

Integracja metod sztucznej inteligencji i filtru Kalmana-Bucy w procesie estymacji stanu rzeki

T. Kwater, Z. Gomółka, E. Żesławska, P. Krutys

Uniwersytet Rzeszowski, Interdyscyplinarne Centrum Modelowania Komputerowego, 35-959 Rzeszów, ul. Pigonia 1

Abstract. W artykule przedstawiono zagadnienie estymacji stanu rzeki w oparciu o filtr Kalmana-Bucy oraz integracyjne rozwiązanie z wykorzystaniem sztucznych sieci neuronowych (SSN). Proces estymacji składa się z pomiarów ciągłych i dyskretnych, dla których zaproponowano dwie struktury SSN dla filtracji i predykcji. Przeprowadzono eksperymenty symulacyjne w wyniku, których otrzymano poprawne przebiegi estymaty stanu.

Wprowadzenie

Woda jest jednym z podstawowych elementów przyrody, posiada niezwykle właściwości fizyczne, które odgrywają dużą rolę w gospodarce. Jej wpływ na ludzi i otoczenie jest na tyle ogromny, że bez niej nie byłoby życia na Ziemi. Jest niezastąpioną i bezcenną substancją w życiu i gospodarce człowieka; wykorzystywana jest do różnych celów m.in. do higieny człowieka, miast i osiedli; bezpośredniego spożycia; rozwoju rolnictwa, przemysłu i innych gałęzi gospodarki. Jakość wody można opisać w oparciu o dwa podstawowe wskaźniki: Biochemiczne Zapotrzebowanie Tlenu (BZT) i Rozpuszczony Tlen (RT). Zawierają one informację o ilości zanieczyszczeń pochodzenia organicznego (BZT) oraz ilość tlenu (RT) potrzebnego do neutralizacji tych związków. Wykorzystując sondę tlenową w łatwy i natychmiastowy sposób można otrzymać stan RT, natomiast BZT jest trudny i długotrwały (5 lub 20 dni) oraz wymaga warunków laboratoryjnych. W celu monitorowania stanu jakości wody można stosować układ monitorujący z wykorzystaniem estymacji stanu BZT i RT. W artykule zaproponowano wykorzystanie sztucznych sieci neuronowych (SSN), które dzięki swoim właściwościom wspomogą realizację procesu estymacji.

Estymacja stanu rzeki o parametrach skupionych

Zagadnienie estymacji stanu $x(t)$ sprowadza się do wyznaczenia estymaty $\hat{x}(t)$ aktualnego stanu, z uwzględnieniem warunku minimalizującego odległość między $x(t)$, a jego estymatą $\hat{x}(t)$. Sprowadza się to do rozwiązania równania różniczkowego:

$$\frac{d}{dt}\hat{x}(t) = A\hat{x}(t) + K[y(t) - C\hat{x}(t)] \quad \hat{x}(t_0) = \hat{x}_0 \quad (1.1)$$

w którym współczynniki wzmocnienia K opisane są wzorami:

$$K = PCV_p^{-1} \quad (1.2)$$

gdzie macierze P są rozwiązaniem równań różniczkowych Riccatiego:

$$\frac{d}{dt}P = AP + PA^T - PC^T V_p^{-1} CP + DW_r D^T \quad (1.3)$$

$$P(t_0) = P_0 \quad (1.4)$$

a macierze kowariancji P, W_r, V_p – są błędem estymacji, zakłóceniem obiektowym i pomiarowym.

Powyższe zależności (1.1–1.3) opisują równanie filtru Kalmana-Bucy, aby otrzymać estymatę stanu $\hat{x}(t)$ należy w pierwszej kolejności rozwiązać równanie Riccatiego (1.3), z którego otrzymamy współczynnik wzmocnienia filtru (1.2), kolejno wyznaczamy estymatę stanu otrzymaną w wyniku rozwiązania równania (1.1). W procesie estymacji składającej się z pomiarów ciągłych i dyskretnych wyróżnić można dwie fazy: filtrację i predykcję. Równania predykcji i filtracji otrzymujemy w oparciu o równania filtru Kalmana-Bucy (1.1), (1.2) i (1.3), w których uwzględniamy nieciągłość pomiaru (1.4), przy założeniu, że: $V_p(t \neq t_k) = \infty$ [1], [2], [3].

W fazie filtracji otrzymujemy estymaty w chwili t_k na podstawie estymat z poprzedniej chwili czasowej t_{k-1} i pomiarów bieżących. Proces ten opisują następujące równania:

$$\hat{x}(t_k/t_k) = \hat{x}(t_k/t_{k-1}) + K_F(t_k)[y(t_k) - C\hat{x}(t_k/t_{k-1})] \quad (1.5)$$

$$P(t_k/t_k) = P(t_k/t_{k-1}) - K_F(t_k)C P(t_k/t_{k-1}) \quad (1.6)$$

$$K_F = P(t_k/t_{k-1}) - C^T [C P(t_k/t_{k-1}) C^T + V_p(t_k)]^{-1} \quad (1.7)$$

gdzie: $\hat{x}(t_k/t_k)$ – estymata w chwili t_k otrzymana na podstawie pomiarów $y(t_0), \dots, y(t_k)$, $P(t_k/t_k)$ – kowariancja błędu estymacji, $K_F(t_k)$ – współczynnik wzmocnienia filtru

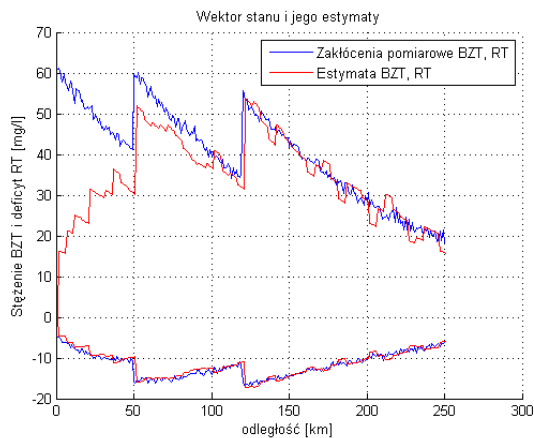
Predykcja polega na znalezieniu estymaty do następnej chwili pomiarowej dla $t \in (t_k, t_{k+1})$, przyjmując za wartości początkowe estymaty otrzymane w fazie filtracji. Predykcję przedstawiają równania:

$$\frac{d}{dt}\hat{x}(t/t_k) = A(t_k)\hat{x}(t/t_k) \quad \hat{x}(t_k/t_k) \quad (1.8)$$


$$\frac{d}{dt}P(t/t_k)A(t_k)^T + A(t_k)P(t/t_k) + W_r \quad P(t/t_k) \quad (1.9)$$

gdzie: $\hat{x}(t_k/t_k)$, $P(t_k/t_k)$ – estymata i kowariancja błędu estymacji przewidywanej dla $t > t_k$, W_r – kowariancja zakłóceń w_r [1], [2], [3].

Właściwością estymat uzyskanych z procesów filtracji i predykcji jest nieciągłość w chwilach otrzymywania pomiarów. Wynika to z dostarczania nowych informacji o obiekcie w postaci pomiarów $y(t_k)$. Wartości estymat modyfikowane są nowymi pomiarami ze wzmocnienia $K_f(t_k)$ w odniesieniu do wartości estymaty otrzymanej z poprzednich obliczeń. Wielkość „poprawki” zależy od aktualnego pomiaru i dotychczasowej wartości estymaty. Równania filtru generują estymaty, których przebiegi są zgodne ze zmianą wektora stanu (patrz rys. 1, rys. 2). Zważywszy na fakt, że dokonujemy pomiaru stanu RT, jego estymata szybciej i z mniejszym błędem podąża za zmianami, niżeli estymata BZT. Mimo posiadania małej wiedzy początkowej o estymacie system dąży do wartości rzeczywistych. Ostatecznie otrzymano estymaty dla wektora stanu BZT i RT.



Rys. 1. Wektor stanu i jego estymaty dla wartości początkowych BZT=60, RT=-5



Rys. 2. Wektor stanu i jego estymaty dla wartości początkowych BZT=20, RT=-10

Analizując otrzymane wyniki estymacji zauważamy, że wartości estymat RT są dokładniejsze niżeli BZT. Wynika to z szacowania wartości BZT w procesie filtracji, a nie z


bezpośredniego pomiaru wartości tak jak ma to miejsce w przypadku RT. System zaczyna pracę od zerowej informacji i dopiero po otrzymaniu pomiaru zaczyna działać. W miarę dostarczania nowych informacji z punktów pomiarowych rezultaty estymacji są coraz lepsze.

Sztuczne sieci neuronowe w procesie estymacji

Zastosowanie filtru Kalmana – Bucy w procesie estymacji stanu wymaga znajomości cech charakterystycznych procesów wymuszeń, do których należą zakłócenia oddziałujące na system i pomiary. Znajomość tego związana jest zwykle z dużymi nakładami pracy i nie zawsze prowadzi to do zadawalających wyników. Alternatywnym rozwiązaniem jest zastosowanie sztucznych sieci neuronowych (SSN), które dzięki swoim właściwościom wspomogą realizację procesu filtracji. W badaniach wykorzystano jednokierunkowe sztuczne sieci neuronowe oraz uczenie oparte na algorytmie uczenia wstecznej propagacji. Zważywszy na złożoność zagadnień, które wynikają z zestawienia pomiarów dyskretnych i ciągłego obiektu trudno jest znaleźć jedną strukturę sieci neuronowej, która generowałaby estymaty o zadawalających wynikach. Dlatego zastosowane zostały dwie oddzielne struktury sztucznych sieci neuronowych dla procesu filtracji i predykcji [2], [4], [5].

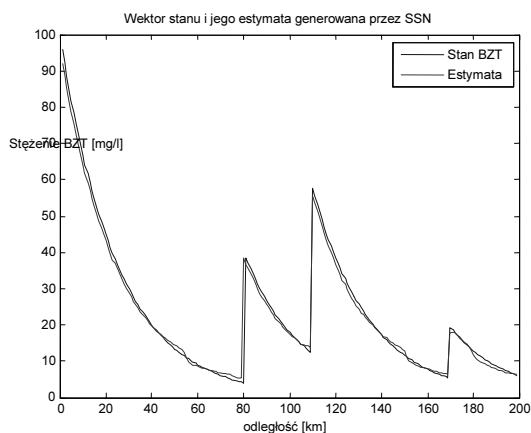
Sztuczne sieci neuronowe w procesie filtracji

Struktura sieci neuronowej przedstawiona na rys. 3 dla filtracji wynika z natury funkcjonowania tego procesu. Na wyjściu otrzymuje się estymatę stanu BZT i RT w dyskretnych chwilach pomiarowych. Sygnałami wejściowymi są estymaty stanu wyznaczone przed momentami pomiarów oraz sygnał pomiarowy. Wobec tego ilość receptorów w warstwie wejściowej wynosi 3 (dwie współrzędne stanu i pomiar), a warstwa wyjściowa zawiera dwa neurony generujące estymaty w chwilach pomiarowych. Ilość neuronów w warstwie ukrytej oraz dobór funkcji przejścia jest wynikiem badań eksperymentalnych i wymaga pewnego doświadczenia. Funkcja przejścia dla neuronów w warstwie ukrytej jest sigmoidalna, a w warstwie wyjścia liniowa, aby zapewnić nieograniczoną wartość sygnałów wyjściowych otrzymanych z sieci. [3], [4], [5].

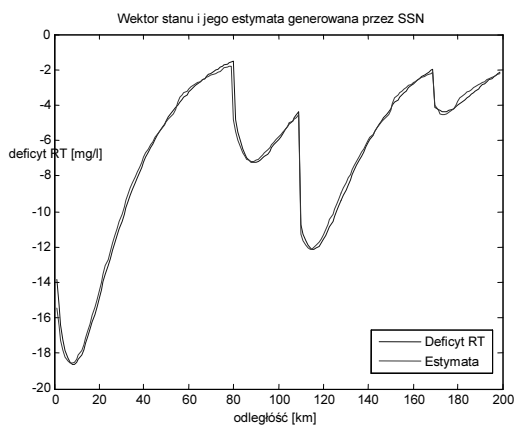


Rys. 3. Sieć neuronowa realizująca proces filtracji

Jakość estymat otrzymywanych w procesie filtracji czy predykcji zależy od procesu uczenia sieci. Podczas którego sieć dokonuje zmiany ilości neuronów w warstwie ukrytej. Ogromny wpływ, na jakość otrzymywanych wyników mają sygnały uczące. Jeżeli zakres zmian sygnałów wzorcowych będzie podobny do zakresu zmian sygnałów w czasie testowania sieci, wtedy generowane estymaty będą zgodne z oczekiwaniami. Przeprowadzono szereg eksperymentów symulacyjnych dla różnych wartości BZT, RT i czasów trwania uczenia, które przedstawiono na rys. 4 i 5.



Rys. 4. Wektor stanu BZT i jego estymaty w procesie filtracji generowane przez SSN




Rys. 5. Wektor stanu BZT i jego estymaty w procesie filtracji generowane przez SSN

Czas trwania procesu uczenia wpływa na otrzymywane estymaty z sieci neuronowych. Pojawienie się dużego błędu uczenia sieci oznacza, że sieć została niedokładnie nau czona, ale jest w stanie wygenerować estymaty obarczone dużymi błędami. W skrajnych przypadkach sieć neuro nowa może zniekształcić przebieg estymat w stosunku do stanu rzeczywistego. Dotyczy to dużych i nagłych zmian stanu, które mogą być spowodowane wystąpieniem dopływów bocznych o wysokim poziomie zanieczyszczenia.

Sztuczne sieci neuronowe w procesie predykcji

Proces predykcji przebiega przemiennie z procesem

filtracji i realizuje zadanie polegające na uzyskaniu estymat wartości BZT i RT do kolejnej chwili pomiarowej na bazie wartości otrzymanych z procesu filtracji. W systemie monitorowania rzeki proces ten musi ściśle współpracować z filtracją i dostarczać informacji o stanie rzeki pomiędzy wykonywanymi pomiarami. Architektura sieci wynika z natury funkcjonowania procesu, dlatego w warstwie wejściowej i wyjściowej znajdują się dwa neurony, a ilość neuronów w warstwie ukrytej może przyjmować różne wartości. W predykcji tak jak i w filtracji zastosowano w warstwie ukrytej sigmoidalną funkcję przejścia, a w warstwie wyjściowej funkcję liniową [3], [5]. Schemat sieci neuronowej realizującej proces predykcji zaprezentowano poniżej:



Rys. 6. Sieć neuronowa realizująca proces predykcji

Podsumowanie

W artykule przedstawiono zagadnienie estymacji stanu z wykorzystaniem filtru Kalmana-Bucy oraz alternatywne podejście z użyciem sztucznych sieci neuronowych w procesie estymacji stanu. Wykorzystując przedstawione podejście można uzyskać estymację stanu rzeki z wykorzystaniem sztucznych sieci neuronowych. Prawidłowo zaprojektowana architektura SSN oraz odpowiednio przeprowadzone procesy uczenia pozwolą na uzyskanie układu, który z bardzo dużą dokładnością, na podstawie informacji z punktów pomiarowych, oszacuje przebiegi zmian Biochemicznego Zapotrzebowania Tlenu oraz deficytu Rozpuszczonego Tlenu na danym odcinku rzeki.

Literatura

- [1]. Szymkiewicz R.: Modelowanie matematyczne przepływów w rzekach i kanałach, Wydawnictwo Naukowe PWN, Warszawa 2000r.
- [2]. Kwater T., Modelowanie sterowania i diagnostyki uogólnionych dynamicznych systemów w środowisku neurosieciowym, Wydawnictwo Tarasa Soroki, Lwów 2005
- [3]. Kwater T., Krutys P.: Estimation of pollution of the river by artificial neural networks, Symbiosis of Engineering and Computer Science Wydawnictwo Uniwersytetu Rzeszowskiego, Rzeszów 2010, ISBN 978-83-7338-620-4, str.37-66
- [4]. Tadeusiewicz R., Sieci neuronowe, Adamiecka Oficyna Wydawnicza, Warszawa 1993
- [5]. Korbicz K., Obuchowicz A., Uciński D., Sztuczne sieci neuronowe. Podstawy i zastosowania, Akademicka Oficyna Wydawnicza PJN, Warszawa 1994