

doi:10.15199/48.2021.08.23

Wybrane algorytmy uczenia maszynowego w segmentacji obrazu kłaczków osadów ściekowych

Streszczenie. W artykule przedstawiono wybrane algorytmy uczenia maszynowego do przetwarzania obrazu mikroskopowego utlenionych kłaczków osadów ściekowych w celu oceny skuteczności monitorowania procesu tlenowej stabilizacji. Przedstawiono i porównano trzy techniki segmentacji algorytmem: *k*-means, fuzji *c*-means oraz progowania Otsu w ocenie skuteczności segmentacji obszarów utlenionych i wykryciu zjawiska spęcznienia lub pienienia się kłaczków osadu ściekowego. Wykorzystane metryki GCE, RI, VI skutecznie porównują zmiany morfologiczne i strukturalne kłaczków poprzez ocenę segmentacji i kwantyfikacji obrazu. Analiza obrazów mikroskopowych przy wykorzystaniu technik uczenia maszynowego zapewniają oszczędność czasu i stanowią alternatywę metod fizyko-chemicznych w ocenie tlenowej stabilizacji osadu ściekowego.

Summary. The article presents selected machine learning algorithms for processing the microscopic image of oxidized sewage sludge flocs in order to assess the effectiveness of monitoring the oxygen stabilization process. Three techniques of segmentation were presented and compared by algorithm: *k*-means, fuzzy *c*-means and Otsu thresholding in assessing segmentation effectiveness of oxidized areas and detecting the swelling or foaming phenomenon of sewage sludge flocs. The GCE, RI, VI metrics has been effectively used and compared for morphological and structural changes of the flocs by assessing the image segmentation and quantification. The analysis of microscopic images using machine learning techniques save time and constitute an alternative to the physico-chemical methods to assessment aerobic stabilization of sewage sludge. (Selected machine learning algorithms for processing the microscopic image of oxidized sewage sludge flocs)

Słowa kluczowe: metody uczenia maszynowego, tlenowa stabilizacja osadów ściekowych, przetwarzanie obrazów

Keywords: machine learning methods, aerobic stabilization of sewage sludge, image processing


Wstęp

Tlenowa stabilizacja osadów ściekowych jest jedną z metod unieszkodliwiania substancji organicznej zawartej w ściekach komunalnych [1,2]. Nieprawidłowe stany procesu, w tym pęcznienie lub pienienie się kłaczków można wykryć za pomocą konwencjonalnych testów fizyko-chemicznych, które są czasochłonne i nie uwzględniają czasu na podjęcie działań zapobiegawczych. Metody przetwarzania obrazów mogą stanowić lepszą alternatywę w wykryciu i identyfikacji nieprawidłowych warunków utleniania osadów ściekowych. Ostatnia dekada pokazuje znaczny wzrost zainteresowania badaniami dotyczącymi wykorzystania automatycznej analizy obrazu w oczyszczalniach ścieków do monitorowania stanów anormalnych [3-5]. Jenne [6] stosował metody progowania opartych na histogramie z użyciem algorytmów segmentacji kłaczków i włókien pochodzących z osadów ściekowych. Heine [7] z kolei wzmocnił segmentację obrazu poprzez zastosowanie progowania i metod gradientowych w wykrywaniu krawędzi obrazu. Sikora i Smolka [8] przeprowadzili segmentację przy użyciu składowych obrazu o niskiej częstotliwości przestrzennej, po której następuje progowanie. Wykorzystali również algorytm Canny'ego do wykrywania krawędzi, po którym następowało dwupoziomowe progowanie. Perez [9] z kolei zastosował sekwencyjny algorytm korekcji tła, wyrównywania histogramów i filtrowania median do morfologicznej analizy kłaczków osadów ściekowych. Przedstawione w literaturze techniki segmentacji były ocenione jedynie przy użyciu globalnego błędu spójności (*ang. Global consistency error*). Podczas procesu utleniania widoczne są różnice w wielkości, strukturze czy morfologii kłaczków osadów ściekowych. W tej pracy oceniono techniki segmentacji kłaczków osadów ściekowych przy użyciu wybranych algorytmów uczenia maszynowego: *k*-średnich, rozmytych *c*-średnich oraz progowania Otsu. W celu ilościowej i jakościowej oceny algorytmów segmentacji użyto następujących metryk wydajności: globalnego błędu spójności GCE, zmienność

informacji VI (z *ang. variation of information*) i indeksu losowego RI (z *ang. Random Index*).

Metodologia

Zdjęcie mikroskopowe próbki osadów ściekowych zostało zrobione w rozdzielczości 1080x720 pikseli i przedstawione na rys.1a. Aby wyeliminować efekt oświetlenia otoczenia, obraz został przefiltrowany filtrem Gaussa (rys. 1b).



Rys.1. Originalny obraz próbki osadów ściekowych a), obraz po zastosowaniu filtru Gaussa b)

Zastosowano i porównano następujące algorytmy uczenia maszynowego w segmentacji obrazu:

a) *Metoda progowania Otsu (ang. Otsu thresholding)* jest nienadzorowaną i nieparametryczną techniką progowania w perspektywie analizy dyskryminacyjnej. Technika generuje wartość progową, która dzieli wartości intensywności obrazu w skali szarości na dwa lub więcej klastrów.

b) *Algorytm klasteryzacji k-średnich (ang. K-means)*-algorytm ma na celu podzielenie danych na *k* klastrów, a następnie minimalizuje wewnątrz klastra sumę kwadratów odległości euklidesowej od danego punktu do środka wszystkich utworzonych gromad. Procedura iteracyjna rozpoczyna się od inicjalizacji *k* liczby centrów klastrów, po których następuje asocjacja danych punktowych z najbliższym środkiem klastra. Średnia danych punktowych

każdego klastra jest obliczana, tworząc nowe centra klastrów dla następczej iteracji. Po konwergencji próg wartości jest pobierany z granicznej wartości intensywności obrazu podzielonego na daną ilość gromad.

c) *Rozmyta metoda c-średnich* (ang. *Fuzzy c-means*)- klasteryzacja jest wykonywana iteracyjnie w celu zminimalizowania sumy kwadratów skalowalnych odległości od punktu do środka klastra w odniesieniu do sumy wszystkich klastrów. Procedura iteracyjna rozpoczyna się od inicjalizacji k liczby centrów klastrów, następnie tworzona jest macierz przypisująca dany punkt do danego klastra. Procedura iteracyjna powtarza się w celu ponownego obliczenia centrów klastrów i stworzenia macierzy aż do osiągnięcia zbieżności obliczeń.

W literaturze znajduje się wiele wskaźników do oceny segmentacji [8,9]. Parametry są wybierane w zależności od określonego aspektu (takiego jak rozmiar, kształt), jak i obszaru zainteresowania ROI (ang. *Region of Interest*).

Do oceny efektywności segmentacji obrazu zostały użyte następujące metryki:

a) globalny błąd spójności GCE (ang. Global Consistency Error) mierzy zakres pomiędzy jedną, a drugą segmentacją. Segmenty, które są ze sobą powiązane, są uważane za spójne jeśli mogą reprezentować ten sam obraz podzielony na segmenty w różnych skalach. W przypadku, jeżeli jeden segment jest podzbiorem drugiego segmentu, piksele znajdują się w obszarze zainteresowania i błąd wynosi 0. GCE liczone jest ze wzoru (1) i (2)

$$(1) \quad GCE = \frac{1}{n} \min \left\{ \sum_i E(S_1, S_2, p_i), \sum_i E(S_2, S_1, p_i) \right\}$$

$$E(S_a, S_b, p_i) = \frac{|R(S_a, p_i) / R(S_b, p_i)|}{R(S_a, p_i)}$$

gdzie: $|x|$ to liczność zbioru, $/$ różnica zbiorów, $R(S, p_i)$ to

region w segmentacji S z danym pikselem p_i

b) Indeks losowy RI (ang. Random index) to miara podobieństwa między dwoma skupieniami danych. Określa prawdopodobieństwo dowolnej pary próbek, które mają spójne etykiety w dwóch regionach. Indeks Random oblicza się ze wzoru (3)

$$(3) \quad RI(S, S') = 1 - \frac{\left[\frac{1}{2} \left(\sum_i \left(\sum_j n_{ij} \right)^2 + \sum_j \left(\sum_i n_{ij} \right)^2 \right) \right] - \sum_i n_{ii}}{\binom{N}{2}}$$

gdzie: $\sum_i n_{ij}$ to jest liczba punktów z daną etykietą i w zbiorze S ,

$\sum_j n_{ij}$ to jest liczba punktów z daną etykietą j w zbiorze S' , a N

– całkowita liczba punktów.


c) Zmienność informacji VI (ang. variation of information) wariancja informacji, która mierzy całkowitą utratę i zysk informacji między dwoma klastrami. W związku z tym szacuje związek, z którym jeden klastr łączy się z drugim. Im niższa wartość, tym lepszy wynik. Definiuje odległość między dwoma klastrami jako entropia warunkowa jednej segmentacji względem drugiej. VI dla dwóch skupień $C1$ i $C2$ są podane przez wzór (4)

$$(4) \quad VI(C_1, C_2) = [H(C_1) - I(C_1, C_2)] + [H(C_2) - I(C_1, C_2)]$$

gdzie: $H(C)$ -entropia klasteryzacji zbioru C , $I(C_1, C_2)$ jest częścią wspólną informacji pomiędzy klastrami $C1$ i $C2$. VI wynosi 0, kiedy $C1=C2$

Omówienie wyników

W ocenie jakości segmentacji obrazu kłaczków osadów ściekowych zastosowano i porównano następujące algorytmy grupowania: rozmytych c-średnich, k-średnich i progowania Otsu. Rys.2. przedstawia wyniki segmentacji obrazu. Można zauważyć, że obrysy kłaczków są wyraźniej widoczne na większości zdjęć. Jednak w przypadku krótkich i mniej wyraźnych granic wyniki są różne. Te wartości wskazują, że zgodnie z oczekiwaniami bardziej zwarte i regularne kłaczkki mają tendencję do wykazywania bardziej kulistych kształtów. Z drugiej strony wysoko nieregularna struktura przedstawia mniejszą kulistość kształtu bioagregatów. Należy zauważyć, że dobra korelacja między takimi parametrami jest pożądana, ponieważ można je wykorzystać do wnioskowania kształtu agregatów drobnoustrojów i przewidzieć zdolność do osadzania się osadu czynnego, na który duży wpływ ma kształt agregatów. Największą jakość segmentacji odnośnie informacji dotyczących spienienia i pęcznienia kłaczków osadów ściekowych uzyskała metoda rozmytych c-średnich.



Rys.2. Rezultaty segmentacji obrazu z użyciem algorytmu: k-średnich a), progowania Otsu b), rozmytych c-średnich

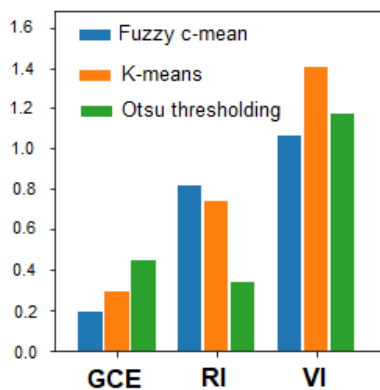
Wydajność algorytmów segmentacji oceniono w oparciu o metryki GCE, RI i VI. GCE jest miarą spójności i odporności na mały błąd niedopasowania granic w segmentacji. GCE stanowi metrykę wydajności w ocenie dokładności segmentowanego obrazu. Efektywność segmentacji algorytmów przedstawiono w tabeli 1. Jednym z istotnych parametrów była zmienność informacji (VI). Parametr ten daje istotne informacje odnośnie wielkości i kształtu kłaczków, co jest istotne w analizie parametrów morfologicznych kłaczków osadów ściekowych. Indeks losowy (RI) podaje istotne informacje odnośnie tekstury

obiekty na obrazie dla analizy jakościowej. W celu oceny jakości segmentacji porównano wydajność algorytmów grupowania. Największą efektywność segmentacji wykazał algorytm rozmytych c-średnich, charakteryzujący się najmniejszą wartością błędów GCE oraz VI, a zarazem największą wartością indeksu losowego. Również efektywność identyfikacji na poziomie 93,4 % z wykorzystaniem klasyfikatora maszyny wektorów nośnych SVM (ang. support vector machine) dała największą skuteczność.

Tabela 1. Parametry i algorytmy w ocenie jakości segmentacji obrazu mikroskopowego kłaczków osadów ściekowych

	k- średnich	Rozmyty c-średnich	Segmentacja Otsu
Dokładność	0.893	0.921	0.792
Błąd GCE	0.301	0.211	0.421
Indeks losowy(RI)	0.742	0.956	0.276
Zmienność informacji (VI)	1.41	1.057	1.19
Efektywność identyfikacji	89%	93.4%	87.6%

Na rys. 3 przedstawiono i porównano efektywność segmentacji wybranych algorytmów. Najgorszą efektywność segmentacji wykazało progowanie Otsu, charakteryzujące się najwyższym wskaźnikiem GCE. Tworzenie się włókien i pęcznienie osadu sprzyja tworzeniu się gęstych, dużych kłaczków powodujących zjawisko flokulacji. Pęcznienie włókniste sprzyja tworzeniu się wysoce nieregularnych kłaczków charakteryzujących szybki spadek szybkości osadzania kłaczków oraz niski poziom zagęszczenia zawiesiny, podczas gdy rozproszony wzrost prowadzi do tworzenia się małych i lekkich kłaczków, które nie osiadają, ale wykazują wysokie stężenie zawiesiny.



Rys.3. Metryki GCE, RI oraz VI w ocenie jakości segmentacji obrazu.

Ocena segmentacji obrazów w utlenianiu kłaczków osadów ściekowych może być w przyszłości używana jako automatyczne narzędzie kontrolne dla określonych środków zaradczych przeciw pęcznieniu i pienieniu. Wykrycie

bakterii nitkowatych, wielkości i kształtu kłaczków, a także ich stabilności wpływających na zdolność osadzania co powoduje, że ich charakterystyka morfologiczna pozwala na skuteczny sposób określić ich standardowe wskaźniki biologiczne.

Podsumowanie

W artykule przedstawiono wybrane algorytmy uczenia maszynowego (k-średnich, rozmytych c-średnich, progowania Otsu) w jakościowej analizie segmentacji obrazu mikroskopowego kłaczków osadów ściekowych. Wydajność algorytmów segmentacji oceniono w oparciu o metryki GCE, VI oraz RI. Analiza oparta o GCE, VI oraz RI wykazała, że najlepszą wydajność wykazał algorytm rozmytej segmentacji c-średnich. Parametryzacja wyodrębnionych struktur osadu może być użyta jako cecha diagnostyczna przy użyciu klasyfikatora SVM. Pozwala to ocenić jakość utlenionych osadów ściekowych, a także morfologicznie scharakteryzować różne typy osadów. Parametry te również mają istotne znaczenie w ocenie skuteczności działania przydomowych oczyszczalni ścieków w oparciu o wskaźniki biologiczne, takie jak: biologiczne czy chemiczne zapotrzebowanie na tlen.

Praca realizowana ze środków na działalność statutową (11165011/320) pt. Utlennianie osadów ściekowych z użyciem modeli uczenia maszynowego finansowanej przez Ministerstwo Nauki i Szkolnictwa Wyższego.

LITERATURA

- [1] Bizukojc E.L.: Application of image analysis techniques in activated sludge wastewater treatment processes, *Biotechnology Letters*, (2005), 1427-1433.
- [2] Mesquita D. P., Amaral A. L., Fareira E. C.: Identifying different types of bulking in an activated sludge system through quantitative image analysis, *Chemoshpere*, (2011), 643-652.
- [3] Xue-Yong L., Humaira N., Ho Yeap K.: An Approach for the Segmentation and Quantification of Activated Sludge Floc Blobs, *Advanced Science Letters*, (2013), 140-146.
- [4] Khan M. B., Nisar H., Choon Aun Ng.: Segmentation and quantification of activated sludge flocs for wastewater treatment, *IEEE Conference on Open Systems (ICOS)* (2014).
- [5] Tatiraju S., Mehta A.: Image Segmentation using k-means clustering, EM and Normalized Cuts.: University Of California Irvine, (2008).
- [6] Jenne R., Banadda E. N., Philips N., Impe J.F.V.: Image analysis as a monitoring tool for activated sludge properties in lab- scal installations, *J. Environ. Sci. Health A Tox Hazard Subst Environ Eng.*(2003), 2009-2018..
- [7] Heine W., Sekoulov I., Burkhardt H., Bergen L.: Early warning system for operation failures in biological stages of WWTPs by online image analysis, *IWA Conference, Berlin*, (2001), 15-19.
- [8] Sikora M., Smolka B.: Feature analysis of activated sludge based on microscopic images, *Canadian conference on Electrical and Computer Engineering*, (2001), 1309-1314.
- [9] Perez Y. G., Leite S. G.F., Coelho M. A. Z.: Activated sludge morphology characterisation through an image analysis procedure, *Brazilian Journal of Chemical Engineering*, (2006), 319 - 330.