

фітопатогену комплексне застосування препаратів Біопополіцид + Фосфоентерин.

Наявність рослини у ґрунті суттєво підвищила ефективність біологічних препаратів, тоді як на хімічний протруйник це не мало істотного впливу.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. Шерстобоева Олена Володимирівна. Оптимізація структури мікробних угруповань кореневої зони озимої пшениці: Дис... д-ра с.-г. наук: 03.00.16. – К., 2004. – 337 с.
2. Агроекологія /Под ред. В.А. Черникова и А.И. Чекереса. – М.: Колос, 2000. – 536 с.
3. Биорегуляция микробно-растительных систем: Монография / Иутинская Г.А., Пономаренко С.П., Андреюк Е.И. и др. под ред. Г.А. Иутинской, С.П. Пономаренко. – К.: Ничлава, 2010. – 464 с.
4. И.И. Новикова, А.И. Литвиненко Биологическая эффективность биопрепаратов на основе микробов-антагонистов против корневых гнилей огурца и вилта земляники и их влияние на видовой состав микромицетов почвы// Вестник защиты растений №2, 2011 с. 10 – 22.
5. Експериментальна ґрунтова мікробіологія: монографія / В.В. Волкогон, О.В. Надкернична, Л.М. Токмакова, Т.М. Мельничук, Л.О. Чайковська; за наук. Ред.. В.В. Волкогона. – К.: Аграр. наука, 2010.–464 с.

УДК: 631.67:91:681.518:504.38

МЕТОДИКА ПРОСТРАНСТВЕННО-ВРЕМЕННОГО МОДЕЛИРОВАНИЯ АГРОХИМИЧЕСКИХ ПОКАЗАТЕЛЕЙ МЕЛИОРИРУЕМЫХ ПОЧВ С ИСПОЛЬЗОВАНИЕМ ГИС И НЕЙРОТЕХНОЛОГИЙ

Пичура В.И. – к.с.-х.н, доцент, Херсонский ГАУ

Постановка проблеми. Методы пространственно-временного прогнозирования агрохимического состояния мелиорируемых почв в данный период требуют более широкого использования и профессиональных знаний относительно принципов и методологических подходов их использования. Верно подобранный метод моделирования и прогнозирования позволяет быстро и достоверно оценить тенденцию развития исследуемых показателей плодородия мелиорируемых почв. Поэтому важно уметь оперировать соответствующими современными методами, методиками и инструментами сбора данных, исследования, моделирование и прогнозирование в системе эколого-агромелиоративных мониторинга (ЭАММ) для принятия рациональных управленческих агрохимических решений. Прогнозирование является одним из важных научных этапов создания стратегии и тактики развития земледелия в целом.

Важным основанием моделирования агрохимических показателей мелиорируемых почв являются временные, генетические характеристики изучаемых комплексных процессов, которые рассматриваются как пространственно-временные образования в границах определенных территориальных единиц (участок, поле, хозяйство, сельский совет, район, область и т.д.).

Цель работы – разработать методику системного использования ГИС и нейротехнологий для пространственно-временного моделирования агрохимических показателей мелиорируемых почв в системе эколого-агромелиоративного мониторинга.

Объект исследований – агрохимическое состояние мелиорируемых почв Херсонской области. Предмет исследований - показатели агрохимического состояния мелиорируемых почв.

Методология и методика исследований. В методике нейросетевые модели рассматриваются, как универсальный аппроксиматор нелинейных функций для временного прогнозирования агрохимических показателей мелиорируемых почв и получения конечного набора значения для их пространственного моделирования с применением геостатистических методов. В отличие от «традиционных» методов временного прогнозирования, нейросети выдают не статистически достоверное, а правдоподобное решение задачи и могут применяться при недостатке эмпирических данных.

Методика пространственно-временного моделирования агрохимического состояния мелиорируемых почв состоит из трех основных этапов (рис. 1): *подготовка данных* - создание атрибутивной реляционной базы данных; *обработка данных* - прогнозирование с помощью нейронных сетей; *визуализация данных* - пространственное моделирование с применением методов и инструментов ГИС-технологий.




Рисунок 1. Основные этапы подготовки данных и пространственно-временного моделирования показателей агрохимического состояния мелиорируемых почв

На первом этапе формируется атрибутивная реляционная база данных (РБД) за показателями плодородия почв путем систематизации исходных экспериментальных данных в табличной форме за стационарами мониторинговых исследований.

На втором этапе реализуется процесс идентификации и эксплуатации нейронных сетей (НС) для временного прогнозирования, который состоит с восьми этапов:

а) *Определение входных и целевых (выходных) эмпирических данных*, на которых обучится нейронная сеть, обучение происходит с «учителем», т.е. входной и выходной сигнал является идентичным.

б) *Формирование обучающей, контрольной и тестовой выборки*. Наилучшее качество прогноза многослойной нейронной сети достигается при соотношении объемов выборок: обучающая – 50%, контрольная – 25%, тестовая – 25% от временного ряда исследований. Точность результатов прогнозирования зависит, в значительной мере, от репрезентативности обучающей выборки.

в) *Выбор архитектуры нейросети и функции активации нейронов*.

Многослойный перцептрон (MLP) имеет некоторое преимущество перед другими типами НС, оно заключается в том, что MLP определяет природу развития исследуемых объектов и систем на сравнительно небольших обучающих выборках с достаточно высокой достоверностью.

При создании многослойной нейронной сети для прогнозирования агрохимических показателей мелиорируемых почв хорошо зарекомендовали себя функции активации нейронов – сигмоидальная и синусоид-гиперболического тангенса (табл. 1).

Таблица 1 - Функции активации нейронов

Название функции	Формула	Область значений
Сигмоидальная (логистическая)	$f(s) = \frac{1}{1 + e^{-s}}$	(0, 1)
Синусоид-гиперболического тангенса	$f(s) = \frac{e^s - e^{-s}}{e^s + e^{-s}}$	(-1, 1)

г) *Выбор метода оценки, интерпретатора ответов, метода оптимизации и определение их параметров*. После определения архитектуры НС задаются, случайным образом равномерно в интервале [-0.01, 0.01], весовые коэффициенты адаптивных сумматоров нейронов, далее определяется метод обучения НС.

В качестве метода оптимизации используются методы: обратное распределение ошибки, метод сопряженных градиентов, Квази-Ньютоновский, Левенберга-Маркара (Маркуордта), быстрого распределения, дельта-дельта-с-чертой.

Для корректировки ошибки НС используется метод наименьших квадратов [1]:

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{jpn} - d_{jp})^2 \quad (1)$$

где y_{jpn} – выходное состояние j -го нейрона слоя n НС при подаче на ее входы p -го обучающего образа; d_{jp} – желаемое выходное состояние этого нейрона.

Наиболее распространенный алгоритм обучения для прогнозирования временных рядов – это алгоритм обратного распространения:

$$w_{ni}(t+1) = \eta \delta_i x_n(t) + \alpha (w_{ni}(t) - w_{ni}(t-1)) \quad (2)$$

где $w_{ni}(t)$ – вес от нейрона n или от элемента входного сигнала n к нейрону i в момент времени t ; x_n – выход нейрона n или n -й элемент входного сигнала; η – коэффициент скорости обучения; α – коэффициент инерции; δ_i – значение ошибки для нейрона i .

В этом алгоритме ошибка (разность между значениями вычисленного и фактического выходных векторов) распространяется в обратном направлении внутри НС и используется для модификации каждого веса на следующей итерации (эпохе) [2].

д) *Определение условий остановки обучения сети.* Остановка процесса обучения происходит при выполнении одного из условий: ошибка сети на обучающей выборке, полученная с помощью выбранного метода оценки, не превышает заданный уровень; уменьшение ошибки сети не превышает заданного значения. Нейросеть считается обученной после достижения заданного (малого) значения функции оценки [1].

е) *Обучение нейросети.* Происходит непосредственное обучение нейросети по ранее заданным параметрам.

ж) *Определение критериев выбора лучшей нейросети.* Осуществляют качественную оценку созданных нейромоделей путем анализа возможности обобщения результатов исследований, уровня чувствительности НС, сравнения эмпирических и аппроксимирующих данных за статистическими критериями.

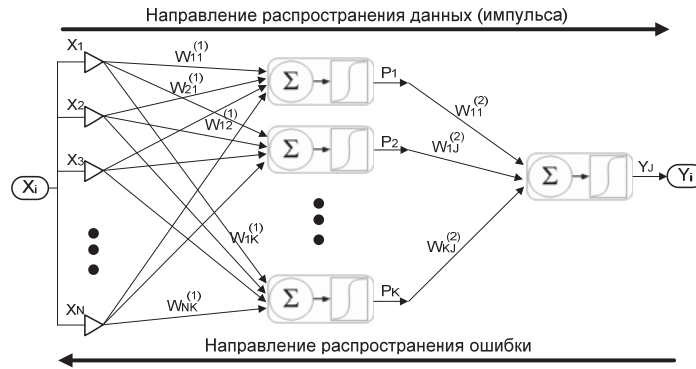
з) *Аппаратная реализация (идентификация) и использование нейросетевой модели для прогнозирования временных рядов.* Аппаратная реализация ИНС с однозначно задаваемой структурой (в зависимости от количества входов) и нейроном максимально соответствующим биологическому прототипу задается архитектурой и функцией нескольких переменных с помощью суперпозиций и сумм функций одной переменной (рис. 2) [3-7].

Далее осуществляется прогнозирование агрохимических показателей мелиорируемых почв и формируются базы данных (фактические и предсказанные данные) за стационарами мониторинговых исследований, которая импортируется в ГИС-приложение для построения картограмм (тематических карт).

На третьем этапе реализуется пространственное моделирование агрохимического состояний мелиорируемых почв с помощью инструментов и методов ГИС-технологий, что включает:

а) *Создание с помощью ГИС-программы (ArcGIS) пространственно-координированных векторных моделей стационаров мониторинговых площадок (тип объектов «точечный») с границами исследуемых территорий (тип объектов «полигон») на основе топографических съемок.* Географическая система координат - WGS 1984. Векторная информация хранится в отдельном слое, тип файла – «*.shp».

б) *Присвоение дискретных атрибутивных данных (фактические и прогнозные данные) за агрохимическими показателями мелиорируемых почв стационарам мониторинговых исследований в Attribute Table shp-файла.*



$$y_i(t) = f\left(\sum_{j=1}^J w_j^{(2)}(t) f\left(\sum_{n=1}^N w_n^{(1)}(t) x_n^{(t)}\right)\right)$$

2

где t – дискретное значение временного ряда; w – матрица весовых коэффициентов; $x_n^{(t)}$ – n -я координата входного вектора в определенный момент времени t ; $y_i(t)$ – i -я координата выходного вектора созданная нейросетью в определенный момент времени t ; $d_i^{(t)}$ – i -я координата фактического выходного вектора в определенный момент времени t ; $f(\cdot)$ – функция активации нейронов скрытого слоя

Рисунок 2. Аппаратная реализация (идентификация) ИНС:
1 – архитектура ИНС; 2 – функция отклика ИНС

в) *Создание тематических цифровых моделей* путем построения и оценки непрерывных интерполяционных пространственных моделей с помощью геостатистических методов: *глобального и локального полиномов, радиально-базисной функции, кригинг, кокригинг* [8].

Создание интерполяционной модели включает три основных этапа: *исследование данных* – определение оптимального метода для построения интерполяционной поверхности агрохимического состояния мелиорируемых почв; *подбор модели для построения интерполяционной поверхности* – настройка критериев выбранного метода для построения интерполяционной поверхности с учетом пространственных закономерностей развития агрохимических показателей; *диагностика пространственных моделей* – реализуется перекрестная проверка, которая дает возможность принять обоснованное решение о том, которая из моделей наиболее точно интерполирует значение.

г) *Идентификация пространственной непрерывной информации в виде картограмм (тематические карты)* – определяется шкала тематической раскраски за показателями группировки агрохимического состояния мелиорируемых почв и отображается пространственное изменение расчетного признака по данной территории для пространственно-временной оценки.

Основные этапы пространственно-временного моделирования агрохимического состояния мелиорируемых почв с использованием методов ГИС и нейротехнологий представлены на рис. 3.

Результаты исследований. Для прогнозирования агрохимического состояния мелиорируемых почв Херсонской области, с применением модуля Statistics Neural Networks (SNN) программного продукта STATISTICA 6.0 были созданы нейромодели архитектуры трехслойный перцептрон - *MLP*:

- для прогнозирования содержания гумуса в пахотном слое – 0-40см: трехслойный перцептрон с тринадцатью нейронами в скрытом слое, метод обучения: обратное распределение (100 эпох) и связанных градиентов (20 и 335 эпох), матрица искусственной нейронной сети состоит из 2275 весовых коэффициентов:

$$\text{функция коррекции весовых коэффициентов: } E(w(t)) = \frac{1}{2} \left(\sum_{i=1}^{25} (f(\sum_{j=1}^{13} w_j^{(2)}(t)) f(\sum_{n=1}^{150} w_n^{(1)}(t) x_n^{(t)}) - d_i^{(t)})^2 \right) \quad (3)$$

$$\text{функция отклика сети: } y_i(t) = f\left(\sum_{j=1}^{13} w_j^{(2)}(t) f\left(\sum_{n=1}^{150} w_n^{(1)}(t) x_n^{(t)}\right)\right), \text{ где } i = \overline{1, 25} \quad (4)$$

$$\text{параметры алгоритма обучения: } \eta = 0,02; \alpha = 0,7$$

$$\text{алгоритм обучения } w_{ni}(t+1) = 0,02\delta_i x_n(t) + 0,7(w_{ni}(t) - w_{ni}(t-1)) \quad (5)$$

- для прогнозирования содержания обменного калия в пахотном слое – 0-40см: трехслойный перцептрон с двенадцатью нейронами в скрытом слое, метод обучения: обратное распределение (100 эпох) и связанных градиентов (20 и 596 эпох), матрица искусственной нейронной сети состоит из 1800 весовых коэффициентов:

$$\text{функция коррекции весовых коэффициентов: } E(w(t)) = \frac{1}{2} \left(\sum_{i=1}^{25} (f(\sum_{j=1}^{12} w_j^{(2)}(t)) f(\sum_{n=1}^{125} w_n^{(1)}(t) x_n^{(t)}) - d_i^{(t)})^2 \right) \quad (6)$$

$$\text{функция отклика сети: } y_i(t) = f\left(\sum_{j=1}^{12} w_j^{(2)}(t) f\left(\sum_{n=1}^{125} w_n^{(1)}(t) x_n^{(t)}\right)\right), \text{ где } i = \overline{1, 25} \quad (7)$$

$$\text{параметры алгоритма обучения: } \eta = 0,2; \alpha = 0,5$$

$$\text{алгоритм обучения } w_{ni}(t+1) = 0,2\delta_i x_n(t) + 0,5(w_{ni}(t) - w_{ni}(t-1)) \quad (8)$$

- для прогнозирования содержания подвижного фосфора в пахотном слое – 0-40см: трехслойный перцептрон с одиннадцатью нейронами в скрытом слое, метод обучения: обратное распределение (100 эпох) и связанных градиентов (20 и 472 эпохи), матрица искусственной нейронной сети состоит из 1650 весовых коэффициентов:

$$\text{функция коррекции весовых коэффициентов: } E(w(t)) = \frac{1}{2} \left(\sum_{i=1}^{25} (f(\sum_{j=1}^{11} w_j^{(2)}(t)) f(\sum_{n=1}^{125} w_n^{(1)}(t) x_n^{(t)}) - d_i^{(t)})^2 \right) \quad (9)$$

$$\text{функция отклика сети: } y_i(t) = f\left(\sum_{j=1}^{11} w_j^{(2)}(t) f\left(\sum_{n=1}^{125} w_n^{(1)}(t) x_n^{(t)}\right)\right), \text{ где } i = \overline{1, 25} \quad (10)$$

$$\text{параметры } \eta = 0,05; \alpha = 0,6$$

алгоритма
обучения:

алгоритм обучения $w_{ni}(t+1) = 0,05\delta_i x_n(t) + 0,6(w_{ni}(t) - w_{ni}(t-1))$ (11)

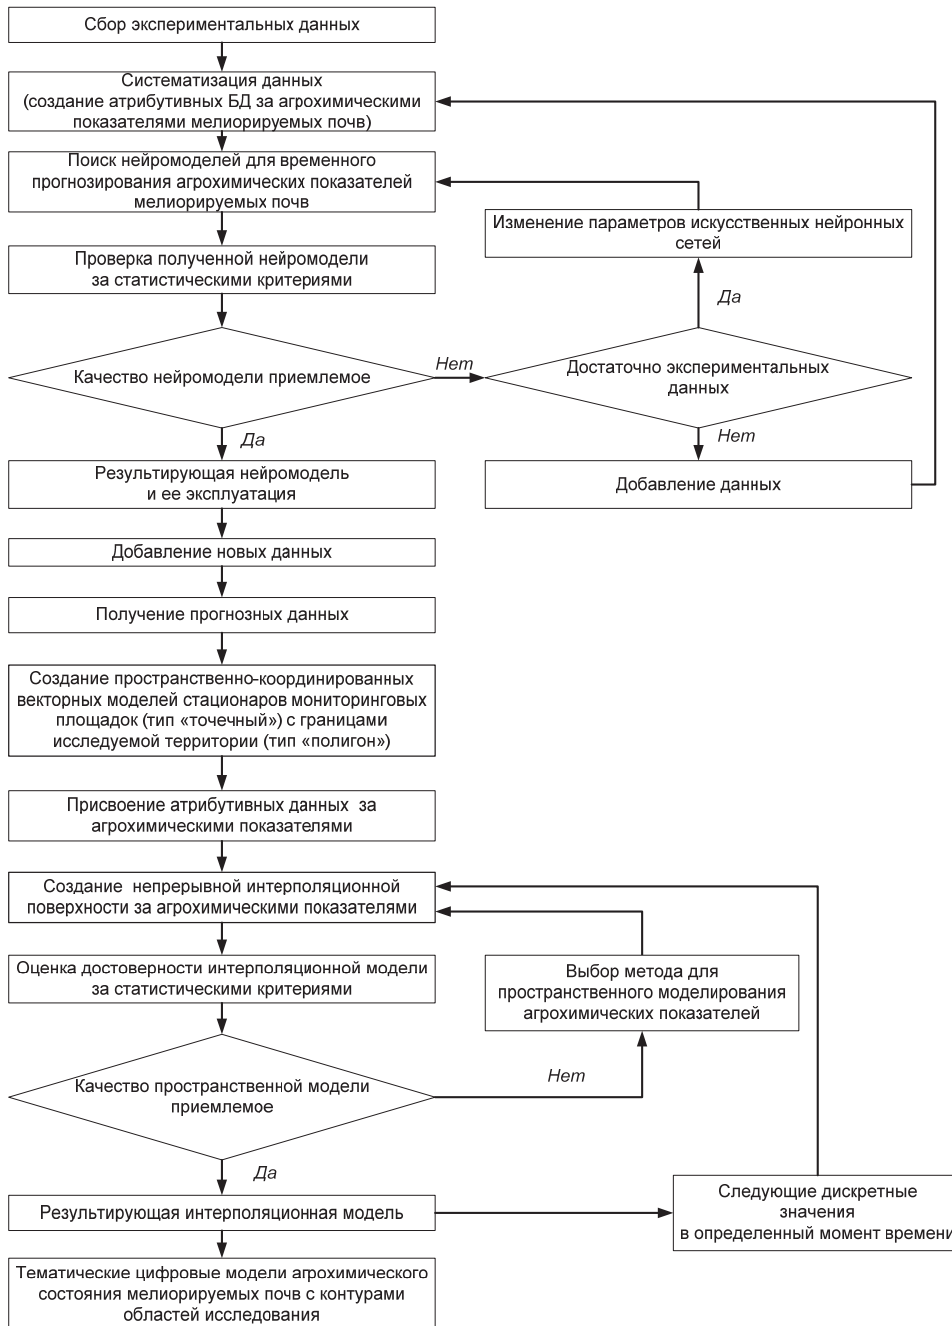


Рисунок 3. Алгоритм пространственно-временного моделирования

агрохімічного стану меліоруваних ґрунтів з використанням методів ГІС і нейротехнологій (розробка автора)

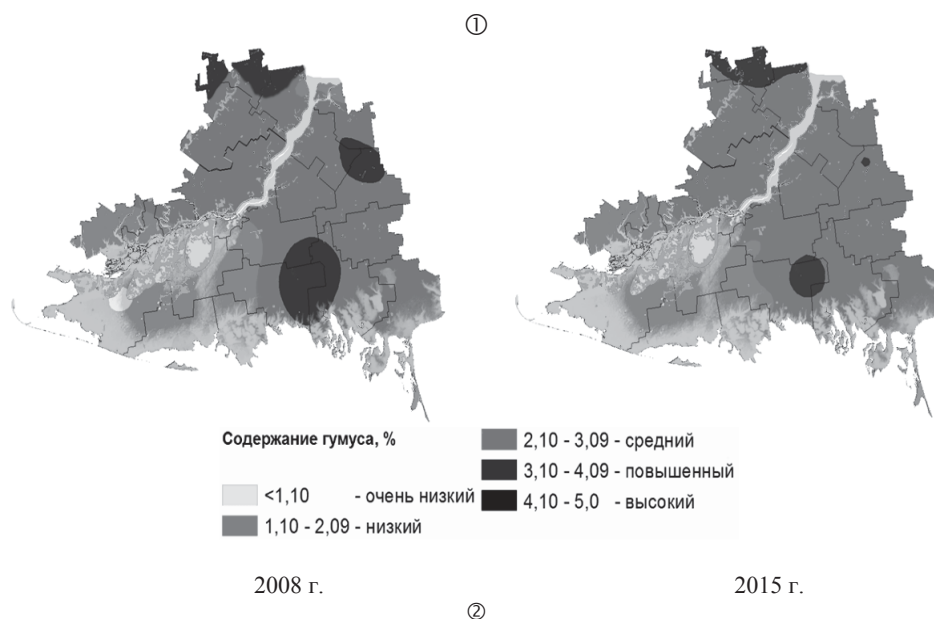
В результаті тестування на контрольних незалежних експериментальних вибірках створені нейромоделі показали достаточну високу апроксимаційну здатність. Достовірність ІНС архітектури MLP була визначена за формулою:

$$D = \frac{\sum_{j=1}^n \left(1 - \left| \frac{x_{i+j} - x_{i+j}^*}{x_{i+j}} \right| \right)}{n} \times 100\% \quad (12)$$

де x_{i+j} – фактичне (реальне) значення; x_{i+j}^* – спрогнозоване значення; n – довжина часового ряду

Достовірність ІНС за стаціонарними дослідженнями становила – для прогнозування вмісту: гумусу – 83-94%, обмінного калію – 85-94%, рухомого фосфору – 85-94%.

За даними багаторічних досліджень Херсонського обласного державного проектно-технологічного центру охорони родючості ґрунтів і якості продукції («Облгосплідордіє») і результатами прогнозування автором створені картограми агрохімічного стану меліоруваних ґрунтів Херсонської області (рис. 4). Групування ґрунтів за вмістом гумусу здійснено за методом Тюріна, вмісту обмінного калію і рухомого фосфору за методом Мачігіна.



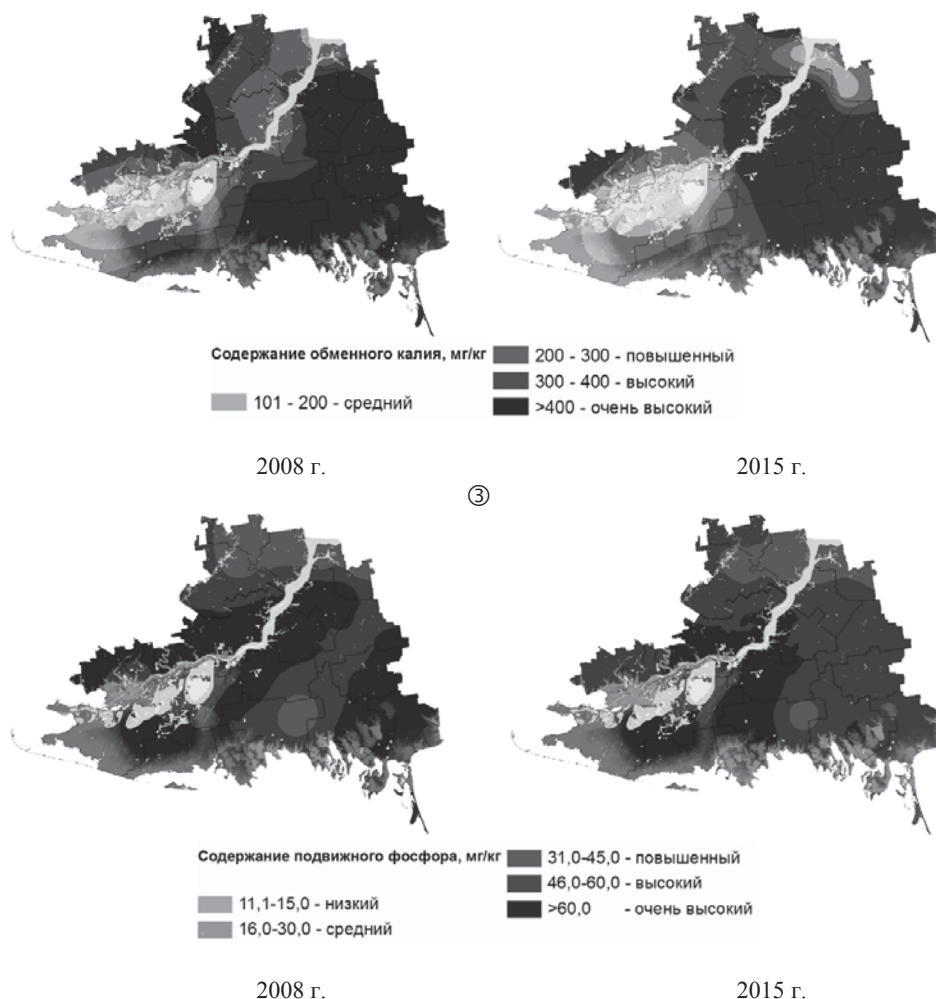


Рисунок 4. Картограмма районирования почв Херсонской области за содержанием гумуса (1), обменного калия (2) и подвижного фосфора (3) состоянием на 2008 г. и их прогноз на 2015 г.

Выводы

1. Впервые разработана методика и представлены результаты пространственно-временного моделирования агрохимических показателей мелиорируемых почв до 2015 года с применением современных методов интеллектуальных искусственных нейронных сетей и ГИС-технологий на примере Херсонской области.

2. Определены оптимальные значения параметров алгоритма обучения искусственных нейросетей для прогнозирования агрохимического состояния мелиорируемых почв: коэффициент скорости обучения в пределах $\eta = 0,02-0,2$; коэффициент момента обучения (коэффициент инерции) в пределах $\alpha = 0,5-0,7$; количество итераций (эпох) до запоминания в пределах $N = 30-50$; количество итераций (эпох) для обучения НС, в зависимости от массива

выборки и сложности развития прогнозируемой системы, в пределах $N = 100-500$; коэффициент гауссового шума при обучении НС составил 0,1. Функции активации нейронов – сигмоидальная и синусоид-гиперболического тангенса.

3. Исследованиями установлено, что на рабочем участке сети правильно выделили закономерности развития временных рядов, т.е. нейронные сети проявили способность к обобщению входных данных и предсказанию агрохимического состояния мелиорируемых почв с достаточно высокой достоверностью - 83-94%.

4. Представленные результаты применения нейротехнологий, указывают на высокую теоретическую и практическую ценность их применения для пространственно-временного моделирования агрохимического состояния мелиорируемых почв с использованием инструментов ГИС-технологий на примере Херсонской области Украины.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ:

1. Хайкин Саймон. Нейронные сети: полный курс. М.: Издательский дом «Вильямс», - 2006. - 1104 с.
2. Денисов С.В. Автоматизация интерпретации результатов гидродинамических исследований скважин путем применения искусственных нейронных сетей / Денисов С.В. - Труды международного симпозиума "Надежность и качество", 2008. - Т. 2. - С. 98-103.
3. Козадаев А.С. Техническая реализация искусственного нейрона и искусственной нейронной сети / Козадаев А.С. - Вестник Тамбовского университета. Серия: Естественные и технические науки, 2010. - Т. 15. - № 1. - С. 301-302.
4. Бахметова Н.А. Моделирование технологических процессов с помощью нейронных сетей / Бахметова Н.А., Токарев С.В. - Современные наукоемкие технологии, 2008. - № 2. - С. 87.
5. Козадаев А.С. Техническая реализация искусственного нейрона и искусственной нейронной сети / Козадаев А.С. - Вестник Тамбовского университета. Серия: Естественные и технические науки, 2010. - Т. 15. - № 1. - С. 301-302.
6. Бахметова Н.А. Моделирование технологических процессов с помощью нейронных сетей / Бахметова Н.А., Токарев С.В. - Современные наукоемкие технологии, 2008. - № 2. - С. 87.
7. Machine Learning, Neural and Statistical Classification / Ed. D. Mitchie et al. – Ellis Horwood, Chichester, UK. - 1994. - 304 p.
8. Using ArcGIS Geostatistical Analyst. - Published by ESRI, 2002. - 306p.