of ARU, and higher scores will reduce the area sampled (Knight & Bayne, 2018; Leseberg et al., 2022). However, according to Leseberg et al. (2022), setting the score threshold will not affect

detection probability but will rather change the amount of work needed to process the detections. Increasing knowledge about detection probability and detection distances could possibly facilitate the integration of different datasets, enabling detailed analyses with larger sample sizes.

Previous studies have shown that brief acoustic sampling periods can provide different species compositions from the same sampling location (Kułaga & Budka, 2019), while for many species, the highest detection probability can be achieved even after a few days of continuous recording (Borker et al., 2015; Hagens et al., 2018). This underscores the advantage of automated detection methods compared to manual ones as multiple recording sessions generate more data for processing, a task that is time-consuming with manual techniques over large datasets. In this context, the species-specific detection probabilities we obtained in our study may be considered minimal since we only used 1-minute-long samples played from a fixed position. However, BirdNET's scores can highly differ between the recordings (Wood & Kahl, 2024) and thus are incomparable between studies. Therefore, recording at the greatest extent while birds move within their territories, combined with a wider temporal window for species to vocalise facilitated with prolonged recording, should enhance the detection probability. After all, it is a dynamic measure, as it increases with more visits to the site or longer surveys (Sólymos et al., 2013; Hostetter et al., 2019), which in PAM translates to an extended survey duration (Wood et al., 2021), and it changes with population density (Borchers & Cox, 2016). Also, incorporating multiple detection methods, whether manual and automated (Ware et al., 2023) or two automated (Pérez-Granados et al., 2023), can maximise detection probability in large datasets. A similar study demonstrated nearly 60% accuracy in detecting three species along a 150 m transect in Spain, highlighting the algorithm's higher accuracy within a 50 m detection radius (Pérez-Granados, 2023b). Similarly to our study, vocalisations of small songbirds were rather poorly detected at a 150 m distance (Figure 2). This shows that recorders

deployed according to the species of interest (Winiarska et al., 2024) coupled with automated detection may indeed provide reliable results while minimising analysis time. Also, a study in Finland showed that the detection probability of the Eurasian Pygmy Owl *Glaucidium passerinum* decreased after 150 m and dropped to 0 at 300 m (Baroni et al., 2023), whereas in our study the species was still well visible in a spectrogram at 500 m in most cases and was detected by BirdNET at 450 m. This highlights the importance of considering species, habitat, and environmental conditions when planning PAM research, as they significantly impact species detectability.

Conclusion

Our study shows that in the era of rapid growth of automated detection tools, PAM planning should consider the desired detection method, as it will greatly influence the number of detected species. The differences in environmental conditions affect detection and may impact BirdNET's effectiveness, especially in more diverse habitats like the tropics. The development of automated detection tools has the potential to revolutionise the analysis of acoustic data leading to standardisation in detecting species. Our findings aid in standardising acoustic survey procedures, which is crucial for effective PAM research and monitoring planning.

Ethics statement

This study was carried out according to Polish law. We obtained all the necessary permissions to carry out the study: permission from the Regional Directorate of Environment Protection (no. WPN-II.6205.8.2021.JM) and permission from the Marshal of the Wielkopolska Region (no. DR-I.7131.1.2.2021).

Data availability statement

The datasets analysed during the current study are available from the corresponding author upon reasonable request.

References

- Bardeli, R., Wolff, D., Kurth, F., Koch, M., Tauchert, K.H., Frommolt, K.H. (2010). Detecting bird sounds in a complex acoustic environment and application to bioacoustics monitoring. *Pattern Recognition Letters*, 31(12), 1524-1534. <https://doi.org/10.1016/j.patrec.2009.09.014>
- Baroni, D., Hanzelka, J., Raimondi, T., Gamba, M., Brommer, J.E., & Laaksonen, T. (2023). Passive acoustic survey reveals the abundance of a low-density predator and its dependency on mature forests. *Landscape Ecology*, 38, 1939–1954. <https://doi.org/10.1007/s10980-023-01667-1>
- Bayne, E., Knaggs, M., & Sóllymos, P. (2017). How to Most Effectively Use Autonomous Recording Units When Data are Processed by Human Listeners. Alberta Biodiversity Monitoring Institute. Available from http://bioacoustic.abmi.ca/wp-content/uploads/2017/08/ARUs_and_Human_Listeners.pdf [Accessed 20 February 2024]
- Billerman, S. M., Keeney, B. K., Rodewald, P. G., & Schulenberg, T. S. (Editors). (2022). *Birds of the World*. Cornell Laboratory of Ornithology, Ithaca, NY, USA. <https://birdsoftheworld.org/bow/home>
- Borchers, D.L., & Cox, M.J. 2017. Distance sampling detection functions: 2D or not 2D? *Biometrics*, 73(2), 593–602. <https://doi.org/10.1111/biom.12581>

- Borker, A.L., Halbert, P., Mckown, M.W., Tershy, B.R., & Croll, D.A. (2015). A comparison of automated and traditional monitoring techniques for marbled murrelets using passive acoustic sensors: Acoustic Monitoring of Murrelets. *Wildlife Society Bulletin*, 39, 813–818. <https://doi.org/10.1002/wsb.608>
- Bota, G., Manzano-Rubio, R., Catalán, L., Gómez-Catasús, J., & Pérez-Granados, C. (2023). Hearing to the unseen: AudioMoth and BirdNET as a cheap and easy method for monitoring cryptic bird species. *Sensors* 23, 7176. <https://doi.org/10.3390/s23167176>
- Brooks, M.E., Kristensen, K., van Benthem, K.J., Magnusson, A., Berg, C.W., Nielsen, A., Skaug, H.J., Maechler, M., & Bolker, B.M. (2017). glmmTMB Balances Speed and Flexibility Among Packages for Zero-inflated Generalized Linear Mixed Modeling. *The R Journal*, 9(2), 378–400. <https://doi.org/10.32614/RJ-2017-066>
- Celis-Murillo, A., Deppe, J.L. and Allen, M.F. (2009). Using soundscape recordings to estimate bird species abundance, richness, and composition. *Journal of Field Ornithology*, 80, 64-78. <https://doi.org/10.1111/j.1557-9263.2009.00206.x>
- Darras, K., Furnas, B., Fitriawan, I., Mulyani, Y., & Tschardtke, T. (2018). Estimating bird detection distances in sound recordings for standardizing detection ranges and distance sampling. *Methods in Ecology and Evolution*, 9, 1928–1938. <https://doi.org/10.1111/2041-210X.13031>
- Darras, K., Pütz, P., Fahrurrozi, Rembold, K., & Tschardtke, T. (2016). Measuring sound detection spaces for acoustic animal sampling and monitoring. *Biological Conservation*, 201, 29–37. <https://doi.org/10.1016/j.biocon.2016.06.021>
- Digby, A., Towsey, M., Bell, B.D., & Teal, P.D. (2013). A practical comparison of manual and autonomous methods for acoustic monitoring. *Methods in Ecology and Evolution*, 4, 675–683. <https://doi.org/10.1111/2041-210X.12060>

- Farmer, R.G., Leonard, M.L., & Horn, A.G. (2012). Observer effects and avian-call-count survey quality: Rare-species biases and overconfidence. *The Auk*, 129, 76–86. <https://doi.org/10.1525/auk.2012.11129>
- Gibb, R., Browning, E., Glover-Kapfer, P., & Jones, K.E. (2019). Emerging opportunities and challenges for passive acoustics in ecological assessment and monitoring. *Methods in Ecology and Evolution*, 10, 169–185. <https://doi.org/10.1111/2041-210X.13101>
- Hagens, S.V., Rendall, A.R., & Whisson, D.A. (2018). Passive acoustic surveys for predicting species' distributions: Optimising detection probability. *PLoS ONE*, 13, e0199396. <https://doi.org/10.1371/journal.pone.0199396>
- Hartig, F. (2022). DHARMA: Residual Diagnostics for Hierarchical (Multi-Level / Mixed) Regression Models. R package version 0.4.6. <http://florianhartig.github.io/DHARMA/>
- Hauptert, S., Sèbe, F., & Sueur, J. (2023). Physics-based model to predict the acoustic detection distance of terrestrial autonomous recording units over the diel cycle and across seasons: Insights from an Alpine and a Neotropical forest. *Methods in Ecology and Evolution*, 14, 614–630. <https://doi.org/10.1111/2041-210X.14020>
- Hostetter, N.J, Gardner, B., Sillett, T.S., Pollock, K.H., & Simons, T.R. 2019. An integrated model decomposing the components of detection probability and abundance in unmarked populations. *Ecosphere*, 10(3), e02586. <https://doi.org/10.1002/ecs2.2586>
- Kahl, S., Wood, C.M., Eibl, M., & Klinck, H. (2021). BirdNET: A deep learning solution for avian diversity monitoring. *Ecological Informatics*, 61, 101236. <https://doi.org/10.1016/j.ecoinf.2021.101236>
- Knight, E. C., & Bayne, E. M. (2018). Classification threshold and training data affect the quality and utility of focal species data processed with automated audio-recognition software. *Bioacoustics*, 28(6), 539–554. <https://doi.org/10.1080/09524622.2018.1503971>

- Kułaga, K. & Budka, M. (2019). Bird species detection by an observer and an autonomous sound recorder in two different environments: Forest and farmland. *PLoS ONE*, 14, e0211970. <https://doi.org/10.1371/journal.pone.0211970>
- Leseberg, N.P., Venables, W.N., Murphy, S.A., Jackett, N.A. and Watson, J.E.M. (2022), Accounting for both automated recording unit detection space and signal recognition performance in acoustic surveys: A protocol applied to the cryptic and critically endangered Night Parrot (*Pezoporus occidentalis*). *Austral Ecology*, 47, 440-455. <https://doi.org/10.1111/aec.13128>
- Llusia, D., Márquez, R., & Bowker, R. (2011). Terrestrial sound monitoring systems, a methodology for quantitative calibration. *Bioacoustics*, 20, 277–286. <https://doi.org/10.1080/09524622.2011.9753651>
- MacLaren, A.R., Crump, P.S., Royle, J.A., & Forstner, M.R.J. (2018). Observer-free experimental evaluation of habitat and distance effects on the detection of anuran and bird vocalizations. *Ecology and Evolution*, 8, 12991–13003. <https://doi.org/10.1002/ece3.4752>
- Mortimer, J. & Greene, T. (2017). Investigating bird call identification uncertainty using data from processed audio recordings. *New Zealand Journal of Ecology*, 41, 126–133. <https://doi.org/10.20417/nzjecol.41.10>
- Naguib, M. & Wiley, R. H. (2001). Estimating the distance to a source of sound: Mechanisms and adaptations for long-range communication. *Animal Behaviour*, 62(5), 825e837. <https://doi.org/10.1006/anbe.2001.1860>
- Nichols, J.D., Thomas, L., Conn, P.B. (2009). Inferences About Landbird Abundance from Count Data: Recent Advances and Future Directions. In: Thomson, D.L., Cooch, E.G., Conroy, M.J. (eds) *Modeling Demographic Processes In Marked Populations*.

- Environmental and Ecological Statistics, vol 3. Springer, Boston, MA.
https://doi.org/10.1007/978-0-387-78151-8_9
- Pérez-Granados, C. (2023a). BirdNET: applications, performance, pitfalls and future opportunities. *Ibis*, 165, 1068–1075. <https://doi.org/10.1111/ibi.13193>
- Pérez-Granados, C. (2023b). A first assessment of Birdnet performance at varying distances: a playback experiment. *Ardeola*, 70(2), 257-269.
<https://doi.org/10.13157/arla.70.2.2023.sc1>
- Pérez-Granados, C., Feldman, M.J., & Mazerolle, M.J. (2023). Combining two user-friendly machine learning tools increases species detection from acoustic recordings. *Canadian Journal of Zoology*, 00, 1–7. <https://doi.org/10.1139/cjz-2023-0154>
- Priyadarshani, N., Marsland, S., & Castro, I. (2018). Automated birdsong recognition in complex acoustic environments: a review. *Journal of Avian Biology*, 49, jav-01447.
<https://doi.org/10.1111/jav.01447>
- Schultze, A. & Dingler, K.-H. (2007). *The Bird Songs of Europe, North Africa and the Middle East*. Ample.
- Shonfield, J. & Bayne, E.M. (2021). Using bioacoustics to study vocal behaviour and habitat use of Barred Owls, Boreal Owls and Great Horned Owls. *AIRO*, 29, 416–431.
Available at: https://www.airo-spea.com/_files/ugd/8fea7e_d3304d6ea34547eeba812d8250f01816.pdf [Accessed 20 February 2024]
- Stowell, D., Wood, M.D., Pamuła, H., Stylianou, Y., Glotin, H. (2019). Automatic acoustic detection of birds through deep learning: The first Bird Audio Detection challenge. *Methods in Ecology and Evolution*, 10, 368–380. <https://doi.org/10.1111/2041-210X.13103>

- Sugai, L.S.M., Desjonquères, C., Silva, T.S.F., & Llusia, D. (2020). A roadmap for survey designs in terrestrial acoustic monitoring. *Remote Sensing in Ecology and Conservation*, 6, 220–235. <https://doi.org/10.1002/rse2.131>
- Sugai, L.S.M., Silva, T.S.F., Ribeiro, J.W., & Llusia, D. (2019). Terrestrial passive acoustic monitoring: review and perspectives. *BioScience*, 69, 15–25. <https://doi.org/10.1093/biosci/biy147>
- Swiston, K.A. & Mennill, D.J. (2009). Comparison of manual and automated methods for identifying target sounds in audio recordings of Pileated, Pale-billed, and putative Ivory-billed woodpeckers. *Journal of Field Ornithology*, 80, 42–50. <https://doi.org/10.1111/j.1557-9263.2009.00204.x>
- Ware, L., Mahon, C.L., McLeod, L., & Jetté, J.-F. (2023). Artificial intelligence (BirdNET) supplements manual methods to maximize bird species richness from acoustic data sets generated from regional monitoring. *Canadian Journal of Zoology*, 101, 1031–1051. <https://doi.org/10.1139/cjz-2023-0044>
- Winiarska, D., Szymański, P., & Osiejuk, T.S. (2024). Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Scientific Reports*, 14, 894. <https://doi.org/10.1038/s41598-024-51297-z>
- Wood, C.M., Kahl, S., Chaon, P., Peery, M.Z., & Klinck, H. 2021. Survey coverage, recording duration and community composition affect observed species richness in passive acoustic surveys. *Methods in Ecology and Evolution*, 12, 885–896. <https://doi.org/10.1111/2041-210X.13571>
- Wood, C.M. & Kahl, S. (2024). Guidelines for appropriate use of BirdNET scores and other detector outputs. *Journal of Ornithology*. <https://doi.org/10.1007/s10336-024-02144-5>

Yip, D.A., Bayne, E.M., Sólymos, P., Campbell, J., & Proppe, D. (2017a). Sound attenuation in forest and roadside environments: Implications for avian point-count surveys. *Condor*, 119, 73–84. <https://doi.org/10.1650/CONDOR-16-93.1>

Yip, D.A., Leston, L., Bayne, E.M., Sólymos, P., & Grover, A. (2017b). Experimentally derived detection distances from audio recordings and human observers enable integrated analysis of point count data. *Avian Conservation and Ecology*, 12 (1), 11. <https://doi.org/10.5751/ACE-00997-120111>

Supporting Information

Supplementary Figure 1. An aerial map of the study area, showcasing the positioning of ten ARUs spaced 50 meters apart along two 500-meter transects, positioned at a height of 4 meters. Speakers at the initiation of each transect were installed at heights of 3, 6, or 9 meters. The inset at a larger scale highlights the absence of any nearby urban agglomeration from the site. The map was created using QGIS software and images sourced from the Geoportal service (<https://www.geoportal.gov.pl/>).

Supplementary Table 1. Meteorological data on each experiment setup.

Supplementary Table 2. List of species with the mean body mass for males and basic acoustic parameters of the vocalisations used as playbacks in transmission experiments. Species groups were created using principal component analysis according to each species' body mass and vocal parameters to better illustrate the differences between species.

Supplementary Table 3. Principal component analysis' eigenvalues and loadings of diurnal and nocturnal species used for grouping. Calculation of the Kaiser-Meyer-Olkin measure of sampling adequacy (KMO) showed the diurnal species data was suitable for PCA (KMO = 0.5, Bartlett test for sphericity, $\chi^2 = 19.28$, $p < 0.001$). KMO showed the nocturnal species data was marginally insignificant for PCA (KMO = 0.5, Bartlett test for sphericity, $\chi^2 = 3.08$, $p < 0.079$),

however, the sample size was small. The analyses were conducted in R (R Core Team 2022), using ‘psych’ (Revelle, 2024) and ‘stats’ (R Core Team) packages.

Supplementary Figure 2. Principal component analysis of diurnal species used for grouping. PC1 explains 85.06% of the variability and is associated with mean peak frequency, while PC2 explains 14.94% and is associated with mean body mass. The labels are the first letter of the genus name and the three letters of the species name.

Supplementary Figure 3. Principal component analysis (PCA) of nocturnal species used for grouping. PC1 explains 76.33% of the variability and is associated with mean peak frequency, while PC2 explains 23.67% and is associated with mean body mass. The labels are the first letter of the genus name and the three letters of the species name.

Supplementary Figure 4. Boxplots of mean BirdNET detection scores according to each distance for each diurnal species. Boxplots show median, first and third quartile and extreme values.

Supplementary Figure 5. Boxplots of mean BirdNET detection scores according to each distance for each nocturnal species. Boxplots show median, first and third quartile and extreme values.

Supplementary Table 4. Effective detection radii (EDR, m) calculated for each detection method. For the Long-tailed Tit *Aegithalos caudatus* and Red Crossbill *Loxia curvirostra* the values for BirdNET were not possible to count as these species were not detected by the algorithm. In the case of Scops Owl *Otus scops*, the values were not counted for the audible method as this species obtained 100% detectability with this method.

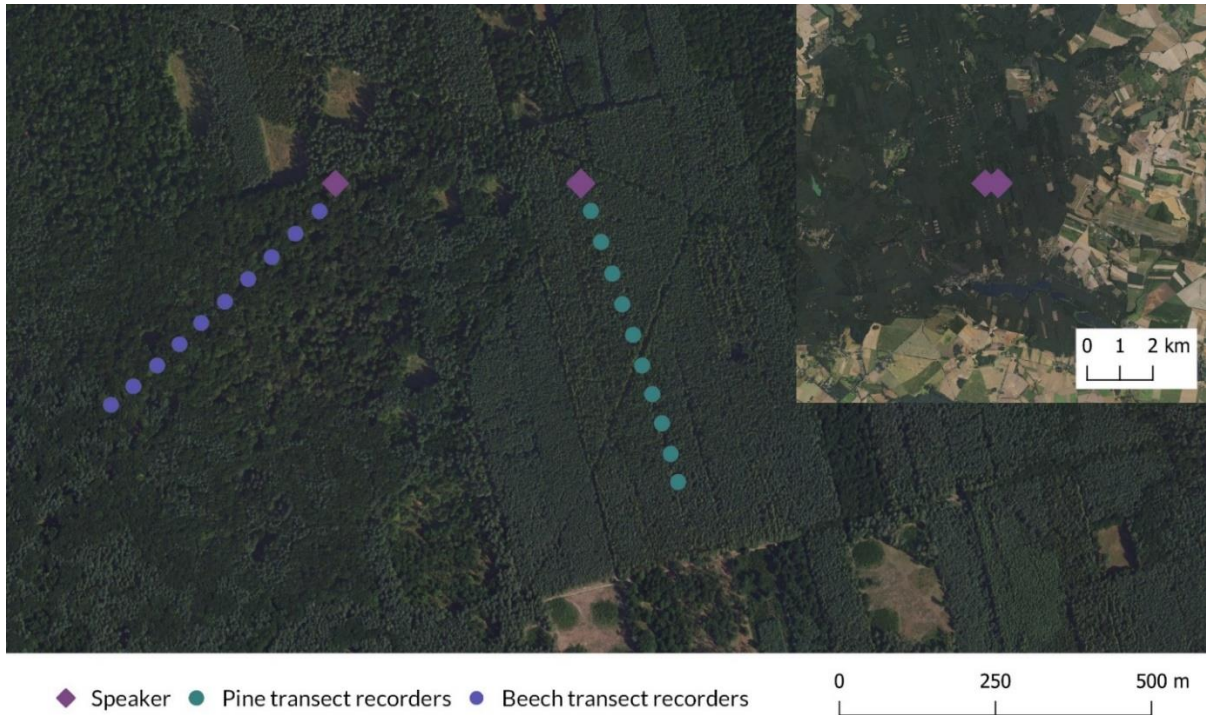
Suplement Rozdziału 2

Methods of acoustic data processing affect species detectability in passive acoustic monitoring

Dominika Winiarska, Paweł Szymański, Tomasz S. Osiejuk

Ibis, manuskrypt po pierwszej recenzji

Methods of acoustic data analysis affect species detectability in passive acoustic monitoring



Supplementary Figure 1. An aerial map of the study area, showcasing the positioning of ten ARUs spaced 50 meters apart along two 500-meter transects, positioned at a height of 4 meters. Speakers at the initiation of each transect were installed at heights of 3, 6, or 9 meters. The inset at a larger scale highlights the absence of any nearby urban agglomeration from the site. The map was created using QGIS software and images sourced from the Geoportal service (<https://www.geoportal.gov.pl/>).

Supplementary Table 1. Meteorological data on each experiment setup.

Transect	Date	Time	Broadcast height	Wind (m/s)	Humidity (%)	Temperature (°C)
Pine	24.03.2021	19:40	9 m	0.05	56.7	7.2
		20:10	6 m	0,00	67.4	6.2
		20:40	3 m	0,00	68.2	6.1
Beech	25.03.2021	19:25	9 m	0,00	65.3	5.8
		19:47	6 m	0,00	71.1	4.4
		20:07	3 m	0,00	73.3	4.0
Pine	01.04.2021	07:05	3 m	0,00	75.8	7.2
		07:50	9 m	0,00	82.1	8.1
		08:30	6 m	0,00	80.2	10.3
Beech	02.04.2021	07:05	9 m	0,22	74.1	0.8
		07:50	3 m	0,22	79.5	2.0
		08:40	6 m	0,00	69.3	3.9
Pine	12.05.2021	06:05	6 m	0,00	74.3	14.1
		06:50	3 m	0,00	75.2	14.8
		07:32	9 m	0,36	67.5	17.1
		21:35	3 m	0,00	74.3	17.6
		22:00	9 m	0,00	80.0	16.5
		22:20	6 m	0,00	82.0	16.3
Beech	13.05.2021	22:45	6 m	0,39	57.6	15.2
		21:35	9 m	0,15	68.7	14.5
		22:00	3 m	0,46	77.7	14.6
Beech	14.05.2021	06:05	3 m	0,62	80.7	12.0
		06:53	6 m	0,52	83.7	12.0
		07:36	9 m	0,29	83.5	12.2
Pine	08.06.2021	05:50	9 m	0,00	79.2	11.3
		06:35	6 m	0,00	78.8	12.8
		07:20	3 m	0,00	76.5	14.9
		22:04	6 m	0,00	64.7	18.0
		22:25	3 m	0,00	69.0	17.1
		22:43	9 m	0,00	69.5	16.8
Beech	09.06.2021	05:58	9 m	0,47	66.4	15.5
		07:23	3 m	0,59	62.6	16.6
		08:06	6 m	0,75	59.9	17.3
		22:02	3 m	0,00	62.9	16.9
		22:23	6 m	0,00	66.0	16.0
		22:51	9 m	0,00	68.5	15.4

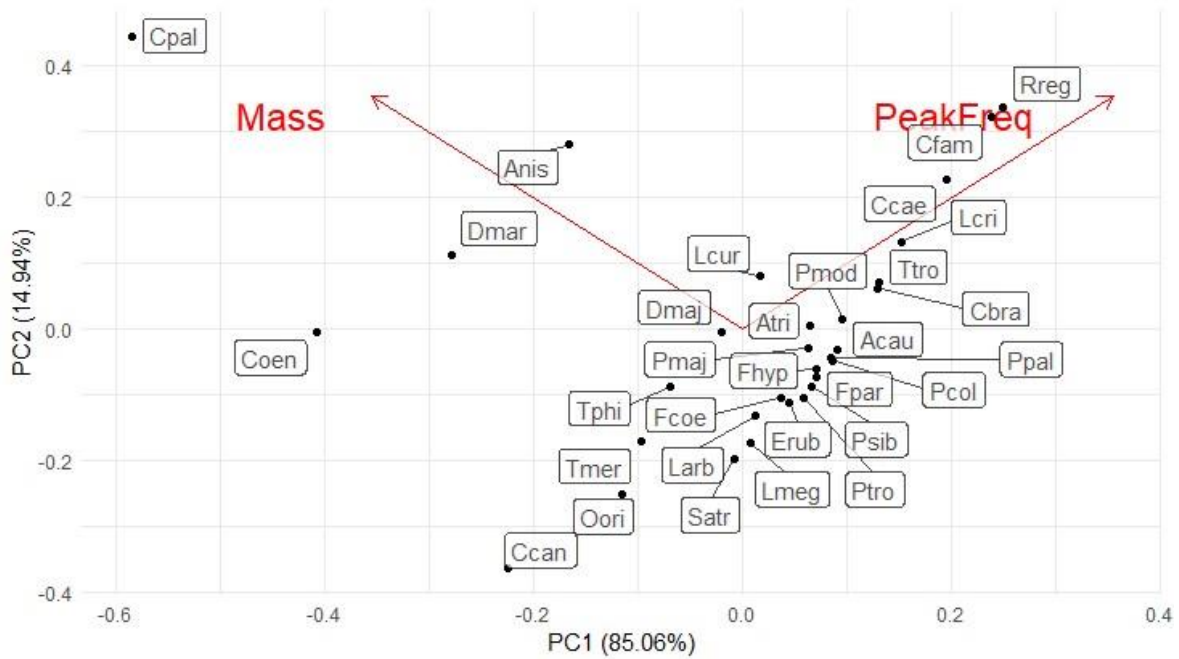
Supplementary Table 2. List of species with the mean body mass for males and basic acoustic parameters of the vocalisations used as playbacks in transmission experiments. Species groups were created using principal component analysis according to each species' body mass and vocal parameters to better illustrate the differences between species.

Species	Body mass (g)	Minimum frequency (Hz)	Maximum frequency (Hz)	Band width (Hz)	Frequency of maximum amplitude (Hz)	Amplitude measured at 1 m (dbA)	Group
Diurnal species							
<i>Accipiter nissus</i>	151	1990	4361	2438	3402	82.5	Medium
<i>Aegithalos caudatus</i>	8	1901	8856	6955	4436	79.3	Small
<i>Anthus trivialis</i>	27	1923	8073	6195	4350	86.0	Small
<i>Certhia brachydactyla</i>	9	4428	7469	3198	5082	85.8	Small
<i>Certhia familiaris</i>	9	2751	8789	6038	6891	81.7	Small
<i>Columba oenas</i>	334	127	1297	1171	431	92.2	Large
<i>Columba palumbus</i>	487	158	1946	1787	517	90.2	Large
<i>Cuculus canorus</i>	124	268	984	872	689	91.8	Large
<i>Cyanistes caeruleus</i>	11	4115	8789	5144	6202	85.2	Small
<i>Dendrocopos major</i>	84	716	6105	5390	3618	84.8	Medium
<i>Dryocopus martius</i>	310	1051	2281	1230	1895	90.9	Medium
<i>Erithacus rubecula</i>	20	1968	9012	7492	3790	84.6	Small
<i>Ficedula hypoleuca</i>	16	1901	9035	7134	4177	86.1	Small
<i>Ficedula parva</i>	10	2438	7425	6038	4134	87.2	Small
<i>Fringilla coelebs</i>	23	1565	8140	6575	3747	85.0	Small
<i>Lophophanes cristatus</i>	13	2572	7134	5479	5513	82.6	Small
<i>Loxia curvirostra</i>	35	1834	10175	8341	4221	84.9	Small
<i>Lullula arborea</i>	29	2013	5412	3399	3445	86.4	Small
<i>Luscinia megarhynchos</i>	28	1029	12712	11684	3273	88.3	Small
<i>Oriolus oriolus</i>	72	738	4652	6060	1981	88.0	Medium
<i>Parus major</i>	17	3176	6821	4808	4221	91.1	Small
<i>Phylloscopus colybita</i>	9	3109	7626	5770	4350	81.9	Small
<i>Phylloscopus sibilatrix</i>	11	3041	9079	6150	4048	82.5	Small
<i>Phylloscopus trochilus</i>	10	2125	6798	5546	3919	82.8	Small
<i>Poecile palustris</i>	12	2706	7402	5322	4350	81.7	Small
<i>Prunella modularis</i>	20	2348	8386	6374	4651	81.6	Small
<i>Regulus regulus</i>	6	4830	8297	6239	7020	80.4	Small
<i>Sylvia atricapilla</i>	20	1498	7402	7581	3058	86.7	Small
<i>Troglodytes troglodytes</i>	9	3131	8587	6083	5125	90.9	Small
<i>Turdus merula</i>	95	1208	8028	6821	2412	85.9	Medium
<i>Turdus philomelos</i>	79	1633	6620	5054	2929	86.8	Medium
Nocturnal species							
<i>Caprimulgus europaeus</i>	76	979	2525	646	2089	89.3	Small
<i>Tyto alba</i>	321	1366	4098	1281	2003	90.5	Small
<i>Glaucidium passerinum</i>	60	1160	2938	356	1529	94.5	Small
<i>Athene noctua</i>	170	722	1263	194	1141	91.6	Small

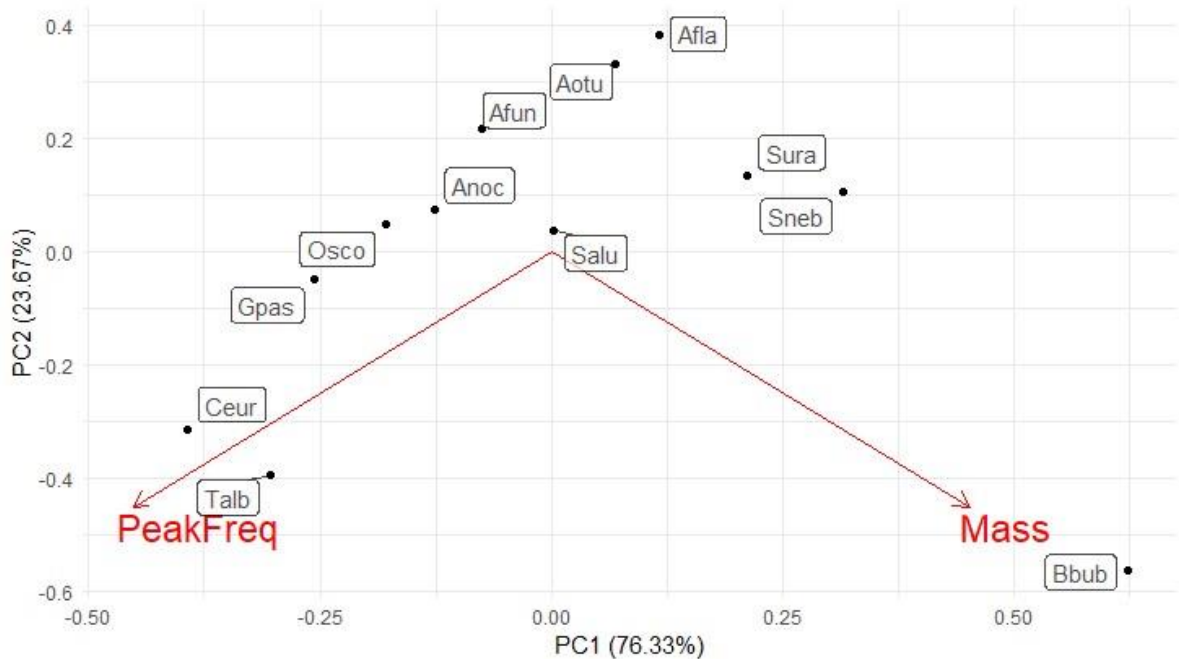
<i>Aegolius funereus</i>	116	515	979	65	883	88.7	Small
<i>Otus scops</i>	98	1186	1804	129	1270	90.4	Small
<i>Asio otus</i>	263	206	2397	991	474	89.1	Medium
<i>Asio flammeus</i>	301	206	3015	786	323	89.9	Medium
<i>Strix aluco</i>	440	541	3428	937	926	92.4	Medium
<i>Strix uralensis</i>	725	180	567	97	409	89.7	Large
<i>Strix nebulosa</i>	938	77	309	86	237	87	Large
<i>Bubo bubo</i>	2175	206	1366	227	366	92.9	Large

Supplementary Table 3. Principal component analysis' eigenvalues and loadings of diurnal and nocturnal species used for grouping. Calculation of the Kaiser-Meyer-Olkin measure of sampling adequacy (KMO) showed the diurnal species data was suitable for PCA (KMO = 0.5, Bartlett test for sphericity, $\chi^2 = 19.28$, $p < 0.001$). KMO showed the nocturnal species data was marginally insignificant for PCA (KMO = 0.5, Bartlett test for sphericity, $\chi^2 = 3.08$, $p < 0.079$), however, the sample size was small. The analyses were conducted in R (R Core Team 2022), using 'psych' (Revelle, 2024) and 'stats' (R Core Team) packages.

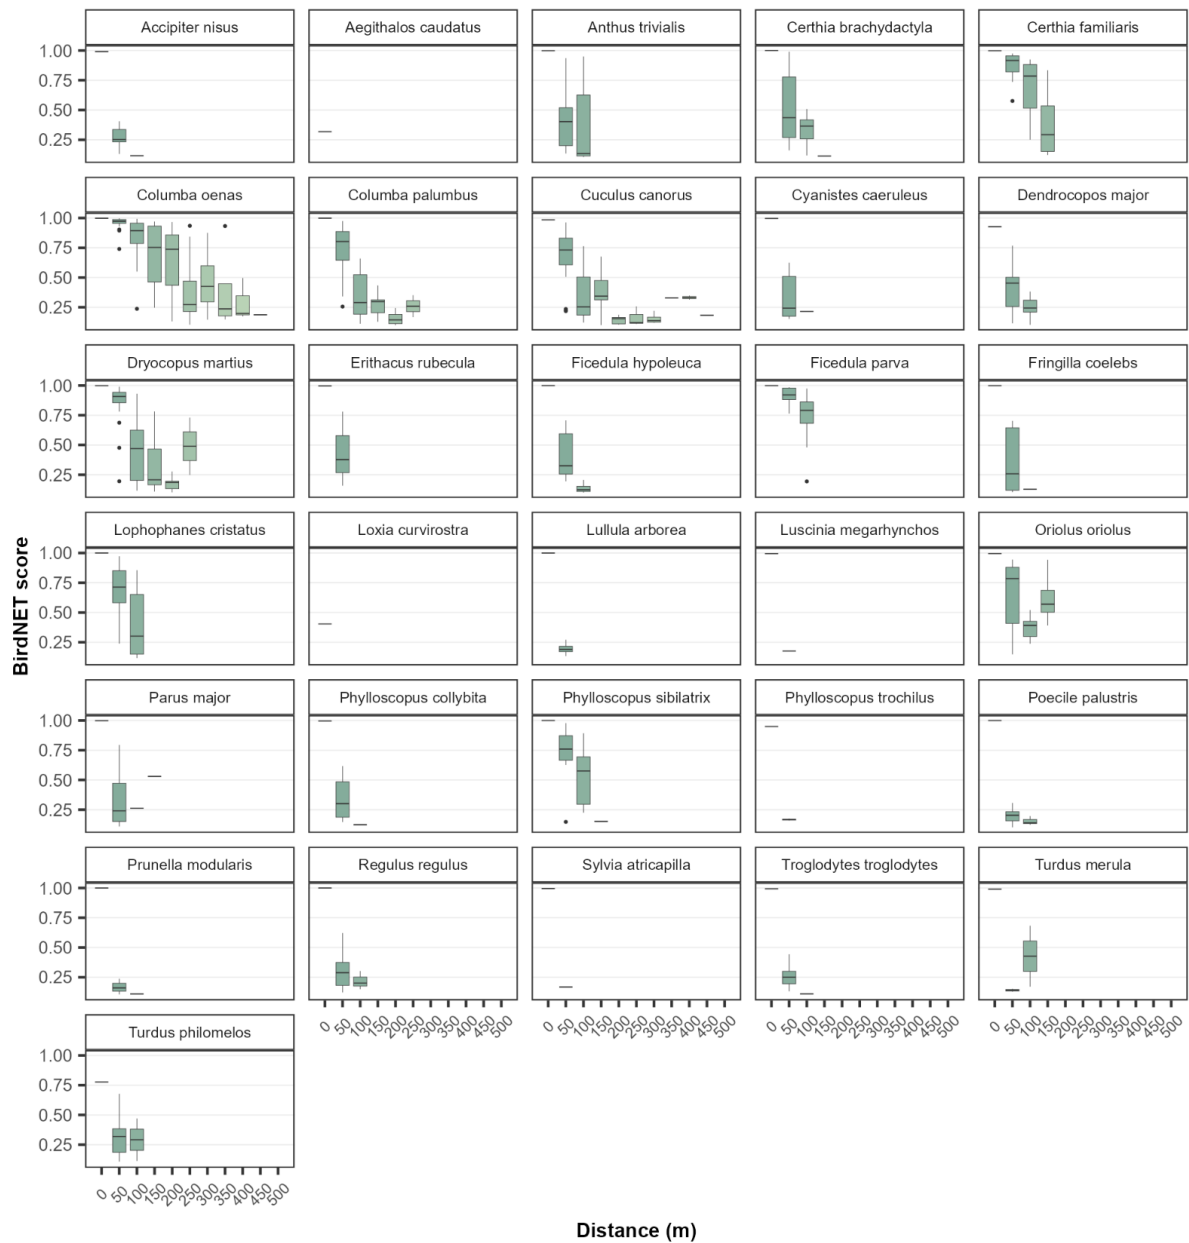
Diurnal species	PC1	PC2
Eigenvalue	1.701	0.298
Variance %	85.06	14.94
Cumulative variance %	85.06	100
Mass	-0.707	0.707
Peak Frequency	0.707	0.707
Nocturnal species	PC1	PC2
Eigenvalue	1.526	0.473
Variance %	76.33	23.67
Cumulative variance %	76.33	100
Mass	0.707	-0.707
Peak Frequency	-0.707	-0.707



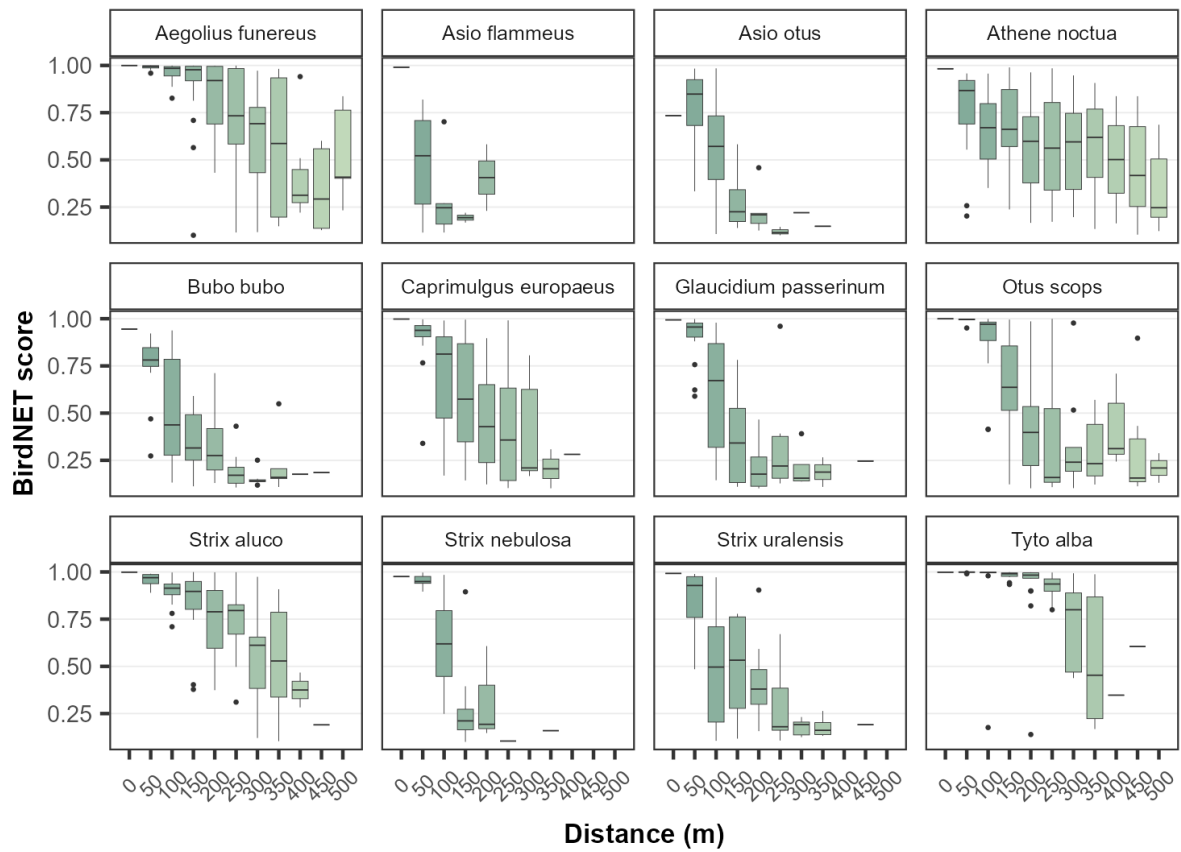
Supplementary Figure 2. Principal component analysis of diurnal species used for grouping. PC1 explains 85.06% of the variability and is associated with mean peak frequency, while PC2 explains 14.94% and is associated with mean body mass. The labels are the first letter of the genus name and the three letters of the species name.



Supplementary Figure 3. Principal component analysis (PCA) of nocturnal species used for grouping. PC1 explains 76.33% of the variability and is associated with mean peak frequency, while PC2 explains 23.67% and is associated with mean body mass. The labels are the first letter of the genus name and the three letters of the species name.



Supplementary Figure 4. Boxplots of mean maximum BirdNET detection scores according to each distance for each diurnal species. Boxplots show median, first and third quartile and extreme values.



Supplementary Figure 5. Boxplots of mean BirdNET detection scores according to each distance for each nocturnal species. Boxplots show median, first and third quartile and extreme values.

Supplementary Table 4. Effective detection radii (EDR, m) calculated for each detection method. For the Long-tailed Tit *Aegithalos caudatus* and Red Crossbill *Loxia curvirostra* the values for BirdNET were not possible to count as these species were not detected by the algorithm. In the case of Scops Owl *Otus scops*, the values were not counted for the audible method as this species obtained 100% detectability with this method.

Species	Audible	Visible	BirdNET
	EDR ± 90% CI	EDR ± 90% CI	EDR ± 90% CI
<i>Accipiter nisus</i>	190.02 ± 10.44	162.79 ± 8.86	46.08 ± 4.19
<i>Aegithalos caudatus</i>	106.36 ± 9.89	72.07 ± 8.48	NA ± NA
<i>Anthus trivialis</i>	121.66 ± 7.6	93.72 ± 6.03	82.13 ± 6.5
<i>Certhia brachydactyla</i>	137.34 ± 8.03	121.27 ± 7.2	92.91 ± 7.26
<i>Certhia familiaris</i>	149.28 ± 8.21	149.28 ± 8.21	142.46 ± 8.49
<i>Columba oenas</i>	487.85 ± 38.19	397.34 ± 27.89	299.12 ± 20.09
<i>Columba palumbus</i>	411.29 ± 29	315.74 ± 19.51	155.29 ± 11.5
<i>Cuculus canorus</i>	645.48 ± 66.77	443.05 ± 34.42	198.81 ± 17.98
<i>Cyanistes caeruleus</i>	153.78 ± 8.62	114.32 ± 7.68	43.89 ± 4.14
<i>Dendrocopos major</i>	113.99 ± 6.75	96.55 ± 5.94	82.85 ± 6.87
<i>Dryocopus martius</i>	300.21 ± 18.09	233.99 ± 13.41	189.92 ± 12.06
<i>Erithacus rubecula</i>	147.26 ± 10.8	92.2 ± 7.15	33.1 ± 2.57
<i>Ficedula hypoleuca</i>	108.34 ± 7.9	85.89 ± 5.92	67.69 ± 6.55
<i>Ficedula parva</i>	138.43 ± 9.04	108.08 ± 6.48	108.08 ± 6.48
<i>Fringilla coelebs</i>	158.76 ± 9.82	105.35 ± 6.44	49.57 ± 4.46
<i>Lophophanes cristatus</i>	154.73 ± 9.3	135.22 ± 8.65	98.22 ± 6.45
<i>Loxia curvirostra</i>	130.17 ± 7.96	106.36 ± 6.51	NA ± NA
<i>Lullula arborea</i>	162.19 ± 10.38	135.86 ± 8.74	36.83 ± 2.93
<i>Luscinia megarhynchos</i>	156.66 ± 9.95	137.37 ± 8.49	26.06 ± 2.4
<i>Oriolus oriolus</i>	230.59 ± 14.2	183.4 ± 12.31	101.35 ± 9.03
<i>Parus major</i>	181.84 ± 9.93	165.09 ± 9.16	61.65 ± 5.4
<i>Phylloscopus collybita</i>	135.01 ± 9.19	110.04 ± 7.17	51.29 ± 4.73
<i>Phylloscopus sibilatrix</i>	150.9 ± 8.52	125.75 ± 7.83	111.2 ± 6.76
<i>Phylloscopus trochilus</i>	136.81 ± 8.07	102.62 ± 6.17	30.29 ± 2.5
<i>Poecile palustris</i>	128.28 ± 7.71	95.84 ± 6.41	72.42 ± 5.66
<i>Prunella modularis</i>	105.59 ± 7.6	67.16 ± 5.05	33.16 ± 3.08

<i>Regulus regulus</i>	113.41 ± 6.91	102.55 ± 6.38	57.29 ± 6.23
<i>Sylvia atricapilla</i>	139.19 ± 8.63	105.81 ± 7.87	26.06 ± 2.4
<i>Troglodytes troglodytes</i>	152.15 ± 10	108.08 ± 6.48	56.27 ± 4.68
<i>Turdus merula</i>	162.94 ± 9.17	141.67 ± 8.14	29.93 ± 3.62
<i>Turdus philomelos</i>	193.19 ± 11.35	163.62 ± 10.39	61.65 ± 5.31
<hr/>			
<i>Caprimulgus europaeus</i>	479.28 ± 37.84	381.66 ± 24.98	255.49 ± 18.04
<i>Aegolius funereus</i>	1375.63 ± 306.93	1284.31 ± 273.39	465.73 ± 43.7
<i>Asio flammeus</i>	1205.67 ± 243.63	589.36 ± 61.38	90.59 ± 8.71
<i>Asio otus</i>	955.82 ± 150.33	677.27 ± 79.93	168.33 ± 14.04
<i>Athene noctua</i>	2108.04 ± 800.27	858.62 ± 117.63	725.45 ± 98.26
<i>Bubo bubo</i>	2986.66 ± 2481.07	746.88 ± 94.4	272.68 ± 20.35
<i>Glaucidium passerinum</i>	1593.81 ± 449.5	776.68 ± 92.16	223.12 ± 19.38
<i>Otus scops</i>	NA ± NA	1160.28 ± 213.01	292.49 ± 30.15
<i>Strix aluco</i>	658.55 ± 71.02	392.43 ± 28.25	333.42 ± 22.55
<i>Strix nebulosa</i>	798.21 ± 102.28	477.64 ± 47.49	150.18 ± 11.03
<i>Strix uralensis</i>	1519.68 ± 375.62	690.29 ± 81.94	243.84 ± 19.97
<i>Tyto alba</i>	504.14 ± 42.57	361 ± 22.06	329.21 ± 20.93

Rozdział 3

Year-round vocal activity of two African barbet species

Dominika Winiarska, Cristian Pérez-Granados, Michał Budka, Tomasz S. Osiejuk

Emu - Austral Ornithology, 1–11. 2024.

<https://doi.org/10.1080/01584197.2024.2352380>

Suplement Rozdziału 3

Year-round vocal activity of two African barbet species

Dominika Winiarska, Cristian Pérez-Granados, Michał Budka, Tomasz S. Osiejuk

Emu - Austral Ornithology, 1–11. 2024.

<https://doi.org/10.1080/01584197.2024.2352380>

Rozdział 4

Passive acoustic monitoring of endangered endemic
Afromontane tropical species: a case study with two turacos

Dominika Winiarska, Cristian Pérez-Granados, Michał Budka, Tomasz S.
Osiejuk

African Journal of Ecology 62, e13280. 2024. <https://doi.org/10.1111/aje.13280>

Suplement Rozdziału 4

Passive acoustic monitoring of endangered endemic

Afromontane tropical species: a case study with two turacos

Dominika Winiarska, Cristian Pérez-Granados, Michał Budka, Tomasz S.

Osiejuk

African Journal of Ecology 62, e13280. 2024.

<https://doi.org/10.1111/aje.13280>

Rozdział 5

Common cuckoo vocalisations as an indicator for the avian diversity

– a study with passive acoustic monitoring

Dominika Winiarska, Łukasz Jankowiak, Piotr Tryjanowski, Tomasz S. Osiejuk

Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring

Dominika Winiarska^{a*}, Łukasz Jankowiak^b, Piotr Tryjanowski^c, Tomasz S. Osiejuk^a

^a Department of Behavioural Ecology, Institute of Environmental Biology, Faculty of Biology, Adam Mickiewicz University in Poznań, Uniwersytetu Poznańskiego 6, 61-614, Poznań, Poland

^b Department of Ecology and Anthropology, Institute of Biology, University of Szczecin, Wąska 13, 71-415 Szczecin, Poland

^c Department of Zoology, Poznań University of Life Sciences, Wojska Polskiego 28, 60-637 Poznań, Poland

* Corresponding author

Dominika Winiarska* ORCID 0000-0002-2086-3618, e-mail: dmwiniarska1@gmail.com

Łukasz Jankowiak 0000-0002-3843-9778, jankowiakl@gmail.com

Piotr Tryjanowski 0000-0002-8358-0797, piotr.tryjanowski@gmail.com

Tomasz Stanisław Osiejuk 0000-0001-5980-7421 tomasz.osiejuk@amu.edu.pl

Abstract

Surrogate species are often used to represent broader groups in conservation and research. However, whether a single species can truly reflect an entire ecosystem remains debated. The common cuckoo (hereafter cuckoo) *Cuculus canorus* has been suggested several times as an

indicator of biodiversity with various outcomes. In this study, we utilised passive acoustic monitoring to record 48 soundscapes within a farmland area in Poland, aiming to assess the relationship between cuckoo vocalisations and bird species richness. We employed automated software for cuckoo vocalisation detection and manually analysed 10-minute samples from each site to determine species numbers. Additionally, we used BirdNET, an automated recognition algorithm, on 8-hour recordings to compare species composition with results obtained manually. We also utilised acoustic indices to evaluate their reflection of overall species richness. Our results revealed significant differences between manual and automatic species detection methods, with BirdNET detecting twice as many species as human observers. Furthermore, we noted more cuckoo vocalisations at sites with elevated bird species and host richness obtained automatically, indicating its potential as a biodiversity surrogate. However, acoustic indices failed to mirror acoustic diversity in the farmland habitat, showing unified values across all sites. These findings highlight the necessity of enhancing monitoring approaches to ensure a more comprehensive depiction of avian diversity, thus strengthening conservation measures.

Keywords: acoustic indicator, surrogate species, passive acoustic monitoring, automatic recognition, *Cuculus canorus*

1. Introduction

Surrogate species are used as a proxy for a wider group of species in various ways that fit the conservation methods, research, and strategies (Grantham *et al.* 2010). This, however, remains a contentious subject as many scientists question if a single species or even a narrow group of species can define the entire ecological system with the uniqueness of each species inhabiting it (Purvis and Hector 2000; Wiens *et al.* 2008; Cushman *et al.* 2010). The real measure of biodiversity is hard to obtain as it consists of various factors such as species richness or

evenness, and it is important to bear in mind that a single measure can never fully represent an entire ecosystem (Caro and O'Doherty 1999; Purvis and Hector 2000).

Nevertheless, certain species have the potential to point to areas of greater biodiversity (Rodrigues and Brooks 2007). Birds as a group are mostly considered fair indicators due to their wide abundance, good knowledge about this taxon and, for many species, the easiness of detection (Carrascal *et al.* 2012; Larsen *et al.* 2012). A species having all those traits is the common cuckoo, *Cuculus canorus*, hereby cuckoo. The results of several studies showed that cuckoo might be a good predictor of avian diversity or at least certain aspects of other indices, such as richness or divergence, as it is a brood parasite over 100 species (e.g., Tryjanowski and Morelli 2015; Møller *et al.* 2016; Morelli *et al.* 2017a; Kosicki and Hromada 2018). The studies are not unanimous, as some show a positive or negative correlation between the cuckoo's density and particular indices differently. The main counterargument is that using a single species is biased, as a predictor of biodiversity might provide only binary information on low or high biodiversity based on the cuckoo's absence or presence. In contrast, species richness is a continuous variable that constantly changes, and therefore, it provides a continuous output (Haest 2019). It is, therefore, assumed that a group of species may more reliably reveal the quality of the environment rather than one particular species. The counterargument to that is the cuckoo's purpose to point out which area can be of greater bird species richness with a given probability rather than to estimate a precise number of species inhabiting it (Morelli *et al.* 2019). Ultimately, previous studies on that species are inconclusive, and only a few of them have taken into consideration measures indirectly linked to the cuckoo, such as host availability (Morelli *et al.* 2015; Tryjanowski and Morelli 2015; Morelli *et al.* 2017b) or cuckoo's vocal output (Møller *et al.*, 2016).

Bird song can be a reliable predictor of miscellaneous traits of birds, like male quality or territory size, which are directly linked to the habitat that the species live in. A female selects a

mate based on his song, as she effectively uses it as an indirect yet trustworthy signal of his quality and/or condition (Catchpole and Slater 2008). The same relation between vocalisation and male quality can also be applied to the cuckoo. Hence, investigating whether cuckoo vocalisations might serve as a proxy for greater biodiversity is promising. The characteristic call of a cuckoo typically comprises two syllables (*cu-coo*), and research showed that males produce more syllables series in the presence of a female or other males (Møller *et al.* 2016; Tryjanowski *et al.* 2018). This suggests that male quality and/or habitat quality is signalled with vocalisations, which would impose strong selective pressure on vocalisations. Although recent findings showed there is no relationship between the cuckoo's body size and its call rate (Elek *et al.* 2021), other studies report the connection of vocalisations with soil type and radioactivity assumed to reflect the quality of the environment important for the cuckoo (Møller *et al.* 2016). There also seems to be a positive correlation between the number of syllables and bird species richness (Benedetti *et al.* 2018). Given that females of many species generally prefer more intense and longer vocalisations that are produced at a higher rate and are of lower frequency (Ryan and Keddy-Hector 1992), these vocal features could be important in this context. In addition, cuckoos' vocalisations differ in various traits, such as frequency or longevity (Fuisz and De Kort 2007; Jung *et al.* 2014; Zsebök *et al.* 2017). Therefore, we could assume that males producing more vocalisations would inhabit areas with higher species richness and other measures, so cuckoos' indicative abilities could be indirectly linked to certain vocal characteristics.

The key method for studying cuckoo vocalisation aspects is passive acoustic monitoring (PAM), which has been developing for several decades (Sugai *et al.* 2019). It enables extended sound recording without human interruption with the use of automated recording units (ARUs), which are fully programmable devices (Shonfield and Bayne 2017) that can be placed in remote areas and left for prolonged and unattended monitoring, depending on the battery and memory

cards capacity, what makes this method neutral to birds (Shonfield and Bayne 2017; Gibb *et al.* 2019). Birds are among the most researched groups with PAM (Sugai *et al.* 2019) as it can be successfully used for surveying due to its capability for many spatial or temporal measures of abundance and individual identification (Gibb *et al.* 2019; Ross *et al.* 2023).

In this study, we utilised PAM to record soundscapes in the study area where cuckoos are abundant and to investigate whether there is a link between the intensity of cuckoo vocalisations and the number of species inhabiting the area. We assumed that cuckoos put more effort into signalling their quality in more species-rich areas, possibly to attract more females of various genets, which are host-specific races (Gibbs *et al.* 2000). We detected the cuckoo vocalisations and estimated the number of species with the use of automatic detection software. Additionally, we used three acoustic indices to compare the number of species detected at each site with their values to see if acoustic diversity reflects the number of species. We hypothesised that areas with higher species diversity would have distinctive indices values.

2. Material and methods

2.1. Study site

The study was conducted in western Poland, around Odolanów town (51.575° N, 17.676° E). The area is mainly farmland consisting of meadows, pastures and arable fields with mixed forest patches, shrubs and baulks (Kwieciński *et al.* 2016). We randomly chose 48 study plots separated by at least 600 m (Figure S1) and deployed 24 Song Meter Micro recorders (Wildlife Acoustics, USA) in two subsequent series. The days of recording were May 30th 2022, for the first series and June 1st, for the second series. At each site, we recorded soundscape from 3 am to 11 am. Recorders were saving single-channel uncompressed PCM WAV files with a 48 kHz sampling rate and 16-bit depth. Sunrise was at ca 4:39 am. The average temperature recorded

during the observation days was around 18°C, while rainfall on May 30th reached only up to 3mm.

2.2. Acoustic analysis

We used Kaleidoscope Pro 5.6.1 (Wildlife Acoustic, USA) software to detect cuckoo vocalisations in the recordings automatically. For the analysis, we selected only the recording of soundscapes from 3 am to 7 am for each site to capture the highest cuckoo activity and reduce anthropogenic noise levels as in the early morning they are diminished. Cuckoo's vocalisations are well-known as they consist of two syllables produced at relatively low frequencies ranging from about 500-900 Hz (Jung *et al.* 2014; Moskát and Hauber 2021), which makes them easy to detect in the recordings. We estimated vocal parameters used for automatic recognition based on the measurements of vocalisations of 20 birds and 70 distinctive vocalisation series captured in the study area that was done with Raven Pro 1.6.4 (Cornell Lab of Ornithology, 2023; Table S1).

We then used the cluster analysis function of Kaleidoscope Pro, which employs unsupervised machine learning and K-means clustering, grouping similar sounds into clusters (Pérez-Granados and Schuchmann 2020). The software was set to detect a series of cuckoo calls. Parameters were 450-730 Hz as minimum and maximum frequency, 2-90 s as minimum and maximum duration and 2 s as a maximum inter-syllable gap. The output was divided into two main clusters, named “cuckoo” and “other,” by the estimation of the first 100 sounds within each initial cluster (if there was at least one cuckoo vocalisation, the cluster was included). All individual candidate sounds from cluster “cuckoo” were manually reviewed by DW, whereas cluster “other” was rejected from further analysis. The performance of the recogniser was evaluated by calculating its precision and recall (Knight *et al.* 2017). Precision was estimated by dividing the number of true positives by the number of true positives with false positives. Recall estimation uses the same formula, but instead of including false positives, it incorporates

false negatives. Because we rejected cluster “other” containing false negatives, we calculated the recall rate with the validation dataset created for detectability measurements. It consisted of 96 recordings, two from each study plot. The validation dataset was manually inspected by DW, who marked all well-visible cuckoo vocalisations series using Raven Pro to count the number of selections and the duration of species vocalisations. Spectrogram parameters were: Hann window with 512 samples, greyscale colour map, brightness, and contrast at 50.

To estimate the number of species in each study plot, we cut out 10-minute recordings from one hour (4:30 am, since most species were vocalising at this time) and encrypted files to identify species independently. DW and TO identified the species. Each person reviewed 24 initial files and marked all species seen in the spectrogram. Using Raven Pro, we marked each species in a separate selection and named them. After marking all 24 files, we cross-checked selections marked by another person. This resulted in a list of species vocalising in each study plot (Table S2). Using the work of Wyllie (1981) and the list of frequent, occasional and rare hosts, we divided the species list into two categories: cuckoos’ hosts and non-hosts.

To assess the performance of 10-minute samples and increase the certainty of the results, we also used BirdNET (version 2.2; Kahl *et al.* 2021) to automatically detect species from 8-hour recordings (3 am – 11 am to capture the highest activity of most diurnal species). We used the BirdNET algorithm implemented into Raven Pro, using the following settings: 1-second overlap, global list of species, and threshold of 0.25. All the detections from the software were then manually checked, where we marked only the first correct detection of the species with the highest score. This was done by TO, while DW checked all detections afterwards.

2.3. Acoustic indices

To assess if the acoustic complexity of the environment captured in the recordings reflects species numbers, we employed acoustic indices, which rely on a simple concept that the more species producing signals are present in the area, the higher the acoustic diversity will be. There

are many acoustic indices, and each of them analyses different properties of an acoustic signal (Alcocer *et al.* 2022). Although acoustic indices still have some controversies involving their effectiveness and real correlation with acoustic diversity (Sueur *et al.* 2014; Gasc *et al.* 2015), some perform relatively well, such as the acoustic complexity index (Alcocer *et al.* 2022). For this study, we chose three of the most popular acoustic indices to investigate how their values correlate with bird species richness in our study.

Acoustic complexity index (ACI) measures spectrogram variability by weighing amplitude differences within frequency bins. Its basic assumption is that it should increase with more vocalising individuals or species. Many studies describe the correlation between ACI values and bird vocalisation number, either positive or negative (Pieretti *et al.* 2011; Eldridge *et al.* 2018; Shamon *et al.* 2021). Bioacoustic index (BI) calculates sound energy under the log amplitude curve. It is thought to perform as well as or better than ACI in predicting bird species richness (Eldridge *et al.* 2018; Shamon *et al.* 2021; Budka *et al.* 2023). The acoustic diversity index (ADI) measures spectrum complexity with the Shannon entropy of frequency bins. Although ADI is thought to have the least strength among these indices for farmland birds, it might perform better in heterogeneous habitats (Shamon *et al.* 2021).

Each of the 10-minute recordings used for species manual identification was cut to 1-minute samples to reflect the mean value across the whole file due to some anthropogenic sounds within them. We calculated BI, ACI and ADI using Kaleidoscope Pro 5.6.1 (Wildlife Acoustics, USA). Frequency parameters for each index were 500 Hz for minimal frequency to capture pigeons and crows and 10,000 Hz for maximum frequency to include birds vocalising at higher frequencies. FFT size was set to 512. We also included a 500 Hz frequency step and a -50 dB threshold in ADI. We also applied frequency limitations of 1 – 8 kHz to hinder the sounds outside the songbirds' bandwidth, but the results were similar.

2.4. Statistical analysis

To test whether the cuckoo vocalisation number reflects bird species richness, we fitted generalised linear mixed models (GLMM) using the “glmmTMB” package (Brooks *et al.* 2022) in R Studio (R Core Team 2022) with the data obtained with Kaleidoscope Pro. The models were fitted with ordinal beta distribution and probit link function to fit the variables, all scaled from 0 to 1. The number of species detected at each site was fitted as a response variable, with the number of vocalisations detected by the Kaleidoscope software set as a fixed effect and the method of detection as a factor (manual or automatic). We also incorporated interaction terms between the cuckoo vocalisations and the method to capture the combined effect of these two variables, with the site included as a random factor. We used the number of detected cuckoo vocalisations for all models, as it was highly correlated with the duration parameter (0.91, $p < 0.001$).

To increase the reliability of the results, we performed nonparametric bootstrapping using the “boot” package for R (Canty and Ripley 2016). Out of 48 observations from 48 sites, we sampled 20 with replacement and repeated the procedure 5000 times. We calculated the means and 95th percentile ranges over the bootstrapped samples (original vs bootstrapped mean 0.24 and 0.31, accordingly, and 95% confidence interval of 0.09 – 0.71; Figure S2).

Due to the relatively low number of observations, we performed a Moran’s I test using Monte Carlo simulation to investigate the presence of spatial autocorrelation among the study sites. We found no significant correlation between sites (Moran’s I statistic -0.02, $p = 0.49$). We also tested whether there is a correlation between the number of species obtained manually and automatically using Pearson correlation statistics.

Additionally, we modelled if acoustic indices values reflect the number of species and cuckoo vocalisations. To do that, we fitted GLMMs, having indices values set as response variables (ACI, ADI, BI) with the number of species or hosts detected manually or automatically as

covariates and site included as a random factor. All models were fitted with ordinal beta distribution and logit link function as all variables were scaled from 0 to 1. We tested the species variables for collinearity using the “performance” package (Lüdecke *et al.* 2021), and all of them showed a variance inflation factor below 3.8 (Table S5), which is considered low. Nevertheless, each of the species and host variables was introduced in a separate model to avoid testing the correlated variables. Based on Akaike’s information criterion (AIC), we selected the independent variable as important if the AIC value was lower than in the null model ($\Delta\text{AIC} < 2$).

Models were diagnosed using the “DHARMA” package (Hartig 2022), which showed no issues with any model.

3. Results

We detected cuckoos at 43 out of 48 study sites (89.6%) and among 145 recordings (60.4% of all considered recordings).

Kaleidoscope Pro analysis resulted in 10,435 candidate sounds. In cluster “cuckoo”, we detected 2,067 vocalisations out of 5,784 candidate sounds, achieving 35.7% precision. We also obtained a 90.9% recall rate as Kaleidoscope detected 964 out of 1,060 vocalisation series marked manually in the validation dataset. The number of vocalisations detected at each recording varied from 0 to 94.

An elevated number of cuckoo vocalisations was associated with a higher count of species and hosts detected with the automatic method (Table 1). The greater the species richness, the more vocalisations cuckoos produced (Figure 1). However, the number of species changed highly compared to manual and automatic methods, but the correlation between them was positive and moderate (0.39, $p = 0.005$ for the total number of species and 0.35, $p = 0.01$ for hosts). On the 10-minute samples, we detected 54 species manually, with a minimum of 4 and a maximum of

13 species at each site. From that, we obtained 26 cuckoo host species and between 1 and 7 hosts at each site. With BirdNET, we detected 118 species in 8-hour recordings, including 43 host species. There were a minimum of 9 and a maximum of 39 species, and between 3 and 19 host species at each site. The maximum score obtained for a species was 0.9999, while the lowest was 0.25.

In acoustic indices, none of the models, except for one BI model, were significantly different from the null model, indicating a lack of effects (Table S3). Acoustic indices showed no significant differences between species detected manually during 10 minutes or automatically from long recordings, except for the BI and host number obtained automatically (which was slightly better than the null model [$\Delta AIC = 1.25$] but still lower than the threshold of two). Nevertheless, we tested this variable and found a weak significance effect indicating a positive relation with BI ($p = 0.048$, Table S4). Sites with the most species achieved mediocre indices values (Figure S3).

Table 1. The bird species richness models' results indicating changes in the number of cuckoo vocalisations in relation to the number of species regarding each method. Significant outcomes are in bold (p -value < 0.05).

Species				
	Estimate	Std. Error	z value	p-value
(Intercept)	0.141	0.075	1.878	0.060
Number of cuckoo vocalisations	0.744	0.212	3.506	<0.001
Method – manual	-1.477	0.097	-15.139	<0.001
Vocalisations * Method – manual	-0.494	0.240	-2.055	0.040
Hosts				
	Estimate	Std. Error	z value	p-value
(Intercept)	0.094	0.075	1.257	0.209

Number of cuckoo vocalisations	0.727	0.227	3.205	0.001
Method – manual	-1.209	0.111	-10.924	<0.001
Vocalisations * Method – manual	-0.420	0.281	-1.496	0.135

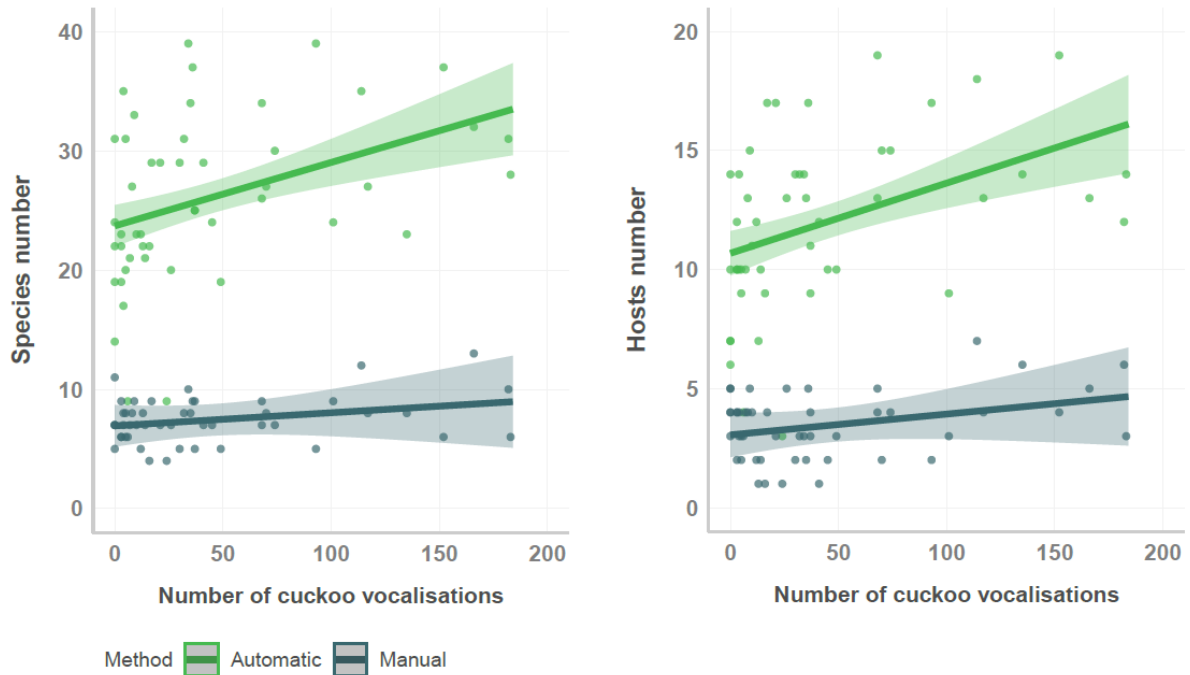


Figure 1. The number of cuckoo vocalisations in relation to the number of species and host species detected with BirdNET from 8-hour recordings and obtained manually during 10-minute recording sample counts at each site. The regression line was made with predicted values derived from the models, with 95% confidence intervals shown.

4. Discussion

In this study, we showed that cuckoos can acoustically indicate areas of higher bird species richness as well as a greater number of hosts. Additionally, our findings revealed that 10-minute species counts in acoustic recordings can underestimate species composition but are positively correlated with the overall species richness obtained from automatic recognition of 8-hour

recordings. Furthermore, we observed that the bioacoustic index (BI), the acoustic diversity index (ADI) and the acoustic complexity index (ACI) do not reflect bird species richness in a farmland area.

4.1. Cuckoos' indicative abilities

We noted that cuckoo vocalisations were most frequent in areas with high species and host diversity. This suggests that cuckoo males may be more likely to inhabit species-rich sites and vocalise more to attract females from various genges, which select habitats based on their respective host species. While previous studies suggested a link between cuckoo presence and overall species richness rather than specifically with hosts (Morelli *et al.* 2015; Morelli *et al.* 2017b), our results expand this statement by linking cuckoos' vocal output to both hosts and non-host species number. Although our study highlights a tendency for cuckoos to vocalise more in areas with higher species richness, it would be difficult to rely solely on a vocalisation measure since there were sites with a relatively high number of species and a low number of cuckoo vocalisations (Figure 1).

Perhaps exploring alternative measures and examining the relationship between vocalisations and other environmental variables could provide additional insights to strengthen the utilisation of cuckoo vocalisations as a biodiversity surrogate. For example, studies show that cuckoo density is the most important predictor of bird species richness (Kosicki and Hromada 2018) when considering its predictive abilities. Linking vocal activity with density could provide more robust validation of the cuckoo's role as a biodiversity indicator. Furthermore, in this study, we only tested male cuckoo vocalisations. However, it has been recently discovered that female vocal activity correlates with the vocal activity of their hosts (Yoo *et al.* 2020). Then, cuckoos' indicative abilities could also be linked to female-specific vocalisations. We tried detecting female vocalisations; however, their number seemed low compared to the candidate sounds in the output and would require much more time devoted to the analysis.

4.2. Cuckoos' detection

Kaleidoscope Pro demonstrated its reliability in detecting cuckoos' vocalisations, achieving a detection rate of over 90% of desired vocalisations from the validation dataset (for cuckoo detectability, see also Deng et al., 2019; Xia et al., 2019). The mediocre precision of 35.7% seems to arise from difficulties in distinguishing between cuckoo vocalisations and those of the Eurasian hoopoe *Upupa epops*, which share frequency range, along with the presence of many geophonic sounds. Nevertheless, cuckoo vocalisation is well suited for automatic recognition as usually, within such a low frequency, there are rarely other sounds that could increase the number of false positives.

4.3. PAM in biodiversity assessment

PAM turned out to be an effective tool for gathering simultaneous data from many areas, allowing us to compare soundscapes between the plots. In our study, acoustic indices did not show a significant relation with the species or host number, except for the weak connection with BI. Acoustic indices largely depend on the environment (Shamon *et al.* 2021; Budka *et al.* 2023) and may change with a single song (Gasc *et al.* 2015), but in our study, the number of species in each plot (detected both manually and automatically) is not reflected in indices values. For example, sites with the most species achieved mediocre and uneven values, whereas some sites with the least species obtained higher results (Figure S3). Indeed, some indices demonstrate a negative relation between species richness and their value (e.g. ACI; Shamon *et al.*, 2021). However, our results do not present any distinguishable pattern. The supposed relation of indices values and species could be more linear, indicating an increase or decrease of a variable in opposition to another. Obtained results reflect middle values the most, with low or high values being individual cases. The study area consists of diverse farmland with various

structures, such as shrubs or reeds, which surely favour many species. Thus, this range of different structures likely has a major impact on indices values.

We found half as many species with manual detection as we did with the automatic method. This shows that a 10-minute count may severely underestimate the real number of species inhabiting an area. Even though both species surveys were correlated, the correlation coefficient was rather low, indicating a moderate relationship. Experienced observers can detect more species vocalising in the background even if they vocalise only once, but the main advantage of using BirdNET was that we were able to process much more acoustic data in a short time. While manual analysis of 10-minute recordings took about 16 hours (~20 minutes per site), using BirdNET, we analysed 384 hours of material in over twice that time, about 36 hours (9% of the total recording length). It also allowed us to detect 70 more species, significantly changing the results. Indeed, BirdNET is a great tool to maximise the species number with little effort (Ware *et al.* 2023). Notably, the algorithm detected the same species we did manually, demonstrating the software's potential for future studies.

4.4. Conclusion

Cuckoo vocalisations serve as indicators of locations with higher bird species richness and a greater number of host species. Further research is needed to investigate whether an elevated number of vocalisations can be more directly linked to specific habitat characteristics that would enhance cuckoo surrogacy's effectiveness. Moreover, our findings underscored the inadequacy of acoustic indices in accurately capturing bird species richness within agricultural landscapes. Conversely, automated species detection methods emerged as a more reliable alternative to human-generated estimates. 10-minute species counts could be enhanced by linking the cuckoo's presence to the potentially higher number of species. PAM allowed us to gather comprehensive data from a large area and analyse it in much less time and effort than would require human observers to do. These insights underscore the importance of refining monitoring strategies to better capture avian diversity and enhance conservation practices.

CRedit authorship contribution statement

DW: Conceptualisation; Data curation; Formal analysis; Investigation; Methodology; Project administration; Validation; Visualisation; Writing - original draft; Writing - review & editing.

ŁJ: Conceptualisation; Data curation; Formal analysis; Investigation; Methodology; Project administration; Supervision; Validation; Writing - review & editing.

PT: Conceptualisation; Data curation; Investigation; Methodology; Project administration; Supervision; Validation; Writing - review & editing.

TSO: Conceptualisation; Data curation; Formal analysis; Investigation; Methodology; Project administration; Supervision; Validation; Writing - review & editing.

Acknowledgements

We thank the students who helped in the field: Eliza Bartolik, Wiktoria Chałupka, Michalina Januszek, Marta Nowak, and Izabela Zamiara.

Conflict of interest

The authors declare no conflict of interest.

Data availability statement

The datasets analysed during the current study are available from the corresponding author upon reasonable request (Dominika Winiarska, email: dmwiniarska1@gmail.com).

References

- Alcocer I, Lima H, Sugai LSM, Llusia D (2022). Acoustic indices as proxies for biodiversity: a meta-analysis. *Biological Reviews* **97**, 2209–2236. doi:10.1111/brv.12890
- Benedetti Y, Slezak K, Møller AP, Morelli F, Tryjanowski P (2018). Number of syllables in cuckoo *Cuculus canorus* calls: A test using a citizen science project. *Scientific Reports* **8**, 1–7. doi:10.1038/s41598-018-31329-1
- Brooks M, Bolker B, Kristensen K, Maechler M, Magnusson A, McGillicuddy M, Skaug H, Nielsen A, Berg C, Bentham K van, Sadat N, Lüdecke D, Lenth R, O’Brien J, Geyer CJ, Jagan M, Wiernik B, Stouffer DB (2022). glmmTMB: Generalised Linear Mixed Models using Template Model Builder. Available at: <https://CRAN.R-project.org/package=glmmTMB> [accessed March 6th 2023]
- Budka M, Sokołowska E, Muszyńska A, Staniewicz A (2023). Acoustic indices estimate breeding bird species richness with daily and seasonally variable effectiveness in

- lowland temperate Białowieża forest. *Ecological Indicators* **148**, 110027.
doi:10.1016/j.ecolind.2023.110027
- Canty A, Ripley B (2016). boot: Bootstrap R (S-Plus) Functions. *R package version 1*, 3–18.
- Caro TM, O’Doherty G (1999). On the use of surrogate species in conservation biology. *Conservation Biology* **13**, 805–814. doi:10.1046/j.1523-1739.1999.98338.x
- Carrascal LM, Cayuela L, Palomino D, Seoane J (2012). What species-specific traits make a bird a better surrogate of native species richness? A test with insular avifauna. *Biological Conservation* **152**, 204–211. doi:10.1016/j.biocon.2012.04.009
- Catchpole CK, Slater PJB (2008). Bird Song. Biological Themes and Variations. Cambridge University Press, Cambridge, UK.
- Cushman SA, McKelvey KS, Noon BR, McGarigal K (2010). Use of Abundance of One Species as a Surrogate for Abundance of Others. *Conservation Biology* **24**, 830–840. doi:10.1111/j.1523-1739.2009.01396.x
- Deng Z, Lloyd H, Xia C, Møller AP, Liang W, Zhang Y (2019). Components of variation in female common cuckoo calls. *Behavioural Processes* **158**, 106–112. doi:10.1016/j.beproc.2018.10.007
- Eldridge A, Guyot P, Moscoso P, Johnston A, Eyre-Walker Y, Peck M (2018). Sounding out ecoacoustic metrics: Avian species richness is predicted by acoustic indices in temperate but not tropical habitats. *Ecological Indicators* **95**, 939–952. doi:10.1016/j.ecolind.2018.06.012

- Elek Z, Bán M, Fülöp A, Marton A, Hauber ME, Moskát C (2021). Call rate in Common Cuckoos does not predict body size and responses to conspecific playbacks. *Journal of Ornithology* **162**, 1183–1192. doi:10.1007/s10336-021-01909-6
- Fuisz TI, De Kort SR (2007). Habitat-dependent call divergence in the common cuckoo: Is it a potential signal for assortative mating? *Proceedings of the Royal Society B: Biological Sciences* **274**, 2093–2097. doi:10.1098/rspb.2007.0487
- Gasc A, Pavoine S, Lellouch L, Grandcolas P, Sueur J (2015). Acoustic indices for biodiversity assessments: Analyses of bias based on simulated bird assemblages and recommendations for field surveys. *Biological Conservation* **191**, 306–312. doi:10.1016/j.biocon.2015.06.018
- Gibb R, Browning E, Glover-Kapfer P, Jones KE (2019). Emerging opportunities and challenges for passive acoustics in ecological assessment and monitoring. *Methods in Ecology and Evolution* **10**, 169–185. doi:10.1111/2041-210X.13101
- Gibbs HL, Sorenson MD, Marchetti K, De L. Brooke M, Davies NB, Nakamura H (2000). Genetic evidence for female host-specific races of the common cuckoo. *Nature* **407**, 183–186. doi:10.1038/35025058
- Grantham HS, Pressey RL, Wells JA, Beattie AJ (2010). Effectiveness of biodiversity surrogates for conservation planning: Different measures of effectiveness generate a kaleidoscope of variation. *PLoS ONE* **5**. doi:10.1371/journal.pone.0011430
- Haest B (2019). Cuckoos: The holy grail of avian biodiversity conservation? *Ecological Indicators* **97**, 59–66. doi:10.1016/j.ecolind.2018.10.007

- Hartig F (2022). DHARMA: Residual Diagnostics for Hierarchical (Multi-Level / Mixed) Regression Models. R package version 0.4.6. Available at: <http://florianhartig.github.io/DHARMA/> [accessed March 6th 2023]
- Jung WJ, Lee JW, Yoo JC (2014). ‘cu-coo’: Can you recognise my stepparents? - A study of host-specific male call divergence in the common cuckoo. *PLoS ONE* **9**, e90468. doi:10.1371/journal.pone.0090468
- K. Lisa Yang Center for Conservation Bioacoustics at the Cornell Lab of Ornithology (2023). Raven Pro: Interactive Sound Analysis Software (Version 1.6.4). Available at: <https://ravensoundsoftware.com/>
- Kahl S, Wood CM, Eibl M, Klinck H (2021). BirdNET: A deep learning solution for avian diversity monitoring. *Ecological Informatics* **61**, 101236. doi:10.1016/j.ecoinf.2021.101236
- Knight EC, Hannah KC, Foley GJ, Scott CD, Brigham RM, Bayne E (2017). Recommendations for acoustic recogniser performance assessment with application to five common automated signal recognition programs. *Avian Conservation and Ecology* **12**, art14. doi:10.5751/ACE-01114-120214
- Kosicki JZ, Hromada M (2018). Cuckoo density as a predictor of functional and phylogenetic species richness in the predictive modelling approach: Extension of Tryjanowski and Morelli (2015) paradigm in the analytical context. *Ecological Indicators* **88**, 384–392. doi:10.1016/j.ecolind.2018.01.009
- Kwieciński Z, Morelli F, Antczak M, Hromada M, Szymański P, Tobolka M, Jankowiak Ł, Tryjanowski P (2016). Seasonal changes in avian communities living in an extensively

- used farmland of Western Poland. *European Journal of Ecology* **2**, 9–18.
doi:10.1515/eje-2016-0012
- Larsen FW, Bladt J, Balmford A, Rahbek C (2012). Birds as biodiversity surrogates: will supplementing birds with other taxa improve effectiveness?: *Effectiveness of birds as biodiversity surrogates. Journal of Applied Ecology* **49**, 349–356. doi:10.1111/j.1365-2664.2011.02094.x
- Lüdecke D, Ben-Shachar M, Patil I, Waggoner P, Makowski D (2021). performance: An R Package for Assessment, Comparison and Testing of Statistical Models. *Journal of Open Source Software* **6**, 3139. doi:10.21105/joss.03139
- Møller AP, Morelli F, Mousseau TA, Tryjanowski P (2016). The number of syllables in Chernobyl cuckoo calls reliably indicate habitat, soil and radiation levels. *Ecological Indicators* **66**, 592–597. doi:10.1016/j.ecolind.2016.02.037
- Morelli F, Jiguet F, Reif J, Plexida S, Valli AS, Indykiewicz P, Šímová P, Tichit M, Moretti M, Tryjanowski P (2015). Cuckoo and biodiversity: Testing the correlation between species occurrence and bird species richness in Europe. *Biological Conservation* **190**, 123–132. doi:10.1016/j.biocon.2015.06.003
- Morelli F, Møller AP, Nelson E, Benedetti Y, Liang W, Šímová P, Moretti M, Tryjanowski P (2017a). The common cuckoo is an effective indicator of high bird species richness in Asia and Europe. *Scientific Reports* **7**. doi:10.1038/s41598-017-04794-3
- Morelli F, Møller AP, Nelson E, Benedetti Y, Tichit M, Šímová P, Jerzak L, Moretti M, Tryjanowski P (2017b). Cuckoo as indicator of high functional diversity of bird communities: A new paradigm for biodiversity surrogacy. *Ecological Indicators* **72**, 565–573. doi:10.1016/j.ecolind.2016.08.059

- Morelli F, Tryjanowski P, Benedetti Y, Liang W, Møller AP (2019). The Holy Grail is just a myth! Response to Haest 2019. *Ecological Indicators* **101**, 720–724. doi:10.1016/j.ecolind.2019.01.078
- Moskát C, Hauber ME (2021). Male common cuckoos use a three-note variant of their “cuckoo” call for duetting with conspecific females. *Behavioural Processes* **191**, 104472. doi:10.1016/j.beproc.2021.104472
- Pérez-Granados C, Schuchmann K-L (2020). Monitoring the annual vocal activity of two enigmatic nocturnal Neotropical birds: the Common Potoo (*Nyctibius griseus*) and the Great Potoo (*Nyctibius grandis*). *Journal of Ornithology* **161**, 1129–1141. doi:10.1007/s10336-020-01795-4
- Pieretti N, Farina A, Morri D (2011). A new methodology to infer the singing activity of an avian community: The Acoustic Complexity Index (ACI). *Ecological Indicators* **11**, 868–873. doi:10.1016/j.ecolind.2010.11.005
- Purvis A, Hector A (2000). Getting the measure of biodiversity. *Nature* **405**, 212–219. doi:10.1038/35012221
- R Core Team (2022). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Rodrigues ASL, Brooks TM (2007). Shortcuts for Biodiversity Conservation Planning: The Effectiveness of Surrogates. *Annual Review of Ecology, Evolution, and Systematics* **38**, 713–737. doi:10.1146/annurev.ecolsys.38.091206.095737
- Ross SRP -J., O’Connell DP, Deichmann JL, Desjonquères C, Gasc A, Phillips JN, Sethi SS, Wood CM, Burivalova Z (2023). Passive acoustic monitoring provides a fresh

- perspective on fundamental ecological questions. *Functional Ecology* **37**, 959–975. doi:10.1111/1365-2435.14275
- Ryan MJ, Keddy-Hector A (1992). ‘Directional patterns of female mate choice and the role of sensory biases’ doi:10.1086/285303
- Shamon H, Paraskevopoulou Z, Kitzes J, Card E, Deichmann JL, Boyce AJ, McShea WJ (2021). Using ecoacoustics metrics to track grassland bird richness across landscape gradients. *Ecological Indicators* **120**, 106928. doi:10.1016/j.ecolind.2020.106928
- Shonfield J, Bayne E (2017). Autonomous recording units in avian ecological research: Current use and future applications. *Avian Conservation and Ecology* **12**, 14. doi:10.5751/ACE-00974-120114
- Sueur J, Farina A, Gasc A, Pieretti N, Pavoine S (2014). Acoustic Indices for Biodiversity Assessment and Landscape Investigation. *Acta Acustica united with Acustica* **100**, 772–781. doi:10.3813/AAA.918757
- Sugai LSM, Silva TSF, Ribeiro JW, Llusia D (2019). Terrestrial Passive Acoustic Monitoring: Review and Perspectives. *BioScience* **69**, 15–25. doi:10.1093/biosci/biy147
- Tryjanowski P, Morelli F (2015). Presence of Cuckoo reliably indicates high bird diversity: A case study in a farmland area. *Ecological Indicators* **55**, 52–58. doi:10.1016/j.ecolind.2015.03.012
- Tryjanowski P, Morelli F, Osiejuk TS, Møller AP (2018). Functional significance of cuckoo *Cuculus canorus* calls: Responses of conspecifics, hosts and non-hosts. *PeerJ* **2018**, 1–13. doi:10.7717/peerj.5302

- Ware L, Mahon CL, McLeod L, Jetté J-F (2023). Artificial intelligence (BirdNET) supplements manual methods to maximise bird species richness from acoustic data sets generated from regional monitoring. *Canadian Journal of Zoology* **101**, 1031–1051. doi:10.1139/cjz-2023-0044
- Wiens JA, Hayward GD, Holthausen RS, Wisdom MJ (2008). Using surrogate species and groups for conservation planning and management. *BioScience* **58**, 241–252. doi:10.1641/B580310
- Wyllie I (1981). ‘The Cuckoo’. (Universe Books, New York, NY)
- Xia C, Deng Z, Lloyd H, Møller AP, Zhao X, Zhang Y (2019). The function of three main call types in common cuckoo. *Ethology* **125**, 652–659. doi:10.1111/eth.12918
- Yoo S, Kim HN, Lee JW, Yoo JC (2020). Seasonal and diurnal patterns of population vocal activity in avian brood parasites. *Ibis* **162**, 1001–1011. doi:10.1111/ibi.12741
- Zsebők S, Moskát C, Bán M (2017). Individually distinctive vocalisation in Common Cuckoos (*Cuculus canorus*). *Journal of Ornithology* **158**, 213–222. doi:10.1007/s10336-016-1376-9

Suplement Rozdziału 5

Common cuckoo vocalisations as an indicator for the avian diversity

– a study with passive acoustic monitoring

Dominika Winiarska, Łukasz Jankowiak, Piotr Tryjanowski, Tomasz S.

Osiejuk

Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring

Supplementary material

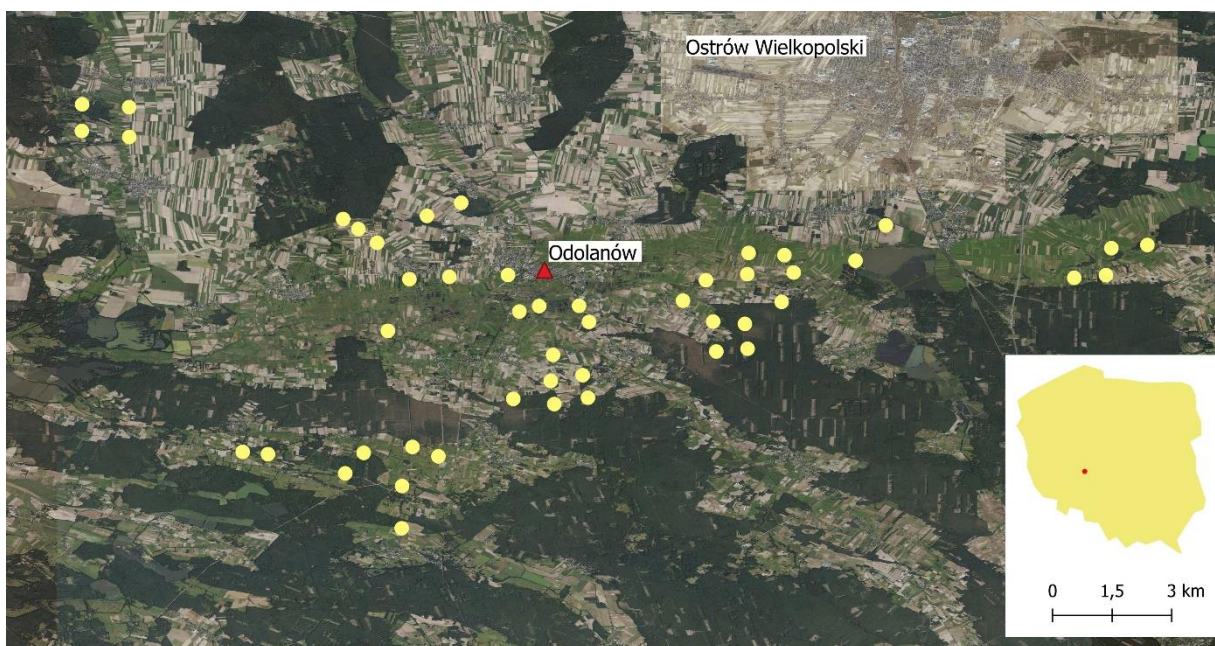


Figure 1. Map of the study site at 51.575° N, 17.676° E, around Odolanów town in Poland. Dots mark 48 study plots where we recorded soundscapes. The map has been created using QGIS software and Geoportal maps (<https://www.geoportal.gov.pl>).

Table S1. Measurements of vocalisations of the cuckoos. We used 20 birds and 70 distinctive vocalisation series done in the study area to determine vocal parameters introduced into automatic recognition software.

Minimum frequency (Hz)	Maximum frequency (Hz)	Duration (s)
453.3 (426.4 – 497.5)	743.1 (690.4 – 832.5)	17.16 (3.7 – 75.9)

Table S2. The list of species detected manually during the 10-minute counts and obtained from 8-hour recordings with the use of BirdNET. Host species names are bolded.

Manual detection	BirdNET
<i>Acrocephalus arundinaceus</i>	<i>Aegithalos caudatus</i>
<i>Acrocephalus palustris</i>	<i>Accipiter gentilis</i>
<i>Acrocephalus schoenobaenus</i>	<i>Acrocephalus arundinaceus</i>
<i>Acrocephalus scirpaceus</i>	<i>Acrocephalus palustris</i>
<i>Aegithalos caudatus</i>	<i>Acrocephalus schoenobaenus</i>
<i>Alauda arvensis</i>	<i>Acrocephalus scirpaceus</i>
<i>Anthus trivialis</i>	<i>Alauda arvensis</i>
<i>Certhia familiaris</i>	<i>Alcedo atthis</i>
<i>Chloris chloris</i>	<i>Anas platyrhynchos</i>
<i>Columba palumbus</i>	<i>Anser anser</i>
<i>Corvus corax</i>	<i>Anthus trivialis</i>
<i>Corvus cornix</i>	<i>Apus apus</i>
<i>Corvus frugilegus</i>	<i>Ardea cinerea</i>
<i>Coturnix coturnix</i>	<i>Buteo buteo</i>
<i>Crex crex</i>	<i>Caprimulgus europaeus</i>
<i>Cuculus canorus</i>	<i>Carduelis carduelis</i>
<i>Curruca communis</i>	<i>Certhia brachydactyla</i>
<i>Cyanistes caeruleus</i>	<i>Certhia familiaris</i>
<i>Emberiza calandra</i>	<i>Chloris chloris</i>
<i>Emberiza citrinella</i>	<i>Chroicocephalus ridibundus</i>
<i>Emberiza hortulana</i>	<i>Ciconia ciconia</i>
<i>Emberiza schoeniclus</i>	<i>Coccothraustes coccothraustes</i>
<i>Erithacus rubecula</i>	<i>Columba livia</i>
<i>Fringilla coelebs</i>	<i>Columba oenas</i>
<i>Grus grus</i>	<i>Columba palumbus</i>
<i>Hippolais icterina</i>	<i>Corvus corax</i>
<i>Lanius collurio</i>	<i>Corvus cornix</i>
<i>Locustella fluviatilis</i>	<i>Corvus frugilegus</i>
<i>Locustella naevia</i>	<i>Corvus monedula</i>
<i>Lullula arborea</i>	<i>Coturnix coturnix</i>
<i>Luscinia luscinia</i>	<i>Crex crex</i>
<i>Luscinia megarhynchos</i>	<i>Cuculus canorus</i>
<i>Motacilla alba</i>	<i>Curruca communis</i>
<i>Motacilla flava</i>	<i>Curruca curruca</i>
<i>Muscicapa striata</i>	<i>Curruca nisoria</i>
<i>Oriolus oriolus</i>	<i>Cyanistes caeruleus</i>
<i>Parus major</i>	<i>Cygnus olor</i>
<i>Passer domesticus</i>	<i>Delichon urbicum</i>
<i>Phasianus colchicus</i>	<i>Dendrocopos major</i>
<i>Phylloscopus collybita</i>	<i>Dendrocopos medius</i>
<i>Phylloscopus trochilus</i>	<i>Dryobates minor</i>

Pica pica
Picus viridis
Poecile montana
Regulus ignicapilla
Saxicola rubicola
Sitta europaea
Streptopelia decaocto
Sturnus vulgaris
Sylvia atricapilla
Turdus merula
Turdus philomelos
Turdus viscivorus
Upupa epops

Dryocopus martius
Emberiza calandra
Emberiza citrinella
Emberiza hortulana
Emberiza schoeniclus
Erithacus rubecula
Falco tinnunculus
Ficedula hypoleuca
Fringilla coelebs
Fulica atra
Galerida cristata
Gallinago gallinago
Gallinula chloropus
Garrulus glandarius
Grus grus
Hippolais icterina
Hirundo rustica
Jynx torquilla
Lanius collurio
Limosa limosa
Linaria cannabina
Locustella fluviatilis
Locustella naevia
Lophophanes cristatus
Loxia curvirostra
Lullula arborea
Luscinia luscinia
Luscinia megarhynchos
Mareca strepera
Milvus milvus
Motacilla alba
Motacilla cinerea
Motacilla flava
Muscicapa striata
Numenius arquata
Nycticorax nycticorax
Oriolus oriolus
Parus major
Passer domesticus
Passer montanus
Periparus ater
Phasianus colchicus
Phoenicurus ochruros
Phoenicurus phoenicurus
Phylloscopus collybita
Phylloscopus sibilatrix
Phylloscopus trochilus
Pica pica
Picus canus
Picus viridis

Poecile montana
Poecile palustris
Prunella modularis
Pyrrhula pyrrhula
Rallus aquaticus
Regulus ignicapilla
Regulus regulus
Remiz pendulinus
Saxicola rubetra
Saxicola rubicola
Scolopax rusticola
Serinus serinus
Sitta europaea
Sterna hirundo
Streptopelia decaocto
Streptopelia turtur
Sturnus vulgaris
Sylvia atricapilla
Sylvia borin
Troglodytes troglodytes
Turdus iliacus
Turdus merula
Turdus philomelos
Turdus pilaris
Turdus viscivorus
Upupa epops
Vanellus vanellus

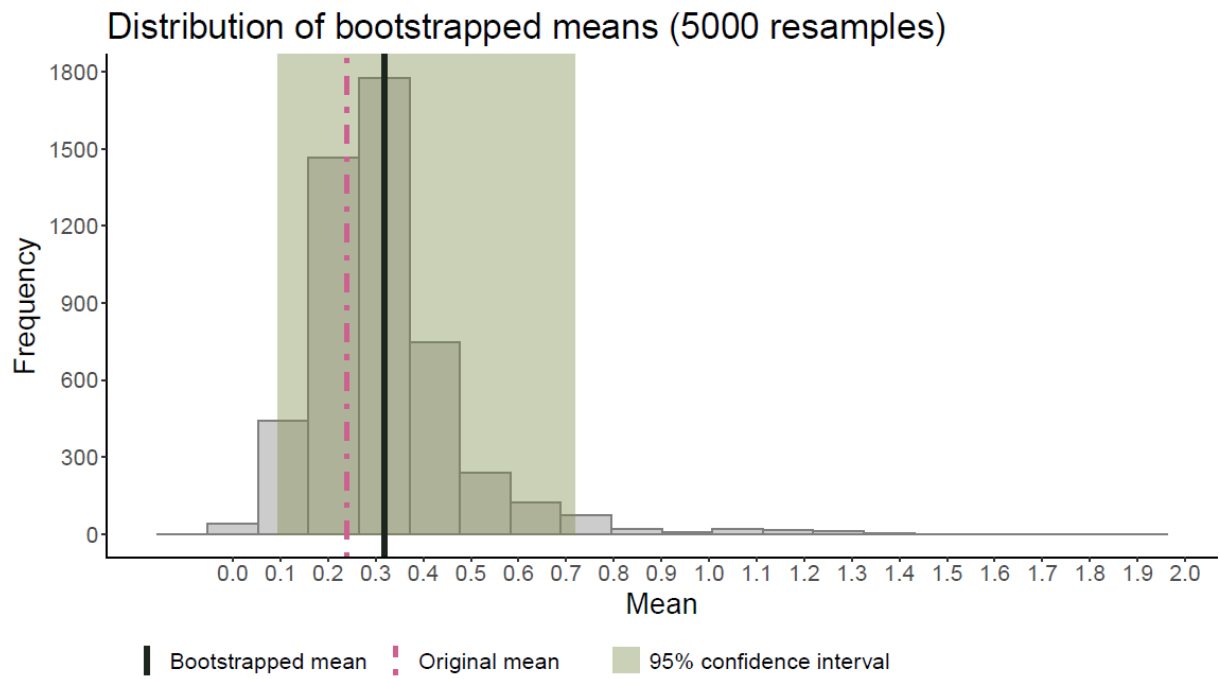


Figure S2. The distribution of the 5000 bootstrapped means obtained from 20 samples taken from our dataset of 48 observations.

Table S3. Rankings of the acoustic indices models examining the relationship between the number of species and cuckoo hosts obtained manually and automatically, with the values of the bioacoustics index (BI) the acoustic diversity index (ADI), and the acoustic complexity index (ACI).

Model	Parameters	AIC	Δ AIC	Weight	Cumulative weights	Log-likelihood
BI ~ hosts automatic	6	5.276	0	0.349	0.349	4.386
BI ~ hosts manual	6	6.059	0.783	0.236	0.584	3.995
BI ~ 1	5	6.525	1.248	0.187	0.771	2.452
BI ~ species automatic	6	6.663	1.386	0.174	0.945	3.693
BI ~ species manual	6	8.979	3.703	0.055	1	2.535
ADI ~ species automatic	6	24.361	0	0.337	0.337	-5.156
ADI ~ 1	5	24.476	0.115	0.318	0.656	-6.524
ADI ~ hosts automatic	6	25.852	1.491	0.160	0.815	-5.902
ADI ~ hosts manual	6	26.850	2.489	0.097	0.913	-6.400
ADI ~ species manual	6	27.060	2.699	0.088	1	-6.505
ACI ~ 1	5	-13.329	0	0.356	0.356	12.379
ACI ~ hosts automatic	6	-12.690	0.639	0.259	0.615	13.369
ACI ~ species automatic	6	-11.761	1.568	0.163	0.778	12.905
ACI ~ species manual	6	-11.155	2.173	0.120	0.898	12.602
ACI ~ hosts manual	6	-10.835	2.493	0.102	1	12.442

Table S4. The results of the Bioacoustics index (BI) model in relation to the host number species obtained automatically differing the most from the null model. Significant outcomes are in bold ($p < 0.05$).

BI ~ hosts automatic	Estimate	Std. Error	z value	p-value
Intercept	-0.440	0.289	-1.523	0.128
Hosts automatic	0.942	0.476	1.977	0.048

Table S5. Variance inflation factor (VIF) values showing collinearity between each variable.

Model: cuckoo vocalisations ~ species automatic + hosts automatic

Variable	VIF	VIF 95% confidence interval
Species automatic	2.81	1.96 – 4.38
Hosts automatic	2.81	1.96 – 4.38

Model: cuckoo vocalisations ~ species manual + hosts manual

Variable	VIF	VIF 95% confidence interval
Species manual	1.48	1.18 – 2.32
Hosts manual	1.48	1.18 – 2.32

Model: cuckoo vocalisations ~ species automatic + species manual + hosts automatic + hosts manual

Variable	VIF	VIF 95% confidence interval
Species automatic	3.60	2.49 – 5.55
Species manual	1.85	1.40 – 2.79
Hosts automatic	3.76	2.59 – 5.81
Hosts manual	2.11	1.56 – 3.19




Figure S3. The number of species and hosts obtained with each method at each study plot regarding acoustic indices values (ACI, ADI, BI) derived from 10-minute recordings used for manual species identification. Lighter points show sites with a higher number of species.

Podsumowanie

Mimo rozpowszechnienia PAM, wciąż nie jest jasne w jaki sposób prowadzić standaryzowane badania z wykorzystaniem tej metody. Moje prace (rozdział 1 i 2) dostarczyły nowych informacji na temat dystansów wykrywania poszczególnych gatunków ptaków w optymalnych warunkach i mogą być wykorzystane jako źródło odniesienia przy planowaniu badań w środowiskach leśnych Europy.

W rozdziale 1 wykazałam, że prawdopodobieństwo wykrycia gatunku zależy od amplitudy wokalizacji, typu lasu, w którym prowadzone są badania, warunków pogodowych oraz ich zmianami w ciągu okresu kwiecień – czerwiec. Ustaliłam też maksymalne dystanse wykrywania 31 gatunków ptaków i wskazałam czynniki mające wpływ na osiągnięte wartości, które okazały się wywierać nieco inny efekt niż w przypadku prawdopodobieństwa detekcji. Ponieważ tak wiele zmiennych oddziałuje na propagację dźwięku, niezwykle istotne było ustalenie które z nich konkretnie mają pozytywny a które negatywny wpływ na dystans wykrywania, co pozwoli na bardziej uważne planowanie badań z użyciem PAM. Choć porównywalność nagrań PAM i pozyskiwanych detekcji między badaniami wykonywanymi w różnych miejscach na pewno w dalszym ciągu będzie podlegała intensywnym badaniom teoretycznym i praktycznym, to na ten moment określenie ekoakustyki danego obszaru poprzez eksperyment z playbackiem wydaje się najlepszym rozwiązaniem (Darras et al. 2016, 2018; Yip et al. 2017). Jednak do czasu osiągnięcia porozumienia w tej kwestii lub ze względu na brak dodatkowych środków pozwalających na przeprowadzenie takich eksperymentów na danym obszarze, wytyczne odnośnie planowania PAM zawarte w mojej pracy ułatwią badaczom projektowanie własnych badań z użyciem tej metody.

W rozdziale 2 wykazałam, że dystans detekcji zależy nie tylko od warunków panujących podczas rejestrowania krajobrazu dźwiękowego, ale także od przyjętej metody wykrywania gatunków. Pomimo długotrwałego czasu analizy, metoda odsłuchowa okazała się najskuteczniejsza, umożliwiając wykrycie gatunków najdalej od źródła dźwięku. Wizualna analiza spektrogramów była mniej czasochłonna niż metoda odsłuchowa, przy niewielkiej redukcji wykryć ptaków. Analiza automatyczna z użyciem BirdNET, mimo jej krótkiego czasu, wykazała najniższą skuteczność, osiągając najmniejszą liczbę poprawnych detekcji, Biorąc pod uwagę ciągły rozwój oprogramowania do automatycznej analizy, metoda automatyczna

najpewniej z czasem zdominuje procesowanie danych akustycznych ze względu na skrócony czas obróbki większej ilości danych. Mimo iż BirdNET jest obecnie powszechnie stosowanym algorytmem umożliwiającym automatyczną detekcję, niniejsza praca jest jedną z pierwszych, które szacują dystanse wykrywania przy jego zastosowaniu. W obliczu rozwoju automatycznej detekcji praca z rozdziału 2 dostarczyła cennych informacji odnośnie tego, z jaką skutecznością wykrywane są ptaki tą metodą, co może przełożyć się na takie planowanie rozmieszczenia rekorderów automatycznych, aby ułatwić wykrywanie większej liczby gatunków i poprawę efektywności badań. W pracy poruszyłam też problematykę porównywalności wykrywania ptaków podczas analizy danych akustycznych różnymi metodami – temat, który do tej pory nie był analizowany w tak dokładny sposób, a który powinien być brany pod uwagę ze względu na możliwe niedoszacowanie aktywności wokalne ptaków.

Pozostałe publikacje wchodzące w skład rozprawy łączą różnorakie zastosowanie PAM w badaniach ptaków, co pokazuje jak wiele możliwości daje ta metoda. W rozdziałach 3 i 4 wykazałam, że dzięki PAM możliwe jest opracowanie wzorców aktywności dla licznie występujących gatunków, ale także dla tych o niższej dostępności. Pozwala to na odkrycie nowych informacji o biologii słabo poznanych gatunków, zwłaszcza w tropikach, które są trudno dostępne i nadal zbadane w niewielkim procencie, oraz daje nadzieję na możliwość dokładniejszego zbadania rzadkich gatunków, które wokalizują sporadycznie. Badania prowadzone przez cały rok generalnie wymagają wielkich nakładów pracy terenowej, jednak dzięki PAM możliwe było zgromadzenie danych z okresu 12 miesięcy w zasadzie bez potrzeby obecności w miejscu badań. W pracach pokazałam, że nawet podobne w obrębie rodzin gatunki wykazują odmienne wzorce aktywności sezonowej lub dziennej; obie prace pokazują także zależności między aktywnością ptaków, a temperaturą i ilością opadów w ciągu roku, co może być przydatne w planowaniu monitoringu, ale też może w przyszłości służyć do oceny wpływu zmian klimatu na czas przystępowania do lęgów. W rozdziale 4 dodatkowo, poza opracowaniem wzorców aktywności dla obu gatunków turakowatych, pokazałam, że PAM jest przydatnym narzędziem w monitoringu zagrożonych gatunków. Technika ta przy regularnym monitoringu ma potencjał do monitorowania zmian liczebności populacji na zdalne wykrycie zmian liczebności, wskazując miejsca pobytu zwierząt, a także potencjalnie wykrywając niepożądaną aktywność ludzi (Astaras et al. 2020).

W rozdziale 5 wykazałam, że używając oprogramowania do automatycznej detekcji na większym zbiorze danych i nieco dłuższym czasie analizy można wykryć wielokrotnie więcej gatunków, niż przy standardowych metodach opracowywania krótkich fragmentów nagrań i

analizy manualnej. Ponieważ PAM pozwala na gromadzenie ogromnych ilości danych, obserwatorzy potrzebowaliby bardzo dużo czasu, równego czasowi trwania nagrań, na ich dokładną analizę. Analiza krótkich odcinków czasowych jest powszechnie stosowana zarówno podczas pracy w terenie, jak i w PAM, ale jak pokazałam w swojej pracy, takie wycinki dają zaniżony obraz występujących na danym obszarze gatunków oraz nie wykazują silnej korelacji z liczbą gatunków uzyskaną z pełnych nagrań. W pracy przetestowałam także skuteczność wskaźników akustycznych w szacowaniu składu gatunkowego, wykazując, że wartości wskaźników jedynie w niewielkim stopniu korelowały z rzeczywistą liczbą gatunków, a tym samym mało wiarygodnie opisywały zróżnicowanie akustyczne badanych obszarów. Ponadto, stosując oprogramowanie do automatycznej detekcji na nagraniach z badanych lokalizacji wykryłam wokalizacje kukułek, które następnie powiązałam z bogactwem gatunkowym ptaków. Jak się okazało, liczba wokalizacji kukułek jest dobrym wskaźnikiem obszarów o wyższej ilości ptaków. Dane zgromadzone przy użyciu PAM pozwoliły mi więc na zbadanie kilku różnych aspektów skuteczności tej metody w monitoringu obszaru rolniczego.

PAM ma wiele zalet i pomimo problemów z porównywalnością, dane uzyskane przy użyciu rekorderów pozwalają na dość dokładne zbadanie obszaru bezpośrednio otaczającego mikrofony. Cały czas też trwają prace nad ustaleniem optymalnego czasu nagrywania, który pozwoliłby na uzyskanie reprezentatywnej próbki gatunków czy liczby wokalizacji odpowiednich do opisanego zagadnienia; jednak w obliczu automatycznej detekcji i opcji skrócenia czasu analizy ogromnych ilości danych, możliwości PAM wydają się nieograniczone. Dzięki temu metoda ta zyskuje zwolenników nawet poza środowiskiem naukowym, m.in. wśród osób przeprowadzających inwentaryzacje i ekspertyzy przyrodnicze; zapewne stanie się powszechnie używana w klasycznym monitoringu obszarów i populacji. Dzięki rozwojowi technik automatycznego rozpoznawania PAM ma szansę na zdominowanie badań monitoringowych. Algorytmy uczenia maszynowego są cały czas rozwijane, więc obecne narzędzia w przyszłości powinny dążyć do maksymalizacji poprawnych detekcji i ograniczenia fałszywych wyników. Przykładem tego jest BirdNET, co pokazuje zwiększenie liczby rozpoznawanych przez to narzędzie gatunków z kilkuset na początku po udostępnieniu programu, do ponad 6000 w dniu dzisiejszym (Wood & Kahl 2024). Uczenie maszynowe jest zależne od liczby oraz jakości próbek dostarczanych do trenowania algorytmu, więc firmy i instytucje oferujące programy do automatycznego rozpoznawania będą dążyć do uzyskania jak najlepszej jakości nagrań, aby ulepszać proces wykrywania. Oprogramowanie wciąż wymaga nadzoru człowieka, choć zapewne z czasem jego praca również ulegnie skróceniu. Powyższe

aspekty czynią PAM skutecznym środkiem do badania środowiska naturalnego oraz gatunków i gromadzenia danych na szeroką skalę, które mogą być wykorzystane na wiele sposobów i po wielu latach.

Bibliografia

- Astaras, C., Linder, J. M., Wrege, P., Orume, R., Johnson, P. J., & Macdonald, D. W. 2020. Boots on the ground: the role of passive acoustic monitoring in evaluating anti-poaching patrols. *Environ. Conserv.*, 47(3), 213–216. <https://doi.org/10.1017/S0376892920000193>
- Darras, K., Furnas, B., Fitriawan, I., Mulyani, Y. & Tschardtke, T. 2018. Estimating bird detection distances in sound recordings for standardizing detection ranges and distance sampling. *Methods Ecol. Evol.* 9: 1928–1938. <https://doi.org/10.1111/2041-210X.13031>
- Darras, K., Pütz, P., Fahrurrozi, Rembold, K. & Tschardtke, T. 2016. Measuring sound detection spaces for acoustic animal sampling and monitoring. *Biol. Conserv.* 201: 29–37. <https://doi.org/10.1016/j.biocon.2016.06.021>
- Wood, C.M., Kahl, S. 2024. Guidelines for appropriate use of BirdNET scores and other detector outputs. *J Ornithol.* <https://doi.org/10.1007/s10336-024-02144-5>
- Yip, D.A., Leston, L., Bayne, E.M., Sólymos, P. & Grover, A. 2017. Experimentally derived detection distances from audio recordings and human observers enable integrated analysis of point count data. *Avian Conserv. Ecol.* 12. <https://doi.org/10.5751/ACE-00997-120111>

Wsparcie finansowe

Badania przedstawione w pracach zawartych w niniejszej rozprawie doktorskiej:

Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>

oraz

Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos. *African Journal of Ecology* 62, e13280. <https://doi.org/10.1111/aje.13280>

zostały sfinansowane przez:

Ministerstwo Edukacji i Nauki - Grant Iuventus Plus nr IP2014 005073,

Narodowe Centrum Nauki - Grant Opus nr UMO-2015/17/B/NZ8/02347,

Projekt UNIWERSYTET JUTRA II – zintegrowany program rozwoju Uniwersytetu im. Adama Mickiewicza w Poznaniu nr POWR.03.05.00-00-Z303/18.



N A R O D O W E C E N T R U M N A U K I

Podziękowania

Dziękuję promotorowi, prof. dr hab. Tomaszowi Osiejukowi, za wzięcie mnie pod swoje skrzydła, kiedy szukałam opiekuna naukowego. Dziękuję także za zaproponowanie tematu, który początkowo mnie przeraził a następnie okazał się fantastyczną przygodą, którą chciałabym kontynuować.

Dziękuję promotorowi pomocniczemu, dr Pawłowi Szymańskiemu, który zawsze oferował mi nieocenione rady, szczególnie w wątpliwościach dotyczących modelowania i statystyki.

Dziękuję dr Kasi Łosak, która nie tylko pomogła mi w pracy terenowej podczas nocnych eksperymentów, ale przede wszystkim oferowała mi swoje wsparcie i pomoc w każdej chwili.

Dziękuję dr hab. Michałowi Budce za udostępnienie mi danych z Kamerunu oraz kibicowanie na każdym etapie doktoratu.

Dziękuję dr Cristianowi Pérez-Granados za przyjęcie mnie na miesięczny staż w Alicante i cenne nauki.

Dziękuję wszystkim pracownikom i doktorantom Zakładu Ekologii Behawioralnej – za długie rozmowy, które zawsze były dla mnie owocne i stworzenie przemiłej atmosfery, w której stale dobrze było przebywać.

I wreszcie, dziękuję mojej Rodzinie za nieustanne wsparcie i doping moich nawet najbardziej szalonych pomysłów. Dzięki Wam mogłam spełnić to marzenie.

Oświadczenia współautorów

Oświadczenie współautora

Oświadczam, że artykuł naukowy:

Winiarska, D., Szymański, P., Osiejuk, TS. 2024. Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Scientific Reports* 14, 894. <https://doi.org/10.1038/s41598-024-51297-z>

którego jestem wiodącą i korespondencyjną autorką, jest częścią mojej rozprawy doktorskiej.

Mój wkład w powstanie tego artykułu to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz napisanie manuskryptu.

10.06.2024 Dominika Winiarska

Data i podpis

moniejk

Podpis promotora

10.06.2024

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., **Szymański, P.**, Osiejuk, TS. 2024. Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Scientific Reports* 14, 894. <https://doi.org/10.1038/s41598-024-51297-z>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz korekta manuskryptu.

10.06.2024 *Szymański*
Data i podpis

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Szymański, P., **Osiejuk, TS**. 2024. Detection ranges of forest bird vocalisations: guidelines for passive acoustic monitoring. *Scientific Reports* 14, 894. <https://doi.org/10.1038/s41598-024-51297-z>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz korekta manuskryptu.

10.06.2024

Data i podpis

Winiarska

Oświadczenie współautora

Oświadczam, że artykuł naukowy:

Winiarska, D., Szymański, P., Osiejuk, TS. Methods of acoustic data processing affect species detectability in passive acoustic monitoring – w recenzji w czasopiśmie Ibis.

którego jestem wiodącą i korespondencyjną autorką, jest częścią mojej rozprawy doktorskiej.

Mój wkład w powstanie tego artykułu to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz napisanie manuskryptu.

10.06.2024 Dominika Winiarska

Data i podpis

Osiejuk

Podpis promotora

10.06.2024

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., **Szymański, P.**, Osiejuk, TS. Methods of acoustic data processing affect species detectability in passive acoustic monitoring – w recenzji w czasopiśmie Ibis.

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz korekta manuskryptu.

10.06.2024 *Szymański*
Data i podpis

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Szymański, P., **Osiejuk, TS**. Methods of acoustic data processing affect species detectability in passive acoustic monitoring – w recenzji w czasopiśmie Ibis.

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, przeprowadzenie eksperymentów terenowych oraz analiz statystycznych, interpretacja wyników oraz korekta manuskryptu.

10.06.2024

Data i podpis

Osiejuk

Oświadczenie współautora

Oświadczam, że artykuł naukowy:

Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>

którego jestem wiodącą i korespondencyjną autorką, jest częścią mojej rozprawy doktorskiej.

Mój wkład w powstanie tego artykułu to:

planowanie badań, dobór metodyki, przeprowadzenie analiz nagrań oraz analiz statystycznych, interpretacja i wizualizacja wyników oraz napisanie manuskryptu i jego korekta.

10.06.2024 Dominika Winiarska

Data i podpis

Winiarska

Podpis promotora

10.06.2024

Co-authorship statement

I declare that in the research article:

Winiarska, D., **Pérez-Granados, C.**, Budka, M., Osiejuk, TS. 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>

of which I am a co-author, Dominika Winiarska is the leading and correspondence author, and my role in it included:

Conceptualization, formal analysis, methodology, writing – review & editing.

Alicante, 10 of June 2024



Dr. Cristian Pérez Granados

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Pérez-Granados, C., **Budka, M.**, Osiejuk, TS. 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

udostępnienie danych, dobór metodyki, interpretacja wyników oraz korekta manuskryptu.

10.06.2024, Michał Budka

Data i podpis

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Pérez-Granados, C., Budka, M., **Osiejuk, TS.** 2024. Year-round vocal activity of two African barbet species. *Emu – Austral Ornithology*, 1–11. <https://doi.org/10.1080/01584197.2024.2352380>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, dobór metodyki, interpretacja wyników oraz korekta manuskryptu.

10.06.2024
Data i podpis
Osiejuk

Oświadczenie współautora

Oświadczam, że artykuł naukowy:

Winiarska, D., Pérez-Granados, C., Budka, M., Osiejuk, TS. 2024. Passive acoustic monitoring of endangered endemic Afrotropical species: a case study with two turacos. *African Journal of Ecology* 62, e13280. <https://doi.org/10.1111/aje.13280>

którego jestem wiodącą i korespondencyjną autorką, jest częścią mojej rozprawy doktorskiej.

Mój wkład w powstanie tego artykułu to:

planowanie badań, dobór metodyki, przeprowadzenie analiz nagrań oraz analiz statystycznych, interpretacja i wizualizacja wyników oraz napisanie manuskryptu i jego korekta.

10.06.2024 Dominika Winiarska

Data i podpis

10.06.2024 Osiejuk

Podpis promotora

Co-authorship statement

I declare that in the research article:

Winiarska, D., **Pérez-Granados, C.**, Budka, M., Osiejuk, TS. 2024. Passive acoustic monitoring of endangered endemic Afrotropical species: a case study with two turacos. *African Journal of Ecology* 62, e13280. <https://doi.org/10.1111/aje.13280>

of which I am a co-author, Dominika Winiarska is the leading and correspondence author, and my role in it included:

Conceptualization, methodology, writing – review & editing.

Alicante, 10 of June 2024

A handwritten signature in blue ink that reads "Cristian". The signature is enclosed within a hand-drawn oval shape.

Dr. Cristian Pérez Granados

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Pérez-Granados, C., **Budka, M.**, Osiejuk, TS. 2024. Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos. African Journal of Ecology 62, e13280. <https://doi.org/10.1111/aje.13280>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

udostępnienie danych, dobór metodyki, interpretacja wyników oraz korekta manuskryptu.

10.06.2024 Michał Budka
Data i podpis

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Pérez-Granados, C., Budka, M., **Osiejuk, TS.** 2024. Passive acoustic monitoring of endangered endemic Afromontane tropical species: a case study with two turacos. African Journal of Ecology 62, e13280. <https://doi.org/10.1111/aje.13280>

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, dobór metodyki, interpretacja wyników oraz korekta manuskryptu.

10.06.2024 *Osiejuk*

Data i podpis

Oświadczenie współautora

Oświadczam, że artykuł naukowy:

Winiarska, D., Jankowiak, Ł., Tryjanowski, P., Osiejuk, TS. Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring.

którego jestem wiodącą i korespondencyjną autorką, jest częścią mojej rozprawy doktorskiej.

Mój wkład w powstanie tego artykułu to:

planowanie badań, dobór metodyki, przeprowadzenie analiz nagrań oraz analiz statystycznych, interpretacja i wizualizacja wyników oraz napisanie manuskryptu i jego korekta.

10.06.2024 *Dominika Winiarska*
Data i podpis

Monika
Podpis promotora
10.06.2024

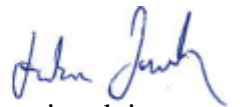
Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., **Jankowiak, Ł.**, Tryjanowski, P., Osiejuk, TS. Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring.

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, dobór metodyki, przeprowadzenie analiz statystycznych, interpretacja wyników oraz korekta manuskryptu.

11.06.2025 

Data i podpis

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Jankowiak, Ł., **Tryjanowski, P.**, Osiejuk, TS. Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring.

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, dobór metodyki, interpretacja wyników oraz korekta manuskryptu.

Data i podpis

10/VII/2024
Pul [Signature]

Oświadczenie współautora

Oświadczam, że w artykule naukowym:

Winiarska, D., Jankowiak, Ł., Tryjanowski, P., **Osiejuk, TS**. Common cuckoo vocalisations as an indicator for the avian diversity – a study with passive acoustic monitoring.

którego jestem współautorem, Dominika Winiarska jest wiodącą i korespondencyjną autorką, a mój wkład w jego powstanie to:

planowanie badań, dobór metodyki, przeprowadzenie analiz nagrań, interpretacja wyników oraz korekta manuskryptu.

10.06.2024
M. Osiejuk

Data i podpis