

JULIA WITCZUK, STANISŁAW PAGACZ

Wpływ cech populacji i środowiska na dokładność i precyzję wyników symulacji lotniczej inwentaryzacji zwierzyny*

Effects of population and habitat characteristics on the accuracy and precision of wildlife aerial surveys results

ABSTRACT

Witczuk J., Pagacz S. 2020. Wpływ cech populacji i środowiska na dokładność i precyzję wyników symulacji lotniczej inwentaryzacji zwierzyny. Sylwan 164 (7): 560-567. DOI: <https://doi.org/10.26202/sylwan.2020023>.

Estimation of population abundance is one of the most difficult tasks in wildlife management. In case of forest-dwelling ungulates, none of the currently available survey methods is satisfying in terms of accuracy, precision, and cost-effectiveness. Therefore, we propose a new method of ungulate monitoring based on distance sampling and using unmanned aerial vehicles equipped with thermal infrared cameras. The method is potentially more reliable and cost-effective than conventional survey techniques. It also allows for aerial surveys in the dark when animals are most active. However, the method needs to be tested before wide-scale implementation in wildlife management practice. While the effects of sampling design and effort on accuracy and precision of abundance estimates are well recognized, the importance of population and habitat characteristics is often overlooked by wildlife managers. We used simulations to assess the effects of population size, animal aggregation, and habitat-dependent detection probability on the accuracy and precision of wildlife aerial survey results. We created 1000 virtual populations defined by population density (2-22 individuals/100 ha), mean group size (1-6 individuals), and probability of animal detection during surveys (proportional to canopy cover, 30-60%). Animals were distributed on a virtual study area (5000 ha) according to randomly generated density distribution. Each population was subjected to 25 simulated surveys using the same design (39 transects grouped in three 2.0×2.5 km blocks). The transects covered 12% of the entire study area. We used conventional distance sampling to estimate abundance and generalized linear models to assess the effect of each parameter on the accuracy and precision of estimates. The estimation accuracy was mostly affected by the probability of detection ($\beta=-0.75$) and, to a lesser degree, by aggregation ($\beta=-0.25$) and population size ($\beta=0.09$). Precision was influenced by the aggregation ($\beta=0.32$) and population size ($\beta=-0.26$), while detection probability had a weaker effect ($\beta=-0.11$). Observed significant differences in quality of abundance estimates derived by the same survey design, but with differing population and habitat characteristics, indicate that each survey requires an individual approach. It is impossible to formulate general recommendations, e.g. concerning flight plan or area coverage. To achieve the required level of precision, while minimizing the survey costs, it is necessary to test alternative survey designs with the aid of computer simulations.

*Badania współfinansowane przez Narodowe Centrum Badań i Rozwoju w ramach 3 Konkursu Programu Badań Stosowanych (umowa nr PBS3/B8/18/2015).

KEY WORDS

bias, drone, simulations, thermal infrared, variability, wildlife monitoring

ADDRESSES

Julia Witczuk – e-mail: juliawit@miiz.eu

Stanisław Pagacz – e-mail: spagacz@miiz.eu

Muzeum i Instytut Zoologii Polskiej Akademii Nauk; ul. Wilcza 64, 00-679 Warszawa

Wstęp

Szacowanie liczebności zwierząt jest jednym z najtrudniejszych zadań gospodarki łowieckiej, a stosowane obecnie metody inwentaryzacji nie są satysfakcjonujące zarówno pod względem dokładności uzyskiwanych wyników, jak i kosztów. Coraz łatwiejszy dostęp do nowoczesnych technologii, takich jak bezzałogowe statki latające (tzw. drony) i kamery termowizyjne, stwarza szanse na opracowanie nowych, bardziej efektywnych metod szacowania liczebności zwierząt. Drony stanowią skuteczną narzędzie inwentaryzacji, upraszczając logistykę prac terenowych, skracając czas potrzebny na ich wykonanie, a także dostarczając trwałych i weryfikowalnych danych w postaci zdjęć lotniczych. W połączeniu z kamerami termowizyjnymi umożliwiają przeprowadzanie inwentaryzacji w warunkach ograniczonej widoczności – o zmierzchu, w nocy i o świcie, czyli w okresie największej aktywności zwierzyny. Prace nad stworzeniem metody inwentaryzacji dzikich kopytnych z wykorzystaniem dronów i termowizji rozpoczęto w 2015 roku we współpracy z firmą Taxus SI [Pagacz, Witczuk 2016; Witczuk i in. 2018]. Dane zbierane były za pomocą samolotu bezzałogowego wyposażonego w kamerę termowizyjną, poruszającego się wzdłuż wyznaczonych uprzednio transektów. Na zarejestrowanych zdjęciach zwierzęta wykrywano specjalnym programem wykorzystującym metody sztucznej inteligencji, a do oszacowania liczebności populacji stosowano metodę „distance sampling” [Buckland i in. 2001].

Przed wprowadzeniem nowej metody inwentaryzacji zwierzyny do powszechnego użycia konieczne jest poznanie zarówno jej możliwości, jak i ograniczeń. Wartość i przydatność metody zależy przede wszystkim od dokładności i precyzji uzyskiwanych za jej pomocą wyników [Pierce i in. 2012]. Dokładność określa stopień rozbieżności pomiędzy oszacowaną a rzeczywistą liczebnością populacji i wyrażona jest błędem systematycznym e (stała tendencja do niedoszacowania lub przeszacowania liczebności). Natomiast precyzja (wyrażona współczynnikiem zmienności CV) to miara rozrzutu uzyskiwanych szacunków przy potencjalnych wielokrotnych powtórzeniach inwentaryzacji w takich samych warunkach. Dokładność i precyzja są od siebie niezależne – metoda może być dokładna (średnia kolejnych szacunków zbliżona jest do rzeczywistej liczebności), ale równocześnie nieprecyzyjna (duże zróżnicowanie wyników kolejnych inwentaryzacji).

Ze względów praktycznych liczenie zwierząt podczas inwentaryzacji prowadzone jest jedynie na części terenu objętego badaniami, czyli na powierzchniach próbnych (także transektach lub punktach). Powszechnie uznaje się istotny wpływ, jaki na dokładność i precyzję oszacowania liczebności mają rozmieszczenie, liczba i wielkość powierzchni próbnych. Zbyt mała liczba lub niereprezentatywność powierzchni próbnych prowadzą do szacunków obciążonych dużym błędem i charakteryzujących się wysoką zmiennością. Inne, rzadziej brane pod uwagę czynniki mogące oddziaływać na dokładność i precyzję wyników inwentaryzacji, związane są z cechami badanych populacji, takimi jak liczebność i stopień agregacji osobników, a także środowiskiem ich bytowania bezpośrednio wpływającym na prawdopodobieństwo wykrycia (obserwacji) zwierząt podczas inwentaryzacji.

Uzyskanie informacji o poziomie dokładności i precyzji danej metody szacowania liczebności, a także o czynnikach je kształtujących wymagałoby wielokrotnego przeprowadzenia inwentaryzacji na obszarze, na którym znana jest rzeczywista liczba osobników, co w praktyce jest bardzo trudne. Podobny efekt można osiągnąć, wykorzystując symulacje komputerowe umożliwiające wygenerowanie wirtualnej populacji o założonych cechach i liczebności, a następnie przeprowadzenie procesu inwentaryzacji według wcześniej przyjętego schematu [Zurell i in. 2010]. Oszacowane wartości liczebności porównywane są z „rzeczywistymi” stanami wirtualnych populacji, a cały proces może być powtórzony wiele razy.

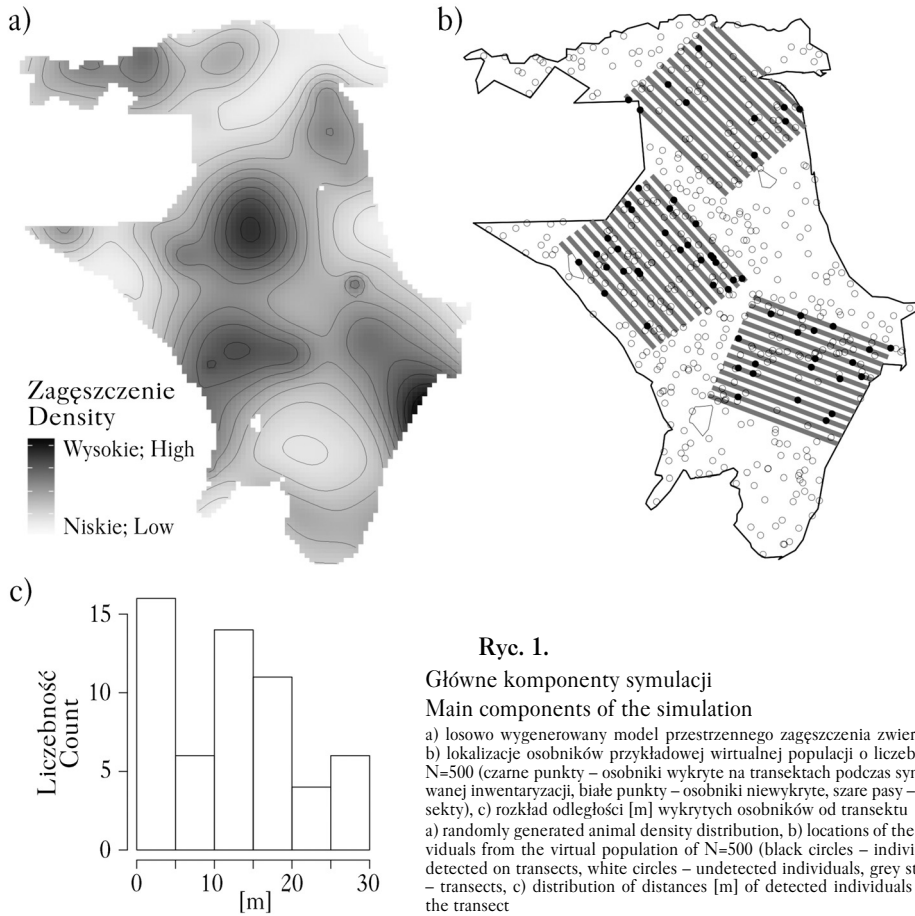
Celem niniejszej pracy było wykorzystanie symulacji komputerowych do zbadania wpływu, jaki na dokładność i precyzję wyników termowizyjnej inwentaryzacji kopytnych samolotem bezzałogowym mają liczebność populacji, stopień agregacji osobników oraz prawdopodobieństwo ich wykrycia. Dwa pierwsze parametry charakteryzują populację podlegającą inwentaryzacji. Zakłada się, że liczebność ma wpływ na wielkość uzyskiwanych prób (liczbę zwierząt obserwowanych na transektach), a przez to na jakość otrzymywanych szacunków. Podobnie stopień agregacji (czyli średnia wielkość grup zwierząt) może mieć wpływ na wielkość prób – przy jednakowej liczebności populacji gatunki mające tendencję do występowania w grupach będą rzadziej spotykane na transektach niż te, które występują pojedynczo. Trzeci parametr – prawdopodobieństwo wykrycia – jest zależny od specyfiki środowiska. Na terenach otwartych zwierzęta są na zdjęciach termowizyjnych wyraźnie widoczne i łatwe do wykrycia. Natomiast w przypadku terenów leśnych niektóre osobniki przebywające pod koronami drzew pozostają niewidoczne dla kamery. Z tego powodu udział terenów otwartych w stosunku do leśnych oraz stopień zwarcia koron drzewostanów może przekładać się na prawdopodobieństwo wykrycia zwierząt podczas inwentaryzacji lotniczej. Poznanie, jak cechy populacji i środowiska wpływają na jakość uzyskiwanych szacunków liczebności, jest kluczowe dla właściwego planowania, a następnie interpretacji wyników inwentaryzacji.

Materiał i metody

Jako wirtualny obszar badań przyjęto Ośrodek Hodowli Zwierzyny w Nadleśnictwie Garwolin o powierzchni około 5 tys. ha (po wyłączeniu terenów uznanych za niedostępne dla zwierzyny).

Był to jeden z obszarów, gdzie przeprowadzano terenowe testy metody. Podczas każdej symulacji inwentaryzacji rozmieszczano w granicach obszaru wirtualną populację zwierząt. Do symulowania rozmieszczenia osobników wykorzystano losowo wygenerowany model przestrzennego zagęszczenia zwierzyny [Marshall 2019]. Model ten był warstwą rastrową, w której do każdej komórki (kwadrat o wymiarach 100×100 m) przypisano wartość zagęszczenia (ryc. 1a). Podczas procesu rozmieszczania osobników wirtualnej populacji o określonej z góry liczebności prawdopodobieństwo „zasiedlenia” danej komórki rastra było wprost proporcjonalne do ustalonej dla niej w modelu wartości zagęszczenia. W ten sposób w symulacjach uzyskano nierównomierne rozmieszczenie zwierząt obserwowane podczas rzeczywistych inwentaryzacji.

Plan lotu symulowanych inwentaryzacji był taki sam jak podczas terenowych testów metody. Ścieżkę lotu samolotu stanowiło 39 transektów zgrupowanych w trzech blokach o wymiarach około 2,0×2,5 km (ryc. 1b). Zgrupowanie transektów w blokach związane było z wymaganą przez przepisy prawne koniecznością przeprowadzania lotów w trybie VLOS, w którym dron przez cały czas znajduje się w zasięgu wzroku operatora lub pomocniczego obserwatora. Przyjęta szerokość transektu (rejestrowanego przez kamerę pasa terenu) wynosiła 54 m, co było minimalną szerokością transektu podczas terenowych testów metody. Łącznie transekty pokryły 12% powierzchni obszaru badań.



Ryc. 1.
Główne komponenty symulacji
Main components of the simulation

a) losowo wygenerowany model przestrzennego zagęszczenia zwierzęcy, b) lokalizacje osobników przykładowej wirtualnej populacji o liczebności N=500 (czarne punkty – osobniki wykryte na transektach podczas symulowanej inwentaryzacji, białe punkty – osobniki niewykryte, szare pasy – transekty), c) rozkład odległości [m] wykrytych osobników od transektu

a) randomly generated animal density distribution, b) locations of the individuals from the virtual population of N=500 (black circles – individuals detected on transects, white circles – undetected individuals, grey stripes – transects, c) distribution of distances [m] of detected individuals from the transect

W pierwszym etapie symulacji wylosowano 1000 zestawów trzech parametrów charakteryzujących 1000 wirtualnych populacji zwierząt oraz środowiska, w których bytują. Parametry te losowane były z równym prawdopodobieństwem z przyjętego wcześniej zakresu wartości. Założono, że liczebność symulowanych populacji (N) będzie zawierać się w przedziale od 100 do 1100 osobników (2-22 os./100 ha). Taki przedział reprezentuje zmienność zagęszczenia różnych gatunków kopytnych obserwowaną na obszarze Polski. Stopień agregacji (μ), wyrażony średnią liczebnością grup zwierząt w populacji, losowany był z przedziału 1-6. W kolejnych iteracjach symulacji wielkość poszczególnych grup losowana była z zero-uciętego rozkładu Poissona o średniej μ charakterystycznej dla danej populacji. Liczebność tak uzyskiwanych grup wynosiła 1-18 osobników. Założono, że średnie prawdopodobieństwo wykrycia (p) na transektach, tożsame z udziałem powierzchni nieprzysłoniętej przez korony drzew, czyli dostępnej dla detekcji, losowane będzie z przedziału 30-60%. Najniższa wartość przedziału (30%) reprezentuje środowiska z niewielkim udziałem terenów otwartych i lasami o dużym zwarceniu koron, a najwyższa (60%) – środowiska o dużym udziale terenów otwartych i/lub lasów z niskim zwarcieniem koron. Przykładowy zestaw parametrów, N=500, $\mu=2$ i p=30%, obrazuje populację o średniej liczebności (10 os./100 ha), w której zwierzęta mają tendencję do występowania pojedynczo lub w niewielkich grupach (średnio po dwa osobniki), a w środowisku, w którym populacja bytuje, tylko 30% powierzchni jest dostępnej dla detekcji.

W drugim etapie każda z 1000 tak zdefiniowanych populacji była rozmieszczana na obszarze badań zgodnie z modelem zagęszczenia zwierzyny. Następnie przeprowadzono 25 powtórzeń symulacji inwentaryzacji danej populacji, zapisując uzyskane dane, m.in. liczbę wykrytych osobników, obserwowaną wielkość grup oraz odległość wykrytych osobników/grup od linii transektu (ryc. 1c). Podczas symulacji prawdopodobieństwo wykrycia zwierzęcia (lub grupy zwierząt) było niezależne od odległości, w jakiej znajdowało się ono od linii transektu. Następnie na podstawie tak uzyskanych danych oszacowywano liczebności każdej z 1000 populacji metodą „distance sampling”. W analizach wykorzystano podstawowe modele funkcji prawdopodobieństwa wykrycia bazujące na funkcjach „half-normal” i „hazard-rate” [Buckland i in. 2001]. Głównymi wynikami analiz były szacowana liczebność populacji i towarzyszący jej współczynnik zmienności. Uśrednione wartości liczebności i współczynnika zmienności z 25 symulowanych inwentaryzacji poszczególnych populacji porównywano z „rzeczywistymi” stanami liczebnymi wirtualnych populacji. Symulacje wykonano, wykorzystując funkcje pakietu DSSim [Marshall 2019] pracującego w środowisku R (www.r-project.org). W celu określenia, który z parametrów (N , μ , p) najistotniej wpływa na dokładność i precyzję wyników szacowania liczebności, porównano szereg uogólnionych modeli liniowych uwzględniających różne kombinacje parametrów, włącznie z ich interakcjami. Przed analizą dane zostały zeskalarowane, aby odchylenie standardowe wszystkich zmiennych miało wartość 1. Selekcji modeli dokonywano na podstawie wartości wskaźnika AIC.

Wyniki

W przypadku 159 z 1000 populacji liczba osobników zaobserwowanych podczas symulowanych inwentaryzacji była zbyt mała, aby umożliwić oszacowanie liczebności. Z tego względu analizy oparto o wyniki uzyskane dla pozostałych 841 populacji.

Wszystkie rozpatrywane parametry miały wpływ na dokładność i precyzję wyników inwentaryzacji. Najlepszym dopasowaniem charakteryzowały się modele uwzględniające wszystkie trzy czynniki oraz jedną zmienną dodatkową będącą interakcją dwóch z nich (tab.). Dokładność szacunków zdecydowanie zwiększała się wraz ze wzrostem prawdopodobieństwa wykrycia (mniejsza bezwzględna wartość błędu, $\beta = -0,75$, ryc. 2e). Ponadto, jednak w znacznie mniejszym stopniu, dokładność wzrastała przy wyższym stopniu agregacji osobników ($\beta = -0,25$, ryc. 2c). Natomiast przy wzroście liczebności populacji obserwowano nieznaczny spadek dokładności szacunków ($\beta = 0,09$, ryc. 2a). Największy wpływ na precyzję wyników inwentaryzacji miał stopień agregacji – najbardziej precyzyjne wyniki uzyskiwano przy jej niskim stopniu ($\beta = 0,32$, ryc. 2d).

Tabela.

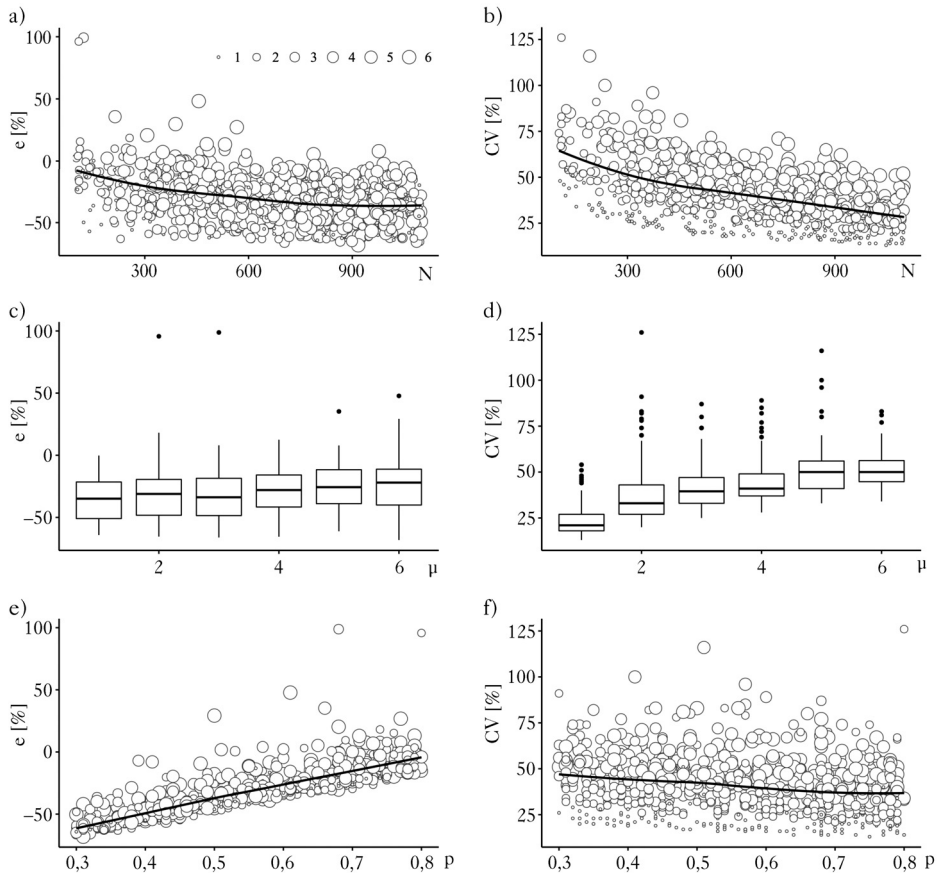
Współczynniki regresji najlepiej dopasowanych uogólnionych modeli liniowych wyjaśniających zależność dokładności i precyzji wyników lotniczej inwentaryzacji zwierzyny od liczebności populacji (N), stopnia agregacji osobników (μ) oraz prawdopodobieństwa wykrycia (p)

Coefficients of regression of the best fitted generalized linear models exploring effects of population size (N), animal aggregation (μ) and detection probability (p) on the accuracy (Dokładność) and precision (Precyzja) of wildlife aerial survey results

| | Dokładność | Precyzja |
|---------|------------|----------|
| N | 0,09** | -0,26*** |
| μ | -0,25*** | -0,32*** |
| p | -0,75*** | -0,11*** |
| $\mu:p$ | - | -0,01* |
| $\mu:N$ | 0,03* | - |

istotność: *** $\alpha < 0,001$; ** $\alpha < 0,01$; * $\alpha < 0,05$

significance: *** $\alpha < 0,001$; ** $\alpha < 0,01$; * $\alpha < 0,05$



Ryc. 2.

Zależność pomiędzy liczebnością populacji (N; a, b), stopniem agregacji osobników (μ ; c, d) oraz prawdopodobieństwem wykrycia (p; e, f) a dokładnością i precyzją wyników lotniczej inwentaryzacji zwierzyny na podstawie 25 powtórzeń symulacji inwentaryzacji dla każdej z 841 wirtualnych populacji

Effect of population size (N; a, b), animal aggregation (μ ; c, d) and detection probability (p; e, f) on accuracy and precision of wildlife aerial survey results based on 25 iterations of a simulated surveys for each of 841 virtual populations

e – średnia względna różnica między oszacowaną a rzeczywistą liczebnością populacji; CV – stosunek błędu standardowego do oszacowanej liczebności; wielkość „bąbli” odpowiada średniej wielkości grupy (legenda w panelu a); linie trendu uzyskano za pomocą regresji lokalnie ważonej (LOESS)

e – relative difference between estimated and known population size, CV – ratio of standard error to estimated population size; bubble size is proportional to the average animal group size in population (legend in panel a); trend lines obtained with local regression (LOESS)

Ponadto bardziej precyzyjne wyniki uzyskiwano wraz ze wzrostem liczebności populacji ($\beta=-0,26$, ryc. 2b). Prawdopodobieństwo wykrycia zwierząt miało mniejszy wpływ na precyzję wyników niż zagęszczenie i stopień agregacji ($\beta=-0,11$, ryc. 2f). Interakcje parametrów, chociaż istotne statystycznie, miały marginalny wpływ na zmiany dokładności ($\beta=0,03$) i precyzji wyników ($\beta=0,01$).

Dyskusja

Przeprowadzone symulacje pokazują, w jak dużym stopniu jakość wyników termowizyjnej inwentaryzacji zwierzyny samolotami bezzałogowymi zależy od cech badanych populacji i środowiska ich bytowania. Dla dokładności szacunków kluczowe znaczenie ma prawdopodobieństwo wykrycia zwierząt, wynikające głównie ze stopnia przystońnięcia dna lasu przez korony drzew i podszyt.

Aby skorygować niedoszacowanie liczebności populacji powodowane niedostępnością zwierząt ukrytych pod koronami, podczas rzeczywistych inwentaryzacji stosuje się współczynniki korekcyjne. Współczynniki te oparte są na danych o zwarcie koron oraz udziale terenów otwartych na badanych transektach, które można pozyskać ze zdjęć termowizyjnych rejestrowanych podczas inwentaryzacji. W sytuacjach, w których nie stosuje się wskaźników korekcyjnych, szacunki uzyskiwane podczas termowizyjnej inwentaryzacji lotniczej należy traktować jako minimalne wartości zagęszczenia zwierzyny na danym terenie.

Druga wartość charakteryzująca uzyskiwane szacunki – precyzja – jest nie mniej ważna niż dokładność, gdyż od niej zależy, czy wyniki inwentaryzacji mogą być użyte do określenia wieloletniego trendu zmian liczebności badanych populacji [Pierce i in. 2012]. Należy zauważyć, że w zależności od założonych cech symulowanych populacji wartość współczynnika zmienności uzyskiwanych szacunków ulegała dużym wahaniom. W przypadku populacji o największym zagęszczeniu (22 os./100 ha) współczynnik zmienności miał stosunkowo niską wartość – średnio około 30%, podczas gdy dla populacji o najmniejszym zagęszczeniu (2 os./100 ha) jego średnia wartość wzrastała do około 60% (ryc. 2b). Podobnie duże różnice w precyzji szacunków wystąpiły w populacjach różniących się stopniem agregacji. Dla populacji, w której osobniki występowały pojedynczo, średnia wartość współczynnika zmienności wynosiła około 20%, podczas gdy dla populacji o wysokim stopniu agregacji ($\mu=6$) średnia wzrastała do około 50% (ryc. 2d). Jeżeli porówna się poszczególne symulowane populacje, wspólny efekt zagęszczenia i agregacji jeszcze bardziej spotęguje różnice w poziomie precyzji. Przykładowo wartości współczynnika zmienności szacunków dla populacji o dużym zagęszczeniu i stopniu agregacji 1 osiągały poziom poniżej 20%, podczas gdy w niektórych przypadkach populacji mało liczebnych i o wysokim stopniu agregacji wartość współczynnika zmienności sięgała ponad 100% (ryc. 2b).

Uzyskane wyniki w dużym stopniu można uznać za uniwersalne. Symulacje inwentaryzacji afrykańskich kopytnych przeprowadzone przez Nuno i in. [2013], pomimo zastosowania innych metod szacowania liczebności, wykazały istnienie podobnych zależności pomiędzy dokładnością i precyzją wyników a wykrywalnością zwierząt oraz ich zagęszczeniem i stopniem agregacji. Znaczące różnice w jakości szacunków wynikające z określonych cech inwentaryzowanych populacji i ich środowiska, pomimo zastosowania dokładnie tego samego schematu inwentaryzacji, oznaczają, że niemożliwe jest formułowanie uniwersalnych zaleceń na przyszłość (np. co do procentu powierzchni badanego obszaru, jaki należy objąć nalotami). Ponadto przy jednoczesnej inwentaryzacji kilku gatunków zwierząt należy spodziewać się odmiennej precyzji szacunków liczebności dla gatunków mniej skłonnych do agregacji (takich jak sarna) niż dla tych występujących na ogół w większych grupach (jak jeleń czy dzik). Każda inwentaryzacja wymaga indywidualnego podejścia – w pierwszej kolejności określenia oczekiwań co do poziomu precyzji szacunków dla poszczególnych gatunków, a następnie takiego zaplanowania szczegółów inwentaryzacji, aby osiągnąć zamierzony cel. Symulacje komputerowe są przydatnym narzędziem optymalizacji planów inwentaryzacji i monitoringu zwierząt [Witczuk i in. 2008; Nuno i in. 2013]. Umożliwiają one racjonalny wybór takiego wariantu inwentaryzacji (w tym wypadku planu lotu, procentu powierzchni objętej nalotami lub liczby powtórzeń nalotów), który zapewni uzyskanie wymaganej precyzji szacunków przy najbardziej optymalnym wykorzystaniu czasu i środków. Niezbędne dane potrzebne do przeprowadzenia symulacji – udokumentowane w przeszłości wartości zagęszczeń zwierzyny na obszarze zainteresowania oraz wielkości grup (chmar/watah) – mogą być zaczerpnięte z planów łowieckich. Z kolei dane o czynnikach środowiskowych, takie jak udział terenów otwartych, proporcje typów drzewostanów (iglastych w stosunku do liściastych) czy zwarcie koron, można uzyskać od jednostek zarządzających lasami na badanym terenie lub pobrać z ogólnodostępnych

baz danych teledetekcyjnych (np. program Copernicus LMS). Wyniki inwentaryzacji zaplanowanych jedynie z myślą o minimalizacji kosztów prac terenowych, bez uwzględnienia cech danego środowiska i populacji oraz ustalenia docelowego poziomu precyzji szacunków, w większości przypadków będą zbyt nieprecyzyjne, aby mogły być w jakikolwiek sposób użyteczne przy planowaniu gospodarki łowieckiej.

Literatura

- Buckland S. T., Anderson D. R., Burnham K. P., Laake J. L., Borchers D. L., Thomas L. 2001. Introduction to distance sampling: Estimating abundance of biological populations. Oxford University Press, Oxford.
- Marshall L. 2019. DSSim: Distance sampling simulations. R package version 1.1.4.
- Nuno A., Bunnefeld N., Milner-Gulland E. J. 2013. Matching observations and reality: using simulation models to improve monitoring under uncertainty in the Serengeti. *Journal of Applied Ecology* 50 (2): 488-498. DOI: <https://doi.org/10.1111/1365-2664.12051>.
- Pagacz S., Witeczuk J. 2016. Wykorzystanie samolotów bezzałogowych i termowizji do nocnej inwentaryzacji kopytnych. *Studia i Materiały CEPL* 49A: 50-57.
- Pierce B. L., Lopez R. R., Silvy N. J. 2012. Estimating animal abundance. W: Silvy N. J. [red.]. *The wildlife techniques manual: Research*. The Johns Hopkins University Press, Baltimore, Maryland. 284-310.
- Witeczuk J., Pagacz S., Mills L. S. 2008. Optimising methods for monitoring programs: Olympic marmots as a case study. *Wildlife Research* 35 (8): 788-797. DOI: <https://doi.org/10.1071/WR07187>.
- Witeczuk J., Pagacz S., Zmarz A., Cypel M. 2018. Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests – preliminary results. *International Journal of Remote Sensing* 39 (15-16): 5504-5521. DOI: <https://doi.org/10.1080/01431161.2017.1390621>.
- Zurell D., Berger U., Cabral J. S., Jeltsch F., Meynard C. N., Münkemüller T., Nehrbass N., Pagel J., Reineking B., Schröder B., Grimm V. 2010. The virtual ecologist approach: simulating data and observers. *Oikos* 119 (4): 622-635. DOI: <https://doi.org/10.1111/j.1600-0706.2009.18284.x>.