

Застосування нейронних мереж для рішення задачі дистанційного визначення концентрації хлорофілу в листах рослин

Розглядається задача оцінювання концентрації хлорофілу в рослинності на основі спектра відображення. Виконано ряд експериментів з метою запису відображених спектрів для озимої пшениці з різними значеннями концентрації хлорофілу. Побудовані графіки перших похідних і виконано аналіз концентрації пігменту. Для побудови моделі, що описує концентрацію хлорофілу, використано той відомий факт, що відношення максимумів графіка перших похідних корельовано з концентрацією хлорофілу. Для зменшення рівня шумів використана процедура згладжування даних, що базується на багатоточечній згортці. Виконано тестування декількох структур нейромереж для оцінювання концентрації хлорофілу в рослинності; знайдені структури, що дозволяють знайти кращі оцінки.

The problem of chlorophyll estimation in vegetation is considered using reflected spectra. A series of experiments has been fulfilled aiming collecting of reflectance data for winter wheat with various content of chlorophyll. The first derivative plots were drawn and analysis performed to determine concentration of the pigment. To construct the model describing content of chlorophyll in vegetation we used known fact that relation of maxima of the first derivative is correlated with chlorophyll content. To decrease level of noise experimental data were smoothed using multipoint folding procedure. Several structures of neural nets were tested to determine the best for estimating content of chlorophyll.

Вступ

Концентрація хлорофілу в листах дорослої рослини є важливою характеристикою його стану. Наприклад, рівень пігменту корелює з потужністю фотосинтезуючого апарата і може бути використаний для прогнозу врожайності. Вплив різних стресів на фотосинтезуючий апарат насамперед виявляється в концентрації хлорофілу. Це явище дозволяє розробляти методи прискореного визначення стресів у фітоценозі шляхом дистанційного вивчення концентрації хлорофілу і динаміки його зміни. Добре відомо, що спектр відображення листів рослин в оптичному діапазоні є самим інформативним щодо концентрації хлорофілу, оскільки він сформований завдяки специфічному спектрові самого пігменту. Крім того, ці спектри добре підходять для дистанційних вимірів.

Для оцінювання концентрації хлорофілу в листах рослин з різними спектральними

коефіцієнтами відображення існують вирази, що засновані на регресійних співвідношеннях та їх комбінаціях. Вони не дуже сильно розрізняються по своїй ефективності в лабораторних умовах, але проблеми виникають, як правило, коли необхідно оцінювати концентрацію хлорофілу для системи “земля – рослинність”. Головною причиною неточностей є вплив відображення від землі. Використання високоточної спектроскопії для дистанційного зондування рослинності дозволяє одержати додаткові характеристики, корельовані з концентрацією хлорофілу. Встановлено, що положення так званого «червоного краю» спектральних кривих і форма цієї спектральної області залежать від концентрації пігменту. У попередніх дослідженнях використовувались різні характеристики червоного краю спектра (680-800 нм), наприклад, положення максимуму на графіку першої похідної. У роботах [1; 2; 3] показано, що існує

регресійна залежність між положенням краю спектра відображення і положенням максимуму першої похідної. Існує також кореляційна залежність між відношенням двох максимумів першою похідною і концентрацією хлорофілу [4; 5].

У даній роботі використовується наведена вище інформація, заснована на існуванні кореляційних залежностей між концентрацією хлорофілу в рослинах і характеристиками спектральних кривих для аналізу і вибору структур нейромереж, що дозволять вирішити розглянуту задачу оцінювання.

Постановка задачі

На підставі отриманих спектральних даних $\{x(\lambda), \lambda = [\lambda_{\min}, \dots, \lambda_{\max}]\}$, на які впливають сигнали, що відображаються від поверхні землі, і шуми пристрою, що реєструє, $\{(\lambda, y)\}$ зі статистичними характеристиками $E[(\lambda, y)] = 0$, $E[2\lambda(y)] = \sigma_y^2$, $\sigma_y^2 \leq \zeta$, $\zeta > 0$, де ζ – відома додаткова скінченна величина. Головна мета, яка ставилася в даній роботі, – це знайти таку архітектуру нейронної мережі, що дозволяє визначати концентрацію хлорофілу і при цьому забезпечила б високу задану точність у заданому діапазоні значень $c = [c_{\min}, \dots, c_{\max}]$. Як вхідні ознаки бралися інтенсивність першої I_1 і другої I_2 компонент, перша похідна від спектрів відображення листів, як вихідна змінна y , бралася концентрація хлорофілу мг/дм^3 [6; 7].

Моделі нейронних мереж, які використовувались

З кінця 80-х років двадцятого сторіччя по дійсний час теорія нейронних мереж переживає різкий зріст кількості наукових публікацій. Головна перевага нейронних мереж – це те, що за їх допомогою можливо скільки завгодно точно апроксимувати будь-яку безперервну функцію та імітувати будь-який безперервний автомат. Дана проблема містить у собі визначення структури нейронної мережі і настроювання її параметрів – навчання, що

включає в себе визначення ефективності готової мережі [8; 9; 10]. В даний час існує достатня кількість ефективних методів навчання нейронних мереж і розроблені критерії оцінки, але не вирішена остаточно важлива проблема визначення архітектури мережі, тобто кількості і способу взаємної організації нейронів і їх вплив на якість рішення тієї або іншої задачі, у кращому випадку такі дослідження проводилися в рамках якоїсь однієї структури типу багат шарових перцептронів. З цієї причини було вирішено, крім рішення основної задачі (розробка архітектури нейронної мережі), досліджувати також вплив архітектури нейронної мережі на якість рішення даної задачі)

Для цього були відібрали лінійні мережі, тришарові і чотиришарові перцептрони, радіально-базисні мережі, узагальнено-регресійна нейронна мережа.

Лінійна модель була обрана нами як початковий пункт і являє собою нейронну мережу без проміжних шарів, що у вихідному шарі містить тільки лінійні елементи, тобто елементи з лінійною функцією активації. Рівень активації нейрона в такій функції передається на вихід у незмінному виді. Ваги відповідають елементам матриці, а пороги – компонентам вектора зсуву. Під час роботи мережа фактично множить вектор входів на матрицю ваг, а потім до отриманого вектора додає вектор зсуву.

Тришаровий і чотиришаровий перцептрони (*multi-layer perceptron* – MLP) були обрані з тієї точки зору, що (1) це найбільше часто використовувана архітектура нейронних мереж.

Багат шаровий перцептрон з одним схованим шаром реалізує наступну складну функцію:

де $W = \{w_{ij} : i = 1, \dots, p\}$ – ваги мережі; $f(\cdot)$ – нелінійні граничні функції, логістична $f(s) = 1 / (1 + e^{-as})$ або гіперболічний тангенс $f(e^{as} - e^{-as} / e^{as} + e^{-as})$.

Кожен елемент мережі буде зважену

суму своїх входів з виправленням у вигляді додатка і потім пропускає цю величину активації через передатну функцію, і в такий спосіб виходить вихідне значення цього елемента. Елементи організовані в пошарову топологію з прямою передачею сигналу. Таку мережу легко можна інтерпретувати як модель вхід-вихід, у якій ваги і граничні значення (зсуви) є вільними параметрами моделі. Така мережа може моделювати функцію практично будь-якого ступеня складності, причому число шарів і число елементів у кожному шарі визначають складність функції.

Під радіально-базисною мережею (RBF-Radial Basis Function Network) визначається двошарова мережа без зворотних зв'язків, що містить схований шар радіально симетричних схованих нейронів. Вихід j -го вихідного вузла описується наступним чином [11]:

де $g(x)$ – радіально симетрична функція (функція Гаусса). x_i – i -й центроїд, d_i – його ширина і W_{ij} – вага з'єднання між i -м схованим і j -м вихідним вузлами.

Вибираючи радіально-базисні мережі (RBF), ми виходили з того, що вони мають ряд переваг перед мережами-персептронами. По-перше, вони моделюють довільну нелінійну функцію за допомогою всього одного проміжного шару. По-друге, параметри лінійної комбінації у вихідному шарі можна цілком оптимізувати за допомогою добре відомих методів лінійного програмування, що працюють швидко і не випробують труднощів з локальними мінімумами, що заважають при навчанні багатшарових персептронів. Тому мережа RBF навчається дуже швидко (на порядок швидше MLP).

Узагальнено-регресійна мережа (Generalized regression Neural Network – GRNN) призначена для рішення задач регресії. Особливістю даної мережі є те, що в пункт розташування кожного навчального спостереження міститься гауссова ядерна

функція [12]. У даній мережі кожне спостереження свідчить про деякий ступінь впевненості в тому, що поверхня відгуку в даній крапці має визначену висоту, і ця впевненість убуває при відході убик від крапки. GRNN-мережа копіює усередину себе всі навчальні спостереження і використовує їх для оцінки відгуку в довільній крапці. Остання вихідна оцінка мережі виходить як зважене середнє виходів по всіх навчальних спостереженнях:

де X^k, y^k – пункти навчальної вибірки.

Перший проміжний шар GRNN складається з радіальних елементів. Другий проміжний шар містить елементи, що допомагають оцінити зважене середнє. Кожен вхід має в цьому шарі свій елемент, що формує для нього зважену суму. Для того, щоб одержати зі зваженої суми зважене середнє, ця сума поділяється на суму вагових коефіцієнтів. Останню суму обчислює спеціальний елемент другого шару. Після цього у вихідному шарі виробляється розподіл за допомогою спеціальних елементів розподілу. Число елементів у другому проміжному шарі на одиницю більше, ніж у вихідному шарі. Як правило, у задачах регресії потрібно оцінити одне вихідне значення, і, відповідно, другий проміжний шар містить два елементи. Головною перевагою даної мережі є її швидке навчання, а до недоліків відносять їх обсяг.

Методи оцінки роботи мереж

Досліджувана вибірка випадковим способом була розбита на дві множини: навчальне 70%, тестове 21%.

Для оцінки якості роботи досліджуваних нейронних мереж використовувалася середньоквадратична помилка E (MSE –

Mean Squared Error), обумовлена як усереднена на P прикладах сума квадратів різностей між бажаною величиною виходу $d_i \in D$ і реально отриманими на мережі значеннями $y_i \in Y$ для кожного прикладу i (4):

$$\bar{\sigma} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2}. \quad (5)$$

Як інший показник, що дозволяє оцінити якість роботи досліджуваної мережі, – відношення стандартних відхилень (S.D. Ratio). Відношення стандартного відхилення помилки прогнозу до стандартного відхилення вхідних та вихідних даних,

кожен з яких визначався за формулою (5). Чим менше відношення, тим вище точність прогнозу.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{(n-1) \sigma_x^2 \sigma_y^2}}, \quad (6)$$

Як третій показник, що дозволяє оцінити якість роботи нейронної мережі, був використаний стандартний коефіцієнт Пірсона між фактичною та прогнозованою змінними, що обчислюється за формулою (6). Коефіцієнт кореляції є гарним показником роботи нейронної мережі – зроблене прогнозування буде дорівнювати 1,0.

Таблиця 1

Показники оцінки якості роботи мереж різних архітектур з використанням у якості вхідних змінних першої I_1 і другої I_2 компонент першої похідної від спектрів відображення листів

		S.D.Ratio Tr. Віднош. станд. відхилень	S.D.Ratio Te. Віднош. станд. відхилень	RMS Error Tr. Середньоквадратична помилка	RMS Error Te. Середньоквадратична помилка	Correlation Tr. Коефіцієнт кореляції	Correlation Te. Коефіцієнт кореляції
Linear	2-1	0.7263	0.3495	1.232	0.0686	0.6874	0.9571
MLP	2-3-1	0.4717	0.3185	0.8	0.8916	0.8823	0.9881
MLP	2-8-7-1	0.5211	0.1701	0.8874	0.6815	0.8586	0.9855
RBF	2-1-1	0.8369	0.9033	1.419	1.286	0.5473	0.9032
GRNN	2-12-2-1	0.3022	0.9478	0.5126	1.5553	0.9579	0.9478
MLP	2-7-1	0.5195	0.2021	0.8817	0.686	0.8691	0.9921



Рис. 1. Лінійна мережа з двома вхідними елементами I_1 і I_2




Рис. 2. Тришаровий перцептрон із двома вхідними елементами I_1 і I_2




Рис. 3. Чотиришаровий перцептрон із двома вхідними елементами I_1 і I_2




Рис. 4. Радіально-базисна мережа з двома вхідними елементами I_1 і I_2




Рис. 5. Узагальнено-регресійна нейронна мережа з двома вхідними елементами I_1 і I_2




Рис. 6. Тришаровий перцептрон із двома вхідними елементами I_1 і I_2

Грунтуючись на ідеях, запозичених з роботи [13], нами були проведені дослідження для підвищення адекватності нейроматематичних моделей, результати яких дозволяють стверджувати, що цього можна досягти побудовою нейромережових структур із синтезом додаткових входів, що є функціональним породженням основних входів.

Були запропоновані як додаткові входи значення, що є відносинами інтенсивності першої I_1 і другої компонент I_2 першої

похідній від спектрів відображення листів ($I_1/I_2, I_2/I_1$), а також різниця по модулі даних компонентів $|I_1 - I_2|$.

$$X^{input} = \{x_i^{input}\} = \left\{ \left\langle I_1, I_2, \frac{I_1}{I_2}, \frac{I_2}{I_1}, |I_1 - I_2| \right\rangle_i \right\}; \quad (7)$$

$$X^{output} = \{x_i\} = \langle c \rangle_i; \quad (8)$$

$$x_i^{input} = \left\{ \left\langle I_1, I_2, \frac{I_1}{I_2}, \frac{I_2}{I_1}, |I_1 - I_2| \right\rangle_i \right\} \longrightarrow X^{output} = \langle c \rangle_i. \quad (9)$$

Результати нейроматематичного моделювання структур нейронних мереж із

Таблиця 2

Показники оцінки якості роботи мереж різних архітектур з використанням у якості вхідних змінних першої I_1 і другої I_2 компонент першої похідної від спектру відображення, а також разом з додатково синтезованими входами: $I_1 / I_2, I_2 / I_1$ і $I_1 -$

		S.D.Ratio Tr. Відн. станд. відхиленнь	S.D.Ratio Te. Відн. станд. відхиленнь	RMS Error Tr. Середньоквадратична помилка	RMS Error Te. Середньоквадратична помилка	Correlation Tr. Коефіцієнт кореляції	Correlation Te. Коефіцієнт кореляції
Linear	5-1	0.5954	0.3887	1.01	1.137	0.8034	0.9671
MLP	5-2-1	0.5408	0.2781	0.9172	0.5785	0.8411	0.9614
MLP	5-20-13-1	0.5268	0.4172	0.902	0.5521	0.8596	0.9089
RBF	5-3-1	0.7000	0.4394	1.187	0.8465	0.7141	0.9335
GRNN	5-12-2-1	0.2845	0.3547	0.4828	1.373	0.9608	0.935
MLP	5-8-1	0.5619	0.9816	0.9529	0.6603	0.8283	0.9816

Відомо, що питання вибору найбільш ефективних вхідних даних є найбільш важким при нейроматематичному моделюванні і створенні архітектур нейронних мереж. Вважається, що єдиним способом, який дозволяє одержати повну гарантію, що вхідні дані обрані щонайкраще, полягає в тому, щоб перепробувати всі можливі варіанти вхідних наборів даних і архітектур мереж і вибрати з них найкращі. При рішенні даної задачі ми скористалися методиками, описаними в роботі [14], застосувавши для добору ефективного сполучення вхідних ознак генетичний алгоритм. У результаті проведених експериментів були відібрані вхідні перемінні $I_1/I_2, I_2/I_1$ і відповідні вирази

$$(7),$$

$$(8), X^{input} = \{x_i^{input}\} = \left\{ \left\langle I_1, I_1/I_2, I_2/I_1 \right\rangle_i \right\}; \quad (10)$$

$$(9)$$

тепер можна представити як (10), (11),

$$(12): X^{output} = \{x_i\} = \left\langle c \right\rangle_i; \quad (11)$$

$$x_i^{input} = \left\{ \left\langle I_1, I_1/I_2, I_2/I_1 \right\rangle_i \right\} \longrightarrow X^{output} = \left\langle c \right\rangle_i. \quad (12)$$

Після визначення відповідного сполучення вхідних даних були проведені подальші експерименти по пошуку

Таблиця 3

Показники оцінки якості роботи мереж різних архітектур з використанням у якості вхідних перемінних $I_1, I_1 / I_2$ і I_2 / I_1

		S.D.Ratio Tr. Відн. станд. відхиленнь	S.D.Ratio Te. Віднош. станд. відхиленнь	RMS Error Tr. Середньоквадратична помилка	RMS Error Te. Середньоквадратична помилка	Correlation Tr. Коефіцієнт кореляції	Correlation Te. Коефіцієнт кореляції
MLP	3-7-1	0.8038	0.9224	1,305	1,898	0.6449	0.4235
MLP	3-71-1	0.5257	0.4695	1.009	0.8634	0.9073	0.8830
RBF	3-10-1	0.1143	0.6899	0.1812	0.0849	0.9934	0.7278
MLP	3-1-1	0.6745	0.8918	1.396	1.171	0.7383	0.4792
MLP	3-4-1	0.4707	1.6741	0.6918	1.64	0.9268	-0.0953
GRNN	3-12-3-1	0.4065	0.5540	0.79	0.8849	0.9156	0.8597
LINEAR	3-1	0.5882	0.5903	1.051	0.6803	0.8087	0.8152
RBF	3-23-1	1.229e-14	1.9328	2.652e-14	3.048	1	0.2017

Як видно з таблиці 3, найбільш ефективними архітектурами виявилися: узагальнено регресійна мережа зі структурою 3-12-3-1, на другому місці

можна поставити тришаровий перцептрон із структурою 3-71-1 і на третьому місці виявилася лінійна мережа зі структурою 3-1.

Таблиця 4

Показники оцінки відібраних найбільш ефективних нейронних мереж з різними архітектурами

		S.D.Ratio Tr. Відн. станд. відхиленнь	S.D.Ratio Ve Відн. станд. відхиленнь	S.D.Ratio Te. Віднош. станд. відхиленнь	RMS Error Tr. Середньоквадратична помилка	RMS Error Ve Середньоквадратична помилка	RMS Error Te. Середньоквадратична помилка	Correlation Tr. Коефіцієнт кореляції	Correlation Ve Коефіцієнт кореляції	Correlation Te. Коефіцієнт кореляції
κLP	2-3-1	0.4717	0.3385	0.3185	0.8	0.7452	0.8916	0.8823	0.9562	0.9881
MLP	2-8-7-1	0.5211	0.2567	0.1701	0.8874	0.6583	0.6815	0.8586	0.9692	0.9855
MLP	2-7-1	0.5195	0.3373	0.2021	0.8817	0.7567	0.686	0.8691	0.9581	0.9921
MLP	5-2-1	0.5408	0.2663	0.2781	0.9172	0.5785	0.7161	0.8411	0.9652	0.9614
MLP	5-20-13-1	0.5268	0.2608	0.4172	0.902	0.5521	0.9413	0.8596	0.9665	0.9089
GRNN	5-12-2-1	0.2845	0.6298	0.3547	0.4828	1.373	0.5646	0.9608	0.8201	0.935
MLP	3-71-1	0.5257	0.6822	0.4695	1.009	1.149	0.8634	0.9073	0.7437	0.8830
GRNN	3-12-3-1	0.4065	0.4013	0.5540	0.79	0.6043	0.8849	0.9156	0.9547	0.8597
LINEAR	3-1	0.5882	0.3965	0.5903	1.051	0.9845	0.6803	0.8087	0.9465	0.8152

Відповідно до обраних критеріїв ефективності роботи нейронних мереж з відповідними вхідними перемінними нами було відібрано по три найбільш ефективні нейронні мережі з відповідними вхідними перемінними (рис. 7).




Рис. 7. Найкращі архітектури нейронних мереж з 2-ма, 5-ма і 3-ма входами

Аналізуючи отримані результати, відповідно до використовуваних критеріїв, можна дійти висновку, що синтез додаткових входів не дав очікуваних результатів.

З даної причини було знову застосовано для зменшення кількості вхідних змінних генетичний алгоритм, результати використання якого дали підстави стверджувати про використання

Таблица 5

Оцінки нейронних мереж із вхідними змінними I_1 і I_1/I_2

		S. D. Ratio Te.	RMS Error Te.	Correlation Te.
LINEAR*	2-1	0.3278	0.8067	0.9499
MLP*	2-1-1	0.5089	1.136	0.9000
MLP*	2-13-1	0.6036	1.011	0.8345
MLP*	2-13-13-1	0.6734	1.646	0.8007
RBF*	2-6-1	1.7629	1.368	0.3960
GRNN*	2-12-2-1	0.9940	1.06	0.8121

Далі нами були проведені експерименти по синтезу архітектур нейронних мереж з єдиними входами: I_1 і I_1/I_2 (табл. 6. і 7).

Таблиця 6

Показники оцінки роботи мереж при використанні в якості вхідної змінної значень інтенсивності першої I_1 компоненти першої похідної від спектрів відображення

		S.D.Ratio Te.	RMS Error Te.	Correlation Te.
MLP*	1-13-13-1	0,7391	0,8969	0,7057
GRNN**	1-12-2-1	0,7758	1,176	0,7255
MLP**	1-20-20-1	0,7945	1,835	0,7627
LINEAR**	1-1	0,9899	2,559	0,1458
RBF**	1-3-1	1,0046	2,407	0,0061
MLP**	1-8-1	1,0392	2,717	-0,1261
MLP**	1-8-8-1	1,1019	1,317	-0,2006

Таблиця 7

Показники оцінки роботи мереж при використанні в якості вхідної змінної відношень значень інтенсивності першої I_1 і другої I_2 компонент першої похідної від спектрів відображення

		S.D.Ratio Te.	RMS Error Te..	Correlation Te.
MLP***	1-20-1	0,4224	0,8758	0,9274
MLP***	1-20-17-1	0,4516	0,7925	0,8934
MLP***	1-31-31-1	0,6184	2,054	0,7864
MLP***	1-47-1	0,8343	1,873	0,8242
GRNN***	1-12-2-1	0,8451	2,845	0,5404
LINEAR***	1-1	1,3645	1,861	-0,2036
RBF***	1-6-1	2,2925	5,25	0,9220

Сумарні результати оцінки роботи найкращих нейронних мереж представлені в табл. 8 і 9.

Таблиця 8

Сумарна таблиця оцінки архітектур нейронних мереж при використанні в якості вхідних перемінних різних сполучень I_1 і I_1/I_2

	Correlation Te.	S.D.Ratio Te.	RMS Error Te.	Correlation Te.
LINEAR*	2-1	0,3278	0,8067	0,9499
MLP***	1-20-1	0,4224	0,8758	0,9274
MLP***	1-20-17-1	0,4516	0,7925	0,8934
MLP*	2-1-1	0,5089	1,136	0,9000
MLP*	2-13-1	0,6036	1,011	0,8345
MLP***	1-31-31-1	0,6184	2,054	0,7864
MLP*	1-13-13-1	0,7391	0,8969	0,7057
GRNN**	1-12-2-1	0,7758	1,176	0,7255
MLP**	1-20-20-1	0,7945	1,835	0,7627

*- I_1 і I_1/I_2 ; ** - I_1 ; *** - I_1/I_2 .

Таблиця 9

Результати тестування деяких архітектур нейромереж

	Correlation Te. Коефіцієнт кореляції	S.D.Ratio Te. Відн. станд. відхилень	RMS Error Te. Середньоквадратична помилка	Correlation Te. Коефіцієнт кореляції
MLP	2-8-7-1	0,1701	0,6815	0,9855
MLP	2-7-1	0,2021	0,686	0,9921
MLP	2-3-1	0,3185	0,8916	0,9881
LINEAR*	2-1	0,3278	0,8067	0,9499
MLP***	1-20-1	0,4224	0,8758	0,9274
MLP***	1-20-17-1	0,4516	0,7925	0,8934

Висновки

1. Експериментально встановлено, що для дистанційного визначення концентрації хлорофілу в листах рослин на основі даних вимірів характеристик спектра відображення рослинного покриву доцільно використовувати нейронні мережі.
2. Результати експериментальних досліджень показали неефективність застосування методики синтезу додаткових входів при застосуванні нейронних мереж для оцінки концентрації хлорофілу.
3. В основу нейроматематичного моделювання при визначенні концентрації хлорофілу доцільно використати нейронні мережі з двома входами, при цьому як входи

Література

1. Demetriodes-Shan T.H., Steven M.D., Clark J.A. High resolution derivative spectra in remote Sensing // Rem. Sens. Envir. – 1993. – V. 33. – P. 55-64.
2. Kochubey S.M., Kobets N.I., Shadchina T.M.. The quantitative analysis of shape of spectral reflectance curves of plant leaves as a way for testing their status // Physiology and biochemistry of cultivated plants. – 1988. – V. 20. – P. 535-539.
3. Кочубей С.М., Кобець Н.И., Шадчина Т.М. Спектральні властивості рослин як базис для дистанційних методів діагностики. – Київ: Наукова думка, 1990. – 260 с.
4. Kochubey S.M. Comparative analysis of information power of multispectral imaging and high-resolution spectrometry in the remote sensing of vegetation cover // Space Sciences and Technology. – 1999. – V. 5. – P. 41-48.
5. Arnon D.I. Copper enzymes in isolated chloroplasts. Polyphenoloxidase in Beta vulgaris Plant Physiol. – 1949. – V. 24. – P. 1-15.
6. Кондратьев К.Я. Досвід використання спектрів відображення для розпізнавання сільськогосподарських культур // Дослідження землі з Космосу. – 1982. – № 11. – С. 976- 978.
7. Бідюк П.І., Баклан І.В., Митник О.В., Литвиненко В.І. Оцінювання хлорофілу в рослинності на основі спектрального аналізу // Стан та перспективи новітніх науково-освітніх комп'ютерних технологій: Матеріали науково-практичної конференції. – Миколаїв: МДГУ ім. Петра Могили, 2003. – С. 62-65.
8. Горбань А.Н., Дунин-Барковский В.Л., Кирдин А.Н. Нейроинформатика. – Новосибирск: Наука, 1998.
9. Тютюрев В.В., Новосельцев В.Б. Дослідження алгоритму автоматичної побудови нейронної мережі // Дослідження з аналізу й алгебри. – Томськ: Томський державний університет, 2001. – № 3. – С. 269-281.
10. Тютюрев В.В. Новосельцев В.Б. Метод автоматичного нарощування вузлів як спосіб побудови нейронної мережі // Нейрокомп'ютери: розробка, застосування. – М.: Радіотехніка, 2001. – № 2. – С. 3-8.
11. Дудник О.В., Бідюк П.І. Застосування радіальних базисних функцій у нейронних мережах для прогнозування економічних показників // Проблеми керування й інформатики. – 2003. – № 2. – С. 126-133.
12. Werbos, P.J Beyond regression: new tools for prediction and analysis in the behavioral sciences. Ph.D. Thesis. – Boston, MA: Harvard University, 1974. – 227 p.
13. Данилюк О.В., Батюк Н.Б., Андрощук О.В. Моделювання технологічних витрат електричної енергії в енергопостачальних компаніях на основі штучної нейронної мережі із синтезом додаткових входів // Вісник національного університету «Львівська політехніка». – № 418. – С. 43-49.
14. Нейронные сети. STATISTICA Neural Networks / Пер. с англ. – Москва: Горячая линия – Телекому, 2000. – 182 с.