

О.М. Безвесільна, д.т.н., проф.

Національний технічний університет України „КПІ”

Т.О. Єльнікова, к.т.н., доц.

Житомирський державний технологічний університет

Ю.О. Подчашинський, к.т.н., доц.

Житомирський державний технологічний університет

ІДЕНТИФІКАЦІЯ ТА ВИЗНАЧЕННЯ ГЕОМЕТРИЧНИХ ПАРАМЕТРІВ І БІОМАСИ ФІТОПЛАНКТОНУ НА ОСНОВІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

Розроблено метод ідентифікації фітопланктону та визначення його біомаси на основі використання цифрових відеозображень проб води та штучної нейронної мережі. Даний метод використовується для контролю стану водойм господарсько-побутового призначення, які є джерелом водопостачання населення.

Вступ. На сьогоднішній день відомо багато варіантів досліджень, оцінки та вимірювань процесів розвитку фітопланктону, а також розроблено багато відповідних методик та засобів контролю за цими процесами. Існуючі методики включають в себе: використання звичайного мікроскопа; підрахунок кількості екземплярів фітопланктону у пробі води шляхом візуального спостереження цієї проби людиною; ручне визначення геометричних параметрів фітопланктону (ГПФ) за допомогою окуляра мікроскопа з вбудованою лінійкою; подальший розрахунок потрібних показників, у тому числі – маси фітопланктону. Ці методики мають обмежені функціональні можливості, недостатню точність і швидкодню вимірювань, особливо при дослідженнях динаміки змін ГПФ у часі. Дані методики також потребують виконання великого об'єму ручної праці в процесі вимірювань. Тому виникла необхідність створити нову методику вимірювань, що використовує сучасні інформаційно-комп'ютерні технології для збору та обробки вимірювальної інформації і в якій відсутні вказані недоліки існуючих методик.

Мета статті розробити методику ідентифікації фітопланктону у пробах води та визначення його біомаси, яка мала б вищу достовірність та продуктивність за існуючі методики.

Виклад основного матеріалу дослідження з обґрунтуванням отриманих наукових результатів. Задача ідентифікації фітопланктону полягає в розподілі множини об'єктів (екземплярів фітопланктону) на класи (види фітопланктону). Основою для цього служить вектор параметрів об'єктів (геометричні параметри кожного з екземплярів фітопланктону). Об'єкти в межах одного класу вважаються еквівалентними з погляду критерію розбивки на класи. Самі класи часто бувають невідомі заздалегідь, а формуються динамічно (як, наприклад, в шарах Кохонена відповідної штучної нейронної мережі (ШНМ)). Класи залежать від досліджуваних об'єктів, і тому додавання нового об'єкта вимагає коректування системи класів.

Будемо характеризувати об'єкти, що підлягають ідентифікації, вектором параметрів $x^p \in X$, що мають N компонент, компоненти позначаємо нижнім індексом: $x^p = (x_1^p, \dots, x_n^p)$. Вектор параметрів – єдина ознака об'єктів при їх ідентифікації.

Введемо множину класів $C^1, \dots, C^M = \{C^m\}$ в просторі класів C :

$$(C^1 \cup C^2 \dots \cup C^M) \subset C.$$

Простір класів може не збігатися з простором об'єктів X і мати іншу розмірність. В найпростішому випадку, коли простір класів і об'єктів збігаються, $X = C$, класи являють собою області простору X , і об'єкт x^p буде віднесений до одного з класів m_0 , якщо $x^p \in C^{m_0}$. У загальному випадку X і C різні. Визначимо ядра класів $\{c^m\} = c^1, \dots, c^m$ в просторі класів C , як об'єкти, типові для свого класу.

Очевидно, що близькість об'єкта до ядра необхідно оцінювати чисельно. Введемо міру близькості $d(x^p, c^m)$ – скалярну функцію від об'єкта і ядра класу, що тим менша, чим більший об'єкт схожий на ядро класу. Можуть знадобитися допоміжні міри близькості, визначені для двох об'єктів, $d(x^{p1}, x^{p2})$, і для двох ядер класів, $d(c^{m1}, c^{m2})$.

Найчастіше застосовується евклідова міра:

$$d(x, y) = \sum_i (x_i - y_i)^2,$$

або евклідова відстань:

$$d(x, y) = \sum_i |x_i - y_i|.$$

Задавшись числом класів M , можна поставити задачу ідентифікації: знайти M ядер класів $\{c^m\}$ і розбити об'єкти $\{x^p\}$ на класи $\{C^m\}$, тобто побудувати функцію $m(p)$ таким чином, щоб мінімізувати суму мір близькості:

$$\min \left\{ D = \sum_p d(x^p, c^{m(p)}) \right\}.$$

Функція $m(p)$, що визначає номер класу по індексу p множини об'єктів $\{x^p\}$, задає розбивку на класи і є рішенням задачі ідентифікації.

У найпростішому випадку $X = C$, простір об'єктів X розбивається на області $\{C^m\}$, і якщо $x^{p_0} \in C^{m_0}$, то $m(p_0) = m_0$, і об'єкт відносять до класу m_0 .

Кількість класів M може динамічно мінятися. При цьому часто виникають ситуації, коли об'єкти розподілені по класах нерівномірно. Необхідно контролювати рівномірність щільності ядер c^m у просторі C і частку об'єктів, що відносяться до кожного класу m_0 . Конкретні вимоги повинні обиратися залежно від задачі. За необхідності можна коректувати щільність злиттям і поділом ядер. Критерії для цього можуть використовуватися різні, і, в основному, емпіричні. Наприклад, два класи можуть зливатися в один, якщо міра близькості їхніх ядер менша, ніж середня міра близькості ядер і всіх об'єктів у цих двох класах. Застосовуючи аналогічні правила, треба пам'ятати про "побічні ефекти". Приведений критерій злиття може працювати некоректно [1, 2, 3].

Міра близькості ядер у цьому випадку набагато менша, ніж середня міра близькості між об'єктами і ядрами. Відповідно до правила класи будуть об'єднані, хоча в багатьох задачах таке об'єднання необгрунтовано.

Корисно визначити діаметр класу – максимальне значення міри близькості між об'єктами даного класу.

Якщо для ідентифікації застосовувати нейронні мережі, необхідно формалізувати задачу [1, 3, 8]. Найбільш очевидний спосіб: виберемо в якості вхідних даних вектор параметрів об'єкта. Результатом роботи мережі буде код класу, до якого належить пред'явлений на вході об'єкт. Тому мережа буде мати M виходів, по числу класів, і чим більше значення приймає вихід номера m_0 , тим більше "упевненість" мережі в тім, що вхідний об'єкт належить до класу m_0 .

Виберемо евклідову міру близькості. У цьому випадку ядро класу, що мінімізує суму мір близькості для об'єктів цього класу, збігається з центром ваги об'єктів:

$$c^{m_0} = \frac{1}{N(m_0)} \sum_{p:p(m)=m_0} x^p,$$

де $N(m_0)$ – число об'єктів x^p в класі m_0 .

При розбивці на класи повинна бути мінімізована сумарна міра близькості для всієї безлічі $\{x^p\}$ вхідних об'єктів:

$$\begin{aligned} D &= \sum_p \sum_i (x_i^p - c_i^{m(p)})^2 = \\ &= \sum_p [(x^p, x^p) - 2(x^p, c^{m(p)}) + (c^{m(p)}, c^{m(p)})]. \end{aligned}$$

У цій сумі два доданки не залежать від способу розбивки і постійні:

$$\sum_p (c^{m(p)}, c^{m(p)}) = \text{const}, \quad \sum_p (x^p, x^p) = \text{const}.$$

Тому задача пошуку мінімуму D еквівалентна пошуку максимуму виразу:

$$\min D \rightarrow \max \sum_p \sum_i x_i^p c_i^{m(p)}.$$

Запишемо варіант алгоритму ідентифікації для пошуку максимуму цієї функції:

1. Цикл: для кожного вектора x^p .
2. Цикл: для кожного m .
3. Розрахувати

$$\sum_i x_i^p c_i^m = D^{m,p}$$

// кінець циклу по m .

4. Знаходимо m_0 , для якого

$$m_0 : \max_m \{D^{m,p}\}$$

5. Відносимо об'єкт до класу m_0

// кінець циклу по x^p .

Такий алгоритм легко реалізується у вигляді нейронної мережі. Для цього потрібно M суматорів, що знаходять всі $D^{m,p}$, і інтерпретатора, що знаходить суматор з максимальним виходом.

Сума $\sum_i x_i^p c_i^m$ дуже нагадує зважену суму $NET_{jl} = \sum_i w_{ijl} x_{ijl}$, що розраховується формальним нейроном. Виберемо x_i^p як вхідні сигнали (що ми, угім, уже зробили) і компоненти ядер c_i^m як вагові коефіцієнти w_{ijl} . Тоді кожен формальний нейрон з числом входів, рівним числу компонентів у вхідному векторі, буде давати на виході одну із сум $D^{m,p}$.

Щоб визначити клас, до якого відноситься об'єкт, потрібно вибрати серед усіх нейронів даного шару один з максимальним виходом – це здійснює інтерпретатор. Інтерпретатор вибирає нейрон з максимальним виходом.

Розглянута мережа нейронів, що використовує евклідову міру близькості для класифікації об'єктів, називається мережею Кохонена, яка зображена в загальному випадку на рис. 1. Нейрони шару Кохонена генерують сигнали $D^{m,p}$. Інтерпретатор вибирає максимальний сигнал шару Кохонена і видає номер класу, що відповідає номеру входу, по якому інтерпретатором отриманий максимальний сигнал. Це відповідає номеру класу об'єкта, що був пред'явлений на вході у виді вектора X^p . Ядра c_i^m є ваговими коефіцієнтами нейронів. Кожен нейрон Кохонена запам'ятовує одне ядро класу, і відповідає за визначення об'єктів у своєму класі, тобто величина виходу нейрона тим більша, чим ближчий об'єкт до даного ядра класу.




Рис. 1. Мережа Кохонена для ідентифікації фітопланктону за його геометричними параметрами: X^p – вектор ГПФ; m – вид фітопланктону; c_i^m – компоненти ядер (вагові коефіцієнти); $D^{m,p}$ – суматор

Загальна кількість класів збігається з кількістю нейронів Кохонена. Змінюючи кількість нейронів, можна динамічно змінювати кількість класів.

Нейрони Кохонена мають лінійну функцію активації.

Вхідні вектора мережі найчастіше нормуються:

$$\frac{x^p}{|x^p|} \rightarrow x^p \quad \text{або} \quad \frac{x^p}{\sum_p |x^p|^2} \rightarrow x^p.$$

Для виявлення центрів кластерів на етапі обробки інформації в нейронних мережах використовується шар нейронів Кохонена (мережа Кохонена). Мережа Кохонена виконує пошук центрів кластерів в тестовій навчальній вибірці даних. В тестовій вибірці містяться набори геометричних ознак визначених відділів фітопланктонних водоростей.

Шар Кохонена ідентифікує вхідні вектори в групі схожих. Це досягається за допомогою такого підстроювання ваг шару Кохонена, що близькі вхідні вектори активують той самий нейрон даного шару. Не важливо, який конкретно нейрон буде активований. Необхідно лише гарантувати, щоб в результаті навчання розділялися несхожі вхідні вектори.

Навчання Кохонена є самонавчанням, що протікає без вчителя. Алгоритм Кохонена передбачає самонавчання по правилу “переможець забирає все”.

Ваговим коефіцієнтам мережі перед початком навчання варто присвоїти початкові значення. Загально прийнятою практикою при роботі з нейронними мережами є присвоювання вагам невеликих випадкових значень. При навчанні шару Кохонена випадково обрані вагові вектори варто нормалізувати. Остаточні значення вагових векторів після навчання збігаються з нормованими вхідними векторами. Тому нормалізація перед початком навчання наближає вагові вектори до їх остаточних значень, скорочуючи, таким чином, процес навчання.

Якщо ваги ініціалізуються випадковими значеннями з рівномірним розподілом, то виникає проблема. Коли ядра розподіляються рівномірно, то в областях простору X , де мало вхідних векторів, ядра будуть використовуватися рідко, тому що мало буде схожих векторів. В тих областях, де вхідних векторів багато, щільність ядер виявиться недостатньою, і несхожі об'єкти будуть активувати той самий нейрон, тому що більш схожого ядра не знайдеться. Для усунення проблеми можна розподілити щільність ядер

класів (векторів ваг) відповідно до щільності вхідних векторів в просторі X . Але розподіл вхідних векторів часто буває заздалегідь невідомо. У цьому випадку допомагає метод випуклої комбінації.

1. Присвоюємо всім вагам те саме початкове значення:

$$w_i^m = \frac{1}{\sqrt{n}}, \quad n = \dim X.$$

Вектори ваг одержують довжину, рівну одиниці, як вимагає нормалізація. Всі вектори ваг однакові.

2. Задаємо навчальну множину $\{x^p\}$ і проводимо навчання, але не з векторами x^p , а з векторами $\beta(t)x^p + \frac{1-\beta(t)}{\sqrt{n}}$, де t – час навчання, $\beta(t)$ – монотонно зростаюча функція, що міняється від 0 до 1 в процесі навчання.

На початку навчання $\beta(t) = 0$ і всі навчальні вектори однакові і дорівнюють початковому значенню ваг. В міру навчання $\beta(t)$ росте і навчальні вектори розходяться із точки з координатами і наближаються до своїх кінцевих значень x^p , що досягаються при $\beta(t) = 1$. Кожен вектор ваг “захоплює” групу чи один навчальний вектор і відслідковує його в міру росту β .

Метод випуклої комбінації дає правильний розподіл щільності ядер. При цьому в мережі не залишається “непотрібних” ненавчених нейронів, що бувають при звичайному навчанні. Коли вектор ваг нейрона знаходиться далеко від всіх навчальних векторів, цей нейрон ніколи не буде «вигравати», і його ваги не будуть коректуватися при навчанні. Випукла комбінація не залишає в мережі таких нейронів.

Задача навчання – навчити мережу активувати той самий нейрон для схожих векторів x^p на вході. Якщо число вхідних векторів дорівнює числу ядер (тобто нейронів), то навчання не потрібно. Досить присвоїти ядрам значення вхідних векторів, і кожен вектор буде активувати свій нейрон Кохонена. Але найчастіше кількість класів менша числа вхідних векторів. У цьому випадку ваги мережі налаштовуються ітеративним алгоритмом.

Алгоритм аналогічний вихідному алгоритму ідентифікації, але корекції ваг проводяться після пред’явлення кожного вхідного вектора, а не після пред’явлення усіх, як вимагає вихідний алгоритм. Збіжність при цьому зберігається.

1. Присвоюємо початкові значення ваговим коефіцієнтам.

2. Подаємо на вхід один з векторів x^p .

3. Розраховуємо вихід шару Кохонена $D^{m,p}$ і визначаємо нейрона-переможця m_0 : $\max D^{m,p}$.

4. Коректуємо ваги тільки нейрона-переможця m_0 , його вихід дорівнює одиниці, а інших нейронів – нулю:

$$w_{m_0} := w_{m_0} - \alpha(x^p - w_{m_0}).$$

В цій формулі корекція записана у вигляді векторного виразу (вектор ваг w_{m_0} нейрона m_0 має стільки компонент, скільки їх у вхідного вектора x^p). α – швидкість навчання, мала позитивна величина. Часто використовують розклад з навчанням, коли $\alpha = \alpha(t)$ монотонно убуває. Вимоги до $\alpha(t)$ ті ж, що й у випадку багатозарового перцептрона.

5. Перевірка виконання правила (в якості цього правила можна прийняти, наприклад, стабілізацію векторів ваг на яких-небудь значень), якщо воно не виконується – продовження циклу навчання (перехід на крок 2); в протилежному випадку – перехід на крок 6.

6. Завершення процедури навчання.

Алгоритм виконується доти, поки ваги не перестануть мінятися. Підсумковим результатом подібних корекцій для двовимірного випадку є вектори ваг, що показують на центри кластерів (центри групування) вхідних образів, що відповідають певним видам фітопланктону (рис. 2). Алгоритм навчання Кохонена забезпечує рішення задачі автоматичної ідентифікації, тобто віднесення пред’явленого вектора входів до одного з класів (наприклад на рис. 2 таких три класи). Така ідентифікація можлива тільки у випадку, коли кластери є лінійно роздільними (гіперплощинами) відносно початку координат у просторі входів.




Рис. 2. Вектори ваг ШНМ Кохонена після закінчення процесу навчання:
 w_1 – вид 1 фітопланктону; w_2 – вид 2 фітопланктону; w_3 – вид 3 фітопланктону

Число нейронів НМ для успішного рішення зазначеної задачі повинне бути не менше, ніж число кластерів; оскільки точне число кластерів може бути заздалегідь невідомо, кількість нейронів задають з визначеним запасом [1].

У робочому режимі для ідентифікації фітопланктону ШНМ визначає відстані від вхідного вектора до центрів кластерів тестової вибірки. Інтерпретатор цієї мережі визначає найменше значення виходів нейронів (мінімальна відстань від вхідного вектора до центрів кластерів), який відповідає за належність відеозображення екземпляра фітопланктону до певного класу. Це і є номер виду фітопланктону, що ідентифікувався.

Суттєвим недоліком існуючих методів ідентифікації фітопланктону є низька достовірність та низька продуктивність ідентифікації фітопланктону у пробах води з водойм.

Тому було розроблено метод ідентифікації фітопланктону на основі використання цифрових відеозображень проб води та ШНМ. В цьому методі після розміщення в мікроскопі препарату з проби води формують його відеозображення за допомогою відеокамери, приєднаної до оптичної системи мікроскопа. Далі вводять це відеозображення в обчислювальне середовище цифрової електронної обчислювальної машини, причому виявлення кожного екземпляра фітопланктону виконують шляхом цифрової обробки відеозображення препарату з проби води. Після цього для кожного екземпляра фітопланктону розраховують геометричні ознаки форми, інваріантні до масштабування, зсуву та повороту цього екземпляра в площині відеозображення. Ідентифікацію фітопланктону виконують за допомогою штучної нейронної мережі, причому кількість входів цієї мережі відповідає кількості ГПФ, що використовують для ідентифікації, а кількість виходів цієї мережі відповідає кількості видів фітопланктону, що обрані для досліджень та можуть існувати в умовах водойм, які досліджують. Для навчання штучної нейронної мережі використовують тестові відеозображення, що містять фітопланктон заздалегідь відомих видів. В якості простора ознак для ідентифікації використовують ГПФ, що виміряні по його відеозображенням.

В даному методі ідентифікацію фітопланктону виконують на основі формування цифрових відеозображень препаратів з проб води та цифрової обробки цих відеозображень з використанням математичного апарату та алгоритмів штучних нейронних мереж.

Підвищення достовірності ідентифікації фітопланктону забезпечується за рахунок використання штучної нейронної мережі, яка успішно вирішує задачу ідентифікації навіть при наявності великої кількості ознак, що треба аналізувати, при великому різноманітті зовнішнього вигляду фітопланктонних водоростей та при відсутності абсолютно чітких формальних критеріїв виконання процедури ідентифікації [4, 2].

В автоматизованій системі було використано ШНМ Кохонена, яка здатна в процесі навчання виявляти в даних, що надходять на її вхід, групи подібних даних (кластери) та визначати усереднені значення ознак (центри кластерів), що характеризують ці групи. Для фітопланктону групи даних (кластери) будуть відповідати його видам, відомим з гідробіології. Після навчання ШНМ для кожного вхідного набору даних визначає центр кластеру, найближчий до цього набору в просторі ознак. Так як кожному кластеру простора ознак відповідає певний вид фітопланктону, то результатом всіх цих дій буде ідентифікація кожного екземпляра фітопланктону за його належністю до одного з видів.

Якщо навіть початкові дані спотворені шумами, наявними на відеозображеннях препаратів з проб води, то ШНМ все одно спроможна після навчання виділяти ознаки та іншу інформацію, суттєву для ідентифікації фітопланктону. Це також забезпечує підвищення достовірності ідентифікації фітопланктону.

Іншим фактором підвищення достовірності ідентифікації фітопланктону є використання геометричних ознак форми, інваріантних до масштабування, зсуву та повороту цих водоростей в площині відеозображення. Використання цих ознак усуває можливі причини похибок ідентифікації при

довільному розташуванні екземплярів фітопланктону в площині відеозображення, яке має місце для будь-яких препаратів з проб води.

Метод ідентифікації фітопланктону виконують в такій послідовності:

1. Відбирають з водойм проби води, що містять фітопланктон. Місця відбору проб води визначають з урахуванням як природних характеристик водойм (просторова форма та структура водойми, наявність глибоководних і мілководних ділянок та їх співвідношення, наявність потоків води, що надходять або витікають з цієї водойми тощо), так і з урахуванням розташування антропогенних джерел забруднень водойми [5].

2. Підготовлюють препарат з кожної проби води на предметному склі та розмішують його під окуляром мікроскопа. Для точного дозування препарату при його нанесенні на предметне скло можуть бути використані спеціальні штепель-піпетки, розраховані на фіксований об'єм цього препарату [6, 5]. Основними вимогами до мікроскопа є збільшення окуляра не менше, ніж 5^{\times} , об'єктива – не менше, ніж 20^{\times} [5]. Сумарне збільшення мікроскопу повинно бути не менш 100^{\times} , рекомендується 400^{\times} .

3. Формують відеозображення препарату з кожної проби води за допомогою відеокамери, приєднаної до оптичної системи мікроскопа та вводять це відеозображення в обчислювальне середовище цифрової ЕОМ.

4. Виявляють кожен екземпляр фітопланктону у препаратах з кожної проби води шляхом цифрової обробки відеозображень цих препаратів. Процедура цифрової обробки включає такі операції, як перетворення кольорової схеми відеозображення, видалення шумів, відновлення відеозображення, його сегментацію.

5. Для кожного екземпляра фітопланктонних водоростей розраховують геометричні параметри, інваріантні до масштабування, зсуву та повороту цього екземпляра в площині відеозображення.

6. Виконують ідентифікацію кожного екземпляра фітопланктону за його належністю до одного з видів. Ідентифікацію фітопланктону виконують за допомогою ШНМ, причому кількість входів цієї мережі відповідає кількості геометричних параметрів, що використовують для ідентифікації, а кількість виходів цієї мережі відповідає кількості видів фітопланктону, що обрані для досліджень та можуть існувати в умовах водойми, які досліджують. Для навчання ШНМ використовують тестові відеозображення, що містять фітопланктон заздалегідь відомих видів. Як простір ознак для ідентифікації використовують геометричні параметри, розраховані в п. 5.

7. Визначають загальну кількість фітопланктону кожного виду у кожному препараті. Цю операцію зазвичай виконують в обчислювальному середовищі цифрової ЕОМ.

8. Розраховують кількісні показники, що характеризують розвиток фітопланктону в цілому та його окремих видів у водоймі. Наприклад, це можуть бути структурно-функціональні показники стану фітопланктону, частота зустрічі його конкретних видів, інформаційне різноманіття фітопланктону [7, 5]. Ці операції зазвичай виконують в обчислювальному середовищі цифрової ЕОМ.

Для прикладу сформовано тестовий сигнал, який складається з 60 наборів геометричних параметрів екземплярів фітопланктону (10 екземплярів для кожного з 6 видів фітопланктону). Цей сигнал подають на вхід ШНМ Кохонена. Ця ШНМ на виході визначає 6 центрів кластерів в режимі навчання (рис. 3).




Рис. 3. Ідентифікація фітопланктону на основі геометричних параметрів та ШНМ: $p(1)$ – ексцентриситет екземплярів фітопланктону; $p(2)$ – коефіцієнт заповнення екземплярів фітопланктону; + – відображення геометричних параметрів кожного екземпляра фітопланктону; o – виявлені центри кластерів геометричних параметрів

Для наведеного прикладу (рис. 3, відображено два геометричні параметри з трьох) кількість нейронів у вхідному прошарку i , відповідно, кількість входів цієї мережі дорівнювала 3 (використовується 3 геометричні параметри для ідентифікації: коефіцієнт випуклості, коефіцієнт заповнення, ексцентриситет). Кількість нейронів у вихідному прошарку, який приймає рішення про належність екземплярів фітопланктону до одного з видів, i , відповідно, кількість виходів мережі становила 6 (на відеозображенні ідентифікуються фітопланктон 6 вказаних видів). Вірогідність безпомилкового визначення належності екземплярів фітопланктону до одного з видів на оброблених прикладах становила 0,95.

Результати експериментальних досліджень підтвердили можливість практичної реалізації та впровадження розробленого методу ідентифікації та розрахунку маси фітопланктону.

Висновки. Розроблено методику ідентифікації фітопланктону у пробах води та визначення його біомаси, яка має вищу достовірність та продуктивність за існуючі методики. Підвищення продуктивності та швидкодії ідентифікації фітопланктону забезпечується за рахунок виключення ручної праці та використання цифрової ЕОМ для обробки відеозображень, що містять вимірну інформацію про фітопланктонні водорості. Також при цьому підвищується достовірність за рахунок виключення суб'єктивних похибок, можливих у випадку використання ручної праці в процесі ідентифікації фітопланктонних водоростей.

Таким чином, розроблений метод ідентифікації забезпечує підвищення достовірності та підвищення продуктивності ідентифікації фітопланктону у пробах води з водойм.

ЛІТЕРАТУРА:

1. Нейронные сети: основные модели / Под ред. И.В. Заенцева. – Воронеж, 1999. – 76 с.
2. Уоссермен Ф. Нейрокомпьютерная техника. – М.: Мир, 1992. – 127 с.
3. Шамша Б.В., Гуржій А.М. та ін. Математичне забезпечення інформаційно-керуючих систем. – Харків: ТОВ "Компанія СМІТ", 2006. – 448 с.
4. Круглов В.В., Дли М.И., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. – М.: Физматлит, 2001. – 224 с.
5. Щербак В.И. Методи досліджень фітопланктону // Методичні основи гідробіологічних досліджень водних екосистем. – К., 2002. – С. 41–47.
6. Топачевский А.В., Масюк Н.П. Пресноводные водоросли Украинской ССР. – К.: Высшая школа, 1984. – 336 с.
7. Андреев А.Д., Щербак В.И. Интегральная количественная оценка состояния фитопланктонного сообщества по структурным показателям // Гидробиологический журнал. – 1994. – Т. 30. – № 2. – С. 3–7.
8. Nelles O., Ernst S., Isermann R. Neuronale Netze zur Identifikation nichtlinearer, dynamischer Systeme: Ein Überblick // Automatisierungstechnik. – 1997. – 45. – № 6. – S. 251–262.

БЕЗВЕСІЛЬНА Олена Миколаївна – доктор технічних наук, професор кафедри приладобудування Національного технічного університету України "КПІ".

Наукові інтереси:

- інформаційні системи;
- прилади та методи вимірювання механічних величин.

СЛЬНІКОВА Тетяна Олександрівна – кандидат технічних наук, доцент кафедри екології Житомирського державного технологічного університету.

Наукові інтереси:

- екологія та гідробіологія;
- засоби вимірювання екологічних параметрів;
- математичне моделювання екологічних систем.

ПОДЧАШИНСЬКИЙ Юрій Олександрович – кандидат технічних наук, доцент кафедри автоматизації і управління технічних систем Житомирського державного технологічного університету.

Наукові інтереси:

- автоматизовані системи та пристрої;
- комп'ютерне моделювання;
- автоматичний контроль екологічних параметрів.

Подано 15.10.2009

Безвесільна О.М., Єльнікова Т.О., Подчашинський Ю.О. Ідентифікація та визначення геометричних параметрів і біомаси фітопланктону на основі штучних нейронних мереж **Безвесильная Е.Н., Ельникова Т.А., Подчашинский Ю.А.** Идентификация и определение геометрических параметров и биомассы фитопланктона на основе искусственных нейронных сетей

Bezvesilnaya E.N., Elnikova T.A., Podchashinskiy Y.A. Authentication and determination of geometrical parameters and biomass of phytoplankton on the basis of artificial neuron networks

УДК 621.317:004.932

Идентификация и определение геометрических параметров и биомассы фитопланктона на основе искусственных нейронных сетей / Е.Н. Безвесильная, Т.А. Ельникова, Ю.А. Подчашинский

Разработан метод идентификации фитопланктона и определения его биомассы на основе использования цифровых видеоизображений проб воды и искусственной нейронной сети. Данный метод используется для контроля состояния водоемов хозяйственно-бытового назначения, которые являются источником водоснабжения населения.

УДК 621.317:004.932

Authentication and determination of geometrical parameters and biomass of phytoplankton on the basis of artificial neuron networks / E.N. Bezvesilnaya, T.A. Elnikova, Y.A. Podchashinskiy

The method of authentication of algae and determination of its mass is developed using digital video images of tests of water and artificial neuron network. This method is used for control of the state of reservoirs of service-utility purpose, which are the source of water-supply of population.