Artur Nowicki 厄 0000-0003-3801-8137 Maciei Janecki 应 0000-0002-8784-2862 Lidia Dzierzbicka-Głowacka D 0000-0001-6151-2390 INSTYTUT OCEANOLOGII POLSKIEJ AKADEMII NAUK W SOPOCIE adres e-mail do korespondencji: anowicki@iopan.pl DOI: 10.26408/FindFISH-08

8. ASYMILACJA DANYCH SATELITARNYCH ORAZ ŚRODOWISKOWYCH W MODELU ECOFISH

EcoFish

Zatoka Gdańska to akwen w południowo-wschodniej części Bałtyku o powierzchni około 6300 km², średniej głębokości około 50 m i maksymalnej 118 m. Zasolenie w Zatoce wynosi około 7-8. Niewielka wartość zasolenia oraz eutrofizacja Zatoki wynikają z jej zasilania dopływami słodkich, bogatych w substancje odżywcze wód rzecznych. Z drugiej strony obserwuje się wlewy wód z Morza Północnego. Warunki atmosferyczne nad Bałtykiem także są zmienne, zarówno w czasie, jak i w przestrzeni. Wszystkie te czynniki powodują dużą dynamikę zjawisk hydrodynamicznych, chemicznych i biologicznych w tym akwenie, co sprawia, że ich modelowanie jest skomplikowane, a osiągnięcie poprawnych wyników wymaga odpowiedniej konfiguracji oraz precyzyjnej parametryzacji modelu. Ponadto dane wykorzystywane przez model, m.in. dane meteorologiczne, dane na granicy oraz dane dotyczące dopływów rzecznych, muszą się cechować dużą dokładnością, aby nie prowadzić do niepoprawnych kalkulacji. Spełnienie tych wszystkich warunków jest bardzo trudne, a czasami wręcz niemożliwe ze względu na brak dostępu do danych, ograniczenia związane z mocą obliczeniową lub zbyt długi czas obliczeń uniemożliwiający przetestowanie wielu różnych kombinacji parametrów modelu. Jednym ze sposobów polepszenia wyników modelu jest asymilacja danych pomiarowych z różnych źródeł, co pozwala niwelować ewentualne odchylenia modelu od rzeczywistych warunków, które ma symulować. Proces ten pozwala na uzyskanie wyników modelowych bardziej zgodnych ze stanem danego ekosystemu wynikającym z pomiarów. Dostępnych jest wiele różnych metod asymilacji, wykazujących się różnego rodzaju właściwościami. Do prostszych należą m.in. metoda optymalnej interpolacji (Gandin, 1963) lub metoda wykorzystująca schemat Cressmana (Cressman, 1959), zastosowana do asymilacji danych



ogram Regionalny





Unia Europejska Europejski Fundusz zwoju Regionalnego Rozy



satelitarnych w modelu 3D CEMBS (Nowicki i in., 2015, 2016), który jest źródłem danych na granicę modelu EcoFish. Bardziej złożone metody to metody wariacyjne 3D-Var (Courtier i in., 2006; Rabier i in., 2006; Andersson i in., 1998) czy też 4D-Var oraz filtry Kalmana i ich modyfikacje (Fisher i Andersson, 2001). Aby poprawić jakość wyników otrzymywanych z modelu EcoFish, a jednocześnie zachować dobra wydajność modelu, opracowano nowe moduły asymilacji oparte na mechanizmach wymuszeń dostępnych w modelu Community Earth System Model (CESM). Moduły te umożliwiaja asymilacje różnych parametrów, takich jak temperatura, koncentracja chlorofilu a, rozpuszczony tlen oraz stężenia biogenów NH_4 , NO_3 i PO_4 . Dane do asymilacji pochodza z pomiarów satelitarnych przetworzonych oraz udostępnionych w ramach projektu SatBałtyk (Woźniak i in., 2011a, 2011b), pomiarów in situ wykonywanych przez WIOS oraz pomiarów wykonywanych sondą Valeport Midas CTD zakupioną w ramach projektu FindFISH (Dzierzbicka i in., 2018) i wykorzystywaną w czasie rejsów rybackich. W związku z tym dane te mają różnorodny charakter i wymagają zastosowania różnych procesów przygotowania, tak aby mogły zostać wykorzystane przez model w procesie asymilacji. W kolejnych podrozdziałach skupiono się na procesie asymilacji oraz na uzyskanych dzięki niemu rezultatach. Przedstawiono zastosowana w modelu EcoFish metode asymilacji oraz weryfikacje jej działania. Walidacja otrzymanych wyników modelowych została omówiona w opracowaniach Janeckiego, Dybowskiego, Nowickiego, Jakackiego i Dzierzbickiej-Głowackiej (2023) oraz Janeckiego, Dybowskiego, Nowickiego i Dzierzbickiej-Głowackiej (2023).

Proces pozyskiwania i przetwarzania danych wykorzystanych do asymilacji szerzej opisano w opracowaniu Nowickiego, Janeckiego, Dybowskiego i Dzierzbickiej-Głowackiej (2023).

8.1. METODY

8.1.1. Opis modułu asymilacji danych satelitarnych

Asymilacja danych w modelu EcoFish polega na wprowadzeniu do niego informacji pochodzących z różnych źródeł zewnętrznych, takich jak zdalne pomiary satelitarne i środowiskowe dokonywane *in situ*. Celem zastosowania asymilacji było zwiększenie poprawności otrzymanych wyników obliczeń modelowych. Za asymilację każdego z parametrów w modelu EcoFish odpowiadają oddzielne moduły, dzięki czemu każdy z nich można niezależnie parametryzować, włączać lub wyłączać, a w przyszłości w razie potrzeby pozwoli to na łatwe dołączenie kolejnych modułów. Każdy z tych modułów oparty jest na zmodyfikowanych i rozbudowanych komponentach wchodzących w skład modelu POP (Smith i Gent, 2004) będącego







Unia Europejska Europejski Fundusz Rozwoju Regionalnego



częścią CESM. Moduły te są integralną częścią modelu EcoFish. Najważniejsze modyfikacje modułów dotyczyły wprowadzenia możliwości asymilacji danych powierzchniowych i danych z różnych głębokości w jednym wspólnym module oraz sposobu wyznaczania obecności danych przy pomocy dynamicznych masek binarnych. Posłużenie się już istniejącymi komponentami pozwoliło na użycie wielu dostępnych już w modelu ustawień umożliwiających parametryzację m.in. długości okna asymilacji czy częstości asymilacji oraz na wykorzystanie przez model wbudowanych modułów odczytu danych. Zaimplementowana w modelu EcoFish metoda asymilacji (Janecki i in., 2021) daje możliwość wprowadzania do modelu asymilowanych zmiennych z określoną, konfigurowalną częstotliwością, np. co każdy krok obliczeniowy modelu, raz na godzinę itp. Pozwala to zachować ciągłość zmienności asymilowanych zmiennych. Jako dane wejściowe moduł asymilacji przyjmuje wartości danej zmiennej otrzymane z obliczeń modelu V_{mod} oraz z pomiarów V_r . Ponadto metoda wykorzystuje szereg parametrów kontrolujących jej zachowanie i opisujących źródło danych. Oto najważniejsze z nich:

- *data_type* częstotliwość pojawiania się danych pozwala określić, z jaką częstotliwością pojawiają się dane do asymilacji, np. co rok, co miesiąc, co N godzin;
- *data_inc* w przypadku danych pojawiających się co N godzin określa liczbę N;
- *interp_freq* określa, jak często informacja z danych asymilowanych jest wprowadzana do wyników modelowych, np. co N godzin, co każdy krok czasowy;
- *interp_type* określa sposób, w jaki dane asymilacyjne są interpolowane pomiędzy częstotliwością wynikającą z *data_type* a tą wynikającą z *interp_freq*. Możliwymi opcjami są: algorytm najbliższego sąsiada, interpolacja liniowa oraz interpolacja wielomianowa trzeciego rzędu z wykorzystaniem czterech najbliższych punktów na osi czasu;
- *interp_inc* określa, z jaką częstotliwością obliczane są różnice pomiędzy danymi modelowymi i pomiarowymi;
- *restore_tau* określa, po jakim czasie wyniki modelu powinny osiągnąć wartość zgodną z wprowadzonymi danymi pomiarowymi.

Z każdym krokiem obliczeniowym każdy moduł asymilacji sprawdza, na podstawie parametrów *data_type* oraz *data_inc*, czy w danym kroku powinny się pojawić nowe dane asymilacyjne. Jeśli tak, to wczytuje kolejny plik z danymi asymilowanymi V_r i wylicza różnicę dV między tymi danymi a danymi modelowymi V_{mod} . Załóżmy przykładowo, że dane pojawiają się raz dziennie. Oczywiście wyliczona różnica dV nie powinna zostać wprowadzona do modelu na raz, w jednym kroku czasowym, gdyż zachwiałoby to ciągłość obliczeń oraz równowagę systemu. Stąd też przy pomocy parametru *interp_freq* można ustalić, żeby dane były wprowadzane stopniowo, co określony czas. Z kolei za pomocą parametru *restore_tau* można określić, po jakim okresie od rozpoczęcia asymilacji model powinien









osiągnąć wartości asymilowane. Mając te parametry, moduł dzieli aktualną różnicę dV na liczbę kroków wynikających z *inter_freq*, które mieszczą się w okresie *restore_tau*. W ten sposób otrzymuje się parametr dV_{step} , będący częściowym przyrostem wartości danej zmiennej, który zostanie wprowadzony do modelu w danym kroku asymilacyjnym.

$$dV_{step} = \frac{interp_freq}{restore_tau} (V_r - V_{mod}) = \frac{interp_freq}{restore_tau} dV$$
(8.1)

Wartość danej zmiennej modelowej zależy od wielu czynników, np. transportu, promieniowania, procesów biologicznych itp. W związku z tym wyliczona na początku różnica *dV* pomiędzy danymi modelowymi i pomiarowymi musi być cały czas korygowana, tak aby na końcu okna asymilacyjnego otrzymać oczekiwaną wartość. Stąd też jest ona aktualizowana według wzoru (8.1) z częstotliwością określoną poprzez parametr *interp_inc*. Wynikową wartość asymilowanej zmiennej w danym kroku czasowym oblicza się poprzez dodanie obliczonego przyrostu do wyniku modelowego.

$$V_{assim} = V_{mod} + dV_{step} \tag{8.2}$$

8.2. REZULTATY

8.2.1. Weryfikacja metody asymilacji danych

W celu sprawdzenia poprawności działania zastosowanej metody asymilacji przeprowadzono weryfikację wyników modelu. Polegała ona na porównaniu wyników modelu bez asymilacji i modelu z asymilacją względem danych, które zostały wykorzystane do asymilacji. Jeśli metoda asymilacji działa poprawnie, to wyniki modelu z asymilacją powinny być bliższe wynikom satelitarnym niż dane modelu bez asymilacji. W przypadku danych satelitarnych weryfikację przeprowadzono dla pomiarów zarówno temperatury powierzchniowej, jak i koncentracji chlorofilu a. W przypadku danych środowiskowych weryfikację otrzymanych wyników przeprowadzono w analogiczny sposób dla temperatury mierzonej przy użyciu sondy Midas oraz dla rozpuszczonego tlenu i substancji biogenicznych pochodzących z pomiarów wykonanych przez WIOŚ. Aby wyniki asymilacji z poszczególnych źródeł wzajemnie na siebie nie wpływały, do weryfikacji każdego z parametrów wykorzystano oddzielny model asymilujący tylko dane satelitarne lub środowiskowe. Przedstawione wyniki weryfikacji oparto na przebiegach modelu na danych z roku 2018. Pierwszym krokiem weryfikacji było wizualne porównanie przykładowych wyników. Kolejne rysunki przedstawiają wyniki weryfikacji.











Na rys. 8.1 widać przykładowe wyniki weryfikacji asymilacji temperatury satelitarnej. Po lewej stronie przedstawiono wyniki modelu bez asymilacji, w środku pomiary satelitarne, a po prawej wyniki modelu z asymilacją. Na tym przykładzie widać wyraźnie wpływ temperatury z pomiarów satelitarnych na wyniki modelu. Temperatura w środkowej części Zatoki Gdańskiej, w miejscu, gdzie dostępne są dane satelitarne, jest znacznie niższa. Rys. 8.2 przedstawia różnicę między modelem bez asymilacji i z asymilacją a danymi satelitarnymi. Zgodnie z oczekiwaniami różnica ta jest niższa na prawym rysunku, który przedstawia wyniki dla modelu z asymilacją. Na podstawie wskazanych przykładów można zatem wnioskować, że algorytm asymilacji działa poprawnie, gdyż wyniki modelu z włączoną asymilacją są bliższe wynikom satelitarnym niż wyniki modelu bez asymilacji.



Rys. 8.1. Porównanie danych SST z różnych źródeł. Lewa strona – model bez asymilacji, środek – dane satelitarne, prawa strona – model z asymilacją źródło: opracowanie własne IO PAN.



Rys. 8.2. Różnica SST między modelem bez asymilacji i z asymilacją a danymi satelitarnymi. Lewa strona – model bez asymilacji, prawa strona – model z asymilacją Źródło: opracowanie własne IO PAN.







Analogiczne wyniki dla koncentracji chlorofilu a mierzonej z satelity przedstawiają rys. 8.3 oraz 8.4. W tym wypadku również widać, że – analogicznie do poprzedniego przykładu – wyniki modelu z asymilacją dobrze odwzorowują wyniki pomiarów satelitarnych, a różnice pomiędzy modelem z asymilacją a danymi satelitarnymi są mniejsze niż między modelem bez asymilacji a tymi danymi. Można zatem przyjąć, że algorytm asymilacji działa poprawnie również w przypadku danych dotyczących chlorofilu a.



Rys. 8.3. Porównanie danych dotyczących chlorofilu *a* z różnych źródeł. Lewa strona – model bez asymilacji, środek – dane satelitarne, prawa strona – model z asymilacją Źródło: opracowanie własne IO PAN.



Rys. 8.4. Różnica stężeń chlorofilu *a* między modelem bez asymilacji i z asymilacją a danymi satelitarnymi. Lewa strona – model bez asymilacji, prawa strona – model z asymilacją

Źródło: opracowanie własne IO PAN.

Na rys. 8.5 zaprezentowano przykładowe wyniki asymilacji temperatury mierzonej przy pomocy sondy Midas w trakcie jednego z rejsów. Lewa część ukazuje trasę rejsu, z kolei środkowa i prawa przedstawiają odpowiednio wyniki modelu bez asymilacji i z asymilacją. W tym przypadku wartości danych rejsowych nie zostały pokazane, gdyż i tak nie byłyby widoczne na rysunku. Weryfikację liczbową natomiast przedstawiono w dalszej części tego rozdziału. Niemniej







na mapie modelu z asymilacją widać zmianę temperatury wzdłuż trasy rejsu. Wprawdzie zmiana ta jest niewielka, ale wystarczająca, by stwierdzić, że model i w tym przypadku asymilował dane środowiskowe.



Rys. 8.5. Trasa sondy pomiarowej na głębokości 3 m z dnia 22.09.2018. Lewa strona – trasa sondy, środek – model bez asymilacji, prawa strona – model z asymilacją Źródło: opracowanie własne IO PAN.

Kolejnym źródłem danych środowiskowych po pomiarach z sondy Midas są wyniki pomiarów zgromadzonych przez WIOŚ. Dane te mają charakter punktowych pomiarów wykonywanych kilka razy w ciągu roku. W związku z tym nie można ich przedstawić w postaci map, gdyż nie będą one na nich widoczne. Aby jednak pokazać, że sam mechanizm asymilacji działa poprawnie, na rys. 8.6–8.9 zamieszczono kilka przykładowych wykresów prezentujących zmierzone wartości poszczególnych parametrów oraz przebiegi czasowe obliczone przez model bez asymilacji i z asymilacją w punkcie dokonania pomiaru. Na każdym z wykresów dane pomiarowe przedstawione są kolorem czarnym, wyniki modelu bez asymilacji – kolorem czerwonym, a modelu z asymilacją – kolorem zielonym.









Rys. 8.6. Przykładowy przebieg modelu dla NH4

Źródło: opracowanie własne IO PAN.





Źródło: opracowanie własne IO PAN.









Rys. 8.8. Przykładowy przebieg modelu dla O2

Źródło: opracowanie własne IO PAN.





Źródło: opracowanie własne IO PAN.







Jak widać na powyższych wykresach, wartości obliczone z wykorzystaniem modelu z asymilacją w każdym przypadku są bliższe pomiarom środowiskowym. Można jednak zauważyć, że efekt asymilacji nie jest bardzo duży, wyniki modelu nie zrównuja się z danymi pomiarowymi, a efekt, jaki powoduje asymilacja, nie pozostaje długo zauważalny i po zaledwie kilku dniach wartości modelowe wracaja w pobliże wartości sprzed asymilacji. Jest to spowodowane kilkoma czynnikami. Po pierwsze, ustawienia modułów asymilacji nie wymuszają zrównania wyników modelowych z pomiarowymi, a jedynie ich zbliżenie. Jest to działanie celowe, wynikające z faktu, że pomiary z WIOŚ i wyniki modelowe nie powinny być traktowane równorzednie. Pomiary środowiskowe maja charakter punktowy oraz chwilowy, wyniki modelowe reprezentują z kolei średnia czasoprzestrzenną danej zmiennej. Sa one uśrednione w czasie, po zadanym przedziale czasowym, np. 1 godzina lub 6 godzin. Długość tego przedziału jest konfigurowalna w modelu. W przestrzeni wartość modelowa reprezentuje wartość średnią z danej komórki przestrzennej zdefiniowanej przez siatkę modelu, która w przypadku EcoFish ma rozmiar 575×575×5 m. Po drugie, dane z WIOŚ reprezentują chwilową wartość pomiaru w danym punkcie, a zmienne asymilowane podlegaja transportowi przez prądy morskie. Zatem jeśli informacja o wartościach z pomiarów środowiskowych zostaje wprowadzona w danej komórce modelu, jest ona rozpraszana przez prady do sąsiednich komórek w kolejnych krokach obliczeniowych.

Do dokładniejszej weryfikacji otrzymanych wyników asymilacji wykorzystano trzy podstawowe miary statystyczne opisane wzorami (8.3)-(8.5). W przypadku chlorofilu a mamy do czynienia z logarytmicznie normalnym rozkładem otrzymanych wartości. W związku z tym do weryfikacji wyników tego parametru wykorzystano bardziej zaawansowane miary statystyczne, odpowiednie dla tego typu rozkładów, opisane dalej przy pomocy wzorów (8.6)-(8.8). We wszystkich poniższych wzorach x oznacza zmienne modelowe, y - zmienne środowiskowe, pozioma linia nad zmienną oznacza zaś jej wartość średnią.

• r – współczynnik korelacji Pearsona określający poziom zależności liniowej pomiedzy dwiema zmiennymi:

$$r = \frac{\sum_{i=1}^{n} (x_i - \overline{x})(y_i - \overline{y})}{\sqrt{\sum_{i=1}^{n} (x_i - \overline{x})^2} \sqrt{\sum_{i=1}^{n} (y_i - \overline{y})^2}}$$
(8.3)

• MBE (*mean bias error*) – miara pozwalajaca na określenie systematycznego odchylenia (błędu) modelu od wartości pomiarowych. Wartość dodatnia oznacza, że model systematycznie zawyża wyniki względem danych referencyjnych, wartość ujemna oznacza, że je zaniża:









$$MBE = N^{-1} \sum_{i=1}^{n} (x_i - y_i)$$
(8.4)

 RMSE (root-mean-square error) – średnia kwadratowa błędów, czyli miara pozwalająca określić wielkość błędu statystycznego modelu względem wartości pomiarowych:

$$RMSE = \sqrt{N^{-1} \sum_{i=1}^{n} (x_i - y_i)^2}$$
(8.5)

• Średni błąd logarytmiczny (mean logarithmic error):

$$<\epsilon>_g = 10^{\overline{\log(x/y)}} - 1$$
 (8.6)

• Standardowy współczynnik błędu (standard error factor):

$$\chi = 10^{\sqrt{N^{-1} \sum_{i=1}^{n} (\log(x/y) - \log(x/y))^2}}$$
(8.7)

• Statystyczny błąd logarytmiczny (statistical logarithmic error):

$$\sigma_{-} = \frac{1}{\chi} - 1, \sigma_{+} = \chi - 1 \tag{8.8}$$

W tabelach 8.1–8.3 przedstawiono wyniki weryfikacji. Tabela 8.1 zawiera wyniki dla danych dotyczących temperatury wody powierzchniowej z pomiarów satelitarnych, w tabeli 8.2 ujęto analogiczne wyniki dla modelu asymilującego temperaturę mierzoną przez sondę Midas, natomiast tabela 8.3 prezentuje wyniki dla asymilacji chlorofilu *a* z pomiarów satelitarnych. Otrzymane wyniki są zgodne z oczekiwaniami. Zarówno w przypadku temperatury, jak i koncentracji chlorofilu *a* dla modelu z asymilacją otrzymano wyniki bliższe danym satelitarnym. W przypadku asymilacji temperatury z pomiarów satelitarnych, jak również środowiskowych korelacja temperatury powierzchniowej, błąd systematyczny oraz błąd statystyczny uległy poprawie względem modeli bez asymilacji.

Warto zwrócić uwagę, że wyniki zawarte w tabeli 8.2 są nieco słabsze niż te w tabeli 8.1. Wynika to z faktu, że ze względu na dostępność danych model był kalibrowany głównie względem danych temperatury powierzchniowej, natomiast tabela 8.2 przedstawia wyniki porównania dla całej kolumny wody, wszędzie tam, gdzie były dostępne dane pomiarowe z sondy Midas. Koncentracja chlorofilu *a* również asymilowana jest poprawnie. Zarówno statystyki liniowe, jak i logarytmiczne pokazują, że wyniki otrzymane z modelu z asymilacją są bliższe danym



R P







satelitarnym niż te z modelu bez asymilacji. Wyjątkiem jest tu błąd systematyczny MBE, który nieznacznie wzrósł, jednak jego wartości są wciąż bardzo małe.

Tabela 8.1

Weryfikacja temperatury powierzchniowej z modeli względem danych satelitarnych

Źródło danych	r	MBE [°C]	RMSE [°C]
EcoFish bez asymilacji	0,95	-1,2	2,4
EcoFish z asymilacją	0,98	-0,56	1,5

Tabela 8.2

Weryfikacja temperatury z modeli względem danych środowiskowych z sondy Midas

Źródło danych	r	MBE [°C]	RMSE [°C]
EcoFish bez asymilacji	0,77	-0,34	3,2
EcoFish z asymilacją	0,83	-0,25	2,7

Tabela 8.3

Weryfikacja powierzchniowej koncentracji chlorofilu a z modeli względem danych satelitarnych

Źródło danych	r	MBE [mg/m³]	RMSE [mg/m³]	$<\epsilon>_{g}$ [%]	X	σ _[%]	σ ₊ [%]
EcoFish bez asymilacji	0,31	0,10	2,0	-30	2,6	-61	160
EcoFish z asymilacją	0,56	-0,05	1,3	-18	1,5	-35	54

Należy zwrócić uwagę, że przedstawione wyniki nie mają na celu oceny jakości obliczeń modelowych, a jedynie ocenę poprawności działania metody asymilacji. Ocena jakości otrzymanych wyników, jak wspomniano we wstępie, została przedstawiona dla dłuższych przebiegów czasowych w opracowaniach Janeckiego, Dybowskiego, Nowickiego, Jakackiego i Dzierzbickiej-Głowackiej (2023) oraz Janeckiego, Dybowskiego, Nowickiego i Dzierzbickiej-Głowackiej (2023).







W związku z małą liczbą danych pomiarowych z WIOŚ oraz ich punktowym i chwilowym charakterem nie było możliwe przygotowanie statystycznie istotnych wyników weryfikacji biogenów oraz rozpuszczonego tlenu. Dlatego w tym przypadku ograniczono się do przedstawionej wcześniej weryfikacji wizualnej.

PODSUMOWANIE

Zastosowana w modelu EcoFish asymilacja danych pomiarowych wpłynęła pozytywnie na otrzymywane wyniki. Różnica wartości pomiędzy modelami bez asymilacji i z asymilacją jest wyraźna, zwłaszcza w przypadku danych satelitarnych dotyczących powierzchniowej temperatury oraz koncentracji chlorofilu *a*. Znacznie mniejszy wpływ na wyniki modelu mają dane środowiskowe, co wynika przede wszystkim z niewielkiej liczby tych danych oraz ich chwilowego i lokalnego charakteru. W przypadku każdej z asymilowanych zmiennych wykazano, że system asymilacji działa poprawnie. W sytuacjach, gdy weryfikacja liczbowa nie była możliwa, przedstawiono przykłady działania systemu w postaci wykresów czasowych, które zademonstrowały wpływ asymilacji na wyniki modelu w danym punkcie, w którym dokonany był pomiar wykorzystany do asymilacji.

Wpływ asymilacji na wyniki modelu jest znaczący, zwłaszcza w przypadku danych satelitarnych. Należy zwrócić uwage, że badany akwen jest niewielki, a zatem dostępność danych na tym obszarze jest ograniczona. Mimo że mapy satelitarne z obszaru całego Bałtyku generowane są niemal codziennie, to mapy pokrywajace badany obszar pojawiaja się znacznie rzadziej i nawet wtedy zazwyczaj pokrywają go tylko częściowo. Ponadto przy asymilacji tego typu danych trzeba pamiętać, że porównuje się dane o innym charakterze. Dane satelitarne oraz dane z modelu są to dane obszarowe o zadanej rozdzielczości, gdzie każdy punkt zawiera informację o wartości średniej z danego obszaru i danego przedziału czasowego. W przypadku danych satelitarnych jest to 1 km² i są one mierzone w bardzo cienkiej warstwie powierzchniowej wody. Dodatkowo są to wartości uśrednione ze wszystkich dostępnych pomiarów danego dnia. Z kolei wielkość komórki przedstawiajacej jeden punkt na siatce modelu wynosi 575×575 m, a jej głębokość to 5 m. Ponadto dane te są zapisywane w postaci średnich z 1 godziny lub 6 godzin obliczeń, zależnie od ustawień modelu. Zmienność przestrzenna i czasowa parametrów, w szczególności stężenia chlorofilu a, może być na takim obszarze i w takim czasie bardzo duża. Biorąc pod uwagę powyższe argumenty, można uznać, że otrzymane wyniki są zadowalające. Zastosowanie asymilacji danych satelitarnych ma wyraźny wpływ na wyniki modelu w przypadku zarówno temperatury powierzchniowej, jak i stężenia chlorofilu a.

W odniesieniu do danych środowiskowych wpływ asymilacji danych pomiarowych na wyniki modelu jest znacznie mniejszy. Wynika to głównie z małej liczby







Unia Europejska Europejski Fundusz Rozwoju Regionalnego



danych do asymilacji oraz – podobnie jak w przypadku danych satelitarnych – z innego charakteru danych pomiarowych i modelowych. Dane z rejsów i pomiarów WIOŚ są danymi *in situ*, a więc są to dane z konkretnych punktów i z konkretnej chwili. W związku z tym nie należy dążyć do dokładnego odwzorowania tych wartości przez wyniki modelu, które reprezentują średnią czasoprzestrzenną. Jak wynika z rys. 8.5–8.9, w samych punktach dokonywania pomiaru danych środowiskowych różnice między modelem bez asymilacji i z asymilacją są znaczące. Sam system został przygotowany w taki sposób, aby można go było z łatwością rozszerzyć o kolejne dane z innych rejsów, boi stacjonarnych, pływaków i innych, dowolnych, dostępnych źródeł. Większa liczba źródeł zwiększy pokrycie obszaru modelowego danymi, a w związku z tym wzrośnie wpływ asymilacji na wyniki. Uwzględniając wskazane argumenty, można zatem stwierdzić, że otrzymane rezultaty są zadowalające.

LITERATURA

- Andersson E., Haseler J., Undén P., Courtier P., Kelly G., Vasiljevic D., Brankovic C., Gaffard C., Hollingsworth A., Jakob C., Janssen P., Klinker E., Lanzinger A., Miller M., Rabier F., Simmons A., Strauss B., Viterbo P., Cardinali C., Thépaut J., *The ECMWF implementation of threedimensional variational assimilation (3D-Var). III: Experimental results*, Quarterly Journal of the Royal Meteorological Society, Reading 1998, 124, 1831–1860. doi:10.1002/qj.49712455004.
- Courtier P., Andersson E., Heckley W., Vasiljevic D., Hamrud M., Hollingsworth A., Rabier F., Fisher M., Pailleux J., *The ECMWF implementation of three-dimensional variational assimilation* (3D-Var). I: Formulation, Quarterly Journal of the Royal Meteorological Society, Reading 2006, 124, 1783–1807. doi:10.1002/qj.49712455002.
- 3. Cressman G.P., An operational objective analysis system, Monthly Weather Review, Boston, MA 1959, 87, 367–374. doi: 10.1175/1520-0493(1959)087<0367:AOOAS>2.0.CO;2.
- Dzierzbicka-Głowacka L., Nowicki A., Janecki M., Szymczycha B., Piotrowski P., Pieckiel P., Łukasiewicz G., *Structure of the FindFISH Knowledge Transfer Platform*, Fisheries and Aquatic Life, Archives of Polish Fisheries, 2018, 26, 193–197. doi: 10.2478/aopf-2018-0021.
- 5. Fisher M., Andersson E., *Developments in 4D-Var and Kalman filtering*, ECMWF Research Department, Reading, UK 2001.
- 6. Gandin L.S., *Objective analysis of meteorological fields*, Israel Program for Scientific Translation, Jerozolima 1963.
- Janecki M., Dybowski D., Jakacki J., Nowicki A., Dzierzbicka-Glowacka L., The use of satellite data to determine the changes of hydrodynamic parameters in the Gulf of Gdańsk via EcoFish Model, Remote Sensing, 2021, 13, 3572. doi: https://doi.org/10.3390/ rs13183572.
- Janecki M., Dybowski D., Nowicki A., Dzierzbicka-Głowacka L., Analiza dynamiki zmienności parametrów biochemicznych w rejonie Zatoki Gdańskiej za pomocą modelu EcoFish (rozdział 7), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 179–204.







- Janecki M., Dybowski D., Nowicki A., Jakacki J., Dzierzbicka-Głowacka L., Analiza parametrów fizycznych wód Zatoki Gdańskiej za pomocą modelu numerycznego EcoFish (rozdział 6), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 145–178.
- 10. Nowicki A., Dzierzbicka-Głowacka L., Janecki M., Kałas M., Assimilation of the satellite SST data in the 3D CEMBS model, Oceanologia, 2015, 57(1), 17–24. doi:10.1016/j.oceano.2014.07.001.
- Nowicki A., Janecki M., Darecki M., Piotrowski P., Dzierzbicka-Głowacka L., *The use of satellite data in the operational 3D Coupled Ecosystem Model of the Baltic Sea 3D CEMBS*, Polish Maritime Research, 2016, 23(1), 20–24. doi:10.1515/pomr-2016-0003.
- Nowicki A., Janecki M., Dybowski, D., Dzierzbicka-Głowacka L., Automatyczny system kontroli modelu EcoFish w trybie operacyjnym (rozdział 10), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybolówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 240–260.
- Rabier F., McNally A., Andersson E., Courtier P., Undén P., Eyre J., Hollingsworth A., Bouttier F., *The ECMWF implementation of three-dimensional variational assimilation (3D-Var). II: structure functions*, Quarterly Journal of the Royal Meteorological Society, 2006, 124(550), 1809–1829. doi:10.1002/qj.49712455003.
- 14. Smith R., Gent P., *Reference manual for the Parallel Ocean Program (POP)*, Los Alamos National Laborator, Los Alamos, NM, USA 2004.
- 15. Woźniak B., Bradtke K., Darecki M., Dera J., Dudzińska-Nowak J., Dzierzbicka-Głowacka L., Ficek D., Furmańczyk K., Kowalewski M., Krężel A., Majchrowski R., Ostrowska M., Paszkuta M., Stoń-Egiert J., Stramska M., Zapadka T., SatBałtyk – a Baltic environmental satellite remote sensing system – an ongoing project in Poland. Part 1: assumptions, scope and operating range, Oceanologia, 2011a, 53(4), 897–924.
- 16. Woźniak B., Bradtke K., Darecki M., Dera J., Dudzińska-Nowak, J., Dzierzbicka-Głowacka, L., Ficek, D., Furmańczyk, K., Kowalewski, M., Krężel, A., Majchrowski, R., Ostrowska, M., Paszkuta, M., Stoń-Egiert, J., Stramska, M., Zapadka, T., SatBaltyk – a Baltic environmental satellite remote sensing system – an ongoing project in Poland. Part 2: Practical applicability and preliminary results, Oceanologia, 2011b, 53(4), 925–958.

Praca wykonana w ramach projektu "Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa" (nr RPPM.01.01.01-22-0025/16-00) współfinansowanego ze środków Europejskiego Funduszu Rozwoju Regionalnego w ramach Regionalnego Programu Operacyjnego Województwa Pomorskiego na lata 2014–2020.

Obliczenia wykonano z wykorzystaniem komputerów Centrum Informatycznego Trójmiejskiej Akademickiej Sieci Komputerowej.









Maciej Janecki (D) 0000-0002-8784-2862 Lidia Dzierzbicka-Głowacka (D) 0000-0001-6151-2390 INSTYTUT OCEANOLOGII POLSKIEJ AKADEMII NAUK W SOPOCIE adres e-mail do korespondencji: mjanecki@iopan.pl DOI: 10.26408/FindFISH-09

9. MODUŁ FISH – MAPOWANIE NAJKORZYSTNIEJSZYCH WARUNKÓW ŚRODOWISKOWYCH DLA BYTOWANIA RYB BADANYCH GATUNKÓW POŁAWIANYCH PRZEMYSŁOWO W REJONIE ZATOKI GDAŃSKIEJ

WPROWADZENIE

Ocena przydatności siedlisk jest ważnym aspektem ochrony siedlisk znajdujących się blisko ujść rzecznych. W celu obliczenia wskaźnika przydatności siedlisk (*habitat suitability index*, HSI) zastosowano metodologię wartości minimalnej (Beecher i in., 2002; Bovee, 1986), metodologię sumowania ważonego (Poulos i in., 2012) oraz metodologię ważonej średniej geometrycznej (Inglis i in., 2006). Metody te wymagają dobrej znajomości preferencji analizowanego gatunku. Ponadto potrzebują dużej liczby bardzo dokładnych danych. W ekologii występuje wiele niepewności, w tym istnienie zmiennych losowych, niekompletne lub niedokładne pomiary oraz wykorzystywanie wyników szacunkowych zamiast pomiarów bezpośrednich.

Ograniczenia wymienionych metod doprowadziły do zainteresowania logiką rozmytą, czyli metodą, która może przetwarzać niepewności. Ważną zaletą logiki rozmytej jest lepsze wykorzystanie nieprecyzyjnych i niepewnych wyników pomiarów oraz rozmytej wiedzy eksperckiej. Podstawowymi elementami logiki rozmytej są zbiory i reguły rozmyte. Wyrażając niepewność symulacji siedliska, zbiory rozmyte wykorzystują nieprecyzyjne lub niejasne informacje. Dostępna wiedza ekspercka jest wyrażona jako zestaw danych preferencji (Fraternali i in., 2012; Prato, 2007). Rozumując za pomocą rozmytych zbiorów i reguł, możemy sformułować granice przejściowe lub wiedzę jakościową, a następnie dokonać rozmytego, kompleksowego osądu, który jest podobny do ludzkiego procesu myślowego. W ten sposób możemy rozwiązywać oparte na regułach problemy rozmyte, które są trudne dla metod ogólnych (Van Broekhoven i in., 2006). Modele oparte



Rzeczpospolita Polska



Unia Europejska Europejski Fundusz Rozwoju Regionalnego



na regułach rozmytych zostały zastosowane w licznych badaniach, dzięki temu, że są zaprojektowane z wykorzystaniem wiedzy jakościowej i mają strukturę, która sprzyja interpretacji wyników (Chou i in., 2007; Fukuda i in., 2011; Legleiter i Goodchild, 2005; Mouton i in., 2009; Rüger i in., 2005; Zhang i in., 2016).

Ze względu na założenia i cele projektu "Platforma transferu wiedzy FindFISH" wykorzystanie zalet logiki rozmytej stało się naturalnym wyborem podczas projektowania modułu Fish. Jest to finalny i najważniejszy element systemu, który przy zastosowaniu logiki rozmytej pozwala na tworzenie map najkorzystniejszych warunków środowiskowych (HSI) do bytowania ryb poławianych przemysłowo w rejonie Zatoki Gdańskiej, tj. śledzia, szprota, dorsza i storni. Dzięki takiemu narzędziu, działającemu w trybie operacyjnym, możliwe jest zwiększenie intensywności transferu wiedzy i wykorzystania potencjału naukowego przez rybaków, a w konsekwencji przyczynienie się do zrównoważonego rozwoju rybołówstwa morskiego i zwiększenia ochrony ekosystemu Zatoki Gdańskiej.

9.1. IMPLEMENTACJA MODUŁU FISH

Przed stworzeniem kodu źródłowego modułu Fish (rys. 9.1) i jego implementacją na serwerze obliczeniowym przeprowadzono szereg prac poprzedzających.



Rys. 9.1. Ogólny schemat modułu Fish

Źródło: opracowanie własne.

W pierwszej kolejności należało ustalić graniczne wartości parametrów określających optymalne warunki dla bytowania badanych gatunków ryb: śledzia, szprota, dorsza oraz storni. Do tego celu wykorzystano dane opisujące preferencje środowiskowe ryb w badanym obszarze (Zatoka Gdańska), które zostały







sprecyzowane w ramach projektu (Pieckiel, Kuczyński, 2023) na podstawie połowów rybackich, danych literaturowych i wiedzy eksperckiej. Są to informacje na temat zarejestrowanych miejsc i czasu występowania łowisk oraz wielkości połowów połaczone z danymi dotyczacymi wartości parametrów środowiska (temperatury, zasolenia, głebokości i zawartości tlenu w wodzie).

Następnie przeprowadzona została walidacja w celu zweryfikowania, czy temperatura, zasolenie i tlen pochodzące z modelu EcoFish cechują się wystarczającą zgodnościa z danymi pomiarowymi, aby mogły służyć jako pola wejściowe do modułu Fish. Szczegóły dotyczące walidacji zmiennych fizycznych (tj. temperatury i zasolenia) zostały przedstawione w opracowaniach Janeckiego, Dybowskiego, Nowickiego, Jakackiego i Dzierzbickiej-Głowackiej (2023) oraz Janeckiego i in. (2021). Szczegóły dotyczace walidacji zawartości tlenu w wodzie przedstawili Janecki, Dybowski, Nowicki i Dzierzbicka-Głowacka (2023).

W kolejnym etapie prace prowadzone były w ramach samego modułu Fish. Powstała baza reguł wykorzystywana przy wnioskowaniu w systemie rozmytym oraz stworzono zestaw funkcji przynależności dla każdego rozpatrywanego gatunku. Po parametryzacji i kalibracji całego systemu należało sprawdzić poprawność wyników dostarczanych przez moduł Fish. W tym celu przeprowadzono walidację parametru HSI poprzez graficzne porównanie wartości otrzymanych z modułu Fish z wynikami wydajności połowowych, pochodzącymi z rejsów oceanograficznorybackich prowadzonych na statku r.v. Baltica przez Morski Instytut Rybacki – Państwowy Instytut Badawczy (Radtke i in., 2017; 2018a; 2018b; 2019a; 2019b; 2020a; 2020b; 2021).

9.1.1. Logika rozmyta

Prace nad implementacją modułu Fish wymagały wykorzystania logiki wielowartościowej (rozmytej). Logika rozmyta stanowi uogólnienie klasycznej dwuwartościowej logiki, w której między stanem 0 (fałsz) a stanem 1 (prawda) rozciąga się szereg wartości pośrednich, określających stopień przynależności elementu do zbioru. Na systemy rozmyte składają się te techniki i metody, które służą do obrazowania informacji nieprecyzyjnych, nieokreślonych bądź niekonkretnych. Pozwalają one opisywać zjawiska o charakterze wieloznacznym, których nie są w stanie ująć teoria klasyczna i logika dwuwartościowa. Charakteryzują się tym, że wiedza jest przetwarzana w postaci symbolicznej i zapisywana w postaci rozmytych reguł. System rozmyty znajduje zastosowanie w tym wypadku, gdyż na występowanie ryb wpływa wiele wzajemnie powiązanych czynników i nie można bazować osobno na poszczególnych parametrach środowiskowych.











Prace programistyczne przy tworzeniu modułu Fish były prowadzone przy wykorzystaniu oprogramowania ze środowiska Matlab, a w szczególności rozszerzenia *Fuzzy Logic Toolbox*.

9.1.2. Fuzyfikacja

Fuzyfikacja (rozmywanie) polega na określeniu stopnia przynależności zmiennych lingwistycznych do każdego ze zbiorów rozmytych. W module Fish wykorzystano do tego celu stabelaryzowane dane, określające zakresy optymalnych wartości poszczególnych parametrów dla bytowania śledzia, szprota, dorsza oraz storni. W pierwszej wersji modułu Fish zastosowano podział na cztery pory roku (wiosna, lato, jesień i zima) oraz porę dnia (dzień i noc) dla następujących parametrów środowiskowych:

- temperatura;
- zasolenie;
- natlenienie;
- głębokość.

Po wstępnej analizie wyników szybko okazało się jednak, że podział na pory roku nie jest wystarczająco szczegółowy, i podjęto działania w celu zwiększenia rozdzielczości danych do miesięcznej (rys. 9.2, 9.3). Na podstawie tych danych stworzone zostały odpowiadające im wykresy zmienności. W pierwszym podejściu jako przedział optymalnych wartości parametrów wykorzystywano 25. i 75. percentyl.

Gatunek	Miesiąc	Temperatura			Zasolenie			Głębokość			Saturacja						
		MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX
	Styczeń	4,5	5,7	6,5	9,1	7,4	7,6	8,3	12,1	15,0	38,7	57,1	84,2	15,0	38,7	57,1	84,2
	Luty	2,5	4,6	5,6	9,2	7,4	7,5	8,5	12,9	15,0	44,3	64,9	85,7	15,0	44,3	64,9	85,7
	Marzec	2,5	5,1	6,8	17,5	7,4	7,5	8,8	12,9	15,0	36,5	57,3	85,7	15,0	36,5	57,3	85,7
	Kwiecień	3,8	5,1	6,1	20,0	5,1	7,7	8,7	11,8	15,0	48,1	58,5	75,9	15,0	48,1	58,5	75,9
	Maj	4,1	5,3	6,1	9,8	7,2	7,6	9,9	11,3	15,1	38,3	66,1	75,6	15,1	38,3	66,1	75,6
éres a	Czerwiec	4,1	5,3	6,1	9,8	7,2	7,6	9,9	11,3	15,1	38,3	66,1	75,6	15,1	38,3	66,1	75,6
Sieuz	Lipiec	4,4	7,8	13,6	20,1	7,3	7,5	7,6	9,4	15,0	25,0	31,4	60,7	15,0	25,0	31,4	60,7
	Sierpień	4,4	7,8	13,6	20,1	7,3	7,5	7,6	9,4	15,0	25,0	31,4	60,7	15,0	25,0	31,4	60,7
	Wrzesień	3,3	4,7	15,1	20,0	7,0	7,4	8,1	10,8	15,0	35,4	52,2	60,3	15,0	35,4	52,2	60,3
	Październik	3,5	6,4	13,6	16,0	7,1	7,4	7,5	10,7	15,0	23,8	41,0	68,8	15,0	23,8	41,0	68,8
	Listopad	3,5	5,6	9,7	12,2	7,0	7,6	9,1	12,1	15,0	35,4	52,6	76,0	15,0	35,4	52,6	76,0
	Grudzień	6,1	6,6	7,2	8,4	7,5	7,6	9,3	11,1	15,1	30,7	53,6	76,5	15,1	30,7	53,6	76,5
	Styczeń	4,5	5,6	6,5	9,1	7,4	7,6	8,5	12,1	15,0	41,9	57,9	84,2	15,0	41,9	57,9	84,2
	Luty	2,4	4,6	5,8	9,2	7,4	7,5	8,6	12,9	15,0	45,9	65,0	85,7	15,0	45,9	65,0	85,7
	Marzec	2,5	3,8	5,2	7,3	7,4	7,6	8,0	11,3	15,0	39,8	55,7	83,0	15,0	39,8	55,7	83,0
	Kwiecień	3,8	4,9	5,9	20,0	5,1	7,7	9,4	11,8	15,0	47,9	59,9	75,9	15,0	47,9	59,9	75,9
	Maj	4,1	5,3	6,1	9,8	7,2	7,6	9,9	11,3	15,1	38,3	66,1	75,6	15,1	38,3	66,1	75,6
	Czerwiec	4,1	5,3	6,1	9,8	7,2	7,6	9,9	11,3	15,1	38,3	66,1	75,6	15,1	38,3	66,1	75,6
Szprot	Lipiec	10,4	12,6	15,5	17,6	7,4	7,5	7,5	7,5	15,4	17,8	24,4	25,7	15,4	17,8	24,4	25,7
	Sierpień	10,4	12,6	15,5	17,6	7,4	7,5	7,5	7,5	15,4	17,8	24,4	25,7	15,4	17,8	24,4	25,7
	Wrzesień	5,8	6,7	17,2	17,3	7,5	7,5	7,6	7,7	15,0	23,7	31,3	41,2	15,0	23,7	31,3	41,2
	Październik	4,6	11,6	15,7	16,0	7,1	7,4	7,5	10,7	15,0	18,8	35,4	68,8	15,0	18,8	35,4	68,8
	Listopad	3,5	5,3	9,8	12,2	7,0	7,5	9,3	12,1	15,0	33,5	50,6	76,0	15,0	33,5	50,6	76,0
	Grudzień	6,1	6,6	7,2	8,4	7,5	7,6	9,0	11,1	15,1	30,4	53,0	76,5	15,1	30,4	53,0	76,5

Rys. 9.2. Stabelaryzowane dane preferencji dla śledzia i szprota. OPT-MIN i OPT-MAX to odpowiednio 25. i 75. percentyl

Źródło: opracowanie własne na podstawie danych zebranych w ramach projektu i opracowanych przez dr. P. Pieckiela.





Unia Europejska Europejski Fundusz Rozwoju Regionalnego



Carbonalt			Temp	eratura			Zaso	lenie		Głębokość			Saturacja				
Gatunek	mesiąc	MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX	MIN	OPT-MIN	OPT-MAX	MAX
	Styczeń	4,1	4,9	5,6	6,0	6,9	7,4	7,8	11,5	18,0	38,0	49,0	55,0	64,0	77,0	89,0	95,0
	Luty	4,3	5,0	5,7	6,1	6,9	7,6	9,5	10,9	9,0	32,0	49,0	57,0	66,0	78,0	86,0	92,0
	Marzec	4,8	5,1	5,8	6,2	7,5	7,7	9,3	10,2	0,7	25,4	48,5	56,8	70,0	79,0	83,0	90,0
	Kwiecień	5,1	5,4	5,8	6,4	7,6	7,7	7,8	8,1	42,9	51,4	56,9	63,3	73,2	77,6	81,0	85,5
	Maj	4,2	6,2	7,9	10,3	9,1	11,2	12,6	13,1	62,5	76,2	85,3	92,6	37,0	45,0	52,0	66,0
Darra	Czerwiec	4,4	5,8	6,8	8,1	9,8	11,0	11,9	12,6	71,2	76,7	81,6	86,1	5,0	21,3	32,2	48,8
DUISZ	Lipiec	4,1	5,8	6,9	8,2	9,5	10,8	11,6	12,5	72,0	77,0	83,0	87,0	5,0	17,0	35,0	53,0
	Sierpień	4,0	5,8	6,9	8,3	8,8	10,3	11,5	12,3	71,0	76,0	84,0	86,0	2,0	16,0	32,0	54,0
	Wrzesień	3,8	5,7	6,9	8,8	8,4	10,1	11,1	12,2	67,8	76,9	82,7	85,4	0,3	13,2	30,1	55,5
	Październik	3,4	5,5	13,1	15,9	4,1	7,5	10,0	11,1	38,5	52,9	62,6	72,4	0,4	11,5	77,1	102,4
	Listopad	3,7	5,2	10,0	12,0	4,9	7,6	10,0	11,4	30,0	47,0	58,0	65,0	15,0	28,0	80,0	102,0
	Grudzień	3,9	5,1	7,0	8,0	5,5	7,4	10,0	11,6	23,0	42,0	53,0	57,0	29,0	42,0	83,0	101,0
	Styczeń	-	-	-	-	-	-	-	-			-		-	-	-	
	Luty		-	-	-		-		-				1.1				1.1
	Marzec	-	-	-	-	-	-	-	-	-	-	-		-	-	-	
	Kwiecień	-	-	-	-		-	-			-			1.1		-	
	Maj	-	-	-	-	-	-	-	-	-	-	-		-	-	-	
Storein	Czerwiec	-	-	-	-		-	-	-	-	-	-				-	
Storma	Lipiec	8,6	14,9	21,1	24,7	7,2	7,4	7,6	7,8	12,8	14,1	14,8	15,5	-	-	-	
	Sierpień	4,8	13,3	20,2	21,0	7,3	7,4	7,5	7,7	0,1	15,2	28,6	44,6	39,7	53,5	65,8	84,4
	Wrzesień	11,6	14,7	16,4	19,3	7,1	7,3	7,4	7,7	19,1	23,1	25,7	29,5	49,8	64,1	82,4	99,8
	Październik	8,8	12,3	14,6	16,9	7,2	7,3	7,6	7,9	0,1	13,2	25,5	40,4	56,3	74,5	86,5	98,2
	Listopad	10,3	11,0	11,6	12,0	7,4	7,5	7,5	7,6	7,0	7,7	10,8	11,6	87,4	89,0	89,7	91,0
	Grudzień	1.1							1.1				1.1	1.1	1.1	1.1	1.1

Rys. 9.3. Stabelaryzowane dane preferencji dla dorsza i storni. OPT-MIN i OPT-MAX to odpowiednio 25. i 75. percentyl

Źródło: opracowanie własne na podstawie danych zebranych w ramach projektu i opracowanych przez dr. P. Pieckiela.

Przedział ten okazał się jednak zbyt szeroki, nie pozwalając na szczegółowe określenie najlepszej wartości parametru dla bytowania danego gatunku w danym miesiącu, co wpływało na małą zmienność HSI. W związku z tym zastosowano medianę optymalnej wartości o stałym odchyleniu. Przykładowe wykresy wartości temperatury (rys. 9.4a) i zasolenia (rys. 9.4b) preferowanych przez śledzia zostały przedstawione na rys. 9.4.



Rys. 9.4. Zmienność preferowanych przez śledzia wartości a) temperatury, b) zasolenia Źródło: opracowanie własne na podstawie danych zebranych w ramach projektu i opracowanych przez dr. P. Pieckiela.









Przy tworzeniu funkcji przynależności zdecydowano się na wybór systemu rozmytego opartego na regułach Mamdaniego. Jest to intuicyjna, powszechnie wykorzystywana i akceptowalna metoda, która dobrze dopasowuje się do opisanych wejść. W celu wykreślenia funkcji przynależności należało ustalić zakres wartości i charakterystyczne punkty wykresu takiej funkcji, tzn. podać optymalne wartości każdego parametru biorącego udział w fuzyfikacji, wybrać typ funkcji i jej kształt (trójkątna, trapezowa, klasy S/Z/Pi, gaussowska, dzwonowa, sinusoidalna etc.). Na rys. 9.5 zaprezentowano przykładową funkcję przynależności dla głębokości bytowania szprota w styczniu.



Rys. 9.5. Krzywa przynależności dla głębokości bytowania szprota w styczniu Źródło: opracowanie własne.

Takie funkcje przynależności ustalono dla każdego z czterech gatunków w każdym miesiącu, dla temperatury, zasolenia i zawartości tlenu w wodzie oraz głębokości występowania gatunku. Każda z funkcji składa się z trzech krzywych. Funkcje przynależności zostały skonstruowane w taki sposób, aby krzywa MEDIUM (M) zawsze odpowiadała optymalnym warunkom środowiskowym przy rozpatrywanym parametrze, a dwie odstające krzywe LOW (L) i HIGH (H) określały wartości parametru rzadziej preferowane przez dany gatunek. Dzięki temu reguły wnioskowania można było przygotować tak, aby były wspólne dla wszystkich gatunków. Wynikowa funkcja przynależności jest rozdzielona na stany określające pięć typów warunków środowiskowych: złe (L = *low*), niekorzystne (ML = *medium-low*), neutralne (M = *medium*), korzystne (MH = *medium-high*) oraz dobre (H = *high*).







9.1.3. Reguły wnioskowania

Reguły wnioskowania łączą zmienne wejściowe (temperaturę, zasolenie, tlen i głębokość) z warunkami środowiskowymi dla bytowania gatunku (HSI) za pomocą szeregu instrukcji warunkowych "JEŚLI-TO". Reguły rozmyte są definiowane na podstawie wiedzy eksperckiej, a rozmyte dane wejściowe można przekształcić za pomocą tych reguł w rozmyte dane wyjściowe (tabela 9.1).

Tabela 9.1

Lp.	Temperatura	Zasolenie	Tlen	Głębokość	HSI
1	Н	Н	L	Н	L
2	М	М	L	Н	ML
3	L	Н	Н	Н	L
4	М	М	Н	Н	М
5	L	М	М	Н	MH
6	Н	Н	L	L	L
7	М	М	Н	L	MH
8	М	М	М	М	Н
9	М	L	М	М	MH
10	Н	М	М	М	L
11	М	L	Н	Н	ML
12	L	Н	М	L	L

Fragment arkusza z regułami wnioskowania w module Fish. Stany L, ML, M, MH, H oznaczają kolejno: niski, średnio niski, średni, średnio wysoki oraz wysoki

Źródło: opracowanie własne na podstawie wiedzy eksperckiej pracowników Instytutu Morskiego.

Na podstawie arkusza zaimplementowano szereg reguł poprzez zaznaczenie zbioru rozmytego dla wejścia w przesłance reguły oraz odpowiadającego mu zbioru wyjścia w konkluzji reguły. Określono $3^4 = 81$ reguł z wykorzystaniem operatora logicznego "I" (AND). Przykładowe reguły:

- Reguła 2: JEŚLI Temperatura Średnia I Zasolenie Średnie I Natlenienie Niskie I Głębokość Wysoka TO Warunki środowiskowe Niekorzystne;
- Reguła 5: JEŚLI Temperatura Niska I Zasolenie Średnie I Natlenienie Średnie I Głębokość Wysoka TO Warunki środowiskowe Korzystne.







W odniesieniu do bazy reguł rozmytych oblicza sie wynikowa funkcje przynależności, a następnie w procesie defuzyfikacji (ostrzenia) uzyskiwany jest wynik w postaci jednej wartości liczbowej dla HSI. Defuzyfikacje przeprowadzono metoda centroidy.

9.1.4. Opis kodu źródłowego

Obliczenia w module Fish przebiegają według następującego algorytmu. Najpierw ładowane sa stałe. Później określana jest lista plików wyjściowych z modelu EcoFish i następuje wczytywanie pól temperatury, zasolenia i koncentracji tlenu na wszystkich głebokościach (poziomach). Sprawdzany jest aktualny miesiac, aby można było wczytać odpowiedni plik z rozmytymi funkcjami przynależności. Po tym etapie koncentracja tlenu jest konwertowana na saturację. Następnie wyznaczane są wartości HSI. Ostatnia część kodu odpowiada za zapisywanie wyznaczonych wartości do plików wyjściowych netCDF. Poza mapami HSI w skrypcie wyznaczane są również dodatkowe informacje, potencjalnie przydatne użytkownikom portalu, na którym dane będą umieszczane. Są to macierze z głębokościami, na których w danej lokalizacji obserwowane sa HSI wieksze niż 0,7, 0,8 oraz 0,9. Ten zabieg ma na celu prezentację wyników w formie przystępniejszej dla użytkowników, który chcą wyświetlić jedynie miejsca cechujące się najlepszymi warunkami środowiskowymi dla bytowania danego gatunku, przy założonym zakresie 0,7-0,9.

9.2. WYNIKI Z MODUŁU FISH

Po etapie implementacji, parametryzacji i testów moduł Fish został uruchomiony na serwerze projektowym, co w połączeniu z działającym operacyjnie modelem EcoFish pozwoliło na tworzenie prognoz (i reanaliz) najkorzystniejszych warunków środowiskowych (HSI) dla wszystkich rozpatrywanych w projekcie gatunków – z pewnymi ograniczeniami dla storni (tylko od lipca do listopada). Poniżej przedstawiono średnie miesięczne dla median HSI z okresu 2017–2020 dla szprota, dorsza, śledzia i storni. Zostały one przygotowane w następujący sposób:

- w każdym oczku siatki modelu wyznaczona została mediana HSI w kolumnie wody, we wszystkich dniach z rozpatrywanego okresu;
- z tak przygotowanego obrazu wyznaczono średnie mediany dla miesięcy;
- następnie przygotowano średnie miesieczne wieloletnie poprzez uśrednienie median z każdego miesiąca w kolejnych latach, tzn. średnia miesięczna HSI dla stycznia to średnia z median HSI ze stycznia lat 2017, 2018, 2019 i 2020.











9.2.1. Szprot

Na mapie (rys. 9.6) z wieloletnimi średnimi miesięcznymi median HSI dla szprota widać, że najkorzystniejsze warunki środowiskowe dla tego gatunku wyznaczone z modułu Fish obserwowane są w miesiącach zimowych (grudzień, styczeń, luty) oraz wiosną (marzec, kwiecień). Warunki środowiskowe od maja do września cechuje układ strefowy z podziałem na dwa sektory o odmiennych własnościach. W płytkowodnej strefie przybrzeżnej panują wyraźnie gorsze warunki środowiskowe niż na obszarach głębokowodnych. Odmienna sytuacja ma miejsce w listopadzie, kiedy to korzystniejsze warunki środowiskowe obserwowane są na wodach płytkich.



Rys. 9.6. Szprot. Wieloletnie (2017–2020) średnie miesięczne median HSI Źródło: opracowanie własne.

9.2.2. Dorsz

Na mapie (rys. 9.7) z wieloletnimi średnimi miesięcznymi median HSI dla dorsza widać, że najkorzystniejsze warunki środowiskowe dla tego gatunku wyznaczone z modułu Fish obserwowane są jesienią (październik, listopad, grudzień). W sezonie letnim od maja do września widać również zwiększone HSI, ale w głębokowodnym obszarze z okolic Głębi Gdańskiej. W płytkowodnej strefie przybrzeżnej oraz na średnich głębokościach panują w tych miesiącach niekorzystne warunki środowiskowe dla bytowania dorsza.



Rzeczpospolita Polska



Unia Europejska Europejski Fundusz Rozwoju Regionalnego





Rys. 9.7. Dorsz. Wieloletnie (2017–2020) średnie miesięczne median HSI Źródło: opracowanie własne.

9.2.3. Śledź

Na mapie (rys. 9.8) z wieloletnimi średnimi miesięcznymi median HSI dla śledzia widać, że najkorzystniejsze warunki środowiskowe dla tego gatunku wyznaczone z modułu Fish obserwowane są od grudnia do kwietnia. Miesiące od maja do września cechuje strefowy rozkład warunków środowiskowych. W płytkowodnej strefie przybrzeżnej panują gorsze warunki środowiskowe niż na obszarach głębokowodnych. W październiku i listopadzie sytuacja jest odwrócona i obszary płytkowodne i przejściowe są korzystniejsze dla bytowania śledzia niż otwarte morze z dużymi głębokościami.









Rys. 9.8. Śledź. Wieloletnie (2017–2020) średnie miesięczne median HSI Źródło: opracowanie własne.

9.2.4. Stornia

W tej chwili moduł Fish generuje wyniki HSI dla storni jedynie dla okresu od 1 lipca do 30 listopada. Jest to związane z brakiem danych połowowych niezbędnych do określenia preferencji storni w pozostałych miesiącach, a próba ich interpolacji z posiadanych danych mogłaby doprowadzić do zwracania złych wyników. Brakujący okres zostanie uzupełniony na podstawie wiedzy eksperckiej.

Na mapie (rys. 9.9) z wieloletnimi średnimi miesięcznymi median HSI dla storni widać, że najkorzystniejsze warunki środowiskowe dla tego gatunku wyznaczone z modułu Fish dla miesięcy w których produkuje on wyniki, obserwowane są w październiku i listopadzie w płytkowodnej strefie przybrzeżnej południowej części Zatoki Gdańskiej oraz w obszarze na północ od Półwyspu Helskiego. Na otwartym morzu, gdzie występują duże głębokości, obserwowane są niekorzystne warunki środowiskowe dla storni.











Rys. 9.9. Stornia. Wieloletnie (2017–2020) średnie miesieczne median HSI Źródło: opracowanie własne.

9.3. WALIDACJA MODUŁU FISH

W związku z brakiem dostępu do szczegółowych danych liczbowych dotyczacych połowów śledzia, szprota, dorsza i storni w rejonie Zatoki Gdańskiej (innych niż zebrane w projekcie) walidację przeprowadzono poprzez graficzne porównanie (wraz z opisem) wyników HSI uzyskiwanych z modułu Fish z mapami wydajności połowowych dla tych czterech gatunków prezentowanymi w dwumiesięcznikach "Wiadomości Rybackie" przez Morski Instytut Rybacki -Państwowy Instytut Badawczy (Radtke i in., 2017; 2018a; 2018b; 2019a; 2019b; 2020a; 2020b; 2021).

Mapy wydajności połowowych zostały opracowane przy wykorzystaniu danych pochodzących z rejsów oceanograficzno-rybackich prowadzonych na statku r.v. Baltica, na którym zrealizowano badania dotyczace rozmieszczenia i biologii ryb w polskich obszarach morskich i w części wód wyłącznej strefy ekonomicznej Szwecji, z uwzględnieniem warunków hydrologicznych.

Były to rejsy typu BITS (Baltic International Trawl Survey – Bałtycki Międzynarodowy Rejs Włokowy), które przeprowadzają instytucje badawcze krajów nadbałtyckich, przy merytorycznej współpracy i koordynującej roli Grupy Roboczej Międzynarodowej Rady Badań Morza ds. Bałtyckich Międzynarodowych Połowów Badawczych Ryb (International Council for the Exploration of the Sea Baltic International Fish Survey Working Group, ICES WGBIFS). Głównym celem tych rejsów jest uzyskanie danych do oceny biomasy i liczebności dorszy i płastug



ogram Regionaln







Unia Europejska Europejski Fundusz zwoju Regionalnego Bon



oraz ich rozmieszczenia geograficznego i batymetrycznego w warstwie przydennej morza, na tle warunków hydrologicznych. Ryby gatunków innych niż wcześniej wymienione, które występują w połowach rejsów BITS, są elementem oceny bioróżnorodności oraz liczebności i rozmieszczenia ichtiofauny. Rejsy BITS sa organizowane dwa razy w roku. Wyprawy zimowe (luty/marzec) przeprowadza się, aby zbadać występowanie dorszy i storni w okresie poprzedzającym ich rozród oraz aby ocenić udział ryb dojrzałych płciowo, które w roku badań przystąpią do tarła (jako jeden z czynników niezbednych do oceny biomasy stada tarłowego). Rejsy jesienne (listopad/grudzień) mają na celu zbadanie występowania dorszy i płastug po tarle oraz dokonanie wstępnej oceny występowania dorszy i płastug z pokolenia urodzonego w roku przeprowadzonych badań. Rejsy zimowe oznacza się akronimem BITS-1Q, a jesienne – BITS-4Q. Połowy ryb w czasie rejsów BITS prowadzone sa przez wszystkie bałtyckie statki badawcze na dnie za pomocą standardowego włoka dorszowego TV3 zakończonego workiem o boku oczka 10 mm. Zgodnie z rekomendacjami ICES czas trwania zaciagu wynosi pół godziny, a wyniki badań połowów prezentowane są standardowo jako wydajności połowów w przeliczeniu na godzinę zaciągu. Na rys. 9.10 przedstawiono rozmieszczenie miejsc zaciągów kontrolnych podczas rejsu, który odbywał się w okresie 4.02–3.03.2020.





Źródło: "Wiadomości Rybackie", MIR-PIB (Radtke i in., 2020b).





Unia Europejska Europejski Fundusz Rozwoju Regionalnego



Rozmieszczenie i liczba zaciągów w rejsach mogą się różnić, jednak w rejonie Zatoki Gdańskiej można było wyróżnić dwa obszary, w których zawsze prowadzono zaciągi: płytkowodny obszar południowej Zatoki Gdańskiej od ujścia Przekopu Wisły w kierunku wschodnim oraz obszar ciągnący się wzdłuż Półwyspu Helskiego. Walidację przeprowadzono dla wszystkich gatunków ryb i wszystkich ośmiu rejsów, które odbyły się w okresie 1.01.2017–31.12.2020. Jedynie dla storni przeprowadzono walidację tylko dla rejsów jesiennych (BITS-4Q) w związku z brakiem danych z modułu Fish dla tego gatunku w miesiącach zimowych. Z uwagi na ograniczenia dotyczące objętości rozdziału w dalszej jego części zaprezentowano walidację z wybranych rejsów, po jednym dla każdego gatunku. Pełne wyniki walidacji znajdują się w podsumowaniu.

9.3.1. Szprot

Podczas rejsu 2020-1Q, który odbywał się w okresie 4.02–3.03.2020, zarejestrowano wysokie wydajności połowowe dla szprota w północnej i wschodniej części obszaru A1 oraz niskie lub zerowe w jego południowej, płytkowodnej części (rys. 9.11a). W granicach obszaru A2 odnotowano głównie średnie i wysokie wydajności połowowe oraz kilka lokalizacji w których były one niskie.



Rys. 9.11. Wydajność połowowa szprota (kg/h) w rejsie badawczym 2020-1Q (4.02–3.03.2020) (a) oraz mediany HSI dla szprota w tym okresie (b) Źródło: a) "Wiadomości Rybackie", MIR-PIB (Radtke i in., 2020b); b) opracowanie własne.

Pochodzące z modułu Fish mediany HSI dla tego okresu są bardzo wysokie (powyżej 0,65) w całej domenie modelu poza płytkowodną strefą przybrzeżną, gdzie przyjmują wartości zbliżone do 0,55 (rys. 9.11b). Wskazuje to na bardzo dobre warunki środowiskowe dla bytowania szprota w obszarze domeny modelu. Odnosząc to do wydajności połowowych, można uznać, że wartości HSI są ogólnie zgodne w obu analizowanych obszarach A1 i A2. Lekko przeszacowana może być







strefa przybrzeżna, w której mimo że panowały korzystne warunki środowiskowe, odnotowano niskie lub zerowe wydajności połowowe. Wynik walidacji modułu Fish dla szprota w tym okresie można uznać za dobry.

9.3.2. Dorsz

Podczas rejsu 2017-4Q, który odbywał się w okresie 13.11–3.12.2017, zarejestrowano niskie (do 100 kg/h) oraz średnie (101–500 kg/h) wydajności połowowe dla dorsza (rys. 9.12a).





Mediany HSI dla tego okresu przyjmują niskie wartości (poniżej 0,5) w płytkiej strefie przybrzeżnej oraz wyższe (powyżej 0,5) na otwartym morzu oraz w Zatoce Puckiej. Mediany HSI pochodzące z modułu Fish są zgodne z wydajnością połowową dorszy we wszystkich punktach poza P4 i P8, gdzie zostały przeszacowane (rys. 9.12b). W związku z brakiem zgodności w jedynie dwóch z ośmiu lokalizacji wynik walidacji należy uznać za dobry.

9.3.3. Śledź

Podczas rejsu 2018-1Q, który odbywał się w okresie 7.02–2.03.2018, zarejestrowano głównie wysokie (501–1000 kg/h) i bardzo wysokie (powyżej 1001 kg/h) wydajności połowowe dla śledzia w obszarze A1 (rys. 9.13a). W obszarze A2 wydajności połowowe były wyraźnie niższe, a w niektórych lokalizacjach nawet zerowe.









Rys. 9.13. Wydajność połowowa śledzia (kg/h) w rejsie badawczym 2018-1Q (7.02–2.03.2018) (a) oraz mediany HSI dla śledzia w tym okresie (b) Źródło: a) "Wiadomości Rybackie", MIR-PIB (Radtke i in., 2018b); b) opracowanie własne.

Pochodzące z modułu Fish mediany HSI dla tego okresu są głównie wysokie (powyżej 0,6) w obszarze A1 oraz średnio wysokie (0,5–0,6) w obszarze A2. Widoczne są również niższe wartości HSI dla płytkowodnej strefy przybrzeżnej od okolic Gdyni aż po polską część Mierzei Wiślanej (rys. 9.13b). Wskazuje to na korzystne warunki dla bytowania śledzia na otwartym morzu. Odnosząc to do wydajności połowowych, można uznać, że wartości HSI są z nimi zgodne w granicach obszaru A1 oraz zbliżone w obszarze A2. Mimo pewnego przeszacowania HSI w obszarze A2 wynik walidacji modułu Fish dla śledzia w tym okresie należy uznać za dobry.

9.3.4. Stornia

Podczas rejsu 2019-4Q, który odbywał się w okresie 11–29.11.2019, zarejestrowano wysokie wydajności połowowe dla storni w granicach obszaru A1, niskie w obszarze A2 oraz niskie i średnie w obszarze A3 (rys. 9.14a).

Mediany HSI dla tego okresu przyjmują wysokie wartości (0,55–0,7) w Zatoce Puckiej oraz w płytkowodnej strefie przybrzeżnej i przejściowej południowej i wschodniej Zatoki Gdańskiej (rys. 9.14b). Na większych głębokościach wartości HSI są niskie lub bardzo niskie (0,4 i poniżej). Mediany HSI pochodzące z modułu Fish są zgodne z wydajnością połowową storni we wszystkich lokalizacjach, w których prowadzono połowy. W związku z dobrą zgodnością wartości HSI z wydajnościami połowowymi wynik walidacji należy uznać za bardzo dobry.











Źródło: a) "Wiadomości Rybackie", MIR-PIB (Radtke i in., 2020a); b) opracowanie własne.

PODSUMOWANIE

Aby w przystępny sposób ocenić zgodność wyników HSI z modułu Fish ze wszystkimi rejsami oceanograficzno-rybackimi, które odbyły się w latach 2017–2020, wyniki walidacji zestawiono w tabeli 9.2. Kolory wskazuja, czy zgodność dla porównania poszczególnych rejsów i gatunków ryb jest dobra/bardzo dobra (kolor zielony), zadowalająca (kolor żółty) czy niezadowalająca/zła (kolor czerwony).

Tabela 9.2

Rejs	Data	Szprot	Dorsz	Śledź	Stornia
2017-1Q	9.02– 8.03.2017	zła	bardzo dobra	bardzo dobra	
2017-4Q	13.11– 3.12.2017	niezadowalająca	dobra	zadowalająca	zadowalająca
2018-1Q	7.02– 2.03.2018	zadowalająca	dobra	dobra	
2018-4Q	14.11– 1.12.2018	dobra	dobra	bardzo dobra	bardzo dobra
2019-1Q	12.02– 7.03.2019	dobra	bardzo dobra	bardzo dobra	

Tabela zgodności dla porównania wyników uzyskanych z modułu Fish z rejsami oceanograficzno-rybackimi











236

					cd. tabeli 9.2
2019-4Q	11– 29.11.2019	dobra	zadowalająca	bardzo dobra	bardzo dobra
2020-1Q	4.02– 3.03.2020	dobra	zadowalająca	bardzo dobra	
2020-4Q	12.11– 2.12.2020	dobra	dobra	dobra	zadowalająca

Źródło: opracowanie własne.

Sumaryczny wynik walidacji przeprowadzonej dla lat 2017-2020 można uznać za bardzo dobry. Oznacza to, że dla dominującej liczby rejsów warunki środowiskowe wyznaczone z modułu Fish odpowiadają wydajnościom połowowym. Najlepsze wyniki uzyskano dla śledzia oraz dorsza. W związku z brakiem preferencji od grudnia do czerwca dla storni niemożliwe było sprawdzenie poprawności działania modułu Fish dla tego gatunku w rejsach zimowych (BITS-1Q). Jednak podczas rejsów jesiennych wyniki były co najmniej zadowalające. Jedynie w dwóch rejsach w roku 2017 dla szprota uzyskano zła i niezadowalająca zgodność ze zmierzonymi wydajnościami połowowymi. Nie powinno to jednak wpłynać na ogólna ocene procesu walidacji, gdyż połowy podczas rejsów oceanograficzno-rybackich prowadzone były przy dnie, a preferencje głębokościowe gatunków rozpatrywanych w projekcie są zróżnicowane. Wykorzystanie mediany preferencji dla kolumny wody zamiast maksimum miało zwiększyć pewność wyników uzyskiwanych z modułu Fish. Po otrzymaniu wysokiej mediany HSI w kolumnie wody rybak ma większą pewność połowów w korzystnych warunkach niż przy takiej samej wartości maksimum HSI. Maksimum HSI może pochodzić tylko z jednej, cienkiej warstwy wody w kolumnie, podczas gdy na pozostałych głębokościach moga panować złe warunki środowiskowe. Gorsze wyniki dla szprota w rejsach z 2017 roku mogą być dodatkowo związane z tym, że rejsy rybackie w projekcie FindFISH, na podstawie których oszacowano preferencje ryb, rozpoczęły się po 2017 roku. W tym roku mogły panować inne warunki środowiskowe podczas połowów niż w latach kolejnych. Brak informacji o nich nie pozwolił na doprecyzowanie (rozszerzenie) krzywych preferencji i "zasymilowanie" tych danych przez moduł Fish.

LITERATURA

- 1. Bovee K.D., *Development and evaluation of habitat suitability criteria for use in the instream flow incremental methodology*, National Ecology Center, Division of Wildlife and Contaminant Research, Fish and Wildlife Service, US Department of the Interior, U.S.A. 1986.
- Chou W.C., Lin W.T., Lin C.Y., Application of fuzzy theory and PROMETHEE technique to evaluate suitable ecotechnology method: a case study in Shihmen Reservoir Watershed, Taiwan, Ecological Engineering, 2007, 31(4), 269–280. https://doi.org/10.1016/j.ecoleng.2007.08.004.







- Fraternali P., Castelletti A., Soncini-Sessa R., Vaca Ruiz C., Rizzoli A.E., *Putting humans in the loop: social computing for water resources management*, Environmental Modelling & Software, 2012, 37, 68–77. https://doi.org/10.1016/j.envsoft.2012.03.002.
- Fukuda S., De Baets B., Mouton A.M., Waegeman W., Nakajima J., Mukai T., *Effect of model formulation on the optimization of a genetic Takagi–Sugeno fuzzy system for fish habitat suitability evaluation*, Ecological Modelling, 2011, 222(8), 1401–1413. https://doi.org/10.1016/j.eco-Imodel.2011.01.023.
- Inglis G.J., Hurren H., Oldman J., Haskew R., Using habitat suitability index and particle dispersion models for early detection of marine invaders, Ecological Applications, 2006, 16(4), 1377–1390. https://doi.org/10.1890/1051-0761(2006)016[1377:uhsiap]2.0.co;2.
- Janecki M., Dybowski D., Jakacki J., Nowicki A., Dzierzbicka-Glowacka L., The use of satellite data to determine the changes of hydrodynamic parameters in the Gulf of Gdańsk via EcoFish Model, Remote Sensing, 2021, 13, 3572. https://doi.org/10.3390/rs13183572.
- Janecki M., Dybowski D., Nowicki A., Dzierzbicka-Głowacka L., Analiza dynamiki zmienności parametrów biochemicznych w rejonie Zatoki Gdańskiej za pomocą modelu EcoFish (rozdział 7), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 179–204.
- Janecki M., Dybowski D., Nowicki A., Jakacki J., Dzierzbicka-Głowacka L., Analiza parametrów fizycznych wód Zatoki Gdańskiej za pomocą modelu numerycznego EcoFish (rozdział 6), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 145–178.
- 9. Legleiter C.J., Goodchild M.F., *Alternative representations of instream habitat: classification using remote sensing, hydraulic modeling, and fuzzy logic*, International Journal of Geographical Information Science, 2005, 19(1), 29–50. https://doi.org/10.1080/13658810412331280220.
- Mouton A.M., De Baets B., Goethals P.L.M., *Knowledge-based versus data-driven fuzzy habitat suitability models for river management*, Environmental Modelling & Software, 2009, 24(8), 982–993. https://doi.org/10.1016/j.envsoft.2009.02.005.
- Pieckiel P., Kuczyński T., Analiza istniejących i nowych danych środowiskowych pochodzących z wypraw rybackich w celu określenia preferencji ryb poławianych przemysłowo w Zatoce Gdańskiej (rozdział 5), w: Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa, red. L. Dzierzbicka-Głowacka, Wydawnictwo Uniwersytetu Morskiego w Gdyni, Gdynia 2023, 118–144.
- Poulos H.M., Chernoff B., Fuller P.L., Butman D., Ensemble forecasting of potential habitat for three invasive fishes. Aquatic Invasions, 2012, 7(1), 59–72. https://doi.org/10.3391/ ai.2012.7.1.007.
- 13. Prato T., Assessing ecosystem sustainability and management using fuzzy logic, Ecological Economics, 2007, 61(1), 171–177. https://doi.org/10.1016/j.ecolecon.2006.08.004.
- 14. Radtke K., Wodzinowski T., Šics I., *Najnowsze wyniki badań z rejsu r.v. Baltica (09.02–08.03. 2017 r.)*, Wiadomości Rybackie MIR-PIB, marzec–kwiecień (216), 2017.
- 15. Radtke K., Wodzinowski T., Wójcik I., *Podsumowanie oceanograficzno-rybackich wyników z rejsu zimowego r.v. Baltica w 2018 roku*, Wiadomości Rybackie MIR-PIB, marzec–kwiecień (222), 2018b.







- 16. Radtke K., Wodzinowski T., Wójcik I., *Wyniki badań oceanograficzno-rybackich r.v. Baltica w rejsie jesiennym 2019 r.*, Wiadomości Rybackie MIR-PIB, styczeń–luty (233), 2020a.
- 17. Radtke K., Wodzinowski T., Wójcik I., *Wyniki badań oceanograficzno-rybackich r.v. Baltica w rejsie jesiennym w 2018 r.*, Wiadomości Rybackie MIR-PIB, styczeń–luty (227), Gdynia, 2019a.
- 18. Radtke K., Wodzinowski T., Wójcik I., *Wyniki badań oceanograficzno-rybackich r.v. Baltica w rejsie zimowym 2020 r.*, Wiadomości Rybackie MIR-PIB, marzec–kwiecień (234), 2020b.
- Radtke K., Wodzinowski T., Wójcik I., Wyniki badań oceanograficzno-rybackiego rejsu r.v. Baltica na przełomie listopada i grudnia 2020 roku, Wiadomości Rybackie MIR-PIB, styczeńluty (239), 2021.
- Radtke K., Wodzinowski T., Wójcik I., Wyniki oceanograficzno-rybackiego rejsu r.v. Baltica zrealizowanego w lutym i marcu 2019 r., Wiadomości Rybackie MIR-PIB, marzec-kwiecień (228), 2019b.
- Radtke K., Wodzinowski T., Wójcik I., Šics I., Wyniki badań demersalnego rejsu r.v. Baltica jesień 2017, Wiadomości Rybackie MIR-PIB, styczeń–luty (221), 2018a.
- 22. Rüger N., Schlüter M., Matthies M., *A fuzzy habitat suitability index for* Populus euphratica *in the Northern Amudarya delta (Uzbekistan)*, Ecological Modelling, 2005, 184(2–4), 313–328. https://doi.org/10.1016/j.ecolmodel.2004.10.010.
- Van Broekhoven E., Adriaenssens V., De Baets B., Verdonschot P.F.M., *Fuzzy rule-based macro-invertebrate habitat suitability models for running waters*, Ecological Modelling, 2006, 198(1–2), 71–84. https://doi.org/10.1016/j.ecolmodel.2006.04.006.
- 24. Zhang H., Sun T., Shao D., Yang W., *Fuzzy logic method for evaluating habitat suitability in an estuary affected by land reclamation*, Wetlands, 2016, 36, 19–30. https://doi.org/10.1007/s13157-014-0606-2.

Praca wykonana w ramach projektu "Platforma transferu wiedzy FindFISH – Numeryczny System Prognozowania warunków środowiska morskiego Zatoki Gdańskiej dla Rybołówstwa" (nr RPPM.01.01.01-22-0025/16-00) współfinansowanego ze środków Europejskiego Funduszu Rozwoju Regionalnego w ramach Regionalnego Programu Operacyjnego Województwa Pomorskiego na lata 2014–2020.

Obliczenia wykonano z wykorzystaniem komputerów Centrum Informatycznego Trójmiejskiej Akademickiej Sieci Komputerowej.







