

Adam RAK

Wydział Mechaniczny
Politechnika Opolska

MODELOWANIE ZMIAN MĘTNOŚCI WODY W PROCESIE TECHNOLOGICZNYM UZDATNIANIA WODY ZA POMOCĄ SZTUCZNYCH SIECI NEURONOWYCH

WATER TURBIDITY MODELING DURING WATER TREATMENT PROCESS WITH USE OF ARTIFICIAL NEURAL NETWORKS

Increasingly wider application of artificial neural networks (ANN) in researches and analysis of unit and technological processes related to the water treatment was a reason of creating ANN model for forecasting of treated water turbidity in newly operating water treatment process system for surface and retention water in “Sosnówka” water reservoir. For modeling of water turbidity during water treatment process for the selected process system the following programme was applied: “Flexible Bayesian Models on Neural Networks, Gaussian Processes and Mixtures and that demonstrates Markov Chain Monte Carlo Methods” operating in UNIX/Linux environment, version 1999-03-13 (FBM). There was a model created which allows to forecast turbidity of water pretreated through a specific process system and the basis of which are information coming out from monitoring of physicochemical parameters of water drawn from the reservoir as well as from monitoring process parameters of water treatment system. FBM model verification was carried out on the same research group. Two selection criteria for final neural network parameters were assumed. The first one is the root mean squared error (RMSE), the second one is the correlation factor R between turbidity forecasted and observed in raw water. Calculated correlation factor $R = 0,84$. Effectiveness in water turbidity decrease was determined on the basis of the turbidity results for raw water drawn from the water retention reservoir (M_s) and turbidity of pretreated water (M_p), as per the following correlation: $R_m = 1 - (M_p/M_s)$. Achieved results proved that the neural networks can also be applied for forecasting quality factors of water pretreated on specific process system.

1. Wprowadzenie

Podstawowym problemem przy ujmowaniu wód z rzek i potoków górskich do celów wodociągowych jest jej nadmierna okresowa mętność. Mętność ta jest spowodowana nagłymi intensywnymi opadami deszczu lub nagłymi roztopami. Prowadzi to do podwyższenia stanu wód w rzekach oraz zwiększenia ilości niesionych przez nią zawiesin

i części stałych. Ich ilość zależy między innymi od czynników klimatycznych, geologicznych, geomorfologicznych, hydrobiologicznych, biologicznych, a także jest wynikiem działalności człowieka. Okresy dużej mętności mogą trwać od kilkudziesięciu godzin do miesiąca. Zmiany mętności w rzekach górskich są bardzo szybkie i mogą osiągnąć kilka tysięcy NTU (*Nephelometric Turbidity Unit*) [1]. Zgodnie z normą [2] „Mętność to zmniejszenie przezroczystości cieczy powodowane obecnością substancji nierozpuszczalnych”. Mętność jest definiowana również jako „zdolność do absorbowania promieni świetlnych wskutek obecności w wodzie bardzo drobnych zawiesin pyłowych lub koloidalnych pochodzenia mineralnego lub organicznego” [3]. Przez mętność należy rozumieć optyczne właściwości drobnych zawiesin w próbce wody, które powodują rozproszenie światła [4].

Mętność jest jednym z podstawowych wskaźników oceny jakości wód, pomimo że nie jest ona spowodowana przez szkodliwe zanieczyszczenia i nie wpływa na zdrowie człowieka, pogarsza jednak estetykę wody do picia. Zgodnie z [5] woda do picia powinna mieć parametr mętności nie większy niż 1 NTU, akceptowany przez konsumentów i bez nieprawidłowych zmian. Dlatego też, przy uzdatnianiu wody mętnej, pochodzącej z ujęcia wód powierzchniowych, stosuje się najczęściej koagulację ze wszystkimi fazami technologicznymi, sedymentacją i filtracją. W normie [2] zostały przedstawione cztery metody oznaczania mętności, dwie metody półilościowe oraz dwie metody ilościowe. Pomiary mogą być zakłócone obecnością rozpuszczonych substancji absorbujących światło. Zgodnie z wyżej wymienioną normą oznaczanie mętności powinno być wykonywane jak najszybciej po pobraniu próbki. Jeśli zachodzi taka konieczność, próbkę należy przechować w chłodnym i ciemnym miejscu nie dłużej jednak niż 24 godziny. Próbkę przed oznaczeniem należy doprowadzić do temperatury pokojowej. Powinny być także chronione przed kontaktem z powietrzem i częstymi zmianami temperatury.

Mętność rzek górskich zależy od stanu wody, tzn. przy wysokich stanach jest znacznie większa niż w czasie stanów niższych. Do zwiększenia mętności przyczyniają się również osady denne oraz zawiesiny spławialne transportowane przy dużej prędkości przepływu wody. Przy wzroście mętności w rzece, na której jest zlokalizowany zbiornik zaporowy, analogicznie obserwuje się wzrost mętności w zbiorniku. Wody pochodzące z rzek i potoków górskich charakteryzują się stosunkowo dobrą jakością. W przypadku ich dużej mętności są stosowane zbiorniki do magazynowania wody. Korzystne rozwiązanie stanowią zbiorniki zapasowe i zapasowo-wyrównawcze. W zbiornikach zapasowych, w zależności od ich umiejscowienia, może być gromadzona zarówno woda surowa, jak i uzdatniona. Pozwalają one na odcinanie ujęcia w przypadku zaistnienia zwiększonej mętności wody lub pojawienia się w wodzie skażenia uniemożliwiającego jej dostateczne uzdatnienie. Zbiorniki zapasowe utrzymują zapas wody przeznaczonej na określony cel, np. w przypadku wystąpienia okresowej zwiększonej mętności. Gdy zbiornik w ciągu technologicznym znajduje się przed ujęciem, musi być zainstalowany system monitoringu ujmowanej wody. System taki służy do wykrywania zaistniałego zanieczyszczenia.

Zbiorniki zapasowe w zależności od ich umiejscowienia w systemie wodociągowym mogą być zbiornikami wody surowej lub wody uzdatnionej. Zbiorniki zapasowo-wyrównawcze, oprócz funkcji gromadzenia wody, mogą również być wykorzystywane do wyrównywania jakości wody.

Coraz częściej zastosowanie w technologii oczyszczania wody znajdują procesy zintegrowane (hybrydowe), w których połączenie typowych technologii oczyszczania wody z metodami niekonwencjonalnymi umożliwia osiągnięcie lepszego stopnia usunięcia

zanieczyszczeń, czego przykładem może być układy łączące koagulację i filtrację membranową [6]. Pomimo znaczącego rozwoju w ostatnich latach procesów hybrydowych i metod określania ich parametrów procesowych (dawka koagulantu, zużycie energii, metody płukania), pozostało jeszcze do rozwiązania wiele problemów związanych z przewidywaniem jakości wody oczyszczonej, m.in. zależnie od sposobu przeprowadzenia eksperymentu oraz zastosowanej metody modelowania [7]. Do tego celu mogą być wykorzystane sztuczne sieci neuronowe (SSN), gdyż modelowanie matematyczne za ich pomocą pozwala na ograniczenie czasochłonnych i drogich badań laboratoryjnych, mających na celu doświadczalne określenie parametrów ilościowych i jakościowych procesów technologicznych. Przesyłanie informacji w sztucznych sieciach neuronowych imituje zachowanie się ludzkiego systemu nerwowego [8]. Neurony, z których składa się sieć, są jednostkami przetwarzania danych. Sztuczna sieć neuronowa oblicza wartości wyjściowe na podstawie informacji podanych na wejściu do sieci. Znanych jest wiele typów SSN, ale obecnie najbardziej popularnym rodzajem sieci neuronowej jest perceptron wielowarstwowy z jedną warstwą wejściową, jedną (lub więcej) warstwą ukrytą i pojedynczą warstwą wyjściową. Atrakcyjność stosowania SSN związana jest głównie z możliwością aproksymacji dowolnych nieliniowości. Do stworzenia modelu sieci nie jest konieczna znajomość postaci funkcji opisującej modelowaną zmienną. Ponadto sztuczne sieci neuronowe dosyć łatwo adaptują się do zmiennych warunków środowiskowych [9]. Ponieważ modelowanie za pomocą sztucznych sieci neuronowych jest uznawane za podejście typu „czarna skrzynka”, dlatego nie jest możliwe określenie *a priori* optymalnej architektury sieci. Do odpowiedniej struktury sieci – w celu rozwiązania konkretnego zagadnienia inżynierskiego – dochodzi się metodą prób i błędów. Znanych jest wiele przykładów zastosowania symulacji matematycznych wykorzystujących SSN do prognozowania wartości zmiennych parametrów. Oczyszczanie wody w procesach membranowych jest dziedziną, w której modelowanie za pomocą SSN jest bardzo popularne. Wykorzystując modele SSN, oparte na ilościowych równaniach opisujących relacje pomiędzy zmiennymi procesowymi, można przewidywać stopień usunięcia naturalnych związków organicznych na poliamidowych membranach nanofiltracyjnych i w procesie odwróconej osmozy [10]. Stopień usunięcia substancji humusowych i zjawisko blokowania membran ultrafiltracyjnych były prognozowane przy użyciu najpopularniejszego algorytmu uczenia sieci – metody wstecznej propagacji błędów [11]. Bardzo ciekawe podejście do prognozowania poboru wody przedstawiono w monografii [12] w której porównano stochastyczne metody prognozowania poboru wody z miejskich sieci wodociągowych z wynikami modeli sztucznych sieci neuronowych. Ze względu na dużą zmienność szeregów czasowych poboru wody, SSN okazały się obiecującym narzędziem do prognozowania krótkoterminowego. Modelowanie odzysku energii z przetwornika ciepła wykorzystywanego w zakładzie oczyszczania wody zostało zaproponowane w pracy [13], w której porównano model termodynamiczny z modelem sztucznej sieci neuronowej. Oba modele wykazały wystarczającą zbieżność wyników pomiarów i symulacji. Rozwiązanie problemu omówionego w tym opracowaniu, z punktu widzenia konieczności dbania o zasoby energetyczne, jest bardzo istotne i dające wiele nadziei na przyszłość.

W szeroko pojętej dziedzinie inżynierii środowiska sztuczne sieci neuronowe są dosyć często wykorzystywane jako nowoczesne narzędzie matematyczne, mogące zastąpić żmudne obliczenia i kosztowne pomiary laboratoryjne. Z uwagi na brak jednoznacznych informacji na temat przewidywania zmian mętności wody oczyszczonej w procesie technologicznym uzdatniania wody, w niniejszej pracy podjęto problem

modelowania zmian mętności wody oczyszczonej w zintegrowanym układzie technologicznym: cedzenie, ozonowanie wstępne, filtracja na filtrach antracytowo-piaskowych, ozonowanie wtórne, sorpcja na węglu aktywnym.

2. Opis obiektu badawczego, metodyka badań

2.1. Opis obiektu badawczego

W Jeleniej Górze, w latach dziewięćdziesiątych ubiegłego wieku w celu zaopatrzenia w wodę miasta wykonano zbiornik zaporowy „Sosnówka”. Zasoby wodne zbiornika są źródłem wody surowej dla zakładu uzdatniania wody (ZUW). Zbiornik „Sosnówka” retencjonuje wody zlewni potoku Czerwonka i Sośniak i jego niewielkiego dopływu Sosnówka o łącznej powierzchni zlewni 15,3 km² [14]. Proces uzdatniania wody na urządzeniach ZUW prowadzony jest od października 2007. Od tego czasu prowadzone są pomiary w systemie ciągłym na układzie technologicznym umożliwiającym stosowanie procesów: cedzenie, ozonowanie wstępne, koagulacja, korekta odczynu, flokulacja, filtracja pośpieszna przez złożę antracytowo-piaskowe, ozonowanie wtórne, sorpcja na węglu aktywnym, końcowa korekta odczynu i twardości oraz dezynfekcja uzdatnionej wody [15].

Woda ze zbiornika „Sosnówka” ujmowana jest z dwóch poziomów i doprowadzona jest grawitacyjnie przewodami 2 Ø 600 mm do komory rozdzielczej. Z komory kierowana jest bezpośrednio na dwa sita obrotowe, każde o prześwicie 1mmx1mm. Sita bębnowe Ø 800 mm płukane są cyklicznie wodą, a tzw. zsitki kierowane są do osadnika popłuczyn. Po sitach woda przepływa do dwóch komór ozonowania wstępnego. Ozon wytworzony z osuszonego powietrza wprowadzony jest do wody za pomocą dyfuzorów porowatych. Pojemność komór zapewnia nominalny czas kontaktu w komorze ozonowania, $t \geq 5$ min. Ozon wytwarzają trzy zespoły generatorów o wydajności 3 x 1500 g O₃·h⁻¹. Z komór ozonowania wstępnego woda kierowana jest rurociągiem grawitacyjnym Ø 800 mm poprzez mieszacz statyczny do dwóch komór reakcji. Przed mieszaczem statycznym doprowadzony jest koagulant w postaci 14% roztworu Al₂(SO₄)₃. Do samej komory reakcji dozowana jest woda wapienna przewodami Ø 80 mm z przepustnicami regulującymi dawkę wapna w zależności od odczynu wody. Do komór w strefie odpływowej dozowany jest flokulant. Następnie woda kierowana jest grawitacyjnie na filtry pośpieszne. Proces filtracji odbywa się na złożach dwuwarstwowych, antracytowo-piaskowych, przy następujących parametrach:

- maksymalna prędkość filtracji; 6,14 m·h⁻¹,
- intensywność płukania powietrzem; 65 m³·m⁻²·h⁻¹,
- intensywność płukania wodą; 36 m³·m⁻²·h⁻¹.

Po procesie filtracji woda przepływa do dwóch komór ozonowania wtórnego. Po ozonowaniu wtórnym kierowana jest na filtry węgla aktywnego. Proces filtracji na węglu aktywnym przybiega przy następujących parametrach:

- maksymalna prędkość filtracji; 7,67 m·h⁻¹,
- intensywność płukania wodą; 20 m³·m⁻²·h⁻¹.

Po filtrach węglowych woda kierowana jest do dwóch zbiorników filtratu o pojemności $2 \times 210 \text{ m}^3$. Przed zbiornikami na rurociągach zamontowano mieszacze statyczne. Do nich doprowadzone są reagenty w celu korekty końcowej jakości (węglan sodu i chlorek magnezu). Woda ze zbiorników filtratu tłoczona jest do zbiornika wyrównawczego. Na rurociągach tłocznych zamontowano urządzenia do dozowania podchlorynu sodu w celu dezynfekcji uzdatnionej wody. Eksploatowany ciąg technologiczny pozwala na wielowariantową kombinację układów technologicznych w zależności od jakości ujmowanej wody w poszczególnych okresach roku hydrologicznego.

Uwzględniając zmiany jakości wody surowej retencjonowanej w zbiorniku wydzielono eksploatacyjne układy technologiczne, które zestawiono w tabeli 1.

Tab. 1. Procesy jednostkowe wydzielonych układów technologicznych

Tab. 1 Unit processes of appointed technology systems

Procesy jednostkowe - Unit processes	Układy technologiczne Technology systems				
	W1	W1A	W1B	W2	W3
Cedzenie przez sito Sieving through a sieve of 1mm x 1mm	+	+	+	+	+
Ozonowanie wstępne – Preozonation	+	+	+	+	+
Koagulacja siarczanem glinu Coagulation with aluminium sulphate	+	+	+		
Flokulacja - Flocculation	+	+	+		
Korekta odczynu wodą wapienną Correction of pH with lime water	+	+			+
Filtracja przez złożo antracytowo-piaskowe Filtration through a sand and anthracite deposit	+	+	+	+	+
Ozonowanie wtórne - Secondary ozonation	+		+	+	+
Filtracja przez złożo węgla aktywnego Filtration through active carbon	+	+	+	+	+
Końcowa korekta jakości wody Final correction of water quality	+	+	+	+	+
Dezynfekcja - Disinfection	+	+	+	+	+

Układ technologiczny *W1*, to pełny układ z wykorzystaniem procesów jednostkowych: cedzenie, ozonowanie wstępne, koagulacja z korektą odczynu, flokulacja, filtracja pospieszna na filtrach antracytowo-piaskowych, ozonowanie wtórne, sorpcja na węglu aktywnym, końcowa korekta jakości wody i dezynfekcja. W zależności od jakości ujmowanej wody ze zbiornika oraz jej temperatury, układ ten można modyfikować. Stąd w układzie technologicznym *W1A* zrezygnowano z ozonowania wtórnego. Natomiast w przypadku wysokiego odczynu wody surowej proces uzdatniania można prowadzić bez korekty. Układ ten oznaczono jako *W1B*. Układ technologiczny *W2* obejmuje takie procesy jednostkowe jak: cedzenie, ozonowanie wstępne, filtracja pospieszna na filtrach antracytowo-piaskowych, ozonowanie wtórne, sorpcja na węglu aktywnym, końcowa korekta jakości i dezynfekcja. W przypadku niskiego odczynu możliwe jest wprowadzenie układu technologicznego *W3* obejmujący dodatkowo korektę odczynu wody.

2.2. Metodyka badań

W ramach automatycznego monitoringu wody surowej i uzdatnionej na Zakładzie Uzdatniania Wody w Sosnowce (ZUW) prowadzony jest ciągły pomiar temperatury wody, odczynu, mętności, oraz przewodności. Ponadto okresie badawczym tj. od listopada 2007 do października 2008 wykonano analizy fizykochemiczne wody w cyklach kilkudniowych. Zakres analizy obejmował pomiar takich wskaźników jak: temperatura wody, mętność, barwa, odczyn, twardość ogólna, zasadowość, żelazo, mangan, chlorki, azot amonowy i azotanowy, utlenialność, tlen rozpuszczony, przewodność i fosforany. Skład jakościowy wody surowej pobieranej do uzdatniania w okresie badawczym był wyrównany i charakterystyczny dla określonej pory roku. Poniżej w tabeli 2 zestawiono wartości minimalne, maksymalne oraz średnie analizowanych wskaźników zanieczyszczeń wody.

Tab. 2. Charakterystyczne wartości wybranych wskaźników jakościowych badanej wody surowej w okresie badawczym

Tab. 2. Characteristics of appointed water quality indicators in period of time

Wskaźniki badanej wody Indicators of tested water	Jednostka Unit	Zbiornik - Reservoir			
		S_{Min}	S_{Ma}	\bar{S}	σ
Temperatura - Temperature	°C	4	^x 22	11,7	6,12
Mętność - Turbidity	NTU	1,0	12,0	5,2	2,47
Barwa - Colour	mgPt·dm ⁻³	5	14,9	8,21	2,791
Odczyn - pH	pH	7,2	8,4	7,63	0,366
Twardość ogólna General hardness	mval·dm ⁻³	0,62	1,03	0,85	0,072
Azot azotanowy Nitrate nitrogen	mg N·dm ⁻³	0,01	0,11	0,05	0,004
Azot azotanowy Nitrate nitrogen	mg N·dm ⁻³	2	5	2,44	1,300
Chlorki - Chlorides	mg Cl·dm ⁻³	4	6,8	4,95	1,321
Utlenialność - Oxidability	mg O ₂ ·dm ⁻³	1,0	5,22	3,458	1,532
Przewodność - Conductivity	μs·cm ⁻¹	98,28	122,50	110,88	6,692
Tlen rozpuszczony Dissolved oxygen	mg O ₂ ·dm ⁻³	9,4	12,4	11,18	1,172
Żelazo - Fe	mg Fe·dm ⁻³	0,05	0,136	0,066	0,027
Mangan - Mn	mg Mn·dm ⁻³	0,012	0,036	0,021	0,007

Biorąc po uwagę stosunkowo dobrą jakość wody surowej, testy technologiczne prowadzono na układzie technologicznym obejmującym: cedzenie, ozonowanie wstępne, filtrację pospieszną na filtrach antracytowo-piaskowych, ozonowanie wtórne, sorpcję na węglu aktywnym oznaczonym jako W2A bez końcowej korekty jakości. W drugiej fazie badań układ technologiczny poszerzono o końcową korektę jakości wody W2.

Wyniki analiz wody surowej i uzdatnionej pozwoliły określić stopień redukcji monitorowanych wskaźników. Możliwość prowadzenia ciągłego monitoringu pozwoliła na analizę przebiegu zmian temperatury wody, odczynu, mętności w cyklach jednodniowych.


3. Wyniki badań

3.1. Wyniki z monitoringu procesu uzdatniania wody na ZUW

W analizowanym okresie uzdatniano wodę na ciąg technologiczny W2 o przepływie 172÷202 m³·h⁻¹ przy tej samej prędkości filtracji na filtrach antracytowo-piaskowych i węgla aktywnego w wysokości 4,9÷5,7 m³·h⁻¹ oraz dozowano do układu technologicznego:

- w procesie ozonowania wstępnego: ozon - dawka 1÷2 mgO₃·dm⁻³,
- w procesie ozonowania wtórnego: ozon - dawka do 1 mgO₃·dm⁻³,
- do korekty odczynu uzdatnionej wody: węglan sodu - dawka 1,0 mgNa₂CO₃·dm⁻³,
- do stabilizacji uzdatnionej wody: chlorek magnezu: dawka 1,0 mgMgCl₂·dm⁻³,
w procesie dezynfekcji: podchloryn sodu: dawka 0,8÷0,9 Cl₂·dm⁻³.


Skład jakościowy wody w okresie badawczym był wyrównany i charakterystyczny dla określonej pory roku. Temperatura wody wahała się od 4 °C w okresie zimowym, do 22 °C w okresie letnim. Przebieg opadów w analizowanym okresie wyznaczono w oparciu o dane IMGW [16]. W tym czasie roczna suma opadów na obszarze zlewni wynosiła 1011,8 mm·a⁻¹. Miesięczny rozkład opadów w tym okresie zobrazowano na rys. 1.



Rys. 1. Rozkład opadów miesięcznych w okresie badawczym (2007/2008)

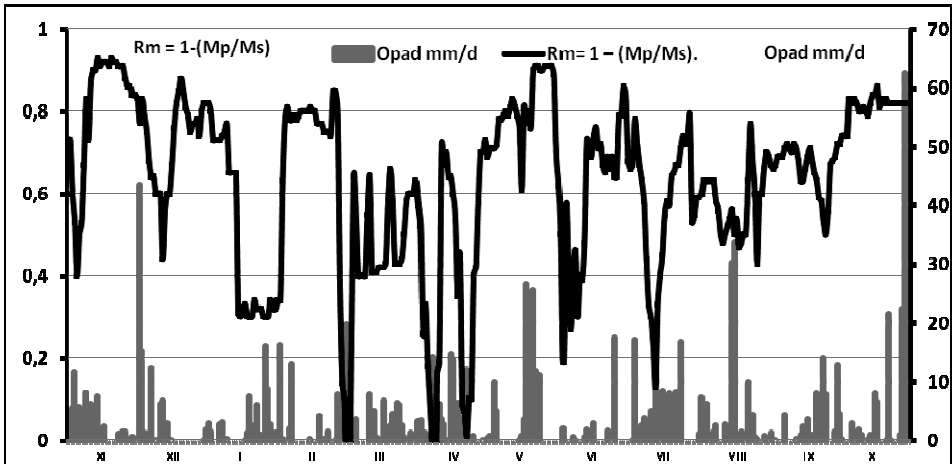
Fig. 1. Range of precipitation per month in examination period (2007/2008)

Mętność wody pobieranej ze zbiornika retencyjnego kształtowała się od 1 do 12 NTU (rys. 2), barwa od 5 do 14,9 mgPt·dm⁻³, odczyn w przedziale pH 7,2- 8,40, a przewodność od 98 do 122 μs·cm⁻¹. Pozyskane wyniki monitorowanych wskaźników pozwoliły na utworzenie zbioru dobowych danych dla całego okresu badawczego, tj. od listopada 2007 do października 2008. Skuteczność zmniejszenia mętności wody wyznaczono na podstawie wyników pomiarów mętności wody surowej pobieranej ze zbiornika retencyjnego (M_s) i mętności wody uzdatnionej (M_p) według zależności: $R_m = 1 - (M_p/M_s)$ [7]. W okresie badawczym średni wskaźnik redukcji mętności R_m wyniósł 0,63, przy odchyleniu standardowym $\sigma = 0,21$. Z przedstawionych zmian wskaźnika R_m na rys. 3, wynika, że układ technologiczny funkcjonował niestabilnie. Szczególnie obserwowano to w okresach roztopowych i wysokich opadów dobowych deszczu. Charakter górski zlewni zbiornika retencyjnego sprawia, że w okresie roztopowych dopływająca woda w ilości nawet 1,5m·s⁻¹ posiada podwyższoną mętność nawet do 27 NTU. Powyższe uwarunkowania były powodem spadku wskaźnika R_m do 0,2. W tych okresach mętność wody uzdatnionej była większa niż 1NTU, okresowo dochodziła do 4NTU. Nadto należy wskazać, że w okresie badawczym nastąpiły zakłócenie w procesie uzdatniania wody. Odnotowano to w okresie wiosennym. Wtedy mętność wody uzdatnionej była nawet wyższa niż dopływająca do układu technologicznego (mętność wody surowej z 3,0 NTU wzrastała do 4,09 NTU po uzdatnieniu).



Rys. 2 Przebieg zmian pomierzonej mętności wody surowej i wody uzdatnionej na układzie technologicznym W2 w okresie badawczym

Fig. 2. The course of changes in the measured turbidity of raw water and treated water W2 in the technological system during the test



Rys. 3 Przebieg zmian wskaźnika redukcji mętności R_m na tle przebiegu opadów dobowych na obszarze zlewni w okresie badawczym

Fig. 3. The course of changes in turbidity reduction index R_m against the background of daily rain in the catchment area during the test

3.2. Prognozowanie mętności wody na wybranym układzie technologicznym

Wyniki mętności wody surowej i uzdatnionej na układzie technologicznym W_2 , pozwoliły na utworzenie zbioru dobowych danych dla całego okresu badawczego, tj. od listopada 2007 do października 2008. Optymalny model do prognozowania powinien w każdej chwili, na podstawie informacji pochodzących z monitoringu warunków hydrologicznych zlewni, obserwacji meteorologicznych, analiz fizykochemicznych ujmowanej wody, dać możliwość określenia przewidywanych efektów uzdatniania wody. Prognozowana mętność wody uzdatnionej powinna być funkcją zjawisk meteorologicznych zachodzących w zlewni w okresie poprzedzającym analizę oraz wynikać z przebiegu zmian monitorowanych wskaźników w zbiorniku, a w szczególności uwzględniać:

- wysokość opadów w zlewni i czasu ich trwania w okresie poprzedzającym prognozę,
- wielkość dopływu do zbiornika w okresie poprzedzającym prognozę,
- ilość wody retencjonowanej w zbiorniku,
- przebieg temperatury wody w okresie poprzedzającym prognozę,
- przebieg charakterystycznych wskaźników jakości wody w zbiorniku (barwa wody, mętność, odczyn), pochodzących z pomiaru automatycznego zainstalowanego na ujęciu wody ze zbiornika,
- charakterystykę układu technologicznego uzdatniania wody (zespół procesów jednostkowych).

Do modelowania zmian wskaźnika mętności wody uzdatnionej na układzie technologicznym W2, posłużono się programem „*Flexible Bayesian Models on Neural Networks, Gaussian Processes and Mixtures and that demonstrates Markov Chain Monte Carlo Methods*” pracującym w środowisku UNIX/Linux, wersja 1999-03-13 [17]. Modele sieci neuronowych zostały opisane w pracy „*Bayesian Learning for Neural Networks*”, publikowanej przez Springer-Verlag (ISBN 0-387-94724-8) [18]. Szczegółowo modele sieci neuronowych opisano w aneksie do tego wydania. Program ma na celu wspieranie badań naukowych i edukacji w zakresie wykorzystania do prognozowania modeli bayesowskich (*Flexible Bayesian Models*) opartych na sieciach neuronowych. Program jest narzędziem do obsługi bayesowskich modeli prognozowania przy pomocy sieci neuronowych. Zawiera także aplikacje wspierające łańcuchy Markova metody Monte Carlo (Markov Chain Monte Carlo methods MCMC) do pobierania próbek z szeregów zmiennych, przez proste formuły, w tym bayesowskie dla uprzednio ustalonego prawdopodobieństwa. Oprogramowanie sieci neuronowych obsługuje modele bayesowskie do uczenia i prognozowania zadanych problemów za pomocą modeli opartych na sieci z dowolną liczbą warstw ukrytych, z uprzednim, szerokim wyborem rozkładu dla parametrów i hiperparametrów sieci. Natomiast oprogramowanie modeli Gaussa wspiera proces klasyfikowania i prognozowania, które są podobne do modeli sieci neuronowych z nieskończoną liczbą jednostek ukrytych. Korzyści płynące z uczenia bayesowskiego dla obu typów modelu to automatyczne ustalanie i regulowanie hiperparametrów bez konieczności walidacji, unikanie nadmiernego dopasowania przy użyciu dużych sieci i niepewności uzyskanych wyników prognoz.

Analizę neuronową przeprowadzono na modelu MLP sieci neuronowej. Struktura modelu MLP oparta jest na analizie numerycznej, w którym zmiennymi objaśnianymi (tzw. *target variable*) stanowiły zmienne ciągłe: mętność wody uzdatnionej oraz pięć zmiennych objaśniających: mętność wody surowej, dopływ do zbiornika, stan retencji zbiornika, opad dobowy i temperaturę wody w zbiorniku – tzw. *input variables*. Uczenie sieci oparto na zgromadzonych danych historycznych dla 366 kompletnie opisanych przypadków od 1 listopada 2007 r. do 31 października 2008 r. Weryfikację każdej struktury modelu numerycznego przeprowadzono na tej samej grupie badawczej. Parametry architektury sieci określono dla poziomów zapewniających najmniejszą wartość uzyskiwanych w predykcji błędów poprzez kontrolę między innymi tzw. wskaźnika odrzutu (*rejection rate*), uzyskanego na poziomie bliskim 0,5 i wybranych hiperparametrów (*hyperparameters*), optymalizujących proces uczenia sieci. Symulację numeryczną przeprowadzono dla 100 kroków iteracji po odrzuceniu pierwszych 20 % kroków tzw. rozruchowych (tzw. *burn-in*).

Do oceny przyjętych parametrów modelu sieci neuronowej wybrano pierwiastek błędu średniokwadratowego RMSE (*Root-Mean-Square-Error*) opisany zależnością:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_P - S_R)^2} \quad (1)$$

gdzie:

N – liczba danych,

S_P – wartości prognozowane mętności po uzdatnieniu wody,

S_R – wartości pomierzone (obserwowane) mętności wody uzdatnionej.

Drugim kryterium oceny było określenie współczynnika korelacji R pomiędzy mętnością prognozowaną a obserwowaną. Wartość współczynnika korelacji liniowej na podstawie n – elementowej próbki obliczono według zależności:

$$R = \frac{\sum_{i=1}^N (S_{Pi} - \bar{S}_P)(S_{Ri} - \bar{S}_R)}{\sqrt{\sum_{i=1}^N (S_{Pi} - \bar{S}_P)^2 \sum_{i=1}^N (S_{Ri} - \bar{S}_R)^2}} \quad (2)$$

gdzie:

\bar{S}_R – obserwowana średnia wartość mętności wody uzdatnionej,

\bar{S}_P – prognozowana średnia wartość mętności wody uzdatnionej.

Współczynnik korelacji R wyraża liniową zależność między dwiema zmiennymi. Współczynnik korelacji im jest bliższy 1, tym zależność liniowa jest silniejsza.

Zbiory wyników badań jakości wody w zbiorniku przyjęte do analizy i uczenia na wielowarstwowych sieciach MLP, podzielono na tygodniowe szeregi czasowe zawierające odpowiednie zbiory pomierzonych dobowych wartości mętności wody surowej oraz uzdatnionej w okresie badawczym. Do modelowania mętności wody uzdatnionej sporządzono model sieci MLP o określonej architekturze. Analizę prognostyczną mętności (zmienna objaśniana) oparto na określonych założeniach architektury sztucznej sieci neuronowej, umożliwiającej optymalne modelowanie. Obejmowały one następujące dane: czas (oznaczenie tygodnia pomiarowego) oraz przypisane dla każdego dnia wysokości opadu dobowego na obszarze zlewni, ilości retencjonowanej wody w zbiorniku i temperatury wody w zbiorniku (tzw. zmienne objaśniające). Wymienione powyżej zmienne posłużyły do budowy neuronowego nieliniowego modelu regresyjnego. Na model nałożono restrykcje, polegające na ograniczeniu warunków przewidywanych wariantów testowych zmiennych objaśniających i określając wartości maksymalne i minimalne zmiennych wyjściowych (prognozowanych) nie przekraczających wartości zmierzonych (założono, że zakresy warunków prognozowanych i odpowiedzi na nie, nie przekraczały wartości pomierzonych). Warstwę wejściową stanowiły neurony, w skład których wchodziły serie uczące i testowane. Dostarczano do nich informacje ze wszystkich zmiennych objaśniających, wchodzących do analizy odpowiednio dla każdego modelu. Warstwę wyjściową stanowiły dane modelowane prognozowanej mętności wody uzdatnionej. Warstwę ukrytą stanowiło 100 warstw neuronów o identycznej liczbie komórek, co w warstwie wejściowej i wyjściowej. Liczbę warstw ukrytych określono arbitralnie w trakcie optymalizacji procesu uczenia. Stwierdzono gorsze możliwości predykcyjne dla innych liczb warstw ukrytych po weryfikacji danych pomierzonych z ich wartościami oczekiwaniami. Pozostałe parametry strukturalne sieci ustalano w trakcie uczenia sieci, zgodnie z obowiązującymi procedurami obsługi programu wykorzystywanego w analizie bayesowskiej sztucznych sieci neuronowych. Ciąg iteracyjny ustalono na 100 kroków, gwarantujący stabilność „energetyczną” (rozkład równowagowy łańcuchów Markowa metody Monte Carlo -MCMC) modelu.

Oznaczając wygenerowany model MLP do prognozowania mętności wody uzdatnionej według specyfikacji: net-spec sun 5 100 20 /- 5:50 5:50 - 5:50 - 100 model-spec sun class data-spec sun 5 1 20 / metn2.txt@1:366. metn2.txt@1:948846, architekturę przyjętej sztucznych sieci neuronowych można opisać następująco: jedna warstwa wejściowa z 5 zmiennymi objaśniającymi, 100 warstw ukrytych, jedna warstwa wyj-


ściowa z 20 jednostkami w zakresie rozstępu ustalonych wartości w oparciu o dane pomierzone, liczba cykli uczących 366, liczba edytowanych predykcji 948846. Do polaryzacji wartości wyjściowej ustalono odchylenie standardowe 100. Obszar (rozstęp) danych warstwy wejściowej 5:50, w warstwach ukrytych 5:50 oraz warstwie wyjściowej 5:50.

Przyjęto oznaczać architekturę sieci neuronowych dla analizowanych szeregów czasowych według następującej kolejności:

- skrót nazwy sieci: MLP - sieci perceptronowe wielowarstwowe,
- liczbę zmiennych wejściowych, po dwukropku ilość zmiennych objaśniających,
- ilość warstw ukrytych,
- ilość warstw wyjściowych, po myślniku ilość jednostek z zakresu rozstępu prognozowanego wskaźnika.


Biorąc powyższe pod uwagę architekturę modelu MLP opisano następująco: MLP 1:5 100 1-20.

Po przeprowadzeniu analizy zbioru na sztucznych sieciach neuronowych według specyfikacji i architektury określonej dla modelu MLP 1:5 100 1-20 oraz po stwierdzeniu równowagi strumienia symulowanych wartości i wysokiej zgodności wartości oczekiwanych z obserwowanymi w kolejnym kroku, przystąpiono do symulacji prawdopodobieństwa wystąpienia określonych wartości mętności dla określonej kombinacji ustalonych w zakresie zmiennej obserwowanej. Rezultaty analizy efektywności modelu MLP prognozowanej mętności wody uzdatnionej zobrazowano na rys. 4, 5 i 6.



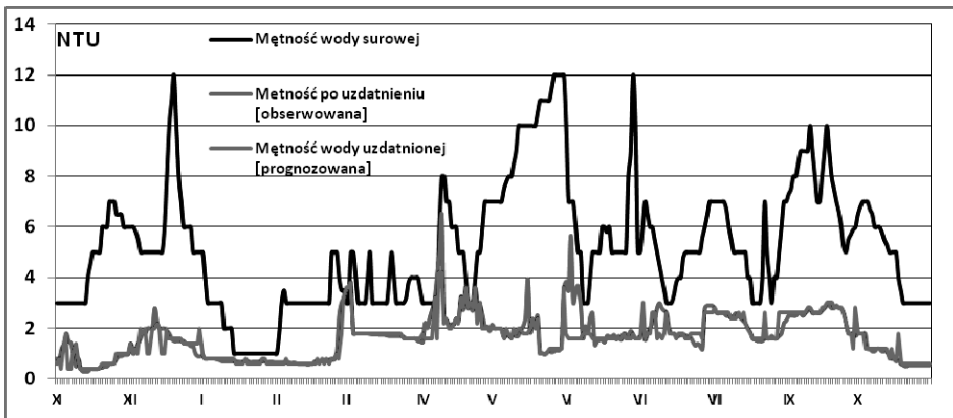
Rys. 4 Wykres korelacji pomiędzy wartościami prognozowanymi i obserwowanymi mętności wody uzdatnionej na układzie technologicznych W2

Fig. 4. Chart of correlation between predicted and observed values for turbidity of the technological system W2



Rys. 5 Histogram błędów prognozy mętności wody uzdatnionej na układzie technologicznych W2

Fig. 5. Histogram of errors regarding prognosis for turbidity of the technological system W2



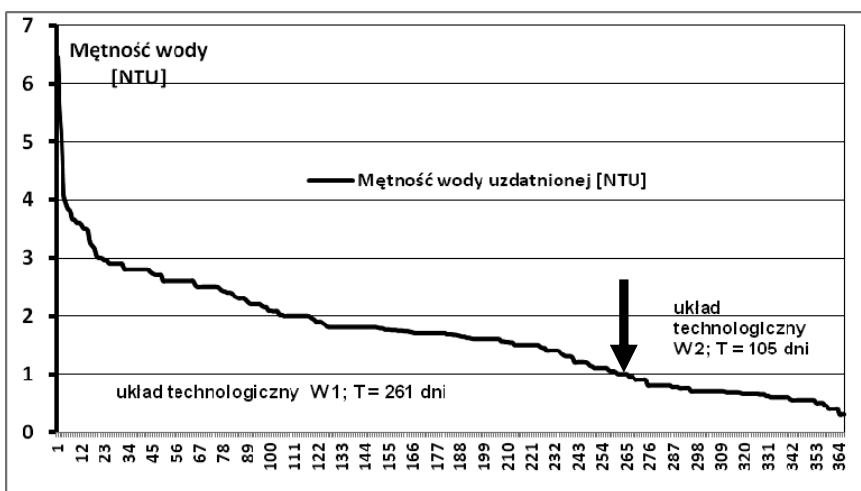
Rys. 6 Przebieg zmian pomierzonej mętności wody surowej i wody uzdatnionej oraz prognozowanej mętności wody uzdatnionej w okresie badawczym

Fig. 6. The course of changes in the measured turbidity of raw water and treated water and treated water turbidity predicted the study period

4. Dyskusja wyników badań

W wyniku rozwoju systemów informatycznych możliwy jest pomiar, przetwarzanie danych procesowych, ich rejestracja w formie elektronicznej, wizualizacja, prezentacja i archiwizacja bazy danych. Jest to możliwe dzięki instalowaniu oprogramowania typu SCADA (*Supervisory Control And Data Acquisition*). System ten stał się powszechny przy monitorowaniu i sterowaniu procesami w zakładach uzdatniania wody. System SCADA pozwala na automatyczne sterowanie pracą urządzeń technicznych, rejestrowanie i archiwizowanie informacji pochodzących z urządzeń pomiarowych. Analizując na bieżąco zmiany kontrolowanych wskaźników, możliwe staje się podejmowanie decyzji technologicznych z odpowiednim wyprzedzeniem czasowym. Decyzje te mają wymiar ekonomiczny. Systemy SCADA powinny posiadać funkcje prognozujące wpływające na wybór optymalnego sposobu eksploatacji układu uzdatniania wody.

Z przeprowadzonych badań i analiz wynika, że zaproponowany model prognozowania jednego wskaźnika uzdatnianej wody, oparty na sztucznych sieciach neuronowych może być pomocny sterowania procesem technologicznym na ZUW. Prognoza określająca wartość mętności wody pozwala wyprzedzająco podjąć działania techniczno – organizacyjne wdrożenia sposobu eksploatacji urządzeń technologicznych ZUW (np. wprowadzenie dodatkowego procesu jednostkowego – koagulacji, zmiany stosowanych w procesie technologicznych reagentów chemicznych – układ technologiczny W1). Z analizy uzyskanych wyników w okresie badawczym wynika, że mętność wody uzdatnionej przez okres 261 dni przekracza wartość 1 NTU (rys.7). Testowany układ technologiczny W2 zapewnia uzyskanie mętność wody poniżej 1NTU tylko przez 105 dni. Stąd wynika, że wymagane jest wprowadzenie dodatkowo układu technologicznego W1.



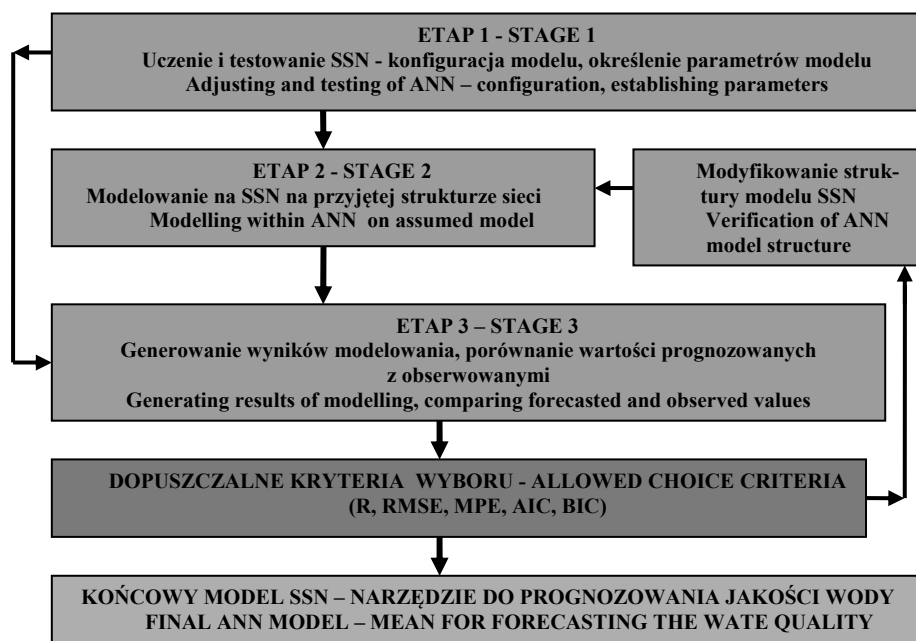
Rys. 7 Krzywa sumy czasu trwania dobowych wartości mętności wody uzdatnionej w okresie badawczym

Fig. 7. Curve of total time of daily treated water turbidity in the study period

W pracy dokonano oceny możliwości zastosowania do prognozowania jednego ze wskaźnika uzdatnionej wody modelu opartego na sztucznych wielowarstwowych sieciach neuronowych typu MLP (*Multi Layer Perceptron*). Do prognozowania posłużono się programem Flexible Bayesian Models on Neural Networks, Gaussian Processes and Mixtures pracującym w środowisku UNIX/Linux. Do analizy numerycznej wykorzystano model regresyjny wielowarstwowej sieci neuronowej MLP, w którym ciągłą zmienną objaśnianą jest mętność wody uzdatnionej oraz cztery zmienne objaśniające: mętność wody surowej, stan wody w zbiorniku (wielkość retencji), opad dobowy na obszarze zlewni, dopływ wody do zbiornika i temperatura wody w zbiorniku. Weryfikację modelu numerycznego przeprowadzono na tych samych zbiorach wyników pomiarów z okresu badawczego. Parametry architektury sieci określono dla poziomów zapewniających najmniejszą wartość uzyskiwanych w predykcji błędów. Przyjęto dwa kryteria wyboru ostatecznych parametrów sieci neuronowej. Pierwszym był pierwiastek błędu średniokwadratowego RMSE. Drugim kryterium było określenie współczynników korelacji R pomiędzy wskaźnikami prognozowanymi a obserwowanymi. Obliczona wartość RMSE wynosi 0,49NTU. Współczynnik korelacji R wynosi 0,84. Wskazuje to na *dość silną* zbieżność wyników. Dodatkowo do porównania analizowanych modeli można wykorzystać metodę porównania procentowego błędu przeciętnego MPE (*Mean Percentage Error*). Natomiast do selekcji wieloparametrowych modeli należy zastosować kryteria informacyjne: AIC (*Akaike Information Criterium*), BIC (*Bayes Information Criterium*).

Przeprowadzona analiza efektywności sieci neuronowej w prognozowaniu wskaźników zanieczyszczeń wody w zbiorniku wykazała relatywnie dobrą jakość predykcji w każdym analizowanym modelu MLP. Z przeprowadzonej analizy wynika, że w przy prognozowaniu mętności wody uwzględnienie wskaźników charakteryzujących dopływ jako zmienne objaśniające, podwyższa dokładność prognozowanych wskaźników. Wybrany model sztucznych sieci neuronowych powinien uzupełniać algorytmy systemów informatycznych projektowanych i modernizowanych systemów zarządzających i sterujących procesami ujmowania i uzdatniania wody wykorzystywanych dla celów komunalnych, przemysłowych lub rolniczych.

Sporządzenie modelu do prognozowania wskaźników jakościowych wymaga przeprowadzenia szeregu badań i analiz indywidualnie dla każdego obiektu gospodarki wodnej. Wynikiem tych badań powinno być wyznaczenie kryterialnych wskaźników jakościowych określających charakter badanej wody i determinujące oczekiwane własności w aspekcie jej aktualnego lub planowanego użytkowania. Prognozowanie wybranych wskaźników jakości wody na sieciach neuronowych przebiegać powinno etapami. Schemat postępowania zobrazowano na rys.8.



Rys. 8 Schemat postępowania przy prognozowaniu wskaźników jakości wody na SSN

Fig. 8 Diagram of steps while forecasting water quality indicators within ANN

Bibliografia

- [1] Pawełek J. Mętność wód rzek i potoków górskich w aspekcie ich oczyszczania do celów wodociągowych. *Ochrona Środowiska* 4(51), 1993, s. 69-73.
- [2] Norma PN-EN ISO 7027:2003 Jakość wody. Oznaczenie mętności.
- [3] Norma PN-G-01300:1997 Hydrogeologia. Podstawowe nazwy i określenia (wycofana).
- [4] Hermanowicz W., Dożańska W., Dojlido J., Koziorowski B. Fizykochemiczne badanie wody i ścieków. Arkady Warszawa, 1976, s. 85-92.
- [5] Rozporządzeniem Ministra Zdrowia z dnia 20 kwietnia 2010 roku, w sprawie jakości wody przeznaczonej do spożycia przez ludzi (Dz. U. nr 72, poz. 466 z póź.zm.).
- [6] Adamski W., Majewska-Nowak K.. Zastosowanie reaktorów wielofunkcyjnych do oczyszczania wody. *Ochrona Środowiska*, 2010, vol. 32, nr 1, s. 3-8,

- [7] Kabsch-Korbutowicz M., Kutylowska M. Zastosowanie sztucznych sieci neuronowych do prognozowania zmian mętności wody w procesie koagulacja/ultrafiltracja. *Ochrona Środowiska*, vol. 32, nr 2, s. 15-20.
- [8] Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.
- [9] Cieżak W., Siwoń Z., Cieżak J. Zastosowanie sztucznych sieci neuronowych do prognozowania szeregów czasowych krótkotrwałego poboru wody w wybranych systemach wodociągowych. *Ochrona Środowiska* 2006, vol. 28, nr 1, s. 39–44.
- [10] Yangali-Guintanilla V., Verliefe A., Kim T., Sadmani A, Kennedy M., Amy G.: Artificial neural network models based on QSAR for predicting rejection of neutral organic compounds by polyamide nanofiltration and reverse osmosis membranes. *Journal of Membrane Science*, 2009, Vol. 342, s. 251–262.
- [11] Al-Abri M., Hilal N. Artificial neural network simulation of combined humic substance coagulation and membrane filtration. *Chemical Engineering Journal*, 2008, Vol. 141, s. 27–34.
- [12] Siwoń Z., Łomotowski J. Cieżak W., Licznar P., Cieżak J. Analizy i prognozowanie rozbiórów wody w systemach wodociągowych. Polska Akademia Nauk, Komitet Inżynierii Lądowej i Wodnej, Instytut Podstawowych Problemów Techniki, Warszawa 2008.
- [13] Hernandez J., Romero R., Juarez D., Escobar R., Siqueiros J. A neural network approach and thermodynamic model of waste energy recovery in a heat transformer in a water purification process. *Desalination*, 2009, Vol. 243, s. 273–285.
- [14] Rak A., Konarczak T. Badania pilotowe jako metoda ustalenia technologii uzdatniania wody powierzchniowej charakterystycznej dla zlewni górskiej retencjonowanej w zbiorniku. Monografia red. M.M Sozański, Z. Dymaczewski, J. Jeż-Walkowiak. „Zaopatrzenie w wodę, jakość i ochrona wód” (Water Supply and Water Quality). Wydawnictwo PZITS Oddział Wielkopolski, 2008, s. 641-657.
- [15] Rak A. Prognozowanie kryterialnych wskaźników jakości wody retencjonowanej w zbiorniku dla potrzeb zakładu uzdatniania. Monografia „Zaopatrzenie w wodę, jakość i ochrona wód – zagadnienia współczesne”, Tom I. Wydawnictwo ISBN 978-83-89696-33-9, PZITS o/ Poznań, 2010, s. 43-60.
- [16] IMGW. Zestawienie meteorologiczne, dobowe sumy opadów atmosferycznych z posterunku w Karpaczu za okres 01.11.2007–31.10.2008. Instytut Meteorologii i Gospodarki Wodnej o/Wrocław, 2009.
- [17] Neal R. Flexible Bayesian Models on Neural Networks, Gaussian Processes, and Mixtures v 2000-08-13. University of Toronto, 1999, s. 1-82. Program ogólnodostępny; <http://www.cs.utoronto.ca/~radford/>.
- [18] Neal R. Bayesian Learning for Neural Networks. Wyd. Springer-Verlag (ISBN 0-387-94724-8, 1996, s. 10-22, s.99-136. Program ogólnodostępny; <http://www.cs.utoronto.ca/~carl/>).

