

MODELOWANIE SERII CZASOWYCH PRZEPŁYWÓW W KRÓTKOTERMINOWEJ PROGNOZIE HYDROLOGICZNEJ

Tomasz Siuta 

Katedra Geoinżynierii i Gospodarki Wodnej, Politechnika Krakowska, ul. Warszawska 24, 31-155 Kraków

ABSTRAKT

Cel pracy

W niniejszym artykule przedstawiono przykład opracowania skutecznej prognozy krótkoterminowej w czasie rzeczywistym przepływów wezbraniowych w przekroju wodowskazowym wybranej zlewni różnicowej rzeki Wisły. Prognoza ta oparta jest na przepływach obserwowanych w przekrojach wejściowych i wyjściowym systemu rzecznej z dobowym opóźnieniem bez uwzględnienia jakichkolwiek danych opadowych.

Materiał i metody

W celu oceny jakości prognozy opracowano cztery typy modeli serii czasowych chwilowego natężenia przepływu dla przekroju wyjściowego Smolice na rzece Wiśle. Pierwszy typ modelu to konwencjonalna liniowa zależność autoregresyjna (AR), drugi – trójwarstwowa sieć neuronowa typu feedforward (SSN), trzeci – dwuwarstwowa rekurencyjna sieć neuronowa i czwarty – trójwarstwowa rekurencyjna sieć neuronowa (RNN). Wszystkie modele były kalibrowane i testowane w oparciu o dane historyczne w formie hydrogramów natężenia przepływu.

Wyniki i wnioski

Spośród wszystkich testowanych typów modeli najdokładniejszą prognozę wartości chwilowej natężenia przepływu w przekroju zamykającym zlewnię uzyskano za pomocą modelu RNN. Ten typ modelu miał również największą zdolność do generalizowania wyników, wykazując podobną jakość prognozy w trzech niezależnych testach.

Słowa kluczowe: system rzeczny, serie czasowe, prognoza krótkoterminowa, przepływ kulminacyjny, modele autoregresyjne, rekurencyjna sieć neuronowa.

WPROWADZENIE

Modelowanie serii czasowych, które ma swoje korzenie w teorii systemów i analizie statystycznej procesów dynamicznych, znajduje również szerokie praktyczne zastosowanie w hydrologii (Hipeli in., 1994; Lohani i in., 2012). Jeśli potraktujemy zlewnię rzeki jako system hydrologiczny, modele serii czasowych stają się naturalną alternatywą dla kompleksowych modeli matematycznych (opartych na szczegółowym

opisie matematycznym procesów hydrologicznych) czy konceptualnych, szczególnie kiedy chodzi o ich zastosowanie do celów prognostycznych. Celem niniejszego artykułu jest prezentacja możliwości i porównanie efektywności zastosowania modeli autoregresyjnych i sztucznych sieci neuronowych (SSN) do prognozy krótkoterminowej dobowych przepływów nieustalonych w czasie rzeczywistym na przykładzie systemu zlewni cząstkowej rzeki Wisły. Użyte tutaj pojęcie prognozy krótkoterminowej (Abrahart i in.,


 e-mail: tomasz.siuta@iigw.pk.edu.pl

2002) odnosi się do relacji pomiędzy chwilowymi stanami zaistniałymi już w systemie rzeczonym (np. związki wodowskazowe) bez uwzględniania danych opadowych. Relacje te będą więc wynikały z procesu transformacji fali wezbraniowej w korycie na odcinku cieków głównego z uwzględnieniem kontrolowanych dopływów skupionych (zmiennie wejściowe do modelu) z cieków drugiego rzędu, jak również z dopływów niekontrolowanych w pewnym stopniu skorelowanych ze zmiennymi wejściowymi. W literaturze można spotkać się z licznymi opisami zastosowań sztucznych sieci neuronowych (SSN) do odwzorowania relacji typu opad–odpływ (Toth i in., 2000; Lin i Wang, 2007). W Polsce tematyka ta w przypadku prognozowania przepływów powodziowych w zlewniach polskich rzek nie jest szeroko przebadana z wyjątkiem zlewni rzeki Raby (Krzanowski i Wałęga, 2007). Prognozy czasowe oparte na modelach SSN często są porównywalne jakościowo z tradycyjnymi modelami autoregresyjnymi (np. ARMA) (Toth i in., 2000, Abrahart i in., 2002) lub przy odpowiednio dobranej architekturze modeli SSN dostarczają dokładniejszej prognozy. Brak adekwatnych danych opadowych nie zawsze stanowi przeszkodę w opracowaniu skutecznego modelu prognostycznego bazującego jedynie na stanach zaistniałych w przekrojach wejściowych i wyjściowym stanie systemu rzecznego, może jednak prowadzić do skrócenia horyzontu prognozy, przy którym jej jakość pozostaje jeszcze satysfakcjonująca z praktycznego punktu widzenia (np. systemu ostrzeżeń przed powodzią). Faktycznie w literaturze przedmiotu można spotkać opracowania (Abrahart i in., 2002), gdzie autorzy analizują zlewnie badawcze, w których korelacja zmiennych opadowych z prognozowanymi stanami wezbraniowymi w przekroju zamykającym zlewnię, w porównaniu z korelacją ze stanami zaistniałymi mierzonymi w przekrojach wodowskazowych w wyższych partiach zlewni, była relatywnie niska. Efekt ten występuje najczęściej w przypadku zlewni cząstkowej obejmującej swym zasięgiem nizinny bieg odcinka rzeki i zależy od obranej długości horyzontu prognozy (czasu opóźnienia pomiędzy sygnałem wejściowym a wyjściowym z systemu). Z drugiej strony, istnieją opracowane przykłady modeli SSN odwzorowujących relację opad–odpływ z dużą dokładnością (współczynnik determinacji sięgający wartości 0,9) bazujących na samych tylko danych opadowych. Dotyczy

to jednak głównie przypadków, kiedy dane pochodzą z pomiarów radarowych (Teschl i in., 2006). Pomimo uzyskiwanej ogólnie dużej dokładności, autorzy donoszą o znaczących błędach odwzorowania stanów kulminacyjnych, których skuteczną prognoza jest konieczna do poprawnego funkcjonowania systemów wczesnego ostrzegania przed powodzią. Mankamentem modeli SSN jest, jak dotąd, brak satysfakcjonującej interpretacji wyliczonych współczynników wagowych połączeń z neuronami sieci. Ostatnio, w miarę pojawiania się coraz to bardziej zaawansowanych typów modeli neuronowych (np. LongShort Term Memory), podejmowane są pewne próby interpretacyjne ich parametrów, np. wiązanie stanu sieci z retencją zlewni, jednak wciąż pozostają modelami typu czarnej skrzynki. Niemniej jednak skuteczność modeli SSN w prognozie hydrologicznej często przewyższa skuteczność tradycyjnych modeli konceptualnych czy matematycznych opartych na modelowaniu złożonych procesów hydrologicznych (Hu i in., 2018)

CHARAKTERYSTYKA SYSTEMU RZECZNEGO, DLA KTÓREGO OPRACOWANO PROGNOZYSTYCZNE MODELE SERII CZASOWYCH

Do celów badawczych wybrano system zlewni różnicowej rzeki Wisły pomiędzy przekrojem wodowskazowym Jawiszowice (km 979,5) a przekrojem Smolice (km 895,7) z uwzględnieniem jej dwóch głównych prawostronnych dopływów: rzeki Soły i Skawy (rys. 1). Powierzchnia analizowanej zlewni różnicowej rzeki Wisły w przekroju zamykającym Smolice wynosi 6796,18 km² i leży w środkowym biegu górnej Wisły, gdzie dominują obszary zielone i uprawne, położone na terenach o niewielkim wzniesieniu lub płaskich. Decydujący wpływ na zasilanie rzeki Wisły w czasie wezbrań na badanym odcinku mają dopływy skupione, a nie bezpośredni spływ powierzchniowy. Rzeka Soła jest prawostronnym dopływem Wisły, a powierzchnia jej zlewni wynosi 1390,6 km². W zlewni Soły dominują lasy i zadrzewienia, które stanowią niespełną połowę tego obszaru, zajmując 601,1 km² i porastają wyższe partie wzniesień Beskidu Śląskiego i Żywieckiego. W środkowym biegu rzeki Soły zlokalizowana jest kaskada trzech zbiorników wodnych oddzielonych zaporami: Tresna, Porąbka i Czaniec, która ma znaczący wpływ na transformację fali powodziowej. Obsza-



Rys. 1. Schemat analizowanego systemu zlewni różnicowej rzeki Wisły
Fig. 1. Diagram of the analyzed system of the Vistula differentia catchment

ry zurbanizowane nie przekraczają 7,5% powierzchni zlewni i są głównie zlokalizowane w sąsiedztwie miasta Żywca. Zlewnia rzeki Skawy o powierzchni 1160 km² (drugiego z głównych dopływów rzeki Wisły w obrębie analizowanej zlewni różnicowej) przebiega w obszarze Beskidów Zachodnich i Pogórza Zachodniobeskidzkiego. Górski charakter jej reżimu hydrologicznego sprawia, że jest rzeką o znacznym potencjale powodziowym i charakteryzuje się gwałtownymi, lecz krótkotrwałymi wezbrzeniami. W niniejszym opracowaniu wykorzystano dane historyczne pochodzące z ogólnodostępnych zasobów IMGW w postaci hydrogramów wezbraniowych określonych w przekrojach wodowskazowych rzeki Wisły – Jawiszowice (km 979.5) i Smolice (895.76) oraz w przekrojach Żywiec (km 49.3) i Oświęcim (km 2.95) na rzece Sole. Ponadto analizowano również dane z przekrojów wodowskazowych: Pustynia (km 917.5) na rzece Wisłę i Zator (km 4.26) na rzece Skawie, które ostatecznie zostały pominięte na etapie identyfikacji zmiennych wejściowych do modeli prognostycznych (bliska odległość pomiędzy przekrojem ujściowym Skawy a przekrojem Smolice). Dane historyczne z przekrojów wodowskazowych Nowy Bieruń (km 921.3) i Las (km 900.5) leżących w obrębie analizowanego odcinka rzeki Wisły nie były wystarczająco kompletne, aby można było uwzględnić je w opracowaniu modeli prognostycznych.

Między stacją wodowskazową Jawiszowice a stacją Smolice występują trzy lewobrzeżne kontrolowane dopływy Wisły: Pszczyńska ze stacją wodowskazową Pszczyzna, Gostynia ze stacją Bojszowy i Przemsza ze

stacją Jeleń. Dane z tych przekrojów wodowskazowych nie były jednak kompletne – brakowało w nich wartości natężenia przepływu średniodobowego dla części z analizowanych fal historycznych i z tego względu nie zostały uwzględnione w modelowaniu.

Wykorzystane dane historyczne to hydrogramy fal powodziowych opadowych, jakie wystąpiły na rzece Wisłę i jej głównych dopływach w latach: 1997, 2001, 2009 i 2010 w okresie letnim w lipcu i sierpniu, na skutek opadów rozlewnych. Dane te mają postać serii czasowych chwilowego natężenia przepływu określonego w przekrojach wodowskazowych w dobowych odstępach czasu. Wybrane hydrogramy (za wyjątkiem fali z roku 2009) przedstawiają najwyższe fale powodziowe, dla których natężenie przepływu kulminacyjnego w przekroju zamykającym (Smolice) przekracza wartość 1600 m³ · s⁻¹ (natężenie przepływu prawdopodobnego Q_{1%} w tym przekroju wynosi 2180 m³ · s⁻¹). Analizowane fale historyczne charakteryzują się relatywnie krótkim czasem wznoszenia (od 3–6 dób) i szybkim tempem przyrostu natężenia przepływu (od 260 m³ · s⁻¹ · d⁻¹–530 m³ · s⁻¹ · d⁻¹). Czas wznoszenia dla hydrogramów fal historycznych wynosi odpowiednio: 4 doby dla fali z roku 1997, 9 dób dla fali z roku 2001, 7 dób dla fali z roku 2009 i 4 doby dla fali z roku 2010.

OPRACOWANE MODELE SERII CZASOWYCH

W celu dokonania porównawczej oceny jakości prognozy krótkoterminowej opracowano cztery różne typy modeli. Pierwszym z nich jest liniowy model autoregresyjny (AR), którego ogólną postać przedstawia

równanie (1). Drugim testowanym modelem jest rekurencyjna liniowa sieć neuronowa (RLN), której zapis matematyczny przedstawia równanie (2). Model ten stanowi pewną modyfikację modelu AR dzięki uzależnieniu odpowiedzi sieci w chwili t od wartości sygnału wyjściowego estymowanego w chwili poprzedniej $t-1$. Wartość sygnału wyjściowego (tutaj: natężenia przepływu w przekroju zamykającym zlewnię) estymowana dla chwili $t-1$ może być traktowana jako funkcja stanu modelu, gdyż jej wartość zależy w pewnym stopniu od wszystkich wartości przeszłych sygnałów wejściowych, pełniąc rolę tzw. pamięci systemu (Rahul i in., 2010). Model taki stanowi pewną analogię do liniowego modelu konceptualnego Muskingum (Gill, 1978) opisującego w przybliżony sposób efekt transformacji fali powodziowej na krótkim odcinku rzeki. Model RLN daje potencjalną możliwość lepszego odwzorowania liniowej (w przybliżeniu) dynamiki systemu w porównaniu ze statycznymi modelami typu AR. Kolejnym opracowanym modelem jest trójwarstwowa sieć neuronowa typu feed forward, która może być interpretowana jako nieliniowy model autoregresyjny (NAR), jej zapis matematyczny przedstawia równanie (3).

$$\hat{Q}_{out,t} = \varepsilon_t + \sum_{i=1}^m w_i \cdot Q_{out,t-i} + \sum_{k=1}^n \left(\sum_{i=1}^p w_{k,i} \cdot Q_{k,t-i} \right) \quad (1)$$

gdzie:

- $\hat{Q}_{out,t}$ – prognozowane natężenie przepływu w chwili t w przekroju wyjściowym,
- $Q_{k,t-i}$ – obserwowane natężenie przepływu w chwili $t-i$ w k -tym przekroju wejściowym,
- n – liczba przekrojów (sygnałów) wejściowych do systemu rzeczno (tutaj: $n = 3$),
- p – liczba elementów serii czasowej w k -tym sygnale wejściowym (tutaj: $p = 2$),
- m – liczba elementów serii czasowej sygnału wyjściowego (tutaj: $m = 2$),
- $w_{k,i}$ – macierz współczynników wagowych sygnału wejściowego opóźnionego,
- w_i – wektor współczynników wagowych sygnału wyjściowego opóźnionego,
- t – chwila czasowa w której prognozowana jest wartość $\hat{Q}_{s,t}$ (z hydrogramu),
- ε_t – wartość nieskorelowanego błędu w chwili t .

$$\hat{Q}_{out,t} = \varepsilon_t + \sum_{i=1}^m w_i \cdot Q_{out,t-i} + \sum_{k=1}^n \left(\sum_{i=1}^p w_{k,i} \cdot Q_{k,t-i} \right) + w_{out} \cdot \hat{Q}_{out,t-1} \quad (2)$$

gdzie:

- w_{out} – współczynnik wagowy sprzężenia zwrotnego sygnału wyjściowego

$$\hat{Q}_{out,t} = \varepsilon_t + h \left(w_0 + \sum_{j=1}^l w_j h \left(w_{0,j} + \sum_{i=1}^m w_{j,i} \cdot Q_{out,t-i} + \sum_{k=1}^n \sum_{i=1}^p w_{k,j,i} \cdot Q_{k,t-i} \right) \right) \quad (3)$$

gdzie:

- h – sigmoidalna funkcja aktywacji (funkcja logistyczna),
- l – liczba neuronów w warstwie ukrytej (tutaj: $l = 2$),
- $w_{k,j,i}$ – macierze współczynników wagowych dla k -ego sygnału wejściowego,
- $w_{j,i}$ – macierz współczynników wagowych dla sygnału wyjściowego opóźnionego,
- w_j – współczynnik wagowy j -ego neuronu w warstwie ukrytej,
- $w_{0,j}$ – wektor współczynników wagowych wolnych w warstwie ukrytej,
- w_0 – współczynnik wagowy wolny w warstwie wyjściowej z sieci.

Ostatnim z testowanych modeli jest szczególny wariant rekurencyjnej sieci neuronowej RNN (4). Stanowi on modyfikację statycznego modelu NAR polegającą na dołączeniu sprzężenia zwrotnego sygnału wyjściowego do warstwy wejściowej sieci neuronowej.

$$\hat{Q}_{out,t} = \varepsilon_t + w_0 + \sum_{j=1}^l w_j h \left(w_{0,j} + \sum_{i=1}^p w_{j,i} \cdot Q_{out,t-i} + \sum_{k=1}^n \sum_{i=1}^p w_{k,j,i} \cdot Q_{k,t-i} + w_{out,j} \cdot \hat{Q}_{s,t-1} \right) \quad (4)$$

gdzie:

- $w_{out,j}$ – wektor wagowy sprzężenia zwrotnego sygnału wyjściowego.

Zastosowano tutaj (podobnie jak w przypadku modelu RLN) liniową funkcję aktywacji w warstwie wyjściowej sieci funkcję logistyczną w warstwie ukrytej (rów. 4). Model taki łączy cechy dwóch poprzednich, tzn. zdolność do aproksymacji liniowej dynamiki systemu i nieliniowej estymacji wartości niekontrolowanego sygnału wejściowego (tutaj: dopływów niekontrolowanych występujących wzdłuż odcinka rzeki). W literaturze można znaleźć opracowania świadczące o tym, iż rekurencyjne sieci neuronowe posiadają większą zdolność do generalizacji w porównaniu z modelami statycznymi SSN (Rahul i in., 2010). Ostatnio pojawiły się również prace na temat skutecznego zastosowania szczególnego rodzaju sieci rekurencyjnej (LSTM) do odwzorowania dynamiki procesu typu opad–odpływ (Hu i in., 2018). Podejmowane są również próby interpretacji fizycznej funkcji stanu stosowanych w modelach typu RNN na gruncie retencji Lewniowej (Kratzert i in., 2018).

Zbiory danych kalibrujących i testowych

Ze względu na niewielką liczbę fal historycznych dostępnych w postaci hydrogramów natężenia przepływu określonego w dobowych odstępach czasu, utworzono trzy kombinacje zbiorów kalibracyjnych (uczących). Zawierają one dane z trzech epizodów wezbrań historycznych. Dla każdego zestawu danych uczących przyporządkowano dane testowe opisujące pojedynczą falę historyczną, które nie były ujęte w danym zestawie danych uczących. Zestawy danych uczących wraz z danymi testowymi przedstawia tabela 1. Na podstawie trzech zdefiniowanych zbiorów danych uczących opracowano trzy warianty dla każdego z czterech typów modeli, a więc sumarycznie liczbę dwunastu modeli testowych.

Dobór zmiennych wejściowych i identyfikacja architektury modeli SSN

Zmienne wejściowe do modelu mają postać opóźnionych dyskretnych wartości natężenia przepływu (równanie 1) określonych w przekrojach wodowskazowych analizowanej zlewni różnicowej rzeki Wisły (rys. 1). Zmienną wyjściową jest natężenie przepływu określone w przekroju Smolice ($Q_{s,t}$) w chwili t , prognozowane w horyzoncie czasowym jednej doby w czasie rzeczywistym. W celu określenia elementów serii czasowych, które będą pełniły rolę zmiennych wejściowych do modeli neuronowych, posłużono się kryterium minimalizacji średniego błędu kwadratowego (RMSE) aproksymacji sygnału wyjściowego za pomocą wielowymiarowej liniowej funkcji regresyjnej (AR) sygnału wejściowego opracowanego na podstawie zbioru danych d97 (tabela 1). W wyniku optymalizacji ustalono, że wektor zmiennych wejściowych do wszystkich modeli typu SSN określony dla przekrojów Jawiszowice i Żywiec będzie dwuelementowy (Q_{t-1} i Q_{t-2}), a dla przekroju Oświęcim i Smolice jednoelementowy (Q_{t-1}). Zmienne wejściowe z przekrojów wodowskazowych Pustynia na rzece Wiśle i Zator na rzece Skawie nie przyczyniły się do redukcji wartości błędu (RMSE) estymowanej zmiennej wyjściowej ($Q_{s,t}$), dlatego nie zostały dołączone do wektora zmiennych wejściowych opracowanych modeli SSN zgodnie z zasadą tzw. brzytwy Ockhama. Do kalibracji (uczenia) testowanych modeli SSN stosowano metodę propagacji wstecznej błędu, powszechnie stosowaną w sieciach neuronowych typu feedforward, pozwalającą na oszacowanie błędu odpowiedzi neuronów w warstwie ukrytej w każdej iteracji algorytmu optymalizacji wag (Saxén i Saxén, 1995). W procesie optymalizacji współczynników wagowych zastosowano

Tabela 1. Zestawy danych uczących z przypisanym zbiorem danych testowych


Table 1. Training data sets with assigned test data set

data set name nazwa zbiorów danych	historical data included in training data set from the years dane historyczne z danego roku zawarte w zbiorze uczącym				test data set from the year zbiór testowy – fala z danego roku
	1997	2001	2009	2010	
d10	yes/tak	yes/tak	yes/tak	–	2010
d01	yes/tak	–	yes/tak	yes/tak	2001
d97	–	yes/tak	yes/tak	yes/tak	1997

wano metodę Levenberg-Marquardt, która pozwala na uzyskanie szybszej zbieżności w porównaniu z metodą Gaussa-Newtona czy metodą gradientową (Jayawardena i Fernando, 1996). Opracowanie i testowanie modeli SSN zrealizowano w programie NNNT (Saxen i Bjorn, 1995). Ze względu na mało liczną reprezentację danych historycznych nie stosowano tzw. testów walidacyjnych w procesie uczenia modeli SSN. W procesie kalibracji wag modeli nie doszło w żadnym z przypadków do efektu tzw. przeuczenia sieci neuronowej (ang. *overfitting*), co przejawia się porównywalnymi (co do rzędu wielkości) wartościami błędów RMSE odwzorowania danych kalibracyjnych i testowych (tabela 2). Brak wspomnianego efektu pomimo pominięcia testów walidacyjnych świadczy o pewnej zdolności opracowanych modeli SSN do generalizacji, co znalazło swoje potwierdzenie w przeprowadzonych testach niezależnych (rys. 3–5 i tab. 2). W przypadku trójwarstwowej sieci neuronowej (NAR), stosując wyżej opisane kryterium minimalizacji błędów (MSE), przyjęto dwa neurony w warstwie ukrytej i w obu warstwach funkcję aktywacji w postaci funkcji logistycznej (przyjmującej wartości z przedziału od 0 do 1). W modelu RNN (rys. 2) również przyjęto dwa neurony w warstwie ukrytej i logistyczną funkcję aktywacji, natomiast w warstwie wyjściowej zastosowano liniową funkcję aktywacji (rów. 4).

ANALIZA WYNIKÓW I OCENA EFEKTYWNOŚCI PROGNOZY KRÓTKOTERMINOWEJ

Na podstawie wyliczonych wartości pierwiastka ze średniego błędów kwadratowego (RMSE) można stwierdzić, iż najdokładniejsze odwzorowanie danych wzorcowych w zbiorze uczącym (kalibracyjnym) uzyskano



Rys. 2. Schemat sieci neuronowej RNN stosowanej w niniejszym opracowaniu

Fig. 2. Sketch of the RNN neural network used in this study

modelem RNN we wszystkich zestawach danych uczących (tab. 2). Przykładowe wartości wag modelu RNN opracowanego na podstawie zbioru uczącego *d97* przedstawiono w tabeli 5. Dokładność odwzorowania serii czasowej przepływów wzorcowych użytych do testów niezależnych jest największa w przypadku modelu RNN – uzyskana dla zbioru *d10*, a dla zbiorów *d97* i *d01* jest porównywalna z wynikami uzyskanymi dla jego liniowego odpowiednika (modelu RLN). Można na tej podstawie stwierdzić, iż zdolność do generalizacji wspomnianych modeli jest nieco większa niż dwóch pozostałych (modele: AR i NAR). Potwierdza to również najwyższa wartość współczynnika determinacji, sięgająca 0.945 w wariancie modelu opartym na zbiorze danych *d01* (tab. 3). Najmniej dokładne wyniki obliczeń uzyskano przy wykorzystaniu modelu NAR – pomimo relatywnie małego błędów kalibracji – stosunek jego wartości do wartości błędów wyników testowych

Tabela 2. Wartości błędów (RMSE) kalibracji i testów opracowanych modeli

Table 2. Error values (RMSE) of calibrated and tested models prediction output

data set zbiór danych	training data error [$\text{m}^3 \cdot \text{s}^{-1}$] – błąd kalibracji				test data error [$\text{m}^3 \cdot \text{s}^{-1}$] – błąd testowy			
	AR	RLN	NAR	RNN	AR	RLN	NAR	RNN
<i>d10</i>	72	69	57	50	89	82.5	86	75
<i>d01</i>	86	69	67	62	121	82.5	118	90
<i>d97</i>	87	81.7	69	65	83	82	91.5	88

ma mniejszą wartość w porównaniu z pozostałymi modelami (tab. 2). Mamy tutaj do czynienia w niewielkim stopniu z mniejszą zdolnością do generalizacji wyników odwzorowania zmiennej wyjściowej, czego nie obserwujemy w przypadku modelu RNN i RLN.

Tabela 3. Wartości współczynnika determinacji (R^2) obliczone na podstawie danych testowych

Table 3. Values of determination coefficient (R^2) calculated on the basis of test data

data set zbiór danych	coefficient R^2 – współczynnik R^2			
	AR	RLN	NAR	RNN
d10	0.898	0.910	0.897	0.922
d01	0.885	0.900	0.893	0.945
d97	0.946	0.955	0.955	0.947

Nieco odmienne jakościowo wyniki uzyskali Krzanoski i Wałęga (2007) w opracowaniu modeli serii czasowych przepływów dla przekroju Gdów zamkniętego badanej zlewni różnicową rzeki Raby. W tym wypadku wartość współczynnika determinacji dla modeli SSN wyniosła około 0,7 (w niniejszym opracowaniu 0,88) a dla modelu typu AR 0,8 (w niniejszym opracowaniu 0,95). Wspomniana większa wartość współczynnika determinacji dla modeli opracowanych dla zlewni różnicowej rzeki Wisły może wynikać z faktu, że zlewnia ta ma charakter nizinny – w odróżnieniu od zlewni rzeki Raby, gdzie istotnym czynnikiem zasilania koryta w górnych partiach jest spływ powierzchniowy i niekontrolowane liczne dopływy skupione. Potwierdzeniem tego jest uzyskanie przez autorów pewnej redukcji wartości błędu RMSE na skutek uwzględnienia w modelowaniu serii czasowych przepływów danych opadowych.

Ponieważ w hydrologicznej prognozie krótkoterminowej kładziemy głównie nacisk na wysokie wartości natężenia przepływu, w tym szczególnie na wartości kulminacyjne, zdefiniowano dodatkowo miary błędu (rów. 5) odwzorowania wartości kulminacyjnego natężenia przepływu (BK) i określono jego błędne umiejscowienie w czasie, określając tzw. błąd fazowy (BF). Ujemna wartość BK wskazuje na przeszacowanie wartości kulminacyjnego natężenia przepływu, zaś dodatnia na niedoszacowanie (tab. 4).

Błąd wartości prognozowanego natężenia przepływu kulminacyjnego oraz błąd fazowy wyznaczono, opierając się na poniższym równaniu:

$$BK = \frac{Q_{\max} - Q_{\max, \text{prog}}}{Q_{\max}} \cdot 100\%, \quad BF = T_k - T_{k, \text{prog}} \quad (5)$$

gdzie:

- BK – błąd predykcji wartości natężenia przepływu kulminacyjnego,
- BF – błąd predykcji chwili czasowej przepływu kulminacyjnego,
- $Q_{\max, \text{prog}}$ – kulminacyjne natężenie przepływu prognozowane w przekroju wyjściowym,
- Q_{\max} – kulminacyjne natężenie przepływu obserwowane w przekroju wyjściowym,
- $T_{k, \text{prog}}$ – prognozowany czas wystąpienia przepływu kulminacyjnego,
- T_k – obserwowany czas wystąpienia przepływu kulminacyjnego.

Analiza wartości błędu BK (tab. 4) wskazuje, iż najmniejsze wartości błędu (biorąc pod uwagę trzy warianty zbiorów danych uczących), określone dla testów niezależnych, uzyskano stosując model regresji liniowej (AR), a największe wartości dla modelu NAR. Podobne rezultaty – większej efektywności prognozowania wysokich przepływów kulminacyjnych za pomocą modeli liniowych w porównaniu z modelami nieliniowymi typu SSN – zauważone były również przez innych badaczy (Abrahart i in. 2002, Rahul i in. 2010).

Poza wspomnianymi badaniami tematyka prognozy przepływów wezbraniowych za pomocą sztucznych sieci neuronowych (SSN) bez uwzględniania danych opadowych nie jest jak dotąd szeroko opisywana w literaturze. Można w niej za to odnaleźć przykład pracy dotyczącej prognozy przepływów średniesięcznych (Özgü i Kişi, 2004) ważnej ze względów np. gospodarki na zbiornikach retencyjnych. Autor donosi tutaj o porównywalnej jakości modelowania za pomocą modeli typu SSN i modelu statystycznego AR. W odniesieniu do wyników niniejszej pracy, gdzie przedmiotem analizy były przepływy wezbraniowe średnio dobowe, można stwierdzić, że modele SSN rekurencyjne (RNN) mogą potencjalnie przyczynić się do dokładniejszego odwzorowania czasu wy-

Tabela 4. Błąd względny wartości przepływu kulminacyjnego (BK) i błąd fazowy (BF)
Table 4. Relative error of peak flow value (BK) and phase error (BF)

data set zbiór danych	AR		RLN		NAR		RNN	
	BK [%]	BF [day]	BK [%]	BF [day]	BK [%]	BF [day]	BK [%]	BF [day]
<i>d10</i>	-4.5	+1	2.6	0	5.9	0	-1.2	0
<i>d01</i>	3.1	+1	2.3	+1	24.4	0	11.9	0
<i>d97</i>	1.5	+1	-10.6	+1	-4.4	+1	3.8	0

stąpienia przepływów kulminacyjnych w porównaniu z modelami typu AR. Ważną rolę z punktu widzenia jakości prognozy przepływów odgrywa właściwy dobór zmiennych wejściowych do modelu, poparty rozumieniem procesu hydrologicznego (ASCE Task Committee, 2000). Znajduje to swoje odzwierciedlenie również w niniejszej pracy, gdzie ustalenie lokalizacji przekroju wejściowego na rzece Wiśle jest ograniczone przyjętym horyzontem prognozy (jedna doba), który koresponduje z czasem propagacji fali wezbraniowej pomiędzy przekrojem wejściowym (Jawiszowice) a przekrojem wyjściowym (Smolice).

Prezentowany w ramach niniejszego artykułu model nieliniowy RNN z pętlą sprzężenia zwrotnego dostarcza prognozy wartości natężenia przepływów kulminacyjnych o jakości porównywalnej z tą, jaką uzyskano na modelu AR, z wyjątkiem testu przeprowadzonego na bazie zbioru danych *d01* (błąd BK sięga tutaj 12%). Bardziej wiarygodna ocena efektywności prognozy przepływów wysokich wymaga poszerzenia liczby danych historycznych opisujących wezbrania powodziowe. Bardzo istotną cechą modelu RNN jest bezbłądne (w świetle użytych danych historycznych) prognozowanie czasu wystąpienia kulminacji fali w przyjętym jednodobowym horyzontie prognozy (tab. 4). W tym aspekcie najmniejszą efektywność ma liniowy model regresyjny AR, który w żadnym z przypadków testowych nie dał poprawnej odpowiedzi odnośnie czasu wystąpienia przepływu kulminacyjnego w przekroju wodowskazowym Smolice. Otrzymane wyniki potwierdzają fakt, iż efekt błędnego przesunięcia w czasie kulminacji fali wynika z nieliniowego charakteru procesu transformacji fali na odcinku koryta rzeki z dopływem niekontrolowanym i dlatego modele NAR i RNN są skuteczniejsze w predyk-


cji chwili czasowej, w której pojawia się przepływ kulminacyjny.

Ponadto należy zwrócić uwagę na to, że jakość prognozy w horyzoncie dobowym poprawia się w miarę zbliżania się w czasie (w fazie krzywej wznoszącej hydrogramu) do przepływu kulminacyjnego (rys. 3., rys. 4., rys. 5.) niezależnie od wybranego typu modelu. Inaczej sytuacja przedstawia się tuż po przejściu kulminacji fali – obserwujemy tutaj wyraźne pogorszenie jakości prognozy (np. rys. 5). Prognoza natężenia przepływu w fazie recesji fali uzyskana za pomocą modelu RNN jest znacząco dokładniejsza od prognozy uzyskanej za pomocą pozostałych badanych typów modeli. Inną cechą badanych modeli nieliniowych (NAR i RNN) jest zdolność do dokładniejszego odwzorowania danych w zbiorach uczących (rys. 5), co w przypadku omawianych modeli jednocześnie nie przyczynia się do pogorszenia wyników testów niezależnych (tab. 2).

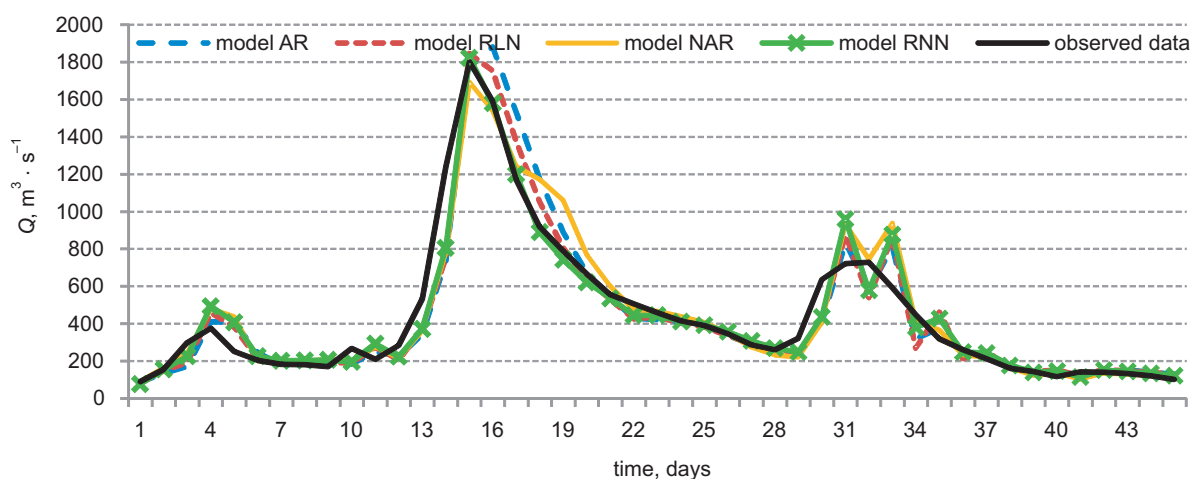
Należy również nadmienić, że w przypadku wystąpienia fali podwójnej, w której jedna z nich odznacza się znacząco mniejszą wartością natężenia przepływu kulminacyjnego, mogą pojawić się artefakty w postaci dodatkowych maksimów lokalnych natężenia przepływu (rys. 4). Efekt ten świadczy o tym, że dominujące znaczenie w procesie kalibracji (uczenia) modeli odgrywają przepływy o stanach ekstremalnych, co ze względów praktycznych jest cechą pożądaną (np. w systemach wczesnego ostrzegania przed powodzią). Nasuwa się również wniosek, iż podział zbiorów uczących według cech dynamicznych opisujących skalę i przebieg wezbrań historycznych, jak również dołączenie danych opadowych mogłoby potencjalnie przyczynić się do dalszej poprawy jakości prognozy przepływów kulminacyjnych.

Tabela 5. Przykładowa macierz współczynników wagowych – model RNN opracowany na zbiorze d97
Table 5. An example of a matrix of weighting factors – the RNN model developed on the set d97


input layer – warstwa wejściowa		$Q_1(t-1)$	$Q_1(t-2)$	$Q_2(t-1)$	$Q_2(t-2)$	$Q_3(t-1)$	$Q_s(t-1)$	$Q_s(t-2)$	$\hat{Q}_s(t-1)$
hidden layer warstwa ukryta	neuron 1	1.65	0	-5.56	1.43	4.89	-11.8	-0.012	3.7
	neuron 2	-0.366	0.59	-0.12	-2.22	0	0.7	-0.15	-0.84
output layer – warstwa wyjściowa		0.099	-0.365	-0.83	-	-	-	-	-



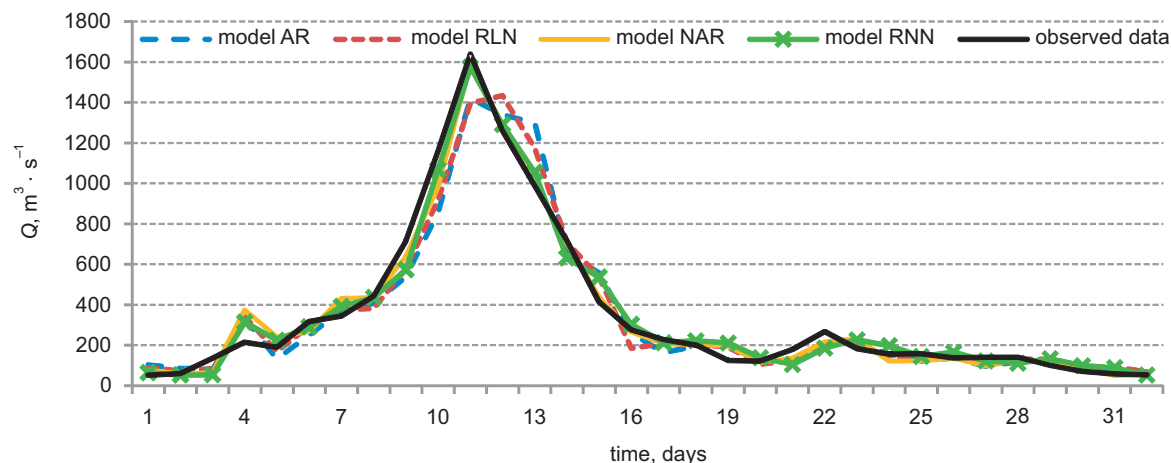
Rys. 3. Wyniki testowe (dane z roku 1997) uzyskane na podstawie zbioru uczącego d97
Fig. 3. Test results (data from the year 1997) obtained on the basis of teaching set d97



Rys. 4. Wyniki testowe (fala z roku 2010) uzyskane na podstawie zbioru uczącego d10
Fig. 4. Test results (data from the year 2010) obtained on the basis of teaching set d10



Rys. 5. Wyniki testowe (dane z roku 2001) uzyskane na podstawie zbioru uczącego d_{01}
Fig. 5. Test results (data from the year 2001) obtained on the basis of teaching set d_{01}



Rys. 6. Przykładowe wyniki prognozy zmiennej wyjściowej uzyskane na podstawie danych uczących d_{01}
Fig. 6. Example results of the output variable forecast based on the training data set d_{01}

PODSUMOWANIE

W wyniku przeprowadzonej analizy porównawczej stwierdzono, że opracowany model serii czasowych w postaci oryginalnej rekurencyjnej sieci neuronowej umożliwia prognozowanie czasu wystąpienia przepływów kulminacyjnych z większą dokładnością, niż modele konwencjonalne (statyczne modele autoregresyjne liniowe i nieliniowe), a jednocześnie błąd predykcji przepływu kulminacyjnego nie przekracza 12%.

Cecha ta ma duże znaczenie praktyczne ze względu na możliwości uzyskiwania wiarygodnej prognozy hydrologicznej z wyprzedzeniem czasowym. Opracowany model typu RNN ma większą zdolność do generalizacji niż pozostałe modele pomimo zastosowania stosunkowo małych zbiorów danych uczących. Przejawia się to głównie w trafnej prognozie chwili wystąpienia przepływu kulminacyjnego w przeprowadzonych trzech niezależnych testach i najmniejszych wartościach błędów kalibracji. Wnioski te po-

twierdzą inni badacze, którzy stosowali modele typu RNN i LSTM do odwzorowania relacji opad–odpływ w krótkoterminowej prognozie hydrologicznej (Toth i in., 2000; Hu i in., 2018). Jednak prognoza stanów kulminacyjnych oparta na takich modelach była źródłem znaczących błędów predykcji ich wartości, przy jednocześnie dużo dokładniejszym odwzorowaniu stanów niższych. Przedstawione w niniejszym artykule przykładowe wyniki prognozy krótkoterminowej uzyskane (za pomocą modelu RNN) na podstawie tylko stanów zaistniałych w systemie zlewniowym (bez danych opadowych) cechują się, w przeciwieństwie do wyżej wspomnianych modeli, relatywnie większą dokładnością odwzorowania przepływów kulminacyjnych w porównaniu z przepływami o stanach niższych. Bardziej wiarygodna (w sensie statystycznym) ocena efektywności prognozy przepływów wysokich wymaga uwzględnienia większej liczby przypadków danych historycznych opisujących przepływy wezbraniowe.

BIBLIOGRAFIA

- Abrahart R.S., See L., (2002). Multi-model data fusion for River flow forecasting; an evaluation of six alternative methods based on two contrasting catchment. *Hydrology and Earth System Sciences*, 6(4), 655–670.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000). *Artificial Neural Networks in Hydrology. II: Hydrologic Applications*, Journal of Hydrologic Engineering, 5(2)
- Gill, M.A. (1978). Flood routing by the Muskingum method, *Journal of Hydrology*, 36, 353–363.
- Hipel, K.W., McLeod, A.I. (1994). *Time Series Modelling of Water Resources and Environmental Systems*. Amsterdam: Elsevier.
- Hsu K., Gupta H. V., Sorooshian S., Application of a recurrent neural network to rainfall-runoff modeling”, *Proceedings Aesthetics in the Constructed Environment*, 31(10), 2517–2530, 1997.
- Hu, C., Wu, Q., Li, H., Jian, S., Li, N., Lou, Z. (2018). Deep Learning with a Long Short-Term Memory Networks Approach for Rainfall-Runoff Simulation. *Water* (10), 1543.
- Imrie, C.E., Durucan S., Korre A. (2000). River flow prediction Using artificial neural networks: Generalisation beyond the calibration range, *Journal of Hydrology*, 233 (1–4), 138–153.
- Jayawardena, A. W., Fernando, D.A.K. (1996). Comparison of multi-layer perceptron and radial basis function network as tools for Floyd forecasting, *Proceedings North America Water and Environment Conference*, ASCE, New York, 457–458.
- Kratzert, R., Klotz, D., Brenner, C., Schulz, K., Herrnegger, M. (2018). Rainfall-runoff model using Long Short-Term Memory (LSTM) networks, *Hydrology and Earth System Sciences*, 22, 6005–6022.
- Krzanowski, S., Wałęga, A. (2007). Zastosowanie sztucznych sieci neuronowych do predykcji szeregów czasowych stanów wody i przepływów w rzece. *Acta Sci. Pol. Formatio Circumiectus*, 6(4), 59–73.
- Lin, G.F., Wang, Ch.M. (2007). A non linear rainfall-runoff model embedded with an automated calibration method – Pt. 1: The model. *J. Hydrol.* 341, 186–195.
- Lohani A.K., Kumar R., Singh R.D. (2012). Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques, *Journal of Hydrology*, 23–35.
- Ozgun, K. (2004). River Flow Modeling Using Artificial Neural Networks. *Journal of Hydrologic Engineering*, 9(1).
- Rahul P. Deshmukh and A. A. Ghatol, (2010). Short Term Flood Forecasting Using Recurrent Neural Networks a Comparative Study, *IACSIT International Journal of Engineering and Technology*, Vol. 2, No.5, 430–434.
- Saxén B., Saxén H., (1995). NNDT — A Neural Network Development Tool. In: *Artificial Neural Nets and Genetic Algorithms*. Springer, Vienna.
- Teschl, R., Randeu, W. L. (2006). A neural network model for short term riverflow prediction, *Nat. Hazards Earth Syst. Sci.*, 6, 629–635.
- Toth, E., Brath, A., Montanari, A. (2000). Comparison of short-term rainfall prediction models for real-time Floyd forecasting, *J. Hydrol.*, 239, 132–147.

MODELING OF THE FLOW TIME SERIES FOR A SHORT-TERM HYDROLOGICAL FORECAST

ABSTRACT

Aim of the study

Within this article an example of an effective approach to real-time, short term forecast of flood rates within Vistula river differential catchment was presented. This forecast is based on flow rates time series measured at the water gauge input and output cross sections of the river system with a daily delay without taking into account any precipitation data.

Materials and methods

In order to assess the quality of the forecast, four types of time series models were developed for the Smolice outlet gage station. The first type of model is the conventional linear autoregressive relationship (AR), the second one -three layer neural network feed forward, the third one – two layer recursive neural network and the fourth one- three layer special kind of recurrent neural network (RNN). All models were trained and tested based on historical flood events data.

Results and conclusions

Among the all tested model types, the most accurate prediction of the instantaneous value of the flow rate in the outlet cross section of the Vistula catchment was obtained using the RNN model. This type of model also had the greatest ability to generalize results.

Keywords: river system, flow rate time series, short-term forecast, peak flow rate, autoregressive model, recurrent neural network