

содержания первого элемента ГОСТ 8.010 – 99, поскольку описать назначение МВИ без её наименования и области применения практически невозможно.

Объединение в один блок операций при подготовке к выполнению измерений, операций при выполнении измерений и операций обработки результатов измерений с требованиями к оформлению результатов измерений представляется вполне логичным. Перестановка остальных элементов, таких как «условия выполнения измерений», «метод (методы) измерений» и «требования к квалификации операторов» не имеет принципиального значения, поскольку эти элементы совершенно инвариантны к месту расположения в МВИ. То же можно сказать о блоке элементов по обеспечению безопасности в рамках МВИ. Разделение блока на «требования к обеспечению безопасности выполняемых работ» и «требования к обеспечению экологической безопасности» является скорее данью моде, чем необходимостью. Безопасность работ при выполнении измерений должная распространяться на оператора и его ближайшее окружение, а также на отдалённые объекты (например, куда выбрасываются пары вредных веществ, удаляемые вытяжным шкафом?). Субъекты, непосредственно выполняющие работы или принимающие в работе пассивное участие должны быть защищены как от непосредственных сильных вредных воздействий, так и от последствий возможного накопления вредных эффектов.

Особое внимание следует обратить на элемент «процедуры и периодичность контроля точности получаемых результатов измерений», который в предыдущей версии стандарта был записан как «нормативы, процедура и периодичность контроля погрешности результатов выполняемых измерений». Фактически этот элемент следует рассматривать как метрологическую аттестацию разработанной МВИ. Признание этого факта влечет за собой ряд серьёзных последствий.

– Аттестация методики выполнения измерений является самостоятельной работой, которая не входит в разработку МВИ. Разработка методики метрологической аттестации МВИ и проведение аттестации требуют значительно более высокой квалификации разработчика и намного больше ресурсов, чем разработка самой МВИ.

– Аттестация методики выполнения измерений может выполняться только после реализации МВИ «в металле», разработки и апробирования методики метрологической аттестации МВИ, которую также придётся реализовать.

– Поскольку «процедуры контроля точности получаемых результатов измерений» принципиально не стареют, требование «периодичности» такого контроля лишено смысла.

Экспериментальное подтверждение приписанной МВИ точности является объективно необходимым мероприятием, но его не следует даже пытаться включать в разработку МВИ по причинам, которые изложены выше. Стандарт на разработку МВИ был бы существенно грамотнее, если бы из него изъяли этот не вписывающийся в данный стандарт элемент и заменили его ссылкой на документ, регламентирующий метрологическое подтверждение пригодности МВИ. В Республике Беларусь таким документом является ТКП 8.006–2011 («СОЕИ РБ. Метрологическое подтверждение пригодности методики выполнения измерений. Правила проведения работ»).

Грамотно разработанная МВИ при её правильном выполнении гарантирует соответствие результатов измерений требованиям Закона РБ.

УДК 631.559

**Шакирин А.И., кандидат технических наук, доцент, Львова О.М., Богданович А.И.**  
Белорусский государственный аграрный технический университет, г. Минск

**Гороховик Я.В.**

Белорусский государственный университет информатики и радиоэлектроники, г. Минск

## **ПРОГНОЗИРОВАНИЕ УРОЖАЙНОСТИ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР: ПЕРСПЕКТИВЫ ИСПОЛЬЗОВАНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ**

Урожайность сельскохозяйственных культур является важным показателем эффективности сельскохозяйственного производства. Для обеспечения продовольственной безопасности страны вопрос предвидения объемов производства приобретает большую актуальность. Получение достоверного прогноза урожая позволит корректно решать вопросы формирования резервных фондов продовольствия, наличия необходимых мощностей для хранения полученного урожая, строить эффективную политику внешней торговли. Однако, урожайность сельскохозяйственных культур является показателем сложным с точки зрения предвидения, поскольку формирование урожая связано не только с действием производственных факторов, но также погодных условий и биологических систем.

На практике применяются следующие подходы к прогнозированию урожайности.

1. Статистические методы – анализ тренда и цикличности в динамичности урожайности, выявление года-аналога, на основе анализа синоптических процессов.

2. Имитационное моделирование – построение многофакторных регрессионных моделей, методы нелинейной динамики.

Подходы первой группы отличаются недостаточной точностью, подходы второй группы – сложностью реализации математического аппарата. В настоящее время одним из перспективных и точных методов прогнозирования являются методы, основанные на применении искусственных нейронных сетей.

*Искусственная нейронная сеть* (ИНС) – математическая модель, а также ее программная и аппаратная

реализация, построенная по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма. Искусственные нейросети успешно решают трудно формализуемые задачи, такие как, распознавание образов и речи, ассоциативный поиск информации и создание ассоциативных моделей, создание моделей нелинейных и трудно описываемых математически систем, а также прогнозирование их развития во времени, что характерно для рядов урожайности сельскохозяйственных культур.

Одно из главных преимуществ нейросетей – возможность обучения. Искусственные нейронные сети могут менять свое поведение в зависимости от внешней среды, то есть на выходе будет получен верный результат на основании данных, которые отсутствовали в обучающей выборке или были искажены.

В основе ИНС лежит *искусственный нейрон* (формальный нейрон), созданный по аналогии с биологическим нейроном [1,2]. Общий вид искусственного нейрона приведен на рисунок 1.




Рисунок 1 – Структура искусственного нейрона

Текущее состояние нейрона определяется как взвешенная сумма его входов:

$$S = \sum_{i=1}^n x_i w_i,$$

где  $n$  – число входов нейрона;

$x_i$  – значение входа  $i$ -го нейрона;

$w_i$  – вес  $i$ -го синапса.

Выходом нейрона является функция его состояния:  $Y = f(S)$ , где  $f$  – активационная функция. В качестве активационной функции выбирается сигмоидальная функция, благодаря нелинейности которой нейроны обладают хорошей обучаемостью.

ИНС являются многослойными (рисунок 2), то есть состоят из нескольких слоев нейронов: входного, внутренних (скрытых) и выходного. Внутренних слоев может быть от одного и больше. В многослойной нейронной сети каждый нейрон в любом слое связан со всеми нейронами предыдущего слоя. Сигнал передается в прямом направлении, от слоя к слою, генерируя выходную функцию. В обратном направлении распространяется сигнал ошибки, который определяется соотношением

$$e_i(n) = d_i(n) - y_i(n),$$

где  $d_i(n)$  – желаемый отклик  $i$ -го нейрона на итерации  $n$ ,

$y_i(n)$  – сигнал на выходе  $i$ -го нейрона на итерации  $n$ .

После того, как вычислена ошибка, происходит коррекция синаптических весов  $w_i$  для каждого нейрона, после чего процесс обучения нейросети повторяется до тех пор, пока ошибка не достигнет достаточно малых значений. Таким образом, цель обучения нейронной сети – определение значений синаптических весов нейронов так, чтобы при заданных параметрах входных значений, получить выходные  $y_i$ , совпадающие с ожидаемыми  $d_i$ .




Рисунок 2 – Структурная схема многослойной ИНС

В качестве инструментария реализации нейронных сетей используются специализированные программные продукты, например пакет статистического анализа STATISTICA Neural Networks, среда Matlab

(Neural Network Toolbox), аналитическая платформа Deductor Studio Academic.

Рассмотрим нейронную сеть, предназначенную для прогнозирования урожайности на примере зерновых культур [3]. Прогнозирование урожайности требует учета влияния различных факторов – это основные почвенно-климатические характеристики, использование удобрений, количество осадков, средняя температура, продолжительность вегетативного периода и т.д. Для анализа были отобраны следующие показатели:

- содержание гумуса в почве;
- количество осадков (за год и за вегетативный период);
- внесение удобрений (минеральных и органических);
- посевная площадь;
- норма высева зерна;
- применение гербицидов и пестицидов.

В аналитической платформе Deductor была построена нейросетевая модель, предназначенная для прогноза урожайности зерновых культур.

Для обучения сети был выбран алгоритм – обратное распространение ошибки. После завершения обработки обучающей выборки, мы можем изменять значения факторов и получать достоверные прогнозные значения урожайности зерновых культур. Так, если при неблагоприятных условиях увеличить норму внесения органических удобрений с 20 до 24 т/га, при сохранении остальных факторов без изменения, прогнозируемый показатель урожайности увеличится до 12,04 ц/га (фактический показатель – 7,9 ц/га).

Поле	Значение
Входные	
9.0 Посевная площадь	7953
9.0 Внесение минеральных удобрений	25
9.0 Внесение органических удобрений	24
9.0 Содержание гумуса	9,6
9.0 Количество осадков	261
9.0 Осадки за вегетацию	96
9.0 Норма высева удобрений	7
9.0 Применение гербицидов	1
9.0 Применение пестицидов	1
Выходные	
9.0 урожайность	12,04

Рисунок 3 – Прогноз урожайности при изменении нормы внесения удобрений в аналитической платформе Deductor Studio Academic

Таким образом, использование нейросетевых технологий позволяет выполнять прогнозирование урожайности сельскохозяйственных культур с учетом разнофакторных показателей – природно-климатических, техногенных, а также особенностей культивируемых видов растений. При этом нет ограничения входных анализируемых параметров. Прогнозирование такого показателя, как урожайность, может свести к минимуму потери урожая при неблагоприятных условиях и добиться наибольших показателей при благоприятных.

#### Список использованной литературы

1. Хайкин С. Нейронные сети. Полный курс. М.: Вильямс М, 2006. 1104 с.
2. Каллан Р. Основные концепции нейронных сетей. М.: Вильямс М, 2001. 291 с.
3. Snehal S.Dahikar, Dr.Sandeep V.Rode. Agricultural Crop Yield Prediction Using Artificial Neural Network Approach. International journal of innovative research in electrical, electronics, instrumentation and control engineering. Vol. 2, 2014.

УДК 620.193.8

**Кудина А.В., кандидат технических наук, доцент, Процко Л.Е.**  
Белорусский государственный аграрный технический университет, г. Минск  
**Сокоров И.О., кандидат технических наук, доцент**  
Белорусский национальный технический университет, г. Минск

## БИОКОРРОЗИЯ КАК СУЩЕСТВЕННЫЙ ФАКТОР, ВЛИЯЮЩИЙ НА КАЧЕСТВО ДЕТАЛЕЙ МАШИН И ОБОРУДОВАНИЯ ПО ПРОИЗВОДСТВУ И ПЕРЕРАБОТКЕ СЕЛЬСКОХОЗЯЙСТВЕННОЙ ПРОДУКЦИИ

**Введение.** В последние годы коррозия металлических и неметаллических материалов стала объектом исследования не только материаловедов и электрохимиков, но и микробиологов. Роль биологического фактора в